



**T.C.  
AKSARAY ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**HARİTA MÜHENDİSLİĞİ ANABİLİM DALI**

**FOTOGRAMETRİK GÖRÜNTÜ TABANLI NOKTA BULUTU  
ÜZERİNDEN OTOMATİK BİNA ÇIKARIMI VE SAYISALLAŞTIRMA**

**YÜKSEK LİSANS TEZİ**

**Buray KARSLI**

**DANIŞMAN**

**Prof. Dr. Ferruh YILMAZTÜRK**

**AKSARAY, 2022**

Aksaray Üniversitesi Fen Bilimleri Enstitüsü'nün 202306017 numaralı Yüksek Lisans öğrencisi Buray KARSLI tarafından hazırlanan “**FOTOGRAFİK GÖRÜNTÜ TABANLI NOKTA BULUTU ÜZERİNDEN OTOMATİK BİNA ÇIKARIMI VE SAYISALLAŞTIRMA**” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Harita Mühendisliği Anabilim Dalında **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

**Danışman: Prof. Dr. Ferruh YILMAZTÜRK**

Aksaray Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.....

**Üye: Prof. Dr. Hacı Murat YILMAZ**

Aksaray Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.....

**Üye: Doç. Dr. Özgün AKÇAY**

Aksaray Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.....

Tez Savunma Tarihi: 10/05/2022

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Doç. Dr. Mehmet Ali HINIS

Fen Bilimleri Enstitüsü Müdürü

## DOĐRULUK BEYANI

Yüksek lisans tezi olarak sunduđum bu çalıřmayı, akademik kurallara ve bilimsel etik, ahlak ve geleneklere aykırı dūřecek bir yol ve yardıma bařvurmaksızın yazdıđımı, yararlandıđım eserlerin kaynakçada gösterilenlerden olduđunu, çalıřmamda kullandıđım verilerin orijinalliđini ve her türlü intihalden uzak olduđunu beyan ederim.

Enstitü tarafından belli bir zamana bađlı olmaksızın, tezimle ilgili yaptıđım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçlara katlanacađımı bildiririm.

**Buray KARSLI**

## TEŐEKKÜR

Tez çalışmam sürecinde danışmanlığımı üstlenen, değerli fikir ve önerileriyle çalışmalarına yön veren ve her türlü desteğini esirgemeyen değerli hocam Prof. Dr. Sayın Ferruh YILMAZTÜRK'e saygı ve minnetle teşekkürlerimi sunarım.

Tez çalışması süresince yöntem ve tez içeriğinin geliştirilmesinde desteklerini esirgemeyen Prof. Dr. Fevzi KARSLI, Öğr. Gör. Emirhan ÖZDEMİR, Harita Müh. Murat BAHADIR ve Harita Müh. Tuba Nur TONYALI'ya teşekkür ederim.

Çalışmada önerilen yöntemin test edilmesi aşamalarında kullanılmak üzere veri sağlayan kurum ve kuruluşlara teşekkürü bir borç bilirim.

Desteklerini hep yanımda hissettiğim, beni sürekli motive eden değerli çalışma arkadaşlarım ve Kolin İnş. Eşme Şantiyesi proje müdürü Harita Müh. Yasin KARSLI'ya teşekkür ederim.

Bugünlere gelmemde sürekli desteğini arkamda hissettiğim, maddi ve manevi fedakârlıktan kaçınmayan ve her zaman bana güvenen değerli aileme sonsuz teşekkürlerimi sunarım.

Buray KARSLI  
AKSARAY, 2022

## İÇİNDEKİLER

TEŞEKKÜR.....	i
İÇİNDEKİLER.....	ii
ÖZET.....	iv
ABSTRACT.....	v
ŞEKİLLER DİZİNİ.....	vi
ÇİZELGELER DİZİNİ.....	viii
SİMGELER VE KISALTMALAR.....	ix
<b>1. GİRİŞ.....</b>	<b>1</b>
1.1 Çalışmanın amacı ve kapsamı.....	3
1.2 Literatür araştırması.....	4
<b>2. GENEL BİLGİLER.....</b>	<b>8</b>
2.1 Temel kavramlar.....	8
2.2 Fotogrametrinin tanımı ve tarihçesi.....	8
2.3 Fotogrametrinin matematik modeli.....	9
2.4 Dijital Fotogrametri.....	12
2.5 Dijital hava kameraları ve özellikleri.....	14
2.6 Lazer Tarama Teknolojisi (LiDAR).....	15
2.7 Nokta bulutu üretim yöntemleri.....	22
2.7.1 LiDAR teknolojisi ile nokta bulutu üretimi.....	22
2.7.2 Görüntülerden eşleştirme ile nokta bulutu üretimi.....	23
2.8 Nokta bulutundan bina detayı çıkarma ve düzenleme.....	27
2.8.1 Geleneksel yöntemler.....	27
2.8.2 Octree (Sekizdal) metodu.....	30
2.8.3 DBSCAN kümeleme metodu.....	34
2.8.4 Bina kenarlarını düzgünleştirme metodu (ABORE).....	36
2.9 Nokta bulutundan zemin (Arazi modeli) çıkarım yöntemleri.....	40
2.9.1 Aşamalı TIN yoğunlaştırma yöntemi.....	40
2.9.2 SMRF yöntemi.....	42
2.10 Referans verileri (Hâlihazır harita).....	44
2.11 Doğruluk analizi yöntemleri.....	45
<b>3. VERİ VE YÖNTEM.....</b>	<b>49</b>
3.1 Çalışma alanının belirlenmesi.....	50
3.2 Test alanları (Test Alanı-1, Test Alanı-2 ve Test Alanı-3).....	50
3.3 Kullanılan kamera ve üretilen veriler.....	53
3.4 Eşleştirme metodu ile yoğun nokta bulutu üretimi.....	55
3.5 Zemin sınıfının çıkarılması.....	56
3.6 Yeşil alanların nokta bulutundan ayıklanması.....	57
3.7 DBSCAN ile binaların sınıflandırılması.....	59
3.8 İyileştirilmiş Octree (I-Octree) ile bina detaylarının çıkarılması.....	61
3.9 Bina kenarlarının regularizasyonu.....	67
<b>4. BULGULAR VE TARTIŞMA.....</b>	<b>69</b>
4.1 Test Alanı-1 için elde edilen bulgular ve tartışma.....	69
4.2 Test Alanı-2 için elde edilen bulgular ve tartışma.....	75
4.3 Test Alanı-3 için elde edilen bulgular ve tartışma.....	80
<b>5. SONUÇ VE ÖNERİLER.....</b>	<b>86</b>

<b>KAYNAKLAR</b> .....	89
<b>EKLER</b> .....	97
EK A. Önerilen algoritmanın (I-Octree) sözde (Pseudo) kod şeması.....	97
<b>ÖZGEÇMİŞ</b> .....	98



## YÜKSEK LİSANS TEZİ

# FOTOGRAMETRİK GÖRÜNTÜ TABANLI NOKTA BULUTU ÜZERİNDEN OTOMATİK BİNA ÇIKARIMI VE SAYISALLAŞTIRMA

**Buray KARSLI**

**Aksaray Üniversitesi  
Fen Bilimleri Enstitüsü  
Harita Mühendisliği Anabilim Dalı**

**Danışman: Prof. Dr. Ferruh YILMAZTÜRK**

### ÖZET

Bina sınırlarını yersel yöntem veya uzaktan algılama verilerinden manuel olarak belirlemek zaman alıcı ve çaba gerektiren bir işlemdir. İlgili veri kaynaklarından bina sınırı çıkarımı harita temel altlığı olması bakımından son derece önemlidir. Eşleştirme ve lazer tarama ile üretilen nokta bulutları, yoğun ve doğruluğu yüksek üç boyutlu (3B) konum bilgisi sağlamaktadır. Binaların 3B nokta bulutundan otomatik çıkarılması oldukça zor bir problemdir. Otomatik veri işleme, harita üretiminde işlem süresi, maliyet ve operatör hatasının azaltılmasına önemli ölçüde katkı sağlamaktadır. Bu çalışmada, sekizdal (Octree) veri organizasyon metodu çalışma prensibi otomatize edilmek suretiyle geliştirilen ve önerilen yeni yaklaşımla (iyileştirilmiş Octree, I-Octree), fotogrametrik görüntülerden üretilen nokta bulutları ve kıyas amaçlı LiDAR nokta bulutları kullanılarak bina detayı otomatik çıkarımı ve sayısallaştırılması hedeflenmiştir. Bu hedefe ulaşmak için: (i) büyük hacimli 3B nokta bulutunun görüntülerden üretilmesi veya LiDAR nokta bulutu temin edilmesi; (ii) nokta bulutundan zemin ve zemin üstü objelerin SMRF ile ayrılması; (iii) DBSCAN algoritması ile bina objelerinin sınıflandırılması; (iv) sekizdal ve iyileştirilmiş sekizdal (I-Octree) yönteminin sınıflandırılan objelere uygulanması ile bina detaylarının çıkarılması ve (v) ABORE ile bina kenarlarının düzgünleştirilmesine odaklanılmıştır. Önerilen yaklaşım, Elazığ ve Erzurum test alanında fotogrametrik nokta bulutları, Kaliforniya test alanında ise LiDAR nokta bulutu üzerinde uygulanmıştır. Tüm test alanları için 1/1000 ve 1/5000 ölçekli hâlihazır haritalar referans verisi olarak kullanılmıştır. Tamlık (Cp), doğruluk (Cr), kalite (Q) ve F-skor (F-1) metrikleri ile obje tabanlı doğrulama yapılmıştır. Test alanlarında doğrulama sonuçları fotogrametrik nokta bulutlarında her bir metrik için maksimum %94 üzerinde iken, LiDAR nokta bulutu test alanında ise bu değer %99 üzerinde olmaktadır. Doğrulama sonucunda, önerilen yaklaşımın test alanlarında seçilen binaları yüksek doğrulukla çıkarabildiği görülmektedir. Sonuç olarak, önerilen yaklaşımla farklı yoğunlukta ki nokta bulutlarından otomatik bir biçimde bina detay çıkarımı ve sayısallaştırma işleminin gerçekleştirilebileceği ortaya çıkarılmıştır.

**Anahtar Kelimeler:** Fotogrametri, LiDAR, Nokta Bulutu, Bina Çıkarımı, Otomatik Sayısallaştırma, I-Octree.

**Mayıs, 2022; 98 sayfa**

## M.Sc. THESIS

# AUTOMATIC BUILDING EXTRACTION AND DIGITALIZATION THROUGH PHOTOGRAMMETRIC IMAGE BASED POINT CLOUD

**Buray KARSLI**

**Aksaray University  
Graduate School of Natural and Applied Sciences  
Department of Geomatics Engineering**

**Supervisor: Prof. Dr. Ferruh YILMAZTÜRK**

## ABSTRACT

Determining the building boundaries manually from terrestrial method or remote sensing data is time-consuming and demanding. Building boundary extraction from relevant data sources is extremely important as it is a map base. Point clouds produced by matching and laser scanning provide dense and highly accurate three-dimensional (3D) position information. Automatic extraction of buildings from the 3D point cloud is a very difficult problem. Automatic data processing contributes significantly to reducing processing time, cost and operator error in map production.

In this study, it is aimed to automatically extract and digitize building details by using point clouds produced from photogrammetric images and LiDAR point clouds for comparison purposes, with the new approach (improved Octree, I-Octree) developed and proposed by automating the working principle of the Octree data organization method. To achieve this goal: (i) generating a large volume of 3D point cloud from images or providing a LiDAR point cloud; (ii) separation of ground and above ground objects from the point cloud by SMRF; (iii) classification of building objects by DBSCAN algorithm; (iv) extracting building details by applying the octagon and improved octree (I-Octree) method to classified objects; and (v) smoothing building edges with ABORE is focused.

The proposed approach was applied on photogrammetric point clouds in Elazig and Erzurum test area and on LiDAR point cloud in California test area. Reference maps with scales of 1/1000 and 1/5000 were used as reference data for all test areas. Object-based validation was performed with completeness (Cp), accuracy (Cr), quality (Q) and F-score (F-1) metrics. In the test areas, the verification results are above a maximum of 94% for each metric in photogrammetric point clouds, while this value is above 99% in the LiDAR point cloud test area. As a result of the validation, it is seen that the proposed approach can extract the selected buildings in the test areas with high accuracy. As a result, it has been revealed that with the proposed approach, building detail extraction and digitization can be performed automatically from point clouds of different densities.

**Keywords:** Photogrammetry, LiDAR, Point Cloud, Building Extraction, Automatic Digitizing, I-Octree.

**May, 2022; 98 pages**

## ŞEKİLLER DİZİNİ

Şekil 2.1. Fotogrametrik veri alım geometrisi ve matematik model.....	10
Şekil 2.2. Dijital fotogrametri genel akış diyagramı.....	13
Şekil 2.3. Kamera yapısı; A) mercek, B) diyafram, C) obturatör, D) odaklama, E) görüntüleme sistemi, F) film, G) film nakil sistemi, H) kamera gövdesi.....	14
Şekil 2.4. Türkiye’de kullanılan bazı hava kameraları ve özellikleri. ....	15
Şekil 2.5. ALS ile obje yüzeyinin taranması.....	16
Şekil 2.6. Hava LiDAR sistemi ve veri toplama.....	17
Şekil 2.7. LiDAR sistemi veri akışı ve işleme. ....	18
Şekil 2.8. LiDAR veri örneği; a) Yüksekliğe göre renklendirilmiş nokta bulutu, b) yoğunluk görüntüsü.....	20
Şekil 2.9. Aynı kentsel alanı içeren farklı coğrafi verilerin görselleştirilmesi; a) yüksekliğe göre renkli LiDAR nokta bulutu, b) ortogörüntü, c) nesne sınıflandırılmış LiDAR nokta bulutu, d) nesne sınıflandırılmış 3B LiDAR nokta bulutu, e) 1/1000 ölçekli temel harita, f) 1/1000 ölçekli 3B bina ve yol haritası. ....	21
Şekil 2.10. Nokta bulutundan detay çıkarımı.....	22
Şekil 2.11. LiDAR nokta bulutu- Pittsburgh.....	23
Şekil 2.12. Stereo görüntüde eşlenik noktalar.....	24
Şekil 2.13. Epipolar eşleştirme; a) sol resim, b) sağ resim. ....	25
Şekil 2.14. 8 yönlü optimizasyon yolu ile en doğru eşleşme.....	26
Şekil 2.15. Nokta eşleme ve epipolar geometri. ....	26
Şekil 2.16. Octree ile oluşturulan eşit 2B ve 3B vokseller. ....	31
Şekil 2.17. Octree hiyerarşik yapısı. ....	32
Şekil 2.18. Octree voksel numaralandırma. ....	33
Şekil 2.19. DBSCAN algoritması çalışma prensibi. ....	35
Şekil 2.20. “Boundary” ile sınır çizimi, ABORE açısı ve kesişim koordinatları. ....	36
Şekil 2.21. İdeal köşe noktası belirleme koşulları. ....	38
Şekil 2.22. Buffer zon işlemleri ve bina regülasyonu.....	39
Şekil 2.23. PTD parametreleri; a) iki boyutta tohum noktalarının seçimi ve TIN oluşturulması, b) arazi üzerinde TIN oluşturma ve tohum nokta seçimi, c) açısı ve mesafe ölçümü, d) yansıtma işlemi.....	42
Şekil 2.24. SMRF sonuç görüntüsü örneği. ....	44
Şekil 2.25. SMRF morfolojik işlemler.....	44
Şekil 2.26. Veri setlerinin referans (vektör) haritası; a) Test_Alanı_1, b) Test_Alanı_2, c) Test_Alanı_3.....	45
Şekil 2.27. Doğruluk metriği parametreleri. ....	47
Şekil 2.28. Örnek metrik doğruluk hesabı. ....	47
Şekil 3.1. Önerilen yöntem genel akış şeması. ....	49
Şekil 3.2. Test_Alanı_1 (Beyhan/Palu/Elazığ). ....	51
Şekil 3.3. Test_Alanı_2 (Horasan/Erzurum).....	52
Şekil 3.4. Test_Alanı_3 (Kaliforniya/ABD).....	53
Şekil 3.5. Test alanları nokta bulutu verisi; a) Test_Alanı_1, b) Test_Alanı_2 ve Test_Alanı_3.....	54
Şekil 3.6. SMRF algoritması ile zemin ve zemin üstü noktaların ayrılması; a ve b) Fotogrametrik nokta bulutu üzerinde SMRF uygulaması, c ve d) LiDAR nokta bulutunda SMRF uygulaması. ....	57

<b>Şekil 3.7.</b> Zemin ve bina noktalarının sınıflandırılması; a ve b) Fotogrametrik nokta bulutu üzerinde sınıflandırma, c ve d) LiDAR nokta bulutunda sınıflandırma. ....	58
<b>Şekil 3.8.</b> DBSCAN algoritması ile bina nokta kümelendirmesi; a) Fotogrametrik nokta bulutunda kümeleme, b) LiDAR nokta bulutunda kümeleme. ....	59
<b>Şekil 3.9.</b> Gürültülü kümelerin ayıklanması; a) Fotogrametrik nokta bulutu, b) LiDAR nokta bulutu. ....	60
<b>Şekil 3.10.</b> Çıkarılan bina noktalarının üç boyutlu gösterimi; a) Fotogrametrik nokta bulutu, b) LiDAR nokta bulutu. ....	60
<b>Şekil 3.11.</b> Octree yöntemi ile prizmalara ayırma; a) Oluşturulan prizmalar, b) Octree için oluşturulan basamak sırası. ....	61
<b>Şekil 3.12.</b> Çoklu Octree uygulama; a) 3B gösterim, b) X-Y düzlemi gösterimi, c) Y-Z düzlemi gösterimi, d) X-Z düzlemi gösterimi. ....	62
<b>Şekil 3.13.</b> MBR algoritması ile basamak analizi; a) 1. basamak, b) 2. basamak, c) 3. basamak. ....	63
<b>Şekil 3.14.</b> Düzlemler arası fark analizi. ....	64
<b>Şekil 3.15.</b> Düzlemlerin karşılaştırılması; a) (X-Z) düzlemindeki basamak analizi, b) (Y-Z) düzlemindeki basamak analizi. ....	65
<b>Şekil 3.16.</b> I-Octree ile basamak analizi sonuçları; a) Y-Z düzlemi, b) Y-X düzlemi. ....	66
<b>Şekil 3.17.</b> I-Octree ile çıkarılan bina çatı tipleri. ....	67
<b>Şekil 3.18.</b> ABORE yöntemi ile bina regülerizasyonu. ....	68
<b>Şekil 4.1.</b> Test Alanı_1 bina kenar bilgileri ve nokta bulutu; a) A1-A3 alt bölgesi, b) B1-B4 alt bölgesi, c) C1-C5 alt bölgesi. ....	72
<b>Şekil 4.2.</b> Test Alanı_1 bina kenar bilgileri ve ortofoto; a) A1-A3 alt bölgesi, b) B1-B4 alt bölgesi, c) C1-C5 alt bölgesi. ....	73
<b>Şekil 4.3.</b> Test Alanı_1 bina kenar bilgileri ve halihazır harita (1/1000 ve 1/5000); a) A1-A3 alt bölgesi, b) B1-B4 alt bölgesi, c) C1-C5 alt bölgesi, d) A1-A3 alt bölgesi, e) B1-B4 alt bölgesi, f) C1-C5 alt bölgesi. ....	74
<b>Şekil 4.4.</b> Test Alanı_1 bina kenar bilgileri ve basamak durumları; a, b) A2 binası, c, d) B2 binası, e, f) C3 binası. ....	75
<b>Şekil 4.5.</b> Test Alanı_2 bina kenar bilgileri ve nokta bulutu; a) D1-D4 alt bölgesi, b) E1-E2 alt bölgesi. ....	78
<b>Şekil 4.6.</b> Test Alanı_2 bina kenar bilgileri ve ortofoto; a) D1-D4 alt bölgesi, b) E1-E2 alt bölgesi. ....	78
<b>Şekil 4.7.</b> Test Alanı_2 bina kenar bilgileri ve 1/1000 ölçekli halihazır harita; a) D1-D4 alt bölgesi, b) E1-E2 alt bölgesi. ....	79
<b>Şekil 4.8.</b> Test Alanı_2 bina kenar bilgileri ve basamak durumları; a, b) D1 binası, c, d) E1 binası. ....	80
<b>Şekil 4.9.</b> Test Alanı_3 bina kenar bilgileri ve nokta bulutu (F1-F4 binaları). ....	82
<b>Şekil 4.10.</b> Test Alanı_3 bina kenar bilgileri ve ortofoto (F1-F4 binaları). ....	83
<b>Şekil 4.11.</b> Test Alanı_3 bina kenar bilgileri ve 1/1000 ölçekli halihazır harita (F1-F4 binaları). ....	84
<b>Şekil 4.12.</b> Test Alanı_3 bina kenar bilgileri ve basamak durumları; a, b) F3 binası. ....	85

## ÇİZELGELER DİZİNİ

<b>Çizelge 3.1.</b> Kamera ve LiDAR sistemi özellikleri. ....	53
<b>Çizelge 3.2.</b> Test alanları için üretilen nokta bulutu yoğunlukları (nokta/m <sup>2</sup> ) ve sayıları. ....	55
<b>Çizelge 4.1.</b> Test_Alanı_1 doğruluk analizi sonuçları. ....	70
<b>Çizelge 4.2.</b> Test_Alanı_1 bina sınır tespiti basamak sayıları. ....	71
<b>Çizelge 4.3.</b> Test_Alanı_2 doğruluk analizi sonuçları. ....	76
<b>Çizelge 4.4.</b> Test_Alanı_2 bina sınır tespiti basamak sayıları. ....	77
<b>Çizelge 4.5.</b> Test_Alanı_3 doğruluk analizi sonuçları. ....	81
<b>Çizelge 4.6.</b> Test_Alanı_3 bina sınır tespiti basamak sayıları. ....	82



## SİMGELER VE KISALTMALAR

<b>3B</b>	Üç Boyutlu
<b>ABORE</b>	Otomatik Bina Sınır Düzgünleştirme Yaklaşımı
<b>ACM</b>	Aktif Kontur Modeli
<b>ALS</b>	Hava Lazer Tarama
<b>CBS</b>	Coğrafi Bilgi Sistemleri
<b>CCD</b>	Yük Bağlamalı Düzen
<b>CNN</b>	Evrişimli Sinir Ağı
<b>Cp</b>	Tamlık
<b>Cr</b>	Doğruluk
<b>DBSCAN</b>	Yoğunluk Tabanlı Kümeleme Algoritması
<b>DEM</b>	Sayısal Yükseklik Modeli
<b>F-1</b>	F-skoru
<b>FN</b>	Yanlış Negatif
<b>FP</b>	Yanlış Pozitif
<b>FWD</b>	Dalga Biçimi Sayısallaştırma
<b>GML</b>	Geiger Mod LiDAR
<b>GNSS</b>	Küresel Navigasyon Uydu Sistemi
<b>GPS</b>	Global Konumlama Sistemi
<b>IMU</b>	İç Navigasyon Sistemi
<b>I-Octree</b>	İyileştirilmiş Sekizdal Veri Organizasyon Metodu
<b>IoU</b>	Birleşim-Kesişim
<b>IR</b>	Kızılötesi
<b>ISODATA</b>	İstatistiksel Kümeleme
<b>İHA</b>	İnsansız Hava Aracı
<b>LiDAR</b>	Lazer Tarama Teknolojisi
<b>LoD1</b>	Detay Düzeyi
<b>MABI</b>	Bina İndeksi
<b>MASI</b>	Gölge İndeksi
<b>MBR</b>	Minimum Sınırlayıcı Dörtgen
<b>Octree</b>	Sekizdal Veri Organizasyon Metodu
<b>PRF</b>	Darbe Tekrarlama Frekansı
<b>PTD</b>	Aşamalı TIN Yoğunlaştırma
<b>Q</b>	Kalite
<b>RANSAC</b>	Rastgele Örneklem Konsensusu
<b>RGB</b>	Çok Bantlı (Kırmızı, Yeşil ve Mavi)
<b>SfM</b>	Hareketten Yapı Eşleşmesi
<b>SGM</b>	Yarı Global Eşleştirme
<b>SMRF</b>	Basit Morfolojik Filtreleme
<b>SPL</b>	Tek Foton LiDAR
<b>SYM</b>	Sayısal Yükseklik Modeli
<b>SYuM</b>	Sayısal Yüzey Modeli
<b>TIN</b>	Düzensiz Üçgen Ağı
<b>TN</b>	Doğru Negatif
<b>TP</b>	Doğru Pozitif
<b>VHR</b>	Çok Yüksek Çözünürlük
<b>YÖA</b>	Yer Örnekleme Aralığı

## 1. GİRİŞ

Uzaktan Algılama teknolojileri obje ya da varlıklar hakkında fiziksel kontak oluşturmadan bilgi edinilen teknolojilerdir (Lai vd., 2019). Günümüze değin çok farklı tipte sensörle ve sayıda uzaktan algılama verisi üretilerek bu verilerle uygulamalar yapılmıştır. Özellikle konumsal ve zamansal çözünürlüğün artması ile bu veriler obje ve ağaç çıkarımı, kıyı çizgisi belirleme ve yol çıkarımı gibi çalışmaların ana kaynağını oluşturmaya başlamışlardır (Lai vd., 2019; Marullo vd., 2018). Bina objesinin özelliklerle kentsel alanların ana bileşeni olmasından dolayı, bina detaylarının uzaktan algılama teknolojileri ile çıkarımı ilgili teknolojinin hızlı, etkin ve ekonomik olmasından kaynaklı olarak ana çalışma konusu olmuştur. Literatürde, farklı araştırmacılar görüntüleri kullanarak bina bilgi çıkarımına yönelik olarak spektral, geometrik, içeriksel ve çatı tipleri ile ilgili bilgileri ortaya koymuşlardır.

Bina çıkarma ve sayısallaştırma, şehir planlama ve arazi yönetimi gibi farklı alanlarda bilgi edinmenin en önemli yoludur. Uzaktan algılama geniş kapsama alanı ve gerçek zamanlı uygulanabilme yeteneği gibi çeşitli avantajlara sahip olduğundan bina çıkarımı için temel bir yaklaşımdır. Çeşitli uzaktan algılama teknolojileri arasında, LiDAR ve fotogrametrik görüntülerden eşleştirme teknikleri üretilerek 3B özellikler sağlayan nokta bulutları bina çıkarımı için en önde gelen önemli araçlardır (Lai vd., 2019).

Lazer tarama ve görüntü eşleştirme teknolojilerinin gelişmesi ile birlikte, 3B bilgi üretimi araştırmacıların ilgi odağı haline gelmiştir. 3B bilgi çıkarımı uygulamaları sayısal yükseklik modeli (SYM) ve sayısal yüzey modeli (SYuM) üretimi ile arkeoloji, topoğrafik izleme, kültürel mirası koruma, orman ve tarımsal modelleme gibi birçok alanda gerçekleştirilmiştir (Christian Rose vd., 2015; Shao vd., 2016). Lazer tarama ile doğru, güvenilir, yoğun ve entegre 3B veri üretilbildiğinden, bu teknoloji son yirmi yıldır tercih edilmektedir. Son yıllarda, fotogrametri ve bilgisayarla görüş alanındaki önemli gelişmeler, görüntü tabanlı 3B veri üretimi, lazer teknolojisi için önemli bir rakip ya da alternatif olarak ortaya çıkmıştır (Rau vd., 2015; Shao vd., 2016). Lazer teknoloji ile karşılaştırıldığında, görüntü tabanlı 3B veri üretiminin avantajları;

- Görüntüler her türlü kamera ile alınabilir, akıllı telefon veya tabletler ile çekilebilir, statik dijital kamera ya da video kamera ile üretilir,

- Bu teknolojinin maliyeti oldukça düşüktür,
- Nokta bulutu verisi aynı zamanda renk bilgisini de içerir,
- Lazer teknolojisine göre daha yoğun nokta bulutu üretilir (Remondino vd., 2014; Shao vd., 2016).

şeklinde özetlenebilir. Bu avantajlarından dolayı son yıllarda özellikle görüntü tabanlı fotogrametrik eşleştirme yöntemi ile üretilen 3B nokta bulutu verileri yaygın biçimde kullanılmaktadır.

Literatürde veri tipine göre bina çıkarımı ve sayısallaştırması için kullanılan metotlar genel olarak üç grupta toplanmaktadır. Birinci grup metotlar, direkt fotoğrafik görüntülerden 2B veya 3B bilgi çıkarımına dayanmaktadır. İkinci grup yöntemler sadece LiDAR verisi kullanırlar. Üçüncü grup yöntemler ise karma içerikli olup, LiDAR ve fotogrametrik görüntüleri entegre biçimde kullanarak bina çıkarımı gerçekleştirir (Siddiqui vd., 2016). Veri işleme stratejisine göre de bina çıkarım metotları ana olarak üç kategoriye ayrılır (Hermosilla vd., 2011; Siddiqui vd., 2016). Veri tabanlı (data-driven) metotlar direkt olarak veriyi kullanarak bina detaylarını belirlemeye çalışırlar. Bu yöntemlerin dezavantajı doğruluk ve bütünlük açısından istenilen düzeyde olmamalarıdır. Model tabanlı (model-driven) yöntemde ise mevcut bilinen bina geometri modeli, veri üzerine fit edilmeye çalışılır. Bu yöntemde sonuç topolojik olarak doğru olup gerçek modelle kimi zaman uygun olamamaktadır. İlk iki modeli hibrit biçimde kullanan üçüncü metotlar ise daha etkin sonuçlar ortaya koymaktadırlar (Gilani vd., 2016).

Bu tez çalışmasında, fotogrametrik görüntülerden eşleştirme metodu ile üretilen yoğun nokta bulutları içerisinde mevcut bina ayak izlerinin (sınırlar), voksel tabanlı sekizdal veri organizasyon metodunun basamak sayısı otomatize edilerek çıkarılması için geliştirilen yeni bir yaklaşım önerilmiştir. Önerilen yaklaşım iyileştirilmiş Octree (*I-Octree*) olarak isimlendirilmiştir. Yaklaşım, 3B nokta bulutlarının eşleştirme ile üretilmesi veya LiDAR nokta bulutu temin edilmesi, zemin ve zemin üstü objelerin çıkarılması ve bina objelerinin gürültülerden ayklanarak sınıflandırılması, sekizdal ve iyileştirilmiş sekizdal (*I-Octree*) veri organizasyonun sınıflandırılan objelere uygulanması ile bina detaylarının çıkarılması ve literatürde mevcut ABORE metodu ile bina kenarlarının düzgünleştirilmesi aşamalarından oluşmaktadır. Farklı test alanlarında üretilen sonuçlar literatürde kabul görmüş doğruluk analizi metotları ile değerlendirilerek tatmin edici sonuçlar ortaya konmuştur.

## 1.1 Çalışmanın Amacı ve Kapsamı

Ülkemizde, özellikle kamu ve özel kurumlar tarafından her türlü amaca yönelik olarak üretilen haritalarda temel detay ya da katmanlardan birisi bina objeleridir. İlgili objelerin her türlü veri içerisinden sayısallaştırılması büyük önem arz etmektedir. Son yıllarda özellikle 3B veri kullanımı ciddi biçimde yaygınlaşmış ve hatta gereklilik haline gelmiştir. Bu tür verilerin üretimi fotogrametrik görüntülerden eşleştirme yöntemi ile ortaya çıkarılan nokta bulutundan olabileceği gibi, LiDAR ile de doğrudan sağlanabilmektedir.

Bu tez çalışmasında ana amaç, fotogrametrik görüntülerden üretilen nokta bulutu içerisinde mevcut binaların tam otomatik olarak, literatürden farklı bir biçimde voksel tabanlı sekizdal veri organizasyon metodunun iyileştirilmesi (I-Octree) ile otomatize bir biçimde ortaya çıkarılması, sayısallaştırılması ve bina kenar bilgilerinin her türlü harita doğruluğunu sağlayacak şekilde gerçekleştirimidir. Üretilen bina kenar detayı ya da ayak izleri direkt olarak harita katmanı biçiminde kullanılıp kullanılmayacağı da farklı ölçekteki referans verilerle test edilmiştir.

Çalışmanın önemli amaçlarından biri de dijital harita için gerekli olan nesnelere bina sınırları/kenarları üretilirken operatör desteğinin minimize edilmesidir. Bina ana hatlarının doğru bir biçimde çıkarılması, nokta bulutu sınıflandırma kalitesine bağlıdır. Ancak, gerçek dünya sahnelerinin karmaşıklığı ve büyük veri hacimleri hatalı bina detayı çıkarım sonuçlarına yol açabilmektedir. Binalar genellikle ağaçlara bitişik olduğundan, çatı üzerindeki noktalar ağaç noktaları olarak sınıflandırılır veya bunun tersi de geçerlidir. Bu tür koşullar, yanlış bina ayak izi veya kenar çıkarma sonuçlarına neden olabilmektedir. Bu yüzden çalışmada, farklı nokta yoğunlukları dikkate alınarak; (i) *bina kenarlarında gürültü ve kusurların etkisinin nasıl ve ne şekilde azaltılabileceği* ve (ii) *rasgele şekle (alfa şekil) sahip karmaşık bina sınırları nasıl doğru bir şekilde regülerize edilir?* sorularına da cevap aranmıştır.

Çalışmanın literatüre katkısı; büyük ölçekli hava görüntülerinden voksel tabanlı iyileştirilmiş sekizdal veri organizasyon metodunu (I-Octree) kullanarak LoD1 düzeyinde tam otomatik bina çıkarımı ve regülerizasyonu gerçekleştirmek ve üretilen binanın referans veri ile karşılaştırılması ile doğruluk analizi gerçekleştirmek şeklinde değerlendirilmektedir.

## 1.2 Literatür Araştırması

Otomatik biçimde nokta bulutu işlemenin önemi, özellikle haritalama bağlamında çeşitli uygulamalar için 3B nokta bulutu kullanımına olan ilgiyle birlikte artmaktadır. Makul bir süre içinde kapsamlı ve doğru 3B veri sağlamanın avantajlarına rağmen, nokta bulutlarını otomatik olarak işleme yöntemleri halen daha gelişmeye açıktır. Konu ile ilgili literatür detayı aşağıda özetle sunulmuştur.

Lai vd., (2019), nokta bulutundan bina çıkarımı için, LiDAR nokta bulutu ve görüntülerden alınan doku özelliklerinin birlikte kullanımından oluşan bir yöntem önermişlerdir. Her bir noktanın yüksekliğini ifade eden bir yükseklik haritası kullanılarak doku özellikleri çıkarılmıştır. Çalışmadaki deneyler, nokta bulutu ve doku özelliklerinin füzyonunun diğer yöntemlerden daha yüksek çıkarım doğruluğu elde edilebildiğini göstermiştir. Önerilen yöntem kullanılarak %87'yi aşan tatmin edici bir bina çıkarımı doğruluğu elde edilmiş olup, verimli ve geçerli bir yöntem olduğunu ortaya koymuşlardır.

Dong vd., (2018), düşey bir hava görüntü kümesi (Vaihingen) ve iki eğik hava görüntü kümesi (Potsdam ve Lunen) üzerinde yaptıkları çalışmada, bina sınırlarını tespit etmek ve düzenlemek için yeni bir yöntem önermişlerdir. Bu yöntem üç aşamadan oluşmaktadır. İlk aşamada, orijinal hava görüntüsünden ve yoğun eşleşme noktalarından alınan özellikler, binaları tespit etmek ve tek bir bina bloğunu elde etmek için birleştirilir. Ardından, orijinal hava görüntülerinden düz çizgi parçalarını eşleştirmek için özellik düzeyinde bir birleştirme stratejisi uygulanır. Son olarak, eşleşen düz çizgi segmentlerini ve bireysel bina bloğunun sınırlarını birleştirerek bina ayak izini oluşturulur.

Siddiqui vd., (2016), küçük ve şeffaf bina çatılarının tespitinde yaşanan sınırlama zorluklarını gidermek adına eğim tabanlı bina çıkarımı yöntemini önermişlerdir. Önerilen yöntem, binaları çıkarmak için fotogrametrik görüntüden çıkarılan bina çizgileri yönünde LiDAR noktalarını kullanır. Ek olarak, belirli bir görüntüden alınan yerel bilgilere dayalı olarak bazı parametrelerin otomatik olarak ayarlandığı yerel renk eşleştirme ve gölge analizi tanıtılır. Önerilen yöntemin performansı, nesne ve piksel tabanlı metrikler kullanılarak iki referans veri seti üzerinde değerlendirilmiş ve

ağaçları ortadan kaldırmada, her büyüklükteki binayı çıkarmada ve şeffaf çatılı ve çatısız bina çıkarımında etkinliğini göstermektedir.

Gilani vd., (2016), nokta bulutu ve ortofoto özellikleri kullanılarak binaları çıkarmak ve düzenlemek için bir metodoloji geliştirmişlerdir. Burada, tamamen veriye dayalı ve otomatik olan bir bina algılama ve ayak izi oluşturma tekniği sunulmaktadır. Aday bina bölgeleri önce bağlantılı bileşen analizi kullanılarak belirlenir. Daha sonra, grid indeks yapısı ve çok kaynaklı veriler aracılığıyla bitki örtüsünün kaldırılmasından sonra kısmen kapatılmış ve gölgelenmiş binalar çıkarılmaktadır. Son olarak, görüntü çizgileri ve çıkarılan bina sınırları kullanılarak bina ayak izleri oluşturulur. Bina çıkarım ve düzenleme süreçleri, nokta yoğunluğu (1 ila 29 nokta/m<sup>2</sup>), bina boyutları, gölgeler, arazi ve bitki örtüsü bakımından farklılık gösteren dört veri seti kullanılarak değerlendirilmiştir.

Dal Poz ve Yano Ywata, (2020), hava LiDAR (ALS) verilerinde binaların çatı düzlemlerini bölümlere ayırmak için üç aşamalı bir yöntem önermişlerdir. İlk adım, ALS nokta bulutu boyunca düzlemsel çatı yüzleri için kapsamlı aramadan kaçınmayı amaçlar. ALS nokta bulutunu işlemek için standart algoritmalar, bina bölgelerini izole etmek için kullanılır. Önerilen yöntemin ikinci adımı, daha önce sınırlandırılmış bina bölgeleri içinde çatı düzlemlerinin bölümlere ayrılmasından oluşur. ALS bina noktalarının tutarlılığını kontrol etmek için Random Sample Consensus (RANSAC) algoritmasını kullanmışlardır. RANSAC algoritması parçalanmış sonuçlar üretebildiğinden, üçüncü adımda, yaklaşık olarak eş doğrusal ve uzaysal olarak yakın olan düzlemleri birleştirmek için son bir işlem gerçekleştirilir. Sonuçlar, önerilen yöntemin düzgün çalıştığını göstermektedir.

Ma vd., (2019), çok yüksek çözünürlüklü (VHR) uzaktan algılama uydu görüntülerinden bina özelliklerini otomatik olarak çıkarmak için yeni bir morfolojik nitelik bina indeksi (MABI) ve gölge indeksi (MASI) önermişlerdir. Önerilen çalışmanın ön işleme adımında, yüksek homojenliğe sahip girdiyi elde etmek ve uzun nesnelere (potansiyel bina olmayanlar) bastırmak için orijinal VHR spektral yansıma verileri üzerinde öznelik filtrelemesi yapılmıştır. Daha sonra elde edilen girdi temel görüntü olarak alınarak MABI ve MASI değerlerini hesaplamışlardır. Karanlık çatıların ihmalini azaltmak için karanlık binalar MABI'de ayrı olarak değerlendirmişlerdir. MABI özellik görüntüsünden binaları daha iyi tespit etmek için,

binalarla karıştırılan yollar ve çıplak zemin gibi bina dışı arazi örtülerini daha fazla filtrelemek için nesne yönelimli bir analiz ve bina-gölge eşzamanlılık ilişkilerini kullanmışlardır. Hem görsel inceleme hem de nicel değerlendirme göz önüne alındığında, önerilen çalışmanın sonuçları, son otomatik bina indeksi ve denetimli ikili sınıflandırma yaklaşımı sonuçlarından daha üstündür.

Sun ve Wang, (2018), bina sınırının çıkarılmasında yaygın olarak kullanılan, ancak genellikle ağaç ve arka plan karışıklıkları nedeniyle kısmen önyargılı bina sınırı çıkarılmasıyla sonuçlanan bir segmentasyon yöntemi olan aktif kontur modelini (ACM) kullanmışlardır. Bu çalışmada, sınır çıkarımı oluşturularak algoritmalarındaki mevcut sınırlamaların üstesinden gelmek için sınıflandırma evrişimli sinir ağları (CNN) ve ACM ile birleştirilmiştir. Önerilen yöntemlerin iki veri setinden beş test alanında bina sınırlarını verimli bir şekilde çıkarabileceğini göstermektedir.

Bulatov vd., (2014), binaları etiketleyerek vejetasyon ve hatalı noktaları normalize edilmiş SYM'den çıkarmış ve bina sınırlarını etiketli pikseller ile grafik tabanlı ortofoto segmentasyonu ile ortaya çıkarmışlardır. Li vd., (2016) grafik kesme tabanlı Markov modeli ile farklı açılardan çekilmiş görüntülerden üretilen noktaları sınıflandırmak suretiyle bina, ağaç ve zemini ayırmışlardır. Ardından RANSAC ile bina çatı düzlemlerini ortaya çıkarmışlardır. Yan vd., (2017) rastgele doku segmentasyon yöntemini kullanarak SYM üzerinden bina ayak izlerini ortaya çıkarmışlardır. Alidoost vd., (2019) tekil görüntüden 3B bina şekillerini çıkarmak üzere çok ölçekli konvolüsyon-dekonvolüsyonlu bir ağ kullanmışlardır. Bina çıkarımı amaçlı olarak derin öğrenme tabanlı görüntü segmentasyon yöntemleri de geleneksel yöntemlerin yanında kullanılmıştır (Z. Cao vd., 2019; Ji vd., 2019).

3B bina çıkarımı için farklı yazarlar tarafından literatüre yeni çalışmalar da kazandırılmıştır (F. Alidoost ve Arefi, 2015; Jayaraj ve Ramiya, 2018; Malihi vd., 2016; Nan ve Wonka, 2017). Fotogrametrik yoğun eşleştirme metotları ile nokta bulutu üretimindeki gelişmeler son yıllarda bina çıkarımı için makine öğrenme tabanlı tekniklerin geleneksel tekniklerin yerini aldığını ortaya koymaktadır (Kendall vd., 2017; Liu ve Ji, 2020; Wu vd., 2019; F. Zhang vd., 2019). Literatürde bina çatı yüzeylerini ayrı ayrı olarak çıkarabilen algoritmalar da mevcuttur (Fatemeh Alidoost vd., 2019; Gilani vd., 2016).

Tez çalışması için, bina yerleşim alanı kentsel, kırsal ve kentsel-kırsal geçiş bölgesini kapsayacak şekilde üç farklı tipte daha önce yüksek çözünürlüklü fotogrametrik kamera ile çekilmiş hava görüntüleri ve kıyaslama amacıyla LiDAR verileri kullanılmıştır. Bu görüntülere ilişkin projede kullanılan kontrol nokta verileri ya da dengelenmiş proje verileri (dış yöneltme elemanları) temin edilmiştir. Seçilen çalışma bölgeleri için uçuş kolon sayısı iki ya da üç olacak şekilde belirlenmiş ve bu kolonlara ait görüntüler görüntü eşleştirme metotları (SGM-Semi Global Matching veya SfM-Structure from Motion) kullanılarak fotogrametrik nokta bulutları yoğun olacak şekilde üretilmiştir (Guerra-Hernández vd., 2018; Y. Li vd., 2016). Nokta bulutu üretiminde özellikle spektral bilgi de (RGB+IR) uzaysal veriye dâhil edilmiştir. Nokta bulutu verisi Agisoft Metashape Profesyonel ticari yazılımı kullanılarak üretilmiştir.

Eşleştirme sonucu üretilen nokta bulutu verisi için öncelikle yer ve yerüstü ayrımı ve ayrıca vejetasyon ayrımı SMRF (Simple Morphological Filter) yöntemi ile gerçekleştirilmiştir (Wuming Zhang vd., 2016). SMRF, Matlab yazılım ortamında çalıştırılmıştır. Bu işlem sonrası sadece binaların mevcut olduğu veri içerisinde bina kümelerinin birbirinden ayrılması için DBSCAN (Density Based Spatial Clustering of Applications with Noise) algoritması kullanılarak kümeleme işlemi yapılmıştır (Ester vd., 1996). Böylece, yaklaşık bina kümeleri ayrık yapıya dönüştürülmüştür.

Böylece genel hatları ile zemin ve yeşil örtüden ayrılan bina verilerinin sınır noktaları, çalışmada önerilen voksel tabanlı iyileştirilmiş sekizdal veri organizasyon metodu (I-Octree) sayesinde kesin olarak ortaya çıkarılmıştır. I-Octree yaklaşımı, sekizdal kümeleri içerisinde ideal basamağa kadar bina çatı ya da ayak izine ait nokta bulutu verilerini otomatik olarak tespit etmektedir.

Tespit edilen sınır noktaları birleştirildikten sonra düzleştirilmesi için literatürde mevcut ABORE yöntemi kullanılmıştır. Doğruluk analizi için çalışma alanını içeren referans harita ile üretilen ve düzleştirilen sınır noktaları karşılaştırılmak suretiyle, bütünlük, doğruluk, kalite, F-skor metrikleri hesaplanmıştır.

## 2. GENEL BİLGİLER

Şehirler, artan dünya nüfusuna ve hızlı kentleşmeye bağlı olarak, alanları ve görünüşleri ile zaman içinde dinamik bir şekilde değişmektedir. 2018 yılında dünyada kentsel nüfus oranı %55 iken, bu oran 1960'tan beri neredeyse iki katına çıkmıştır. Eğilim, doğrusal bir büyüme göstermektedir ki kentsel nüfusun 2050'de %68 ve 2100'de ise %85 olacağıdır (Schlosser vd., 2020). Bu süreç, hızlanan kentsel yayılmanın, bina inşaat hızının ve yerleşim alanlarının artışı üzerinde önemli bir rol oynamaktadır. Buna göre, kentsel alanlar ve nüfus arasındaki ilişkinin incelenmesi bölge planlamasında en önemli konulardan biridir. Bu nedenle konut ve hizmet merkezlerinin konumu, nüfus yoğunluğu ve kent kenar bölgesi özellikleri hakkında bilgi edinmek oldukça önemlidir. Bu hızlı gelişme, sıkı bir kontrol gerektirir ve buna bağlı olarak kentsel büyümeyi ve etkileri izlemenin geleneksel yolları yavaş veya verimsiz olabilmektedir (Maktav vd., 2005). Kentsel çevrenin ortak unsurları düşünüldüğünde, binalar en önemli nesnelere (Lai vd., 2019). Kentsel yayılmayı izlemek önemli bir görevdir ve otomasyon için olası bir yol, uzaktan algılanan verilerden özellik çıkarmaktır (R. Chen vd., 2018). Uzaktan algılama, verimli bir veri toplama yöntemidir ve çıkarılan bilgiler, kentsel planlama, arazi kullanım analizi, nüfus dağılımı, güneş enerjisi tahmini, hava ve gürültü kirliliği, bina yeniden inşası, 3D şehir modelleme dâhil olmak üzere çeşitli şekillerde kullanılabilir (Mohammad Awrangjeb vd., 2010; Vosselman, 2002). Bina nesnelere algılamak, yüksek kalitede uzaktan algılama verileriyle dahi zorlu bir konudur (Schlosser vd., 2020).

### 2.1 Temel Kavramlar

Bu başlık altında tezde kullanılan metodolojinin teorik içeriği detaylı bir biçimde anlatılmış, tüm metodlar hakkında yeterli düzeyde bilgi sunulmuştur.

### 2.2 Fotogrametrinin Tanımı ve Tarihi

Fotogrametri, topoğrafik görüntülerden yayılan elektromanyetik enerjinin ölçülerek kayıt altına alınması ve özellikle yorumlama işlemleri sonucu fiziksel nesnelere ve çevre hakkında dijital ortamda doğruluğu yüksek sayısal bilgiler sunan, cisimlerden yansıyan enerji ve manyetik olayları inceleyen bir bilim dalıdır (Konecny, 2003).

Fotogrametrinin başlangıç noktası 1839 yılında Niepce ve Dagurre'nin fotoğraf makinası icadına dayanır. Fransız ordusunda yer alan topograf Laussedat tarafından fotoğraflar ile ölçüm yapan ilk kamerayı ortaya çıkartması günümüz fotogrametrisinin doğuşudur. Fotogrametrinin gelişmesinde bir diğer önemli olay ise 1958 yılında Meydenbauer adında Alman mimar tarafından kamu binaları için fotoğraflar aracılığıyla ölçüm yöntemlerinin ortaya koyulmasıdır. Kısaca objelerin optik sistemler aracılığı ile düz bir yüzeye iz düşürülerek aktarılmasının keşfi fotogrametri oluşumunu özetleyen kısa bir tanımdır (Acar, 2012).

Fotogrametrinin günümüzde pek çok tanımı mevcuttur. Bu tanımlardan biri Uluslararası Fotogrametri ve Uzaktan Algılama Birliği'nin tanımıdır ve şu şekildedir: Fotogrametri, nesnelerin görüntü ve mesafe verilerinden genellikle zaman içinde güvenilir üç boyutlu geometrik ve tematik bilgileri çıkarma bilimi ve teknolojisidir. Fotogrametrinin genel bir biçimde açıklaması yapılırsa; iki boyuta sahip görüntülerin üç boyutlu uzayda modellenmesine fırsat sunan bir ölçüm tekniği olduğu söylenebilir. Bu durum iki boyutlu fotoğrafik görüntüler kapsamında uygun bir açıklama olsa da radar veya tarayıcı sistemler ile çalışan teknikler fotogrametrik teknikten aykırı kalabilmektedir. Bu çerçevede kullanılan fotogrametrik teknikler çıktı veri türüne ve duyarlılığına göre çeşitlilik göstermektedir (Egels ve Kasser, 2001).


Bir diğer açıdan fotogrametri, herhangi bir fiziksel temas bulunmaksızın ölçüm işlemlerini görüntüler aracılığı ile yapabilmek anlamına gelmektedir. Cisim uzayında, üç boyutlu koordinat bilgisi gereksinimi halinde, yalnızca bir fotoğraf ile bu gereksinim karşılanamamaktadır. Tek bir fotoğraf ile özel durumlar dışında yalnızca iki boyutlu koordinat bilgisi elde edilebilir. Üç boyutlu veriye sahip olunabilmesi için en az bindirmeli iki görüntü gereklidir. Fotogrametrideki üç boyutlu veri elde edilebilmesi durumu, insan görme yetisi ile karşılaştırıldığında oldukça benzerlik taşımaktadır. Nesnelere algılanan derinlik hissi, sağ ve sol gözden gelen ayrı sinyallerin insan beyinde değerlendirilmesi sonrası oluşmaktadır (Linder, 2009).

### **2.3 Fotogrametrinin Matematik Modeli**

Objeye uzay koordinat sistemindeki noktaların fiziksel oluşum esaslarının matematiksel olarak ifadesine matematiksel model denir. Fotogrametrinin matematiksel modeli kolinearite (izdüşüm) denklemleri temeline dayanır. Kolinearite denklemlerinin esas,

cisim uzayındaki noktaları gösteren ışınlar izdüşüm merkezinden geçerek resim düzlemine bir doğru boyunca iz düşürülür biçimindedir.

İki aşamada gerçekleştirilen yeniden konumlandırma/oluşturulma işlemi için birinci aşama Şekil 2.1'deki gibi iç yönlme parametrelerinin, yani asal uzaklık ( $c$ ) ve asal nokta koordinatlarının ( $c, x_0, y_0$ ) hesaplanmasıdır. İkinci aşama ise, dış yönlme parametreleri adımdır ki bu adımda izdüşüm merkezi koordinatları ve dönüklük değerleri ( $\omega, \varphi, \chi, X_0, Y_0, Z_0$ ) elde edilir.



Şekil 2.1. Fotogrametrik veri alım geometrisi ve matematik model

Fotoğraf uzayı ile obje uzayı arasındaki açısal bağlantılar ortogonal dönüşüm matrisi ile belirlenmektedir. Bu bağlantının formülleri noktalar arası üç boyutlu vektörler ile belirtilmektedir. Burada;

$O$ , kartezyen obje koordinat sisteminin orijini ( $X, Y$  ve  $Z$ ),  $P_i$  nesne noktası koordinatı ( $X_i, Y_i, Z_i$ ),  $O'$  izdüşüm merkezi ( $X_0, Y_0, Z_0$ ),  $OP_i$  iki vektör arasındaki mekansal üçgeni oluşturmaktadır. Objeye ve resim koordinatı arasındaki ölçek faktörü  $\lambda_i$ , ve dönüklük matrisi  $R$ 'nin de bilinmesi gereklidir.

$$\vec{x}_i = \vec{x}_0 + \lambda'_i R \vec{p}'_i \quad (1)$$

(1) nolu denklem açık biçimde yazıldığında (2) nolu denklem elde edilmektedir.

$$\begin{pmatrix} X_i \\ Y_i \\ Z_i \end{pmatrix} = \begin{pmatrix} X'_0 \\ Y'_0 \\ Z'_0 \end{pmatrix} + \lambda'_i R \begin{pmatrix} x'_i \\ y'_i \\ -c \end{pmatrix} \quad (2)$$

Objekt koordinat sistemi eksenlerinin ve görüntü koordinat sisteminin birbirleriyle yakın noktalara değinmesinin kolaylığı için, kamera sabiti ( $c$ ) negatif olarak yazılır. Objekt koordinat ve görüntü koordinat sistemlerinde birim vektörler ( $i, j, k$  ve  $a, b, c$ ) ile ortogonal şekilde birbirlerine dik ve aynı zamanda tüm eksenlerde aynı ölçek mevcuttur. Böylece matrisin tersi,  $R^{-1}$ 'den ters  $R$  matrisinin hesaplanmasına ihtiyaç duyulmaz fakat (3) nolu eşitlikte görüldüğü üzere transpozesi  $R^T$  şeklinde gösterilebilir.

$$\begin{pmatrix} x'_i \\ y'_i \\ -f \end{pmatrix} = \frac{1}{\lambda'_i} R^T \begin{pmatrix} X_i - X'_0 \\ Y_i - Y'_0 \\ Z_i - Z'_0 \end{pmatrix} \quad (3)$$

Dönüklük matrisi ( $R$ ) için birden fazla tanım yapmak mümkündür. Bu,  $x'x, x'y...z'z$  eksenleri arasındaki açılardan (5), (6) ve (7) nolu eşitliklerde gösterildiği gibi kosinüs ve sinüs değerlerinin alınmasıyla hesaplanır. Her bir dönüklük açısı için ayrı ayrı dönüklük matrisi ( $R_\omega, R_\varphi, R_\chi$ ) hesaplanır. (4) nolu eşitlikte görüldüğü üzere bu matrislerin çarpımı ile de dönüklük matrisi ( $R$ ) hesaplanır.

$$R^T = R_\omega^T \cdot R_\varphi^T \cdot R_\chi^T \quad (4)$$

$$R_\omega^T = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos\omega & \sin\omega \\ 0 & -\sin\omega & \cos\omega \end{pmatrix} \quad (5)$$

$$R_\varphi^T = \begin{pmatrix} \cos\chi & 0 & \sin\varphi \\ 0 & 1 & 0 \\ -\sin\varphi & 0 & \cos\varphi \end{pmatrix} \quad (6)$$

$$R_\chi^T = \begin{pmatrix} \cos\chi & \sin\chi & 0 \\ -\sin\chi & \cos\chi & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad (7)$$

$$R^T = \begin{pmatrix} \cos\varphi\cos\chi & \sin\chi\cos\omega + \cos\chi\sin\varphi\sin\omega & \sin\chi\sin\omega - \cos\chi\sin\varphi\cos\omega \\ -\sin\chi\cos\varphi & \cos\chi\cos\omega - \sin\chi\sin\varphi\sin\omega & \cos\chi\sin\omega - \sin\chi\sin\varphi\cos\omega \\ \sin\varphi & -\sin\omega\cos\varphi & \cos\varphi\cos\omega \end{pmatrix} \quad (8)$$

$$R^T = \begin{pmatrix} r_{11} & r_{21} & r_{31} \\ r_{12} & r_{22} & r_{32} \\ r_{13} & r_{23} & r_{33} \end{pmatrix} \quad (9)$$

(9) nolu eşitliğe resim ve arazi koordinat bilgisi eklenilerek (10) nolu eşitlik elde edilir.

$$\begin{pmatrix} x'_i \\ y'_i \\ -c \end{pmatrix} = \frac{1}{\lambda'_i} \begin{pmatrix} r_{11} & r_{21} & r_{31} \\ r_{12} & r_{22} & r_{32} \\ r_{13} & r_{23} & r_{33} \end{pmatrix} \begin{pmatrix} x_i - x'_0 \\ y_i - y'_0 \\ z_i - z'_0 \end{pmatrix} \quad (10)$$

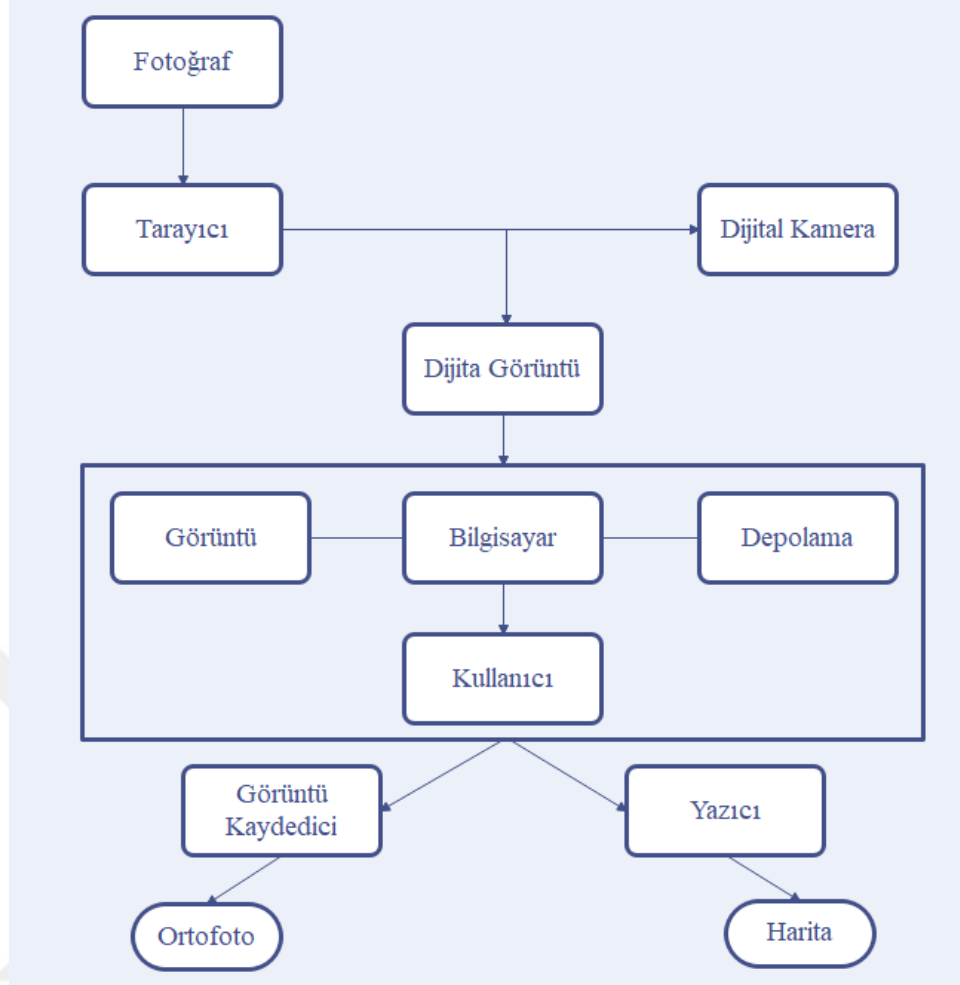
(10) nolu denklemde görüntü koordinatları konumları ve dönüklükleri tıpkı  $\lambda_i$  gibi ayrıca bilinmeyen unsurlardır. Kamera sabiti ( $c$ ) bilindiğinden, ilk ve ikinci denklemi üçüncü ile bölünerek denklem sayısı ikiye indirilir. Bu işlem, (11) ve (12) nolu eşitliklerde gösterilen izdüşüm denklemleriyle sonuçlanır. Bu denklemlerin oluşturulabilmesi için, görüntü noktası, izdüşüm merkezi ve arazi noktası düz bir hat üzerinde olmalıdır kuralı işletilir (Konecny, 2003).

$$x'_i = -c \frac{r_{11}(x_i - x'_0) + r_{12}(y_i - y'_0) + r_{13}(z_i - z'_0)}{r_{31}(x_i - x'_0) + r_{32}(y_i - y'_0) + r_{33}(z_i - z'_0)} \quad (11)$$

$$y'_i = -c \frac{r_{21}(x_i - x'_0) + r_{22}(y_i - y'_0) + r_{23}(z_i - z'_0)}{r_{31}(x_i - x'_0) + r_{32}(y_i - y'_0) + r_{33}(z_i - z'_0)} \quad (12)$$

## 2.4 Dijital Fotogrametri

Fotogrametri, değerlendirme yöntemine göre Plançete, Analog, Analitik ve Dijital Fotogrametri sınıflarına ayrılmaktadır. Bu sınıflara günümüzde yaygın ve etkin kullanım alanı bulan Fotogrametrik Bilgisayarla Görü'de eklenebilir. Dijital fotogrametri teknolojinin gelişmesi ile birlikte yüksek boyutlu görüntülerin işlenebilmesi ve depolanabilmesi sayesinde analitik ve analog fotogrametriyi geride bırakabilecek seviyeye gelmiştir. Günümüzde farklı dijital kamera çeşitleri ile elde edilen fotoğraflar dahi dijital formata dönüştürülerek bilgisayar ortamında işlenebilmektedir. Dijital bir biçime dönüştürülmüş olan görüntüler kullanıcılar aracılığıyla bilgisayar ortamında işlenerek fotogrametrik veri elde edilebilmektedir (Şekil 2.2).



Şekil 2.2. Dijital fotogrametri genel akış diyagramı (Acar, 2012)

Analog ve analitik fotogrametride olduğu gibi dijital fotogrametride de kullanılacak fotoğrafın, fotoğraf koordinatlarının bilinmesi gereklidir. Bunların yanı sıra dijital fotogrametrinin avantajları aşağıda ifade edilebilir.


- **Görüntü iyileştirme:** Görüntü dijital ortamda bulunduğu için, kontrast ve ışık şiddeti gibi çeşitli görüntü işleme operasyonlarına fırsat sunmaktadır.
- **İşlem kolaylığı:** Dijital fotogrametrik işlemler diğer fotogrametrik işlemlere göre daha hızlı ve kolaydır.
- **Ürünlerin elektronik ortamlarda saklanması:** CBS veri katmanlarına veri aktarımı açısından önemli bir kolaylık sağlamaktadır. Değerlendirme sonuçlarının aynı anda izlenebilmesi hataları daha da azaltmaktadır.

- **Veri depolama:** Sonuç ürünleri bilgisayar teknolojisinin sağladığı imkânlar neticesinde ekonomik olarak saklanabilmektedir.

Dijital fotogrametrinin en önemli veri sağlayan araçları fotogrametrik dijital hava kameralardır. Bu kameralar özellikle değerlendirme sürecinin hızlı ve etkin bir biçimde gerçekleştirimini sağlamaktadır.

## 2.5 Dijital Hava Kameraları ve Özellikleri

Dijital kamera veya tarayıcı ile üretilen ve bilgisayarda izlenen görüntüye dijital görüntü denilmektedir. Bu görüntüleri fotogrametrik amaçlı kullanılmak üzere dijital hava kameraları ile üretmek mümkündür. Bu kameralar çalışma prensipleri ve geometrik özellikleri bakımından analog kameralarla benzerlik göstermektedir. Fotogrametride görüntüleme amaçlı kullanılan kameraların genel yapısı Şekil 2.3'te gösterilmektedir.



**Şekil 2.3.** Kamera yapısı; A) mercek, B) diyafram, C) obtüratör, D) odaklama, E) görüntüleme sistemi, F) film, G) film nakil sistemi, H) kamera gövdesi (Limandal, 2019)

Kameralar dijital görüntülerin oluşturulmasında temel faktördür. Kamera; kamera gövdesi, mercek, taşıyıcı (CCD; Yük Bağlamalı Düzen-Charge Couple Device), diyafram ve obtüratörden oluşmaktadır.


Kameranın işleyişi incelendiğinde, CCD hassasiyetine göre, obtüratör gözlemi etrafında diyaframdan geçen ışık, CCD aracılığıyla mercekte toplanılıp elektrona çevrilip manyetik ortama kaydedilir. Dijital görüntüler için kameranın en önemli bölümü olan CCD'nin görevi ışığı elektron şarjına dönüştürerek, şarjı belirli bir süre depoladıktan sonra transfer etmektir. Elektronik devre biçiminde çalışarak sensörlere düşen fotonların elektrona dönüşmesine ayrıca yardımcı olurlar. Dijital görüntüler CCD aracılığıyla dijital ortama aktarılır. CCD sensörler, elektronları sensör üzerinden herhangi bir deformasyona uğramadan aktarılması için üretim aşamalarında kullanılan özel bir teknik ile yüksek kaliteli ve yoğun pikseli görüntülerin elde edilmesine yardımcı olur. Şekil 2.4'te Türkiye'de aktif olarak kullanılan dijital hava kameralarına örnekler verilmiş olup, bu kameralar ile ortalama 1000 m yükseklikten uçulması durumunda üretilen yer örnekleme aralığı (YÖA/GSD) değerleri verilmiştir.

	DMC I	Ultracam-X	Ultracam XP	Ultracam Eagle	DMC II	Ultracam FP
▲						▼
Piksel Boyutu	12 µm	7,2 µm	6 µm	5,2 µm	5,6 µm	6 µm
Görüş Alanı Açısı	69,3° (dik) 42° (paralel)	55° (dik) 37° (paralel)	55° (dik) 37° (paralel)	66° (dik) 46° (paralel)	45,5° (dik) 38,6° (paralel)	55° (dik) 37° (paralel)
Piksel	13824 (sattır) 7680 (sütun)	14430 (sattır) 9420 (sütun)	17310 (sattır) 11310 (sütun)	20010 (sattır) 13080 (sütun)	16768 (sattır) 14016 (sütun)	17310 (sattır) 11310 (sütun)
Odak Uzaklığı	120 mm	120 mm	100 mm	80 mm	112 mm	70 mm
A/D Bant Başma Çözünürlük	12 bit	>12 bit	>12 bit	>>12 bit	14 bit	>>12 bit
Veri depolama Kapasitesi	840 GB	1,7 TB	4,2 TB	3,3 TB	2 TB	3,3 TB
Yer Örnekleme Aralığı (GSD)	10 cm	6 cm	6 cm	6,5 cm	5 cm	8,5 cm

Şekil 2.4. Türkiye'de kullanılan bazı hava kameraları ve özellikleri (Limandal, 2019)

## 2.6 Lazer Tarama Teknolojisi (LiDAR)

LiDAR, lazer tarama teknolojisi olarak bilinen ve lazer ışınlarının herhangi bir cisim yüzeyine gönderilerek geri yansıyan ışınların gelene kadar geçen sürenin hesaplanması ile cisim ve lazer tarayıcı arasındaki mesafenin ölçümü olarak tanımlanmaktadır. Hava lazer tarama (ALS) sistemi aracılığıyla bir cisim yüzeyinin taranması Şekil 2.5'de görülmektedir.



**Şekil 2.5.** ALS ile obje yüzeyinin taranması (Acar, 2018)


Lazer tarayıcıları ile yapılan ölçümlerde lazer ışınları ölçülen cisimlere gönderilir ve geri dönüş süresi kaydedilir. Ölçüm esnasında gönderilmiş olan ışınların isabet ettiği noktaların konum bilgilerinin ( $X$ ,  $Y$  ve  $Z$ ) belirlenebilmesi için tarayıcının konumu ve konumlandırma açısının bilinmesi gerekmektedir. Tarayıcının konumu ölçüm esnasında sürekli olarak Global Konumlandırma Sistemi (GPS) ve İnersiyal Ölçme Aleti (IMU) yardımıyla elde edilmektedir.

Lazer ışınlarının ilk yansıma değerlerine bakılarak bir yüzey oluşturulmak istenirse bu noktalar yer üstü objeleri temsil ederken, son yansıma değerlerine bakıldığında ise meydana gelen yüzey noktaları zemini temsil etmektedir. Lazer tarayıcıları cisimlerden yansıyan değerleri yansıma sıralarına göre kaydetmektedir. Böylece meydana gelen farklılıklar üzerinden değerlendirme yapılabilmektedir. Örneğin bir ağacın en üst, orta ve en alt yüksekliğinden birden fazla yansıyan ışınlar meydana gelebilmektedir. Böylece bu düzensiz verilerden yararlanılarak cismin ağaç olduğu anlaşılabilir.

Lazer tarayıcılarından çıkan ışınlar doğrultuları boyunca farklı cisimlerden farklı yansımalar meydana getirmektedir. Düz yüzeylerden yansıyarak geri dönen lazer

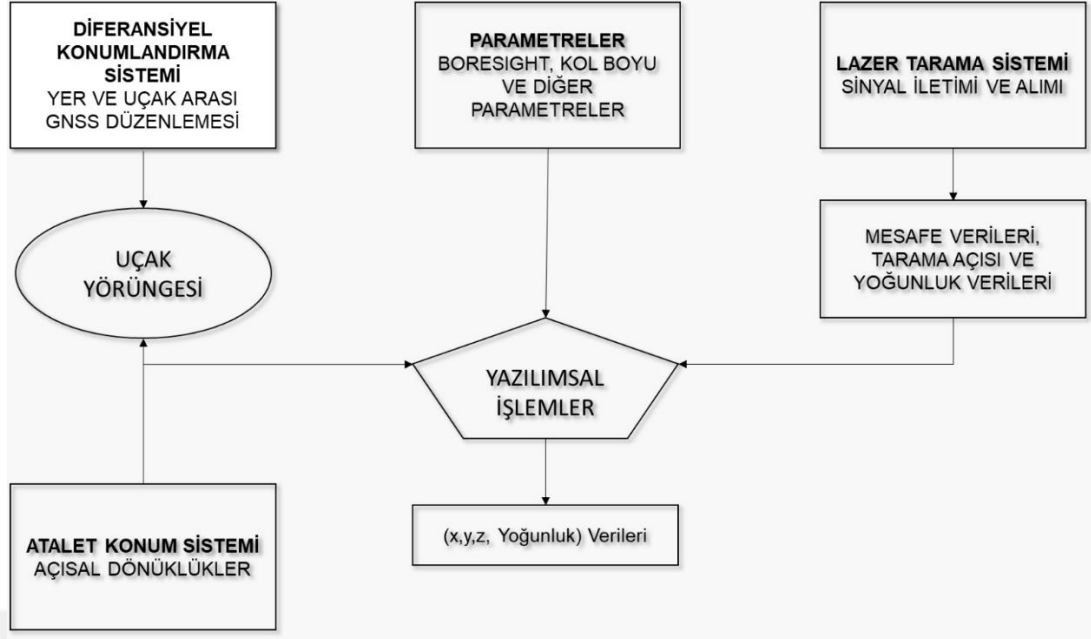
ışınları farklı cisimlere de yansırarak tarayıcı sisteme geri dönebilmektedir. Farklı yollar ile tekrar ederek yansıma yaparak tarayıcıya geri gelen ışınların uzunluğu çok büyük olduğundan bu ölçümlere kaba hatalı ölçümler denilebilmektedir. Suya benzer sıvı yüzeylerde ise tarayıcıdan dik bir açıyla gelen lazer ışınlarının yutularak ortadan kaybolması oldukça fazladır. Bundan dolayı göl gibi su kütesinin olduğu yerlerde soğurma olayı oldukça fazla olduğu için geri dönen ışın miktarı da o derece azdır. Böylece noktalar suyun sığ olduğu bölgelerde yoğun bir şekilde oluşmaktadır (Acar, 2018).

Şekil 2.6'da gösterildiği üzere, bir hava LiDAR sistemi, hava platformu (uçak veya helikopter), LiDAR sensörü, Küresel Navigasyon Uydu Sistemi (GNSS), yer tabanlı bir GNSS baz istasyonu, IMU sensörü ve üretilen farklı verileri arşivleyen bilgisayardan oluşmaktadır. Ayrıca ilgi alanın spektral bilgisini kaydeden orta format bir dijital kamerada sisteme dahil edilebilir.



**Şekil 2.6.** Hava LiDAR sistemi ve veri toplama (Lohani ve Ghosh, 2017)

LiDAR sistemi ile toplanan çeşitli sensör verileri için işlem adımları Şekil 2.7'de gösterilmektedir. Uçağın doğru konumu, yerleşik ve referans GNSS alıcı verilerinin işlenmesiyle belirlenir. Konum belirleme işlemi aracılığıyla lazer mesafeleri ve tarama açıları, yerdeki noktanın koordinatları GNSS koordinat sisteminde belirlenir. Sistem kalibrasyon parametreleri de belirli hataları en aza indirmek için bu aşamada işleme dahil edilir. Oluşturulan koordinatlar daha sonra istenen herhangi bir yatay ve düşey veriye dönüştürülebilir.



**Şekil 2.7.** LiDAR sistemi veri akışı ve işleme (Lohani ve Ghosh, 2017)

Son yirmi yılın büyük bir bölümünde, tek veya çoklu darbe yeteneğine sahip tek dalga boylu ve tek darbeli doğrusal (lineer) mod LiDAR (LML) hâkim olmuştur. Bununla birlikte, son zamanlarda birkaç yeni LiDAR sensör formu da ortaya çıkmış olup uygulamada kullanılmaya başlanmıştır.

Tek darbeli tek dalga boylu doğrusal mod LiDAR sensörlerinde, sensöre tek bir lazer darbesi iletilir ve alınır. Herhangi iki ardışık darbe yeterli zaman aralığı ile ayrılır, böylece bir sonraki darbe yalnızca önceki darbe alındıktan sonra iletilir. 400 kHz mertebesinde Darbe Tekrarlama Frekansı (PRF) piyasada mevcut tarayıcılar yardımıyla mümkündür. Bu sensörlerde kullanılan en yaygın tarama mekanizması zikzak veya paralel çizgi desenleridir.


Tek darbeli LiDAR durumunda, darbeler arasında ayırım yapmak için bir yöntem olmadığından darbeler sırayla iletilir. Bu, PRF'yi ve uçuş irtifasını sınırlamaktadır. Dolayısıyla, Hava Teknolojisinde Çoklu Darbeler veya MPiA, havadaki LiDAR sisteminin önceki darbenin dönüş dalga biçimini almadan önce ikinci lazer darbesini ateşlemesine izin vererek, herhangi bir irtifada darbe hızının iki katına çıkmasına neden olan sistemler olarak kullanılmaktadır.

Tam dalga biçimi sayısalıştırması (FWD) durumunda, dönüş dalga biçimi kısa zaman aralıklarında tamamen sayısalıştırılır. Bu nedenle, tekli veya çoklu dönüşlerin aksine, bir ayak izinin tüm derinliğinde geri saçılan yüzeylerin özelliđi tam dalga biçiminde yakalanır. Daha sonra Gauss Ayırışımı gibi teknikler kullanılarak ayak izi içindeki önemli geri saçılım yüzeylerini belirlemek mümkündür.

Çok spektral LiDAR (MSL) sensörlerinde, dönüş darbesinin yoğunluğu, görüntülerde olduđu gibi, LiDAR verilerinin sınıflandırılmasına yardımcı olabilmektedir. Bu nedenle, aynı şey, farklı aralıklar ve açılar için geri dönüş yoğunluğunun normalleştirilmesi çalışmaları da dahil olmak üzere çeşitli arařtırmacılar tarafından geniş çapta arařtırılmıştır. Ancak, yalnızca tek bir dalga boyuyla (dar bant genişliğiyle) sınıflandırma dođruluđu sınırlıdır. Çok spektral LiDAR durumunda, 532 nm, 1064 nm ve 1550 nm dalga boyları şeklinde üç bağımsız darbe yayılımı gerçekleştirilir.

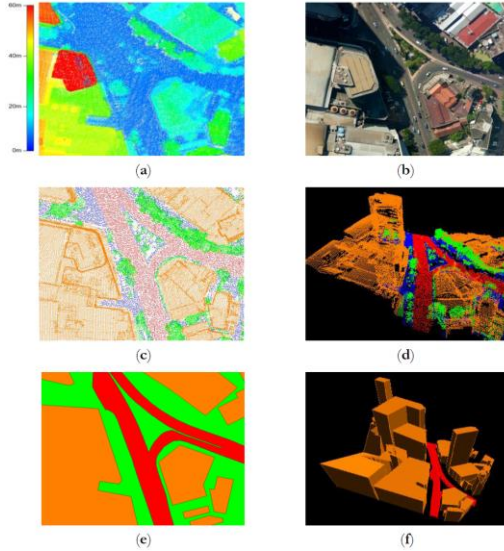
Geiger Modu LiDAR (GML) ve Tek Foton LiDAR (SPL) teknolojileri Harris Corporations ve SigmaSpace olmak üzere iki farklı şirket tarafından desteklenmektedir. Doğrusal Mod LiDAR'ın aksine, hem GML hem de SPL, dönüş lazerinin birkaç fotonunu bile algılanarak mesafeyi ölçebilir. Bu sistemlerde, bir lazer darbesi birden fazla darbeye bölünür. Her saniyede yaklaşık 60.000 darbe seti üretilir, böylece her saniyede 6 milyon olası ölçüm yapılabilir. Tipik dairesel tarama modeli, yüksek binaların çevresinde tam kapsama sağlar ve böylece verilerdeki gölge varlığı en aza indirilir. Bu sensörlerin ana avantajı, LML durumunda mümkün olmayan 2000 m ile 10000 m arasında uçuş yüksekliklerinde oldukça yoğun nokta bulutu oluřturmasıdır.

Farklı sensör tipleri tarafından üretilen LiDAR verileri temel olarak, nokta koordinatı (X, Y, Z), dönüş yoğunluğu (I), eş zamanlı olarak her bir noktaya karşılık gelen ilgili renk bilgisinden (R, G, B ve IR) oluşur. Bunun yanı sıra veriler, dönüş sayısı, bir darbe için dönüş sayısı, tarama açısı, veri noktasıyla ilişkili arazi örtüsü sınıfı vb. bilgiler de içerir. Verilerle ilgili tüm bu bilgiler \*.las dosya biçiminde saklanır. LiDAR verilerine bir örnek Şekil 2.8'de gösterilmektedir (Lohani ve Ghosh, 2017).



**Şekil 2.8.** LiDAR veri örneği; a) Yüksekliğe göre renklendirilmiş nokta bulutu, b) yoğunluk görüntüsü

LiDAR, fotogrametri, uzaktan algılama ve bilgisayarla görme camiasında başlıca veri toplama tekniklerinden biri olarak kabul edilmektedir. Bir LiDAR sistemi, topografik yüzeyi temsil eden doğru ve yoğun 3B LiDAR nokta bulutlarını elde edebilmektedir. LiDAR sistemlerinin temel gücü, üretilen sinyalin bitki örtüsündeki küçük boşluklara ve yüzeyin üzerindeki diğer yarı saydam nesnelere nüfuz edebilmesidir. LiDAR nokta bulutlarının genellikle 2.5B geometrik yapıya sahip olduğu düşünülür (Su vd., 2016) ve genel olarak RGB renk bilgisi içermez. Şekil 2.9, aynı alan üzerinde farklı coğrafi verilerden LiDAR nokta bulutu, orto görüntü ve bunlara karşılık gelen 1/1000 ölçekli temel haritayı içermektedir.




**Şekil 2.9.** Aynı kentsel alanı içeren farklı coğrafi verilerin görselleştirilmesi; a) yüksekliğe göre renkli LiDAR nokta bulutu, b) orto görüntü, c) nesne sınıflandırılmış LiDAR nokta bulutu, d) nesne sınıflandırılmış 3B LiDAR nokta bulutu, e) 1/1000 ölçekli temel harita, f) 1/1000 ölçekli 3B bina ve yol haritası (Widyaningrum, 2021)

Hava fotoğrafları ile karşılaştırıldığında, LiDAR nokta bulutlarının keskin kenarları temsil etmede sınırlamaları olabilmektedir. Bunun nedeni, genel olarak lazerin her zaman kenarları boyunca bir nesneye tam olarak çarpmamasıdır. Ancak, LiDAR gölgeden bağımsız olduğu ve distorsiyonu olmadığı için bina çıkarımı için hava görüntülerine göre daha üstün kabul edilmektedir (Yu vd., 2010). Geleneksel 2B görüntülerle karşılaştırıldığında, 3B LiDAR nokta bulutları, nesnelere ve ortamları analiz etmek için önemli ölçüde daha zengin geometrik bilgi ve ipuçları sağlama yeteneğine sahiptir (Lin vd., 2019; Vosselman vd., 2005). Bununla birlikte, LiDAR nokta bulutları, hava görüntülerine kıyasla nesne yüzeyi ile ilgili sınırlı yansıtma özelliklerine sahiptir (Widyaningrum, 2021).

## **2.7 Nokta Bulutu Üretim Yöntemleri**

Nokta bulutu, nesnelere temsil eden noktalardan oluşan veri kümeleridir. Üç boyutlu bir koordinat sisteminde, genellikle X, Y ve Z koordinatları tarafından tanımlanır ve genellikle bir nesnenin dış yüzeyini temsil etmek için tasarlanmıştır.

Coğrafi bilgi sistemlerinde nokta bulutları, arazinin dijital yükseklik modelini üretmek için kullanılan kaynaklardan biridir. Ayrıca, kentsel ortamların 3B modellerini üretmek ve köprü, yol vb. detayların 3B modellemek için kullanılır (Şekil 2.10).




**Şekil 2.10.** Nokta bulutundan detay çıkarımı (URL-2, 2022)

Literatürde yaygın olarak üretilen ve kullanılan nokta bulutları, fotogrametrik görüntülerden eşleştirme yöntemiyle üretilebileceği gibi, LiDAR sistemleri ile direkt olarak da elde edilebilmektedir.

### 2.7.1 LiDAR teknolojisi ile nokta bulutu üretimi

LiDAR teknolojisi ile nokta bulutu üretimi, optik bir sinyal (pulse) olan lazerin üretilmesi ve gönderimi ile başlar. Sinyal bir nesneye çarparak geri yansır ve alıcıya geri döner. Bazı sinyaller için birden fazla dönüş olur. Dönen her sinyalin şiddeti (intensity, nesnenin sinyali ne kadar geri yansıttığı) kaydedilir. Alıcı sinyalin seyahat süresini hassas bir şekilde ölçer. Işığın hızı bilindiğinden seyahat süresi mesafeye çevrilir. Mesafe, lazerin tarama açısı, lazerin konumu (GPS) ve yöneltmesi (IMU) bilindiğinden, her bir lazer sinyali için doğru X, Y, Z yer koordinatları (nokta bulutu) hesaplanır. Bu arada eğer istenilirse, proje alanının sayısal fotoğrafı veya video görüntüsü de çekilir. Nokta bulutu bir dizi işlemlerden geçirilerek kaba hatalar ayklanır ve filtreleme gibi işlemlerle veri değerlendirilerek istenilen sonuç ürün elde edilir. Şekil 2.11’de de görüldüğü üzere Pittsburgh bölgesine ait üç boyutlu nokta


bilgileri (saniyede yüz binlerce nokta) diziler şeklinde yüksek doğrulukta ölçülmüştür. Bu nokta bulutları, plan, profil, üçgen model, yükseklik eğrilerine dönüştürülebilir.



Şekil 2.11. LiDAR nokta bulutu- Pittsburgh (URL-1, 2022)


### 2.7.2 Görüntülerden eşleştirme ile nokta bulutu üretimi

Görüntü eşleştirme kavramı, Dijital Fotogrametri, Uzaktan Algılama, Görüntü İşleme ve Bilgisayarla Görme gibi alanların en önemli ortak konularından biridir. Analog fotoğrafların yerini dijital fotoğrafların alması, obje konumlarının dijital stereo görüntü çiftleri yardımı ile otomatik olarak belirlenebilmesine imkân tanımaktadır. Özellikle fotogrametri ve uzaktan algılamada, stereo değerlendirme ile üç boyutlu konum bilgisi üretimi ve görüntü uzayında koordinatın elde edilmesi amacıyla görüntü eşleştirme işlemi mutlaka yapılmalıdır. Görüntülerin eşleştirilebilmesi için, şekilde görüldüğü gibi detay noktalarının (feature points) stereo görüntüler üzerinde seçilmesi ve eşlenik noktaların optimum şekilde belirlenmesi gerekmektedir (Şekil 2.12).



**Şekil 2.12.** Stereo görüntüde eşlenik noktalar (Muja ve Lowe, 2012)

Fotogrametrik uygulamalar için geliştirilmiş ticari ya da akademik programlar yardımı ile eşlenik noktalar yarı manuel olarak seçilirken, detay çıkarım algoritmaları ile eşlenik noktaların otomatik olarak elde edilebilmesi mümkün kılınmıştır. Algoritmalar ile otomatik olarak çıkarılan noktaların eşleştirilebilmesi için görüntülerde normalizasyon işlemi yapıp, her bir görüntünün aynı eksene paralel duruma getirilerek epipolar geometrinin oluşturulması gerekmektedir. Eşleşen noktalara bağımlı olarak oluşturulan Fundamental Matrix (Temel Dönüşüm Matrisi) ile stereo görüntü çiftlerinin normalizasyonu gerçekleştirilir ve epipolar çizgiler oluşturulur. Oluşturulan epipolar geometri ile gerçek eşlenik noktalar epipolar düzlem üzerinden bulunarak yanlış eşleşmeler giderilir (Şekil 2.13).




**Şekil 2.13.** Epipolar eşleştirme; a) sol resim, b) sağ resim (Egels ve Kasser, 2001)

Günümüzde değişik algılama sistem ve yöntemlerle üretilmekte olan 3B nokta bulutları, bina, ağaç ve enerji nakil hattı çıkarımı, yol ve kaldırım tespiti, şehir modeli oluşturma gibi alanlarda yaygın olarak kullanılmakta olan bir veridir (Acar vd., 2019; Akbulut vd., 2018; Weinmann vd., 2015).

LiDAR algılayıcılar nokta bulutlarını doğrudan üretirken, fotogrametrik görüntülerden nokta bulutu üretilmesi için eşleme algoritmaları mutlak gereklidir. Bu algoritmalarından Yarı Global Eşleme (SGM) fotogrametri alanında yaygın olarak kullanılan stereo eşleme algoritmasıdır. SGM, iç ve dış yöneltme elemanları bilinen resim çiftlerinin, epipolar geometri ile piksel tabanlı olarak eşlenik noktaların bulunarak 3B koordinatlarının üçgenleme ile hesaplanması temeline dayanmaktadır (Hirschmüller, 2008, 2011; Huang vd., 2020). SGM, radyometrik değişimlerden ve belirlenen parametrelerden bağımsız bir biçimde eşleştirme yapabilmektedir (Hirschmüller, 2008). SGM, Şekil 2.14'de gösterildiği gibi görüntü boyunca her bir piksel ile buluşan 8 yoldan ilerler ve (13) numaralı maliyet fonksiyonunu kullanarak 1B optimizasyon gerçekleştirir (Acar vd., 2019; Hirschmüller, 2011).


$$E(D) = \sum_p \left( C(p, D_p) + \sum_{q \in N_p} P_1 T[|D_p - D_q| = 1] + \sum_{q \in N_p} P_2 T[|D_p - D_q| > 1] \right) \quad (13)$$

Burada,  $E(D)$  derinlik haritası  $D$ 'ye bağlı olarak hesaplanan enerjiyi ve  $C(p, D_p)$  tüm  $p$  pikselleri için  $D$ 'ye bağlı olarak eşleştirme maliyetini tanımlamaktadır (Acar vd., 2019; Hirschmüller, 2011). Her bir piksel ve eşleşme için 8 yoldan elde edilen maliyetler toplanır ve en küçük maliyete sahip olan yol tercih edilir (Acar vd., 2019; Hirschmüller, 2011; Huang vd., 2020).



**Şekil 2.14.** 8 yönlü optimizasyon yolu ile en doğru eşleşme (Hirschmüller, 2011)

SGM algoritması için gerekli epipolar geometri (Şekil 2.15), resim çiftlerinden eşlenik noktaların bulunması için kullanılan, resim çifti arasındaki projektif geometridir. Resim çifti arasındaki epipolar geometri, eksen olarak taban çizgisine sahip olan düzlem çizgisi ile görüntü düzlemleri kesişimi geometrisidir. Objeye ait geometriden bağımsız olup yalnızca kamera iç yönelme parametrelerine ve bağlı konumuna bağlıdır (Hartley ve Zisserman, 2004).



**Şekil 2.15.** Nokta eşleme ve epipolar geometri (Hartley ve Zisserman, 2004)

## 2.8 Nokta Bulutundan Bina Detayı Çıkarma ve Düzenleme

Kentsel alanın önemli bileşeni olan binaların tanımlanması, çıkarılması ve düzenlenmesi, 3B Coğrafi Bilgi Sistemleri, kentsel temel coğrafi veri tabanı güncelleme, kentsel planlama, çevresel simülasyon, afet yönetimi, dijital haritalama, ulaşım planlaması, kadastral yönetim, turizm, mobil navigasyon, mirasın korunması, enerji çalışmaları ve telekomünikasyon ağ tasarımı gibi birçok uygulamada önemli konu haline gelmiştir (Mohammad Awrangjeb vd., 2018; Benciolini vd., 2018; R. Cao vd., 2017; Du vd., 2017; Gao vd., 2018; Guo vd., 2021; T. H. G. Tran vd., 2018; Zhixin Li, 2022). Yersel çalışmalar ile bina verilerinin elde edilmesi emek yoğun ve zaman alıcı bir işlemdir. Bina bilgi/veri güncellemeleri, özellikle gelişmekte olan ülkelerde şehirleşme hızına kıyasla daha yavaş gerçekleşmektedir. Çeşitli uygulama taleplerini karşılamak için hızlı, ekonomik ve doğru bina çıkarımı gereklidir. Bu manada, günümüzde uzaktan algılama verilerinden bina çıkarımı, hızlı, uygun maliyetli ve büyük ölçeklerde etkili olduğu için araştırmalarda özellikle dikkati çekmektedir (Guo vd., 2021; Kulawardhana vd., 2014; Lai vd., 2019; Reutebuch vd., 2005). Bununla birlikte, bina yapılarının karmaşıklığı ve çeşitliliğinin yanı sıra nokta bulutlarının seyrekliği ve gürültüsü nedeniyle hem geometrik düzenlilik hem de anlamsal bilgi ile bina modellerinin otomatik olarak yeniden yapılandırılması zorluk derecesini halen korumaya devam etmektedir (R. Cao vd., 2017; Haala ve Kada, 2010; Xiong vd., 2015; Zhixin Li, 2022). Takip eden bölümde çeşitli kaynaklardan elde edilen nokta bulutu verilerinden bina detayı çıkarımı ve düzenlenmesine ilişkin geleneksel ve güncel yöntemler ile çalışmada önerilen yöntem hakkında detaylı bilgi verilecektir.

### 2.8.1 Geleneksel yöntemler

Metodolojik olarak bina çıkarımı, belirli bir veri setini örtüşmeyen homojen bölgelere ayırma ve bu bölgelerdeki binaları tanıma olarak ifade edilebilir. Piksel ve geometrik yapı özelliklerine ve nesne tabanlı tanımlamaya dayalı olarak görüntü üzerinden çeşitli bina tanıma algoritmaları önerilmiştir. Piksel tabanlı sınıflandırma yöntemleri, temel olarak farklı spektral kanallardaki her pikselin özelliklerini analiz ederek piksellerden çok sayıda öznitelik çıkarır ve ardından sınıflandırma işlemi gerçekleştirilir. Tanıma doğruluğu seviyesi, temel olarak piksellerden çıkarılan özellikler ve kullanılan paralel yüzü, minimum mesafe, maksimum olasılık, sinir ağı, destek vektör makinesi, K-ortalama ve ISODATA kümeleme yöntemlerini içeren sınıflandırma yöntemleri ile

belirlenir (Guo vd., 2021). Piksel tabanlı yöntemlerin yanı sıra, binaların düzenliliğinden dolayı çıkarım için geometrik yapı uydurma da uygulanmıştır. Bir görüntüdeki binaların kenarları, köşeleri ve sınırları çıkarılabilir ve bir özellik modeli eşleştirilip tanımlanabilir. Geometrik özelliklere dayanarak, Brédif vd., SYM'den çokgen bina ayak izlerini çıkarmak için tam otomatik bir küresel optimizasyon çerçevesi sağlamışlardır (Brédif vd., 2013). Son zamanlarda nesne tabanlı bina tanımlama yöntemleri ortaya çıkmıştır. Bu süreçte, bir görüntü ilk önce çok ölçekli bölütleme kullanılarak doku, şekil ve spektral özellikleri içeren birden çok nesne parçasına bölünür. Daha sonra sınıflandırma işlemini tamamlamak için güvenilir bir yöntem seçilir. Baatz vd., spektral, doku ve bağlam özelliklerinin bir kombinasyonuna dayalı bir yöntem önermiş ve yüksek çözünürlüklü uzaktan algılama görüntüleri ile iyi sonuçlar elde etmiştir (Baatz ve Schape, 2000; Guo vd., 2021).

Günümüzde derin öğrenme teknikleri, yüksek doğruluk elde etmek için büyük miktarda özelliği otomatik olarak kullanabildikleri için yaygın olarak kullanılmaktadır (Abdollahi vd., 2020). Yapılan çalışmalar, derin öğrenmenin özellikle görüntülerden bina çıkarma doğruluğunu artırabileceğini göstermiştir. Yoğun yapılaşma alanında bu yöntemlerle tatmin edici bir sonuca ulaşmak oldukça zordur. 3B tarayıcıların geliştirilmesi ve nokta bulutu verilerinin kullanılabilirliği ile bina çıkarımı iyileştirilmiştir. Bu durum bina özelliklerini çıkarmak için nokta bulutlarının kullanılmasını özendirmiştir. Yaygın olarak kullanılan iki klasik yöntem vardır. Birincisi bölge büyütme tekniğini kullanırken, diğeri bir veri setindeki kenarları tespit ederek bölgeleri betimlemektedir (Dorninger ve Pfeifer, 2008; Vo vd., 2015). Sampath ve Shan, ham nokta bulutu verilerinden bina sınırlarını çıkarmak için bir dışbükey gövde algoritmasını değiştirmiş ve bina sınırlarını düzenlemek için hiyerarşik en küçük kareler analizi uygulamıştır (Sampath ve Shan, 2007). Model tabanlı bina çıkarma yöntemleri arasında sağlam bir yöntem RANSAC yaklaşımıdır (H. Li vd., 2018; Xu vd., 2017). Yüksek uzamsal çözünürlüklü LiDAR tabanlı 3B veri kümelerinin rutin ve sık elde edilmesinin önündeki maliyet ve lojistik engellerin üstesinden gelmek için fotogrametrik nokta bulutları kullanılabilir. Bu anlamda, SfM yöntemi geniş alanlara uygulanarak yüksek uzamsal çözünürlüklü 3B nokta bulutları üretilebilir. Özellikle, yoğun nokta bulutu oluşturma yöntemleri (yoğun görüntü eşleştirme), 3B modelleme ve haritalama, robotik, tıbbi görüntüleme, gözetim, izleme ve navigasyon gibi profesyonel ve amatör uygulamalar için giderek daha fazla

kullanılmaktadır. Bununla birlikte, gürültülü noktaların varlığından dolayı bina çıkarımı için fotogrametrik nokta bulutlarının güvenilirliğinin değerlendirilmesi önem arz etmektedir (Guo vd., 2021; Melo vd., 2020; Remondino vd., 2014).


Çok çeşitli bina yeniden çıkarım yöntemleri olmasına rağmen, temelde veriye dayalı (data driven) ve modele dayalı (model driven) olmak üzere iki farklı strateji kategorize edilmiştir. Veriye dayalı bina çıkarımı yöntemi, genellikle tek tek bina noktalarının bölge büyümesine göre düzlemsel yamalar halinde bölümlere ayrılmasıyla başlayan ve son yıllarda yaygın olan bir yaklaşımdır (Kwak ve Habib, 2014; Maalek vd., 2015; Nurunnabi vd., 2016; Oh vd., 2021; Rabbani, 2004). Parametrik yaklaşımlar olarak da bilinen model güdümlü strateji farklı araştırmacılar tarafından kullanılmıştır (Dehbi vd., 2021; Z. Li vd., 2020; Wenyuan Zhang vd., 2021; Zhixin Li, 2022).

Bina çıkarma yöntemleri, makine öğrenmesi yöntemleri ve klasik yöntemler olmak üzere iki kategoride sınıflandırılabilir. Makine öğrenmesi yöntemlerinde elde edilen ham veriler önce çok boyutlu bir özellik uzayına dönüştürülür. Ardından, özellikleri istenen çıktılarla eşleştirmek için bir öğrenme sınıflandırıcısı tarafından optimal bir özellik alanı tahmin edilir (Maltezos vd., 2019). Örnek olarak Ni vd., (2019) ilk olarak düzlemsel, pürüzsüz ve pürüzlü yüzeyler dahil olmak üzere üç çeşit parçayı çıkarmak için aşamalı bir nokta bulutu bölütleme yöntemi önermiştir (Ni vd., 2017). Rastgele Orman (RF) daha sonra öznelikleri seçmek ve yukarıda bahsedilen bölümleri sınıflandırmak için kullanılmıştır. Zhang vd., (2020), binaları yüksek çözünürlüklü görüntülerden ve LiDAR verilerinden çıkarmak için yeni bir hibrit füzyon mimarisine dayalı hibrit bir füzyon ağı geliştirmiştir (P. Zhang vd., 2020). Wen vd., (2021) önce bir grafik evrişim modülü önermiştir, bu modül, tüm noktalar arasındaki uzamsal ilişkiyi inceleyebilir ve evrişim ağırlıklarını belirleyebilir (Wen vd., 2021). Ardından, nokta bulutlarının çok ölçekli özelliklerini kullanarak havadaki nokta bulutlarını sınıflandırmak için küresel-yerel bir grafik CNN tasarlanmıştır. Zolanvari vd., (2020), eğitim ve test için halka açık bir açıklama veri seti sağlayarak, PointNet, PointNet++ ve SO-Net dahil olmak üzere iyi bilinen üç CNN modelini kıyaslamada test etmişlerdir (Hui vd., 2021; Iman Zolanvari vd., 2020). Makine öğrenimi yöntemleri bina çıkarımını gerçekleştirebilmelerine rağmen bu yöntemler bazı sınırlamalar içermektedir. Örneğin, yüksek kaliteli eğitim verileri gereklidir ve eğitim verileri ile deney verileri arasındaki veri dağılımındaki farklılıklar düşük doğruluğa yol açmaktadır (Hui vd., 2021; Ywata vd., 2021).

Yalnızca LiDAR verilerini kullanan bina çıkarma yöntemleri, iyi çıkarma sonuçları elde edebilmesine rağmen, bu yöntemlerin bazı pratik sınırlamaları mevcuttur. Örneğin, LiDAR sistemi tarafından yayılan lazer darbeleri genellikle belirli bir eğim açısına sahiptir ve bu da bazı alanlarda noktaların olmamasına neden olur. Bu veri boşlukları eksik bina çıkarımına neden olmaktadır. LiDAR verileri doğru üç boyutlu koordinatlar sağlamasına rağmen, özel şekillere sahip binaları tanımlamak için çok önemli olan doku bilgisinden yoksundur (Zhou ve Zhou, 2014). Bu sınırlamaların üstesinden gelmek için, bazı yazarlar yüksek doğruluk elde etmek için çok kaynaklı verileri entegre biçimde kullanmışlardır. Awrangjeb vd., (2012), LiDAR verilerini ve çok bantlı orto görüntüleri birleştirerek otomatik bir üç boyutlu çatı çıkarma yöntemi önermiştir (M. Awrangjeb vd., 2012). Qin vd., (2014), yüksek çözünürlüklü uzaktan algılanan görüntüyü ve SYM'yi birleştirmiştir (Qin ve Fang, 2014). Gilani vd., (2016) binaları çıkarmak ve düzenlemek için nokta bulutu ve orto görüntüden gelen özellikleri kullanan bir metodoloji geliştirmiştir (Gilani vd., 2016). Siddiqui vd., (2016), LiDAR yükseklik bilgisini yoğunluğa dönüştürerek görüntüdeki gradyan bilgisini analiz etmiştir. Ek olarak, ağaçları ortadan kaldırmak için bir işlem sonrası adım olarak yerel bir renk eşleştirme yaklaşımı tanıtılmıştır (Siddiqui vd., 2016). Lai vd., (2019) nokta bulutu ve doku özelliklerini birleştirerek bir bina çıkarma yöntemi önermiştir (Lai vd., 2019). Chen vd., (2020) ayrıca yüksek uzamsal çözünürlüklü görüntüleri ve LiDAR nokta bulutu verilerini entegre etmiştir (S. Chen vd., 2020; Hui vd., 2021).

### **2.8.2 Octree (Sekizdal) metodu**

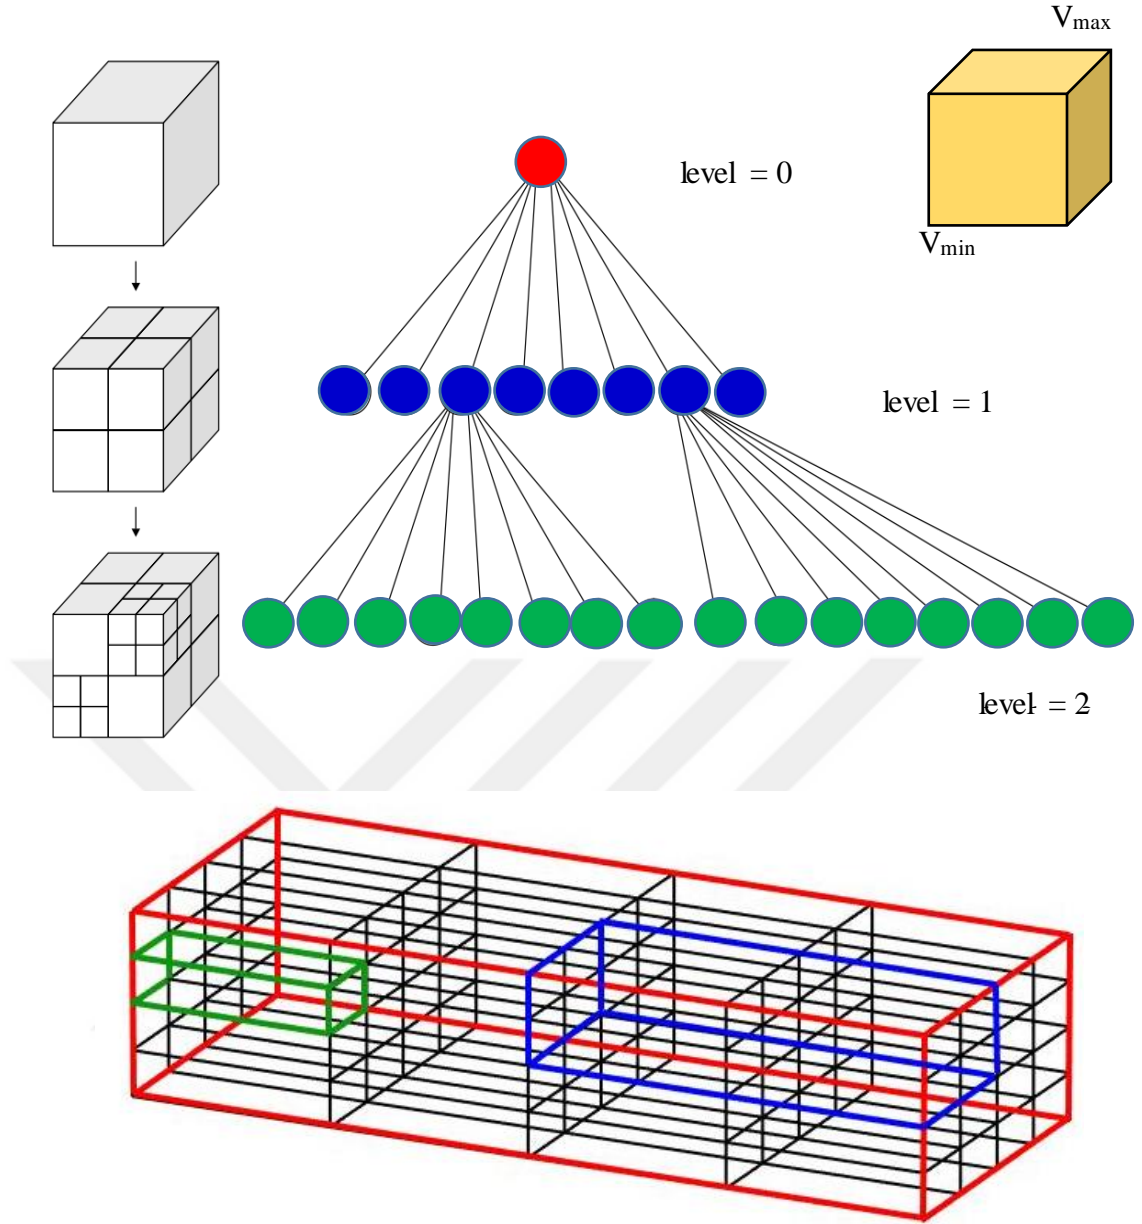
Tez çalışmasında önerilen yöntemin temelini oluşturan Octree (sekizdal) yöntemi, girdi olarak kullanılan verilerin sekize bölünerek indeksli düzende oluşmasını sağlayan bir vokselleme yöntemidir ve 3B nokta bulutlarının uzamsal bölünmesi için yaygın olarak kullanılır. Voksel kavramı, 3B nokta bulutlarında (fotogrametrik veya LiDAR) eşit hacim ve büyüklüklere sahip prizmatik şekilleri temsil etmektedir. Eğer oluşturulan vokseller 2B konumsal uzayda incelenirse ızgara biçiminde eşit dörtgenler (pikseller) oluşmaktadır (Şekil 2.16).



**Şekil 2.16.** Octree ile oluşturulan eşit 2B ve 3B vokseller

Şekil 2.16’da gösterilen 2B şekilde dikdörtgen biçiminde oluşan şekiller verinin türüne göre kare şekle benzeyebilmekte iken, 3B şekildeki dikdörtgen prizma olarak gösterilen vokseller kübik şekilde de oluşabilmektedir. Ancak her iki durumda da oluşturulacak vokseller hacim, alan ve kenar uzunlukları bakımında birbirine eşittir.

Sekiz dallı ağaç olarak adlandırılan Octree yapısı başlangıçta girdi olarak kullanılan tüm nokta bulutunu tek bir prizma olarak tanımlamaktadır. Daha sonra her adımda alt seviyelere indikçe, tek bir prizma olarak tanımlanan kök hücre sekiz eşit parçaya bölünmektedir. Her aşamada, bir üst kademedeki bölünen bu sekiz adet hücre “oktan” olarak adlandırılır. Bu hücrelerin her biri için bir alt bölünmede 8 adet oktan oluşturulur. Belirlenen derinlik sayısına göre en son ortaya çıkan en küçük yapıdaki prizmalar ise voksel olarak adlandırılmaktadır (Dybedal vd., 2019). Octree yapısındaki sekize bölünerek üretilen voksel yapısı Şekil 2.17’de gösterilmektedir.



Şekil 2.17. Octree hiyerarşik yapısı

Şekil 2.17’de gösterilen Octree hiyerarşik yapısında kök hücre (level 0) kırmızı renkli çizgi ile temsil edilmektedir. Kök hücrenin bölünmesiyle level 1’de oluşturulan prizmalar/küpler mavi renk ile gösterilmektedir. Sekizli ağaç yapısının en sonunda oluşan level 2’deki prizmalar (vokseller) ise yeşil renk ile temsil edilmektedir. Octree yöntemi için oluşturulacak voksellerin derinlikleri “*max Depth*” değişkeni ile belirlenmektedir. Şekil 2.17’deki gibi level 2’ye kadar bölünmenin devam etmesi için “*max Depth*” değişkenininin 3 olarak alınması gerekmektedir. Bu şekilde gösterilen sarı küp Octree yaprak düğümünün özelliğini göstermektedir. Octree algoritması çalıştırıldığında oluşan her bir prizmanın  $V_{min}$  ve  $V_{max}$  noktaları otomatik bir şekilde

tespit edilir. Bu noktaların koordinat ve yükseklik değerleri algoritma ile tutulmaktadır.


Şekil 2.17'deki örneğe göre Octree algoritması level 0'da 1 adet, level 1'de 8 adet, level 2'de 64 adet olacak şekilde toplam 73 adet dörtgen prizma oluşturur. Derinlik arttıkça sekizli ağaç yapısı dallanmaya devam edeceği için bu sayılar sekize katlanarak devam edecektir. Dörtgen prizmaların (voksellerin) numaralandırılmış hali Şekil 2.18'de gösterilmiştir. Voksel sayısının artışı aşağıdaki şekildedir:

Level 0 =  $2^0 = 1$  adet dörtgen prizma (kök hücre)

Level 1 =  $2^3 = 8$  adet dörtgen prizma

Level 2 =  $2^6 = 64$  adet dörtgen prizma

Level 3 =  $2^9 = 512$  adet dörtgen prizma



Şekil 2.18. Octree voksel numaralandırma

Şekil 2.18'de gösterilen her bir voksel en alt seviyedeki (örnek için level 2) dörtgen prizmaları temsil etmektedir. Numaralandırma level 0 ve level 1'de oluşan toplam 9 adet dörtgen prizmalardan dolayı 10'dan başlayarak 73'e kadar ilerlediği görülmektedir.

Octree ağaç yapısında en alt kısımda bulunan yaprak hücre olarak adlandırılan voksellerin içinde herhangi bir nokta bulunmaz ise ilgili hücre boş olarak görülmektedir. Bölünmenin son seviyesinde, içerisinde nokta bulunan hücreler (vokseller) octree yapısındaki yaprakları temsil etmektedir (Lohmann, 1998).

### 2.8.3 DBSCAN kümeleme metodu

Parametrik olmayan yoğunluk tabanlı bir kümeleme tekniği olan DBSCAN (Density-Based Spatial Clustering of Applications with Noise) algoritması (Ester vd., 1996), son yıllarda basitliği, farklı boyut ve şekillerde kümeleri tespit etme gibi özelliklerinden dolayı birçok alanda yaygın olarak kullanılmaktadır. Bu algoritmanın ana fikri, bir noktanın o kümedeki birçok noktaya yakın olduğunda hangi kümeye ait olduğunu belirlemektir. DBSCAN, bir veri kümesinde mevcut olan gruplar hakkında herhangi bir ön bilgi olmaksızın karşılaştırılabilir bir yoğunluğa sahip olduklarında doğal kümeleri ve bunların veri alanı içindeki düzenlemelerini bulmak için iyi bir adaydır (T. N. Tran vd., 2013). DBSCAN algoritması uzamsal veri türleri için, nesne grupları nispeten iyi ayrılmıştır, ancak diğer veri türleri için bu her zaman böyle değildir. Bitişik kümelerin sınır nesnelere algılandığında algoritma kararsız hale gelir. Ester ve arkadaşları bu konuyu bir dezavantaj olarak kabul etmişlerdir (T. N. Tran vd., 2013). DBSCAN algoritmasının çalışma prensibi Şekil 2.19'da gösterilmiştir. Algoritmanın temel parametreleri şunlardır:


**Epsilon ( $\epsilon$ ):** Bir veri nesnesinin komşularını belirlemek için gerekli olan yakınlık mesafesidir. Kümeleri belirten yarıçap mesafesidir. Aralarındaki mesafe epsilon'dan küçük iki nokta komşu olarak kabul edilir.

**MinPts:** Bir bölgenin yoğun olarak adlandırılabilmesi için epsilon komşuluğunda bulunması gereken en az komşu nokta sayısıdır. Diğer bir tanımla bir kümeyi tanımlamak için gereken minimum nokta sayısıdır. Bu iki parametre ve komşuluk bölgesindeki nesnelere sayısını göz önünde bulundurarak çekirdek (core) nokta, sınır (border) nokta ve gürültü (aykırı değer) olarak üç tür nesne ayrıtılır.

**Çekirdek nokta (core):** Çevresinde en az *MinPts* kadar nokta (noktanın kendisi dâhil) varsa, ilgili nokta çekirdek (core point) noktadır. Yani *epsilon* yarıçapı ile oluşturulacak kümenin içinde en az *Minpts* kadar nokta bulunuyorsa bu noktalar çekirdek nokta olarak tanımlanır.

**Sınır noktası (border):** Çekirdek noktanın dışında herhangi bir noktaya rastgele bir çekirdek noktadan erişim sağlanabiliyorsa ve bu noktanın oluşturacağı *epsilon* yarıçapındaki çemberin içinde *Minpts* değerinden daha az nokta bulunuyorsa bu nokta sınır noktası olarak tanımlanır.

**Gürültü (noise) noktası:** Nokta bulutundaki herhangi bir nokta, çekirdek nokta niteliğine sahip olmazsa ve herhangi bir çekirdek noktadan erişim sağlanamıyorsa (sınır noktası) ilgili nokta gürültü (aykırı) nokta olarak tanımlanır.



Şekil 2.19. DBSCAN algoritması çalışma prensibi

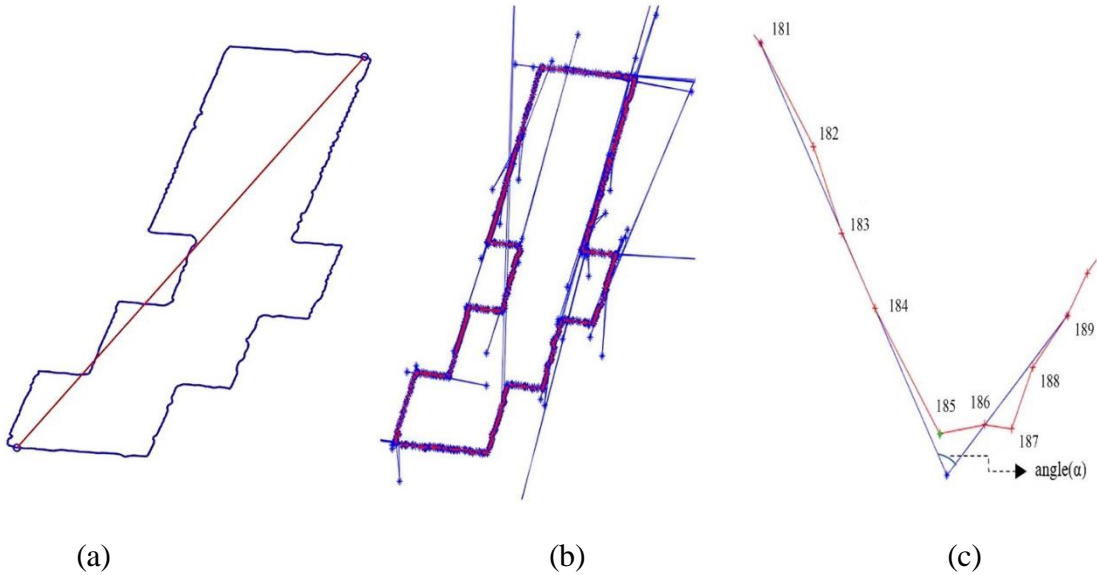
Şekil 2.19'daki çekirdek noktaların oluşturduğu epsilon yarıçapındaki çemberlerde görüldüğü üzere içinde noktanın kendisi dâhil en az *Minpts* değeri kadar nokta bulunduğu zaman ilgili nokta çekirdek noktası olarak tanımlanırken, çekirdek nokta özelliği göstermediği halde komşuluk ilişkisi bulunan noktalar ise sınır noktası olarak tanımlanmaktadır. Çekirdek nokta ve sınır noktaları birbirine olan komşuluk ilişkisine göre ortak bir kümeye atanır. Eğer N kümesinde gösterildiği gibi ilgili nokta herhangi bir çember (küme) ile komşuluk ilişkisi gerçekleştiremiyorsa bu nokta gürültü olarak ayrı bir kümeye atanır (Ester vd., 1996; T. N. Tran vd., 2013).

DBSCAN kümeleme algoritmasının, küme sayısına ihtiyaç duymaması, rastgele şekil kümeleriyle iyi performans göstermesi, aykırı değerlere karşı sağlam ve algılayabilir olması avantajı olarak değerlendirilirken, bazı durumlarda, uygun bir *Epsilon* mesafesinin belirlenememesi, belirlenen *Epsilon* ve *Minpts* parametreleri bütün veri

setleri için doğru cevabı üretememesi algoritmanın dezavantajı olarak ön plana çıkmaktadır.

#### 2.8.4 Bina kenarlarını düzgünleştirme metodu (ABORE)

Literatüre henüz girmiş olan ABORE (Automatic Building Outline Regularization) yöntemi (Ozdemir vd., 2021), herhangi bir ek veriye ihtiyaç duymadan sadece ham LiDAR nokta bulutu verisinden bina kenarlarını düzgünleştirmeyi sağlamaktadır. ABORE yöntemi iki aşamadan oluşmaktadır. İlk aşamada ele alınan bina “*boundary*” fonksiyonu yardımıyla dış sınırı çevrilir (Şekil 2.20a). Bu aşamada çıkarılan düzensiz bina sınır noktaları kullanılarak her bir sınır noktasının öncesinde ve sonrasında bulunan noktalardan doğru geçirilir (Şekil 2.20b ve 2.20c). Bu doğrular arasındaki açı ve doğruların kesişim noktaları otomatik olarak belirlenir. Bu aşamada, tüm sınır noktaları için otomatik olarak her bir sınır noktasına ait açı ve kesişim noktası hesaplanır. Binaların köşe noktalarını belirlemek için hesaplanan açı değerleri bir koşullandırma işlemine tâbi tutulur. ABORE yönteminin ortogonal şekilde bir binada köşe noktası olabilecek aday noktaları için belirlediği açı tolerans miktarı eşitlik (14)’de verilmektedir. ABORE yöntemine göre, belirlenen açı koşulu dik kenarlı binalarda her bir iç açının  $90^\circ$  ve  $270^\circ$  dereceye yakın olması gerekmektedir.



Şekil 2.20. “Boundary” ile sınır çizimi, ABORE açı ve kesişim koordinatları

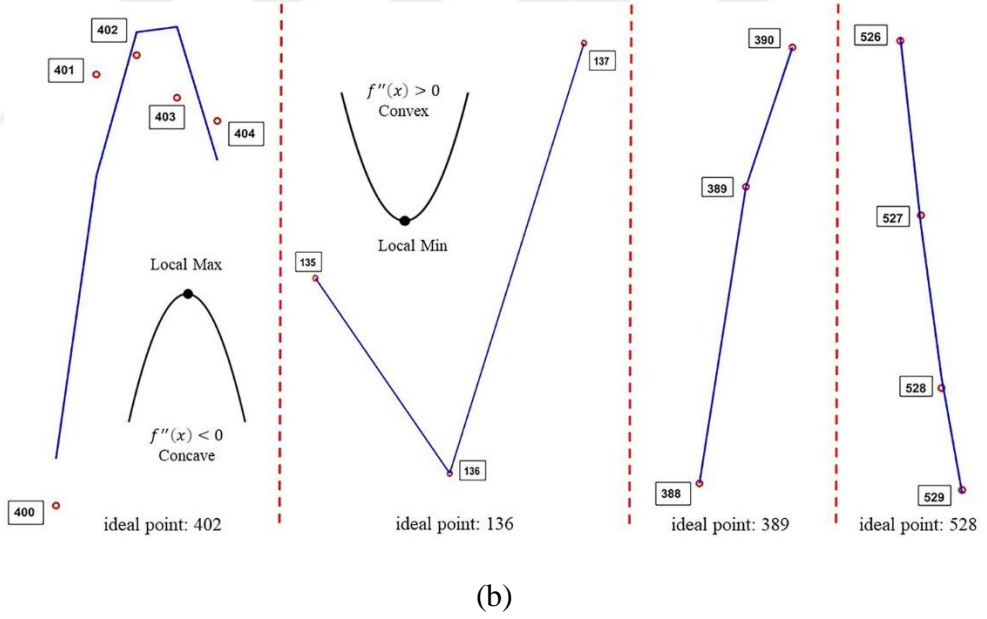
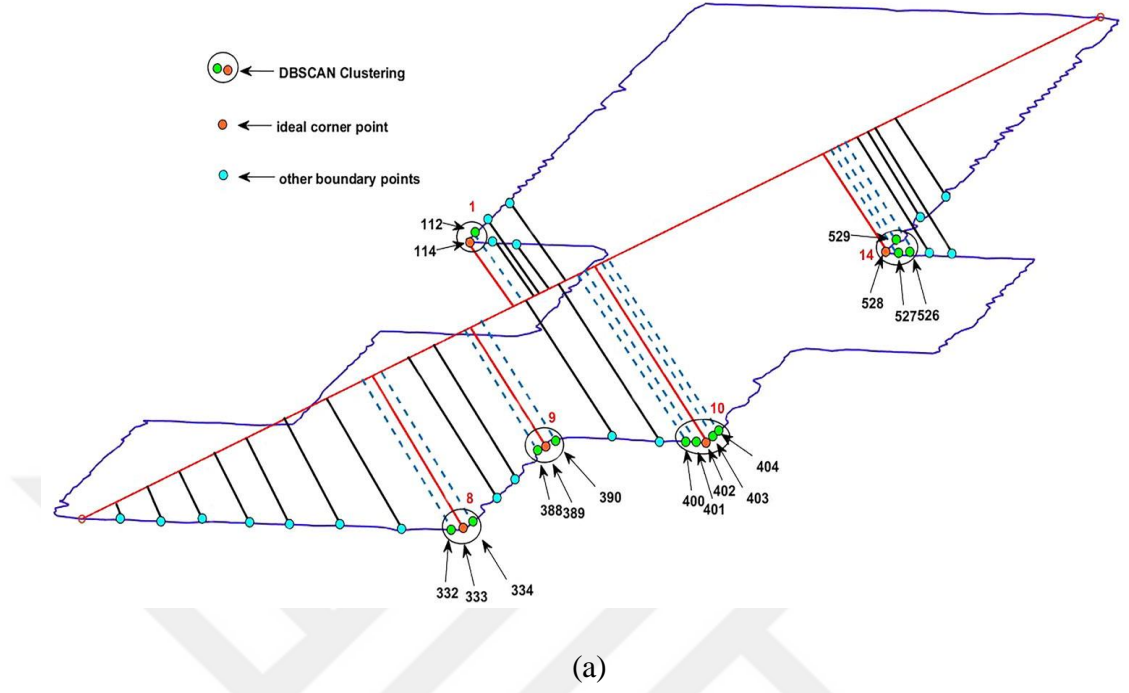
Şekil 2.20a “*boundary*” fonksiyonu ile üretilen düzensiz bina sınırını temsil etmektedir ve kırmızı çizgi en uzun mesafeli iki noktanın birleştirilmesinden oluşmaktadır. Şekil 2.20b tüm noktalarda hesaplanan açı ve kesişim koordinatı, Şekil 2.20c ise tek bir noktada hesaplanan açı ve kesişim koordinatını temsil etmektedir. Yeşil işaretli 185 numaralı nokta işlenecek noktayı temsil eder. Kırmızı işaretli noktalar ise öncesinde ve sonrasında bulunan diğer sınır noktalarını temsil etmektedir. 186-189 ve 181-184 arasından birer doğru geçirilir ve kesişim noktası hesaplanır. Şekildeki “*angle*” kısmı bu iki doğru arasında açığı gösterir ve bu binanın iç tarafını gösterecek şekilde semt açısı farklarından yararlanılarak hesaplanır. Bu iki doğrunun kesişimi ise kesişim koordinatı olarak arka planda tutulmaktadır.

$$find((angle > 70^\circ \& angle < 110^\circ) | (angle > 250^\circ \& angle < 290^\circ)) \quad (14)$$

Açı koşuluna uyan noktalar ayrı bir değışkende tutulur. Bu noktalar aslında bina köşe noktası olabilecek aday noktaları temsil etmektedir. Ayrıca herhangi bir köşe için birden fazla aday nokta oluşabilir (Şekil 2.21a). Bu durum için DBSCAN algoritması ile aday köşe noktaları kümelmesi sağlanır ve her bir kümenin içerisindeki noktalardan ikinci dereceden bir eğri geçirilerek konveks, konkav, sürekli artan ve azalan kümeler belirlenir. Bu dört koşul ile aday köşe noktaları arasından en uygun bina köşe noktası belirlenir (Şekil 2.21b). Elde edilen köşe noktalarının sınır koordinatları yerine başlangıç aşamasında hesaplanan kesişim koordinatları kullanılır. Bu şekilde “*boundary*” fonksiyonu ile elde edilen sınır noktaları üzerinden işlemler yapılırken, sonuç çıktısında ABORE yöntemine özgü oluşturulan kesişim koordinatları kullanılır. Bu sayede var olan noktalar dışında daha doğru bir köşe noktası tespit edebilmektedir (Şekil 2.21c).

ABORE yöntemi ilk bina köşe noktalarını tespit edildikten sonra ikinci bir düzenleme yoluna giderek daha kesin bir bina köşesi oluşturmaya çalışır. İlk aşama sonucu bulunan bina köşe noktalarından belirli genişlikte buffer zon geçirilir ve buffer içinde bulunan noktalardan regresyon denklemini kullanarak birinci dereceden eğri (doğru) fit edilir (Şekil 2.22a). Hesaplanan bu doğruların kesişim noktaları tespit edilir ve kesin bina köşe noktaları oluşturulur. Bu noktaları birleştirerek bina kenarının düzensiz sınırının ortogonal bir şekilde regülarizasyonunu sağlamaktadır (Şekil 2.22b). ABORE yöntemi ikinci aşamadaki düzenleme yöntemi ile bina kenarındaki

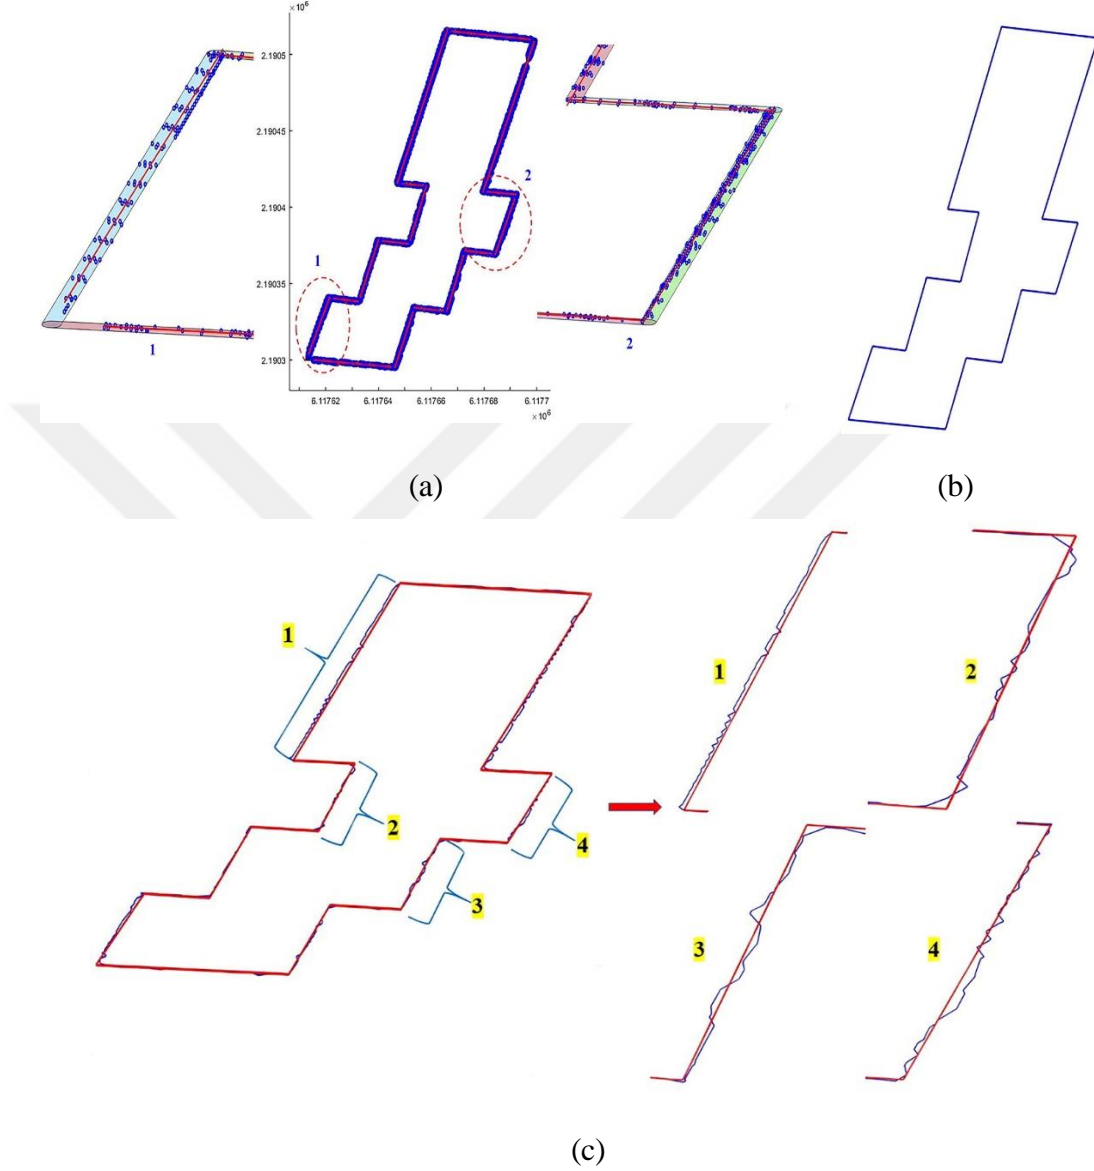
noktaları da işleme katarak daha kesin ve doğru bir köşe noktası tayin edebilmektedir (Ozdemir vd., 2021).



Şekil 2.21. İdeal köşe noktası belirleme koşulları

Şekil 2.21a açılış koşuluna uyan noktaların bina sınırı üzerindeki konumunu temsil etmektedir. DBSCAN algoritması ile kümelenecek aday köşe noktaları şekilde görülmektedir. Aday noktaların kırmızı doğruya olan öklid mesafelerine göre Şekil 2.21b'deki gibi dört sınıf belirlenir. Bu nokta kümelerinden ikinci dereceden eğri

geçirildiğinde oluşan bu şekillerden en ideal köşe noktaları ABORE yöntemi tarafından otomatik bir şekilde seçilir (Ozdemir vd., 2021).



**Şekil 2.22.** Buffer zon işlemleri ve bina regülarizasyonu

Şekil 2.22a her bir kenar için uygulanan buffer zon işlemlerini ve bu buffer içindeki noktalara uydurulan doğruları temsil etmektedir. Şekil 2.22b ABORE yönteminin iki aşamalı regülarizasyonu sürecinin sonuç çıktısını temsil etmektedir. Şekil 2.22c ise ABORE yönteminin düzenleme işlemine katkısını yakından analiz etmektedir (Ozdemir vd., 2021).

## 2.9 Nokta Bulutundan Zemin (Arazi Modeli) Çıkarım Yöntemleri

### 2.9.1 Aşamalı TIN yoğunlaştırma yöntemi

Klasik PTD (Aşamalı TIN Yoğunlaştırma) yöntemi (Axelsson, 2000) tarafından geliştirilmiştir. PTD yönteminin ana avantajları, iyi filtreleme performansı ve hesaplama verimliliğindedir. Klasik PTD yönteminde temel düşünce, belirli kriterlere göre seçilen tohum noktalarından (seed point) oluşturulan ilk TIN (Triangular Irregular Network)'i yinelemeli olarak yoğunlaştırmaktır. Birçok veri seti, dünya yüzeyinin çok üstünde veya altında olan ölçümler içerir ve bu ölçümlere aykırı değerler (gürültü) denir. Literatürde aykırı değerleri ortadan kaldırmak için üç alt adım tasarlanmıştır (J. Zhang ve Lin, 2013). İlk olarak yükseklik histogramı oluşturulup en düşük ve en yüksek olan noktaları elimine etmek için yükseklik eşiği belirlenir. İkinci olarak kalan aykırı değerler, her noktanın tüm komşularına göre minimum yükseklik farkı kullanılarak aranır. Komşu sorgusu 2B Kd-ağacı ile yapılır ve komşularına göre çok yüksek ve düşük olan noktalar veri setinden çıkarılır. Üçüncü olarak, otomatik olarak yapılan aykırı değer sınıflandırmasının verdiği hatalar manuel olarak düzeltilir. Klasik PTD yöntemi temel olarak parametre belirleme, tohum noktası seçimi ve TIN yapımı ve TIN'in yinelemeli yoğunlaştırılması dahil olmak üzere üç adımdan oluşur.

PTD'de önceden ayarlanması gereken altı temel parametre vardır. Bu parametreler aşağıda açıklanmıştır.

- **Maksimum bina büyüklüğü ( $m$ ):** Bir uzunluk eşiğidir ve algoritma bu değere kadar uzunluğa sahip binaları ele alabilir. Izgara hücre boyutunu tanımlamak için kullanılır.
- **Maksimum arazi açısı ( $t$ ):** Sınıflandırılmamış bir noktada yansıtma tekniğinin uygulanıp uygulanmadığına karar veren eğim eşiğidir. TIN'deki bir üçgenin eğimi  $t$ 'den büyükse, bu üçgenin içinde bulunan herhangi bir sınıflandırılmamış/potansiyel nokta, karşılık gelen bir ayna noktası ile değerlendirilmelidir.
- **Maksimum açı ( $\theta$ ):** Üçgen düzlemi ile potansiyel bir noktayı en yakın üçgen tepe noktasına bağlayan bir çizgi arasındaki maksimum açıdır. Sınıflandırılmamış bir nokta  $\theta$ 'dan daha büyük bir açıya sahipse, nesne ölçümü, aksi takdirde zemin ölçümü olarak etiketlenir.

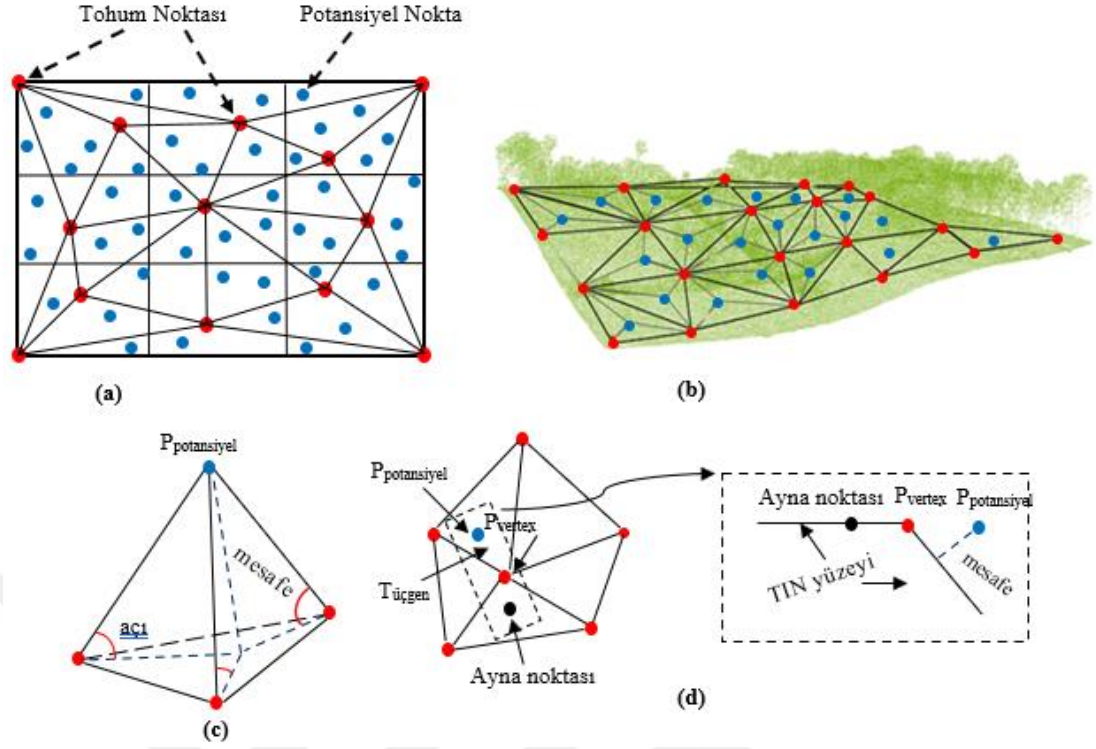
- **Maksimum mesafe ( $d$ ):** Bir yineleme sırasında bir noktadan üçgen düzleme olan maksimum mesafedir. Sınıflandırılmamış bir nokta  $d$ 'den daha büyük bir mesafeye sahipse, nesne ölçümü, aksi takdirde zemin ölçümü olarak etiketlenir.

- **Minimum kenar uzunluğu ( $l$ ):** TIN'deki herhangi bir üçgenin maksimum (yatay olarak yansıtılan) kenar uzunluğu için minimum eşiktir.

- **Maksimum kenar uzunluğu ( $l'$ ):** TIN'deki herhangi bir üçgenin minimum (yatay olarak yansıtılan) kenar uzunluğu için maksimum eşiktir. Ancak maksimum kenar uzunluğu parametresi, zemin noktalarını inceltmek için kullanılır ve filtreleme ile hiçbir ilişkisi olmayıp dikkate alınmasına gerek yoktur (J. Zhang ve Lin, 2013).

Veri kümesi için ızgara (grid) yapısı oluşturulur. PTD yöntemine göre her ızgara hücreindeki en düşük/alt nokta, tohum noktası (seed point) olarak seçilir (Şekil 2.23a ve 2.23b). İlave olarak veri kümesini sınırlayan dört köşe noktası tohum noktası olarak eklenmelidir ve bu dört köşenin yüksekliği yatay düzlemde gridlerden elde edilen tohum noktalarından birine eşit olmalıdır. Daha sonra bu tohum noktalarına dayalı olarak TIN oluşturulur ve bu aşama yalın arazi yüzeyini veya başlangıç arazi modelini temsil etmektedir. TIN oluşturduktan sonra tohum noktalar dışında kalan noktalar varsayılan nesne ölçümleri (yer üstü noktalar) olarak adlandırılır.

TIN'in yinelemeli yoğunlaştırılması, parametrelerin eşiklerine dayalı olarak tüm sınıflandırılmamış noktalar için bir karar sürecidir (Nie vd., 2017). Her yinelemede, ilgili noktanın iki temel parametresi, verilen eşik değerlerini aşmıyorsa sınıflandırılmamış bir nokta bir temel nokta olarak kabul edilecektir. Bu parametrelerden ilki, ilgili TIN yüzeyi ile noktayı yüzeye en yakın tepe noktasına bağlayan çizgi arasındaki açı, diğeri ise noktadan ilgili TIN yüzeyine olan mesafedir (Şekil 2.23c). Ek olarak, zemin noktalarını daha iyi ayırt etmek için yansıtma tekniği kullanılır. Sınıflandırılmamış bir noktanın ayna (mirror) noktası (Şekil 2.23d) potansiyel bir yer noktası olarak kabul edilirse bu sınıflandırılmamış noktayı bir yer noktası olarak etiketlemektedir. Bu karar verme süreci yinelemeli olarak yapılır ve artık daha fazla temel nokta kalmayınca durdurulur.



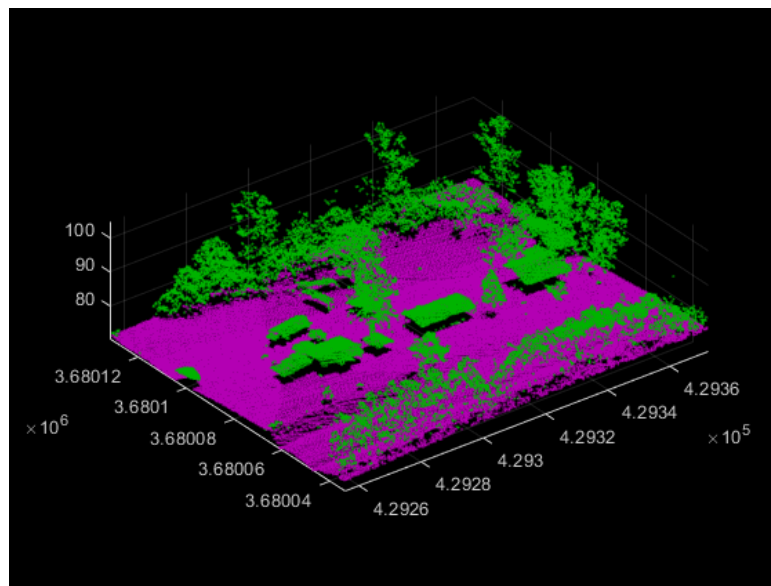
**Şekil 2.23.** PTD parametreleri; a) iki boyutta tohum noktalarının seçimi ve TIN oluşturulması, b) arazi üzerinde TIN oluşturma ve tohum nokta seçimi, c) açı ve mesafe ölçümü, d) yansıtma işlemi

## 2.9.2 SMRF yöntemi

SMRF (Simple Morphological Filter) algoritması nokta bulutunu zemin ve zemin üstü noktalar olmak üzere iki sınıfa ayırmaktadır. SMRF algoritması kavramsal olarak dört farklı aşamadan oluşur (Pingel vd., 2013). Birinci aşama, minimum yüzeyin ( $ZI_{min}$ ) oluşturulmasıdır. İkinci aşama raster veriden alınan ızgara hücrelerinin çıplak arazi ya da nesnelere içerdiği tanımlandığı minimum yüzeyin işlenmesidir. Üçüncü aşama, bu gridlenmiş noktalardan bir DEM oluşturulmasıdır. Dördüncü aşama, orijinal 3B noktaların, enterpolasyonlu DEM ile ilişkilerine dayalı olarak yalın arazi (zemin) veya nesne (diğer objeler) olarak tanımlanmasıdır.


İlk aşamada hücre boyutu parametresinden  $ZI_{min}$  üretilir. Bütün koordinatlar için [minimum: hücre boyutu: maksimum]'a karşılık gelen iki vektör ( $x_i, y_i$ ) belirlenir. SMRF algoritması, ( $x, y$ ) boyutlarının her biri için minimum değerden maksimum değere kadar bir raster veri oluşturur. Algoritmanın ikinci aşamasında, minimum yüzey ızgarasına ( $ZI_{min}$ ) aşamalı bir morfolojik filtre uygulanır. İlk yinelemede filtre, minimum yüzeye bir görüntü açma işlemi (erozyon + dilatasyon [genişleme])

uygulanır (Şekil 2.25). Görüntü üzerinde açma işlemi için genişleme filtresinin ardından bir erozyon filtresi uygulanır (Pingel vd., 2013). Bu durum için bir yapılandırma elemanı (structure element) seçilir. Bu yapılandırma elemanı her adımda yarıçapı, bir piksel başlangıç değerinden maksimum değerin ( $wk_{max}$ ) piksel eşdeğerine bir piksel artırılır. Maksimum pencere yarıçapı (max window radius) bir mesafe metriği olarak sağlanır. Maksimum pencere yarıçapı hücre boyutuna bölünür ve çıkan sonuç bir üst tam sayıya yuvarlanarak bir piksel eşdeğerine dönüştürülür. Bu aşamada bir piksel başına belirlenen hücre boyutu ve eğim toleransını kullanarak bir piksellik pencerede yükseklik eşiği hesaplanır. Bu hesaplama için eğim değeri, hücre boyutu ( $m$ ) ve 1 (piksel) birbirleriyle çarpılır. Yineleme işlemi için hesaplanan bu yükseklik eşiğini aşan bir fark değerine sahip herhangi bir ızgara hücresi, daha sonra bir nesne hücresi veya zemin dışı olarak işaretlenir. Yineleme sonucunda her bir hücre yalnız arazi (zemin) veya nesne (zemin dışı) olarak sınıflandırıldığı ikili bir maske oluşturulur. Algoritma daha sonra bu maskeyi, zemin olmayan hücreleri ortadan kaldırmak için başlangıç minimum yüzeyine uygular. Daha sonra geçici bir DEM üretilir. Algoritmanın son adımı yer/nesne 3B noktalarının belirlenmesidir. Bu durum için her nokta ile geçici DEM arasındaki dikey mesafeyi ölçerek ve bir eşik hesaplaması gerçekleştirilir. Orijinal noktalar, gerekli dikey mesafe parametresine ve isteğe bağlı ölçeklendirme parametresine göre yalnız arazi (zemin) olarak sınıflandırılır. SMRF sonucu nokta bulutunun zemin ve zemin üstü nokta olarak iki sınıfa ayrılmasına örnek Şekil 2.24’te gösterilmiştir.



Şekil 2.24. SMRF sonuç görüntüsü örneği

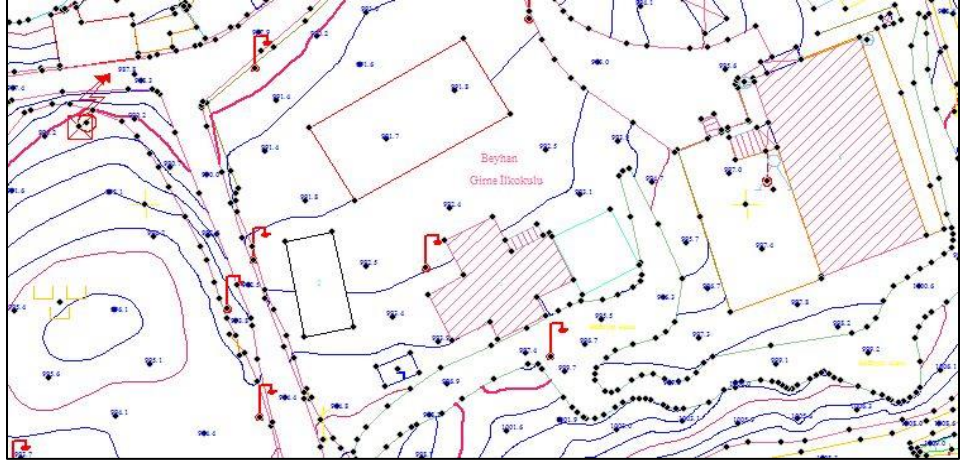
Şekil 2.24'te gösterilen yeşil noktalar zemin üstü objeleri, pembe renkli noktalar ise zemin noktalarını temsil etmektedir.




Şekil 2.25. SMRF morfolojik işlemler (C. Chen vd., 2021)

## 2.10 Referans Verileri (Hâlihazır Harita)


Bu çalışma için kullanılan Beyhan/Palu/Elazığ, Horasan/Erzurum ve Kaliforniya/ABD veri setlerinin 1/1000 ölçekli vektör haritaları (hâlihazır) Şekil 2.26'da sunulmuştur. Önerilen yöntem için mevcut bulunan vektör haritalar, referans olarak kabul edilmiştir ve uygun değerlendirme ölçütleri ile doğruluk analizi gerçekleştirilmiştir. Çalışma amacı gereği hâlihazır haritalardaki ilgili binalar, Global Mapper programında poligon (alan) şeklinde manuel olarak çıkartılmış ve doğruluk değerlendirmesine hazır hale getirilmiştir.



(a)



(b)



(c)

**Şekil 2.26.** Veri setlerinin referans (vektör) haritası; a) Test Alanı\_1, b) Test Alanı\_2, c) Test Alanı\_3

## 2.11 Doğruluk Analizi Yöntemleri

Düzenlenen bina sınırları referans altlıklar ile ilişkilendirilerek doğruluk analizi gerçekleştirilmiştir. Doğruluk analizi ile, etiketlenen verilerle gerçek etiketlerin karşılaştırılması üzerine başarı ölçülmektedir. Bu çalışmada doğruluk değerlendirmesi için tamlık (14), doğruluk (15), kalite (16) ve F-skor (17) piksel tabanlı metrikleri kullanılmıştır. Doğruluk metriklerinin hesaplanması için referans ve düzenlenen/tespit edilen bina sınırları için Doğru Pozitif (TP), Yanlış Pozitif (FP) ve Yanlış Negatif (FN) değerlerinin hesaplanması gerekmektedir. Ayrıca literatürde kullanılan diğer değerlendirme ölçütü olan IoU (Intersection over Union) metriği Quality (kalite) metriği ile aynı anlama gelmektedir ve aynı formülü kullanmaktadır. F-skor değeri,

Recall (geri çağırma) ve Precision (doğruluk) metriklerinin harmonik ortalaması olarak tanımlanmaktadır.

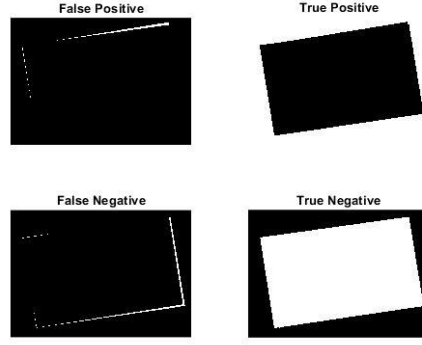
Gerçek pozitif (TP), bir ön plan nesnesi olarak sınıflandırılan referans verilerindeki bir nesneye karşılık gelen pikselleri gösterir. Yanlış negatif (FN), referansta arka plan olarak sınıflandırılan bir ön plan nesnesine karşılık gelen pikselleri temsil eder ve yanlış pozitif (FP), bir ön plan nesnesi olarak sınıflandırılan referans verilerinde bir ön plan nesnesine karşılık gelmeyen pikselleri gösterir. Gerçek bir negatif (TN), hem sınıflandırma sonuçlarında hem de referans verilerde arka plana ait bir varlıktır (Karsli vd., 2016; Rutzinger vd., 2009). Bu terimlerin görsel karşılıkları Şekil 2.27’de gösterilmiştir. Doğruluk değerlendirmesine ilişkin matematik model hesabına bir örnek ise Şekil 2.28’de gösterilmiştir.

$$\begin{aligned} \text{Completeness} &= \text{Precision} \\ &= \frac{|TP|}{|TP| + |FN|} \end{aligned} \quad (14)$$

$$\begin{aligned} \text{Correctness} &= \text{Recall} \\ &= \frac{|TP|}{|TP| + |FP|} \end{aligned} \quad (15)$$

$$\begin{aligned} \text{Quality} \\ &= \frac{|TP|}{|TP| + |FN| + |FP|} \end{aligned} \quad (16)$$

$$\begin{aligned} F - \text{score} &= \frac{2 \times \text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \\ &= \frac{|TP|}{|TP| + \frac{1}{2} (|FN| + |FP|)} \end{aligned} \quad (17)$$



Şekil 2.27. Doğruluk metriği parametreleri

Tahmini değerler (hesaplanan)

1	2	3
4	5	6
7	8	9

Gerçek değerler (referans)

1	2	3
4	5	6
7	8	9

Boş piksel  
Bina

		GERÇEK DEĞERLER			
		Bina		Bina değil	
TAHİMİNİ DEĞERLER	Bina	1 5 8	TP FP	3 7	
	Bina değil	4 6	FN TN	2 9	

Şekil 2.28. Örnek metrik doğruluk hesabı

Şekil 2.28’de gösterilen 3×3 boyutundaki tahmini değerler matrisi, yapılan çalışmanın sonuç görüntüsüne ait örnek bir parçayı temsil etmektedir. Gerçek değerler matrisi 3×3 ise referans altlığa dayalı olarak ilgili pikselin gerçek karşılığını temsil etmektedir. Doğruluk analizi gerçekleştirmek için gerçek değerler matrisi ile tahmini değerler matrisinin aynı boyutta olması zorunludur. Doğruluk değerlendirmesinde bu iki matrisin karşılıklı elemanları ilişkilendirilerek TP, FP, FN ve TN gruplarına atanır. Bu grupların oluşumu şu şekilde gerçekleşir:

- Tahmini deęer (algoritma sonucu elde edilen grnt) matrisinde ele alınan bir piksel bina pikseli olarak hesaplandı ise ve gerek deęer matrisindeki karřılıęı da bina pikseli ise bu durumda ilgili piksel TP,
- Tahmini deęer (algoritma sonucu elde edilen grnt) matrisinde ele alınan bir piksel boř piksel olarak hesaplanır ve gerek deęer matrisindeki karřılıęı da boř piksel ise bu durumda ilgili piksel TN,
- Tahmini deęer (algoritma sonucu elde edilen grnt) matrisinde ele alınan bir piksel bina pikseli olarak hesaplandı ise ve gerek deęer matrisindeki karřılıęı boř piksel ise bu durumda ilgili piksel FP,
- Tahmini deęer (algoritma sonucu elde edilen grnt) matrisinde ele alınan bir piksel boř piksel olarak hesaplanır ve gerek deęer matrisindeki karřılıęı bina pikseli ise bu durumda ilgili piksel FN olarak belirlenir.

rneęin bu gruplandırmalarda X retilen grntnn pikselinin gerek grntdeki karřılıęının doęru veya yanlıř tahmin edildięini temsil ettięi dřnldęnde, eęer bina-bina veya boř-boř olarak iliřkilendirme varsa X ile gsterilen kısım T (True) olarak deęerlendirilir. Y ile sembolize edilen kısım ise elde edilen grntdeki ilgili pikselin olumlu veya olumsuz yorumlanmasını ierir. Bu alıřmadaki rnekte doęruluk deęerlendirmesine konu olan kısım bina pikselidir. Yani bu alıřmada bina pikseli pozitif kısım ierirken boř piksel ise negatif kısım iermektedir. Karřılıklı elemanlar karřılařtırılırken tahmin matrisinde eęer bina pikseli mevcut ise Y sembol pozitif, boř piksel mevcut ise Y sembol negatif olarak etiketlenmektedir.

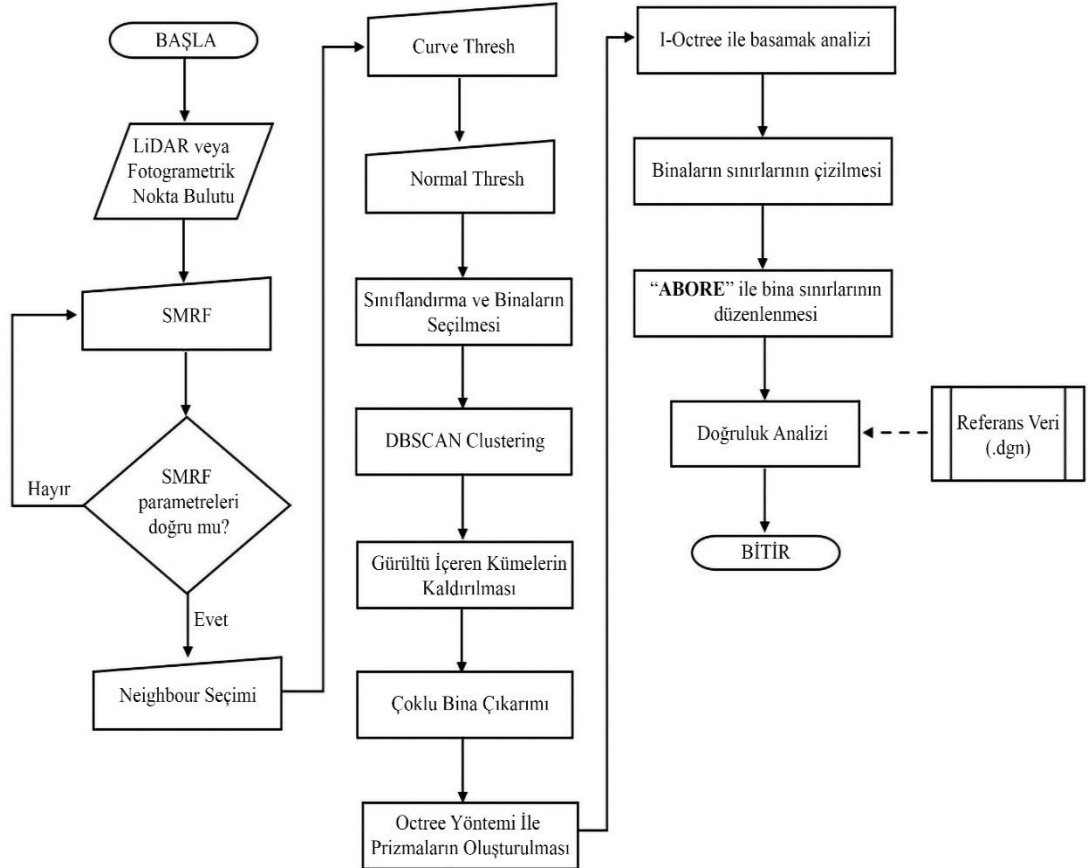
řekil 2.28'deki rnek matris incelendięinde sayısal hesap yapmak gerekirse, 3 adet TP (1, 5 ve 8) ve 2'řer adet TN (2, 9), FP (3, 7), FN (4, 6) pikseli oluřtuęu grlmektedir. Yukarıda verilen formllerin yerine ilgili piksel adedi yazılırsa doęruluk oranları ařaęıdaki řekilde hesaplanır.

- $C_p = 0.6$
- $C_r = 0.6$
- $Q = 0.43$
- $F\text{-skor} = 0.6$

Verilen rnek grnt matrisi dikkate alındıęında, doęruluk deęerlendirme sonularının [0-1] arasında deęiřtięi gzlemlenmektedir. Ortaya ıkan sonular 100 ile arpılarak yzdelik olarak doęruluk deęerlerine ulařılabilir.

### 3. VERİ VE YÖNTEM

Bu tez çalışmasında, klasik uçak ve İHA üzerine takılı kameralar ile elde edilmiş yüksek çözünürlüklü fotogrametrik görüntülerden üretilen nokta bulutlarından SMRF ve Octree yöntemleri ile binaların çıkarılması ve ardından Otomatik Bina Sınır Düzgünleştirme Yaklaşımı (ABORE) ile bina sınırlarının düzenlenmesine yönelik bir çalışma gerçekleştirilmiştir. SMRF yöntemi ile nokta bulutu ağaç, bina ve zemin sınıflarına genel olarak ayrılmış, Octree yaklaşımı esas alan ve otomatik basamak sayısını tespit eden I-Octree ile yaklaşık bina sınıfı içinden net bir biçimde bina çatı noktaları otomatik olarak tespit edilmiştir. Bina kenar noktaları üzerinden sayısallaştırma işlemi ise ABORE yöntemi ile gerçekleştirilmiştir. Önerilen yöntemin akış şeması Şekil 3.1’de gösterilmiştir. Önerilen akış diyagramı ayrıca LiDAR nokta bulutu üzerinde de uygulanmış, fotogrametrik nokta bulutu ile LiDAR nokta bulutu kullanımı sonucu ortaya çıkan sonuçlar kıyaslanmıştır.



Şekil 3.1. Önerilen yöntem genel akış şeması


### 3.1 Çalışma Alanının Belirlenmesi

Tez çalışmasında önerilen yöntem ya da yaklaşımın uygulaması üç farklı test/çalışma alanına ait veri setleri üzerinde gerçekleştirilmiştir. Test alanlarından iki adedi için fotogrametrik kamera ile alınan görüntülerden üretilen nokta bulutları, diğeri için ise LiDAR nokta bulutu verisi kullanılmıştır. Her bir test alanında tekli bina, ikili veya üçlü bina ve çoklu bina kombinasyonları oluşturacak şekilde alt veri grupları oluşturulmuştur. Test alanları ile ilgili detaylı bilgi bir sonraki alt bölümde detaylı bir biçimde açıklanmıştır.

### 3.2 Test Alanları

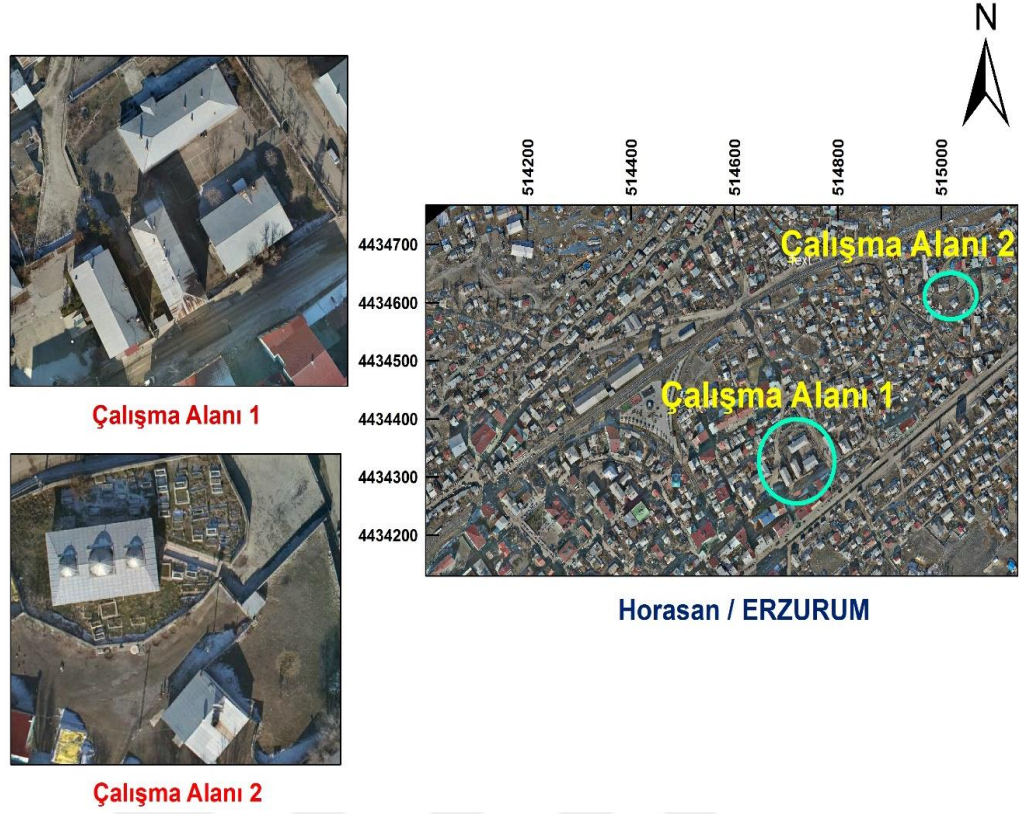
Tez çalışmasında önerilen yöntemin performansını test etmek üzere Beyhan Beldesi (Palu/Elazığ), Horasan (Erzurum) ilçesi ve Kaliforniya (ABD) olmak üzere üç farklı test alanı seçilmiş ve kullanılmıştır. Bu alanlar sırasıyla *Test Alanı\_1*, *Test Alanı\_2* ve *Test Alanı\_3* olarak adlandırılmıştır. *Test Alanı\_1* ve *Test Alanı\_2* için seçilen alanlarda sırasıyla klasik dijital fotogrametrik kamera ve İHA tabanlı dijital kamera ile görüntü alımı yapılmış olup, bu görüntülerden seçilen örnekler üzerinde eşleştirme işlemi ile nokta bulutu üretilmiştir. *Test Alanı\_3*'de ise hava LiDAR cihazı ile veri toplanmak suretiyle oluşturulan nokta bulutları kullanılmıştır.

*Test Alanı\_1*, Elazığ ili, Palu İlçesi, Beyhan Belde sınırlarını içeren alan olarak seçilmiştir (Şekil 3.2). Belde, Palu, Bingöl ve Diyarbakır arasında bulunan Ak Dağlar tarafından çevrelenmektedir. Belde'nin alanı 1050 km<sup>2</sup> olup, merkezinin denizden yüksekliği 840 metredir. Belde tipik doğu Anadolu belde karakterini yansıtmakta, alanda seyrek sayıda binalar ve yeşil alanların mevcudiyeti söz konudur. Bu test alanında 1/1000 ölçekli Sayısal Fotogrametrik Harita Üretimi amacıyla 2021 yılı Nisan ayında fotogrametrik uçuşlar yapılmış, 1/1000 ve 1/5000 ölçekli vektör ve raster haritalar üretilmiştir. Bu test alanı için dijital hava fotoğrafları araziden ortalama 1175 m yükseklikten %65 boyuna ve %25 enine bindirme oranı ile Phase One iXM-RS150F kamerası ile çekilmiştir. Çekilen görüntüler çok bantlı (RGB) olup, yer örnekleme aralığı (YÖA) 9 cm civarındadır.



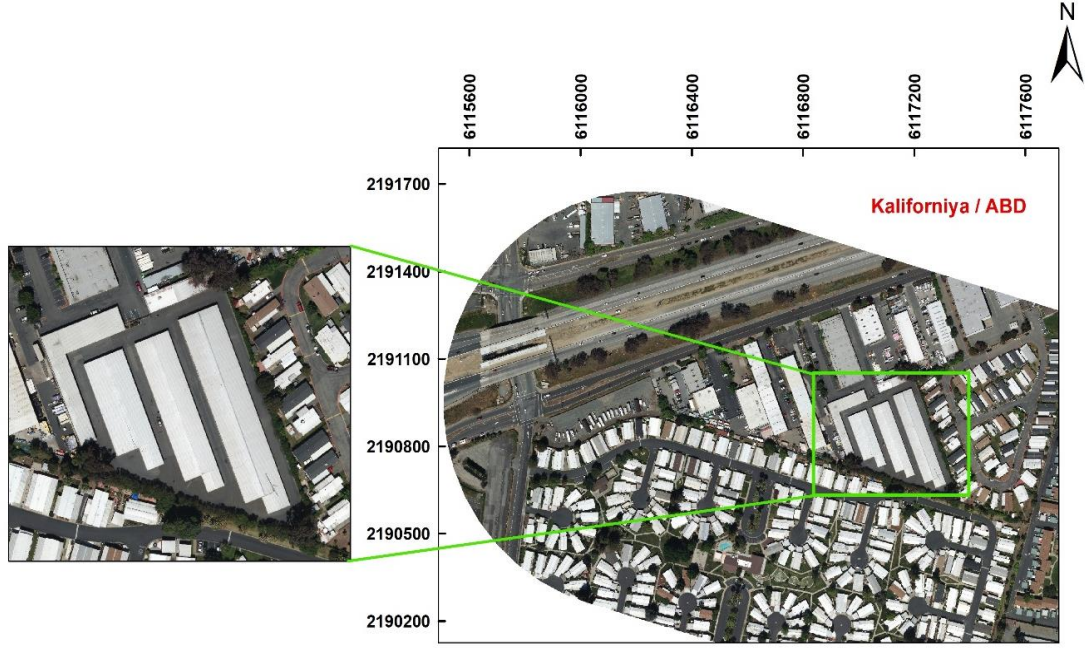
**Şekil 3.2.** Test\_Alanı\_1 (Beyhan/Palu/Elazığ)

*Test Alanı\_2*, Erzurum ili, Horasan İlçesi merkez sınırlarını içerecek şekilde seçilmiştir (Şekil 3.3). Horasan İlçesi Erzurum ilinin doğusunda, Aras nehrinin kenarında kurulu olup, yüzölçümü 1662 km<sup>2</sup>'dir. Deniz seviyesinden yüksekliği 1650 metredir. İlçe, doğusunda Sarıkamış, güneydoğusunda Eleşkirt, güneyinde Karayazı, batısında Köprüköy ve kuzeyinde Narman ilçeleri ile çevrelenmektedir. İlçe tipik doğu Anadolu ilçe karakterini yansıtmakta, merkezinde oldukça çok sayıda binalar ve yeşil alanların mevcudiyeti söz konudur. Bu test alanında 1/1000 ölçekli Sayısal Fotogrametrik Harita Üretimi amacıyla 2021 yılı Aralık ayında İHA tabanlı fotogrametrik uçuşlar yapılmış, 1/1000 ölçekli vektör ve raster haritalar üretilmiştir. Bu test alanı için dijital hava fotoğrafları araziden ortalama 400 m yükseklikten %80 boyuna ve %70 enine bindirme oranı ile Sony RX1R II kamerası ile çekilmiştir. Çekilen görüntüler çok bantlı (RGB) olup, yer örnekleme aralığı (YÖA) 5 cm civarındadır.



Şekil 3.3. Test\_Alanı\_2 (Horasan/Erzurum)

*Test\_Alanı\_3*, Amerika'nın Kaliforniya eyaleti sınırları içerisinde bir bölgede seçilmiştir (Şekil 3.4). Kaliforniya kuzeyinde seçilen bölgenin LiDAR verisi çevrimiçi olarak temin edilmiştir. Seçilen bölge yoğun yerleşim alanları ile kaplı olup, deniz seviyesinden yüksekliği 10 metredir. Bu test alanında büyük ölçekli çizgisel ve ortofoto harita üretimi için hem fotogrametrik hem de LiDAR verisi üretimi yapılmıştır. İlgili test alanı için LiDAR verisi ortalama 10 nokta/m<sup>2</sup> yoğunlukta ve 12 km<sup>2</sup>'lik alanda 2020 yılı Şubat ayında üretilmiştir. LiDAR nokta bulutu araziden yaklaşık olarak 1400 m yükseklikten Optech Galaxy T1000 cihazı ile çekilmiştir.



Şekil 3.4. Test\_Alanı\_3 (Kaliforniya/ABD)


### 3.3 Kullanılan Kamera/LiDAR ve Üretilen Veriler

Tez çalışması kapsamında üç farklı test alanında ve bu test alanları içerisinde farklı bina adedi kapsayacak şekilde seçilen alt test/çalışma alanları belirlemek suretiyle veri setleri üretilmiştir. Ana veri setleri için hava ve İHA bazlı olmak üzere iki farklı dijital kamera ve bir adet de LiDAR sistemi kullanılmıştır. Sözü edilen kamera ve LiDAR sistemlerine ilişkin özellikler Çizelge 3.1’de detaylı bir biçimde sunulmuştur.

Çizelge 3.1. Kamera ve LiDAR sistemi özellikleri

Ölçü Sistemi/ Özellik	Dijital Hava Kamerası	İHA Kamerası	LiDAR
<i>Sensör</i>	<i>Phase One iXM-RS150F</i>	<i>Sony RX1R II</i>	<i>Optech Galaxy T1000</i>
<i>Piksel Boyutu (<math>\mu\text{m}</math>)</i>	<i>3,76</i>	<i>4,50</i>	<i>-</i>
<i>Çözünürlük</i>	<i>14204×10652</i>	<i>7952×5304</i>	<i>1064 (NIR)</i>
<i>Kamera Sabiti (mm)</i>	<i>51,78</i>	<i>34,08</i>	<i>-</i>
<i>YÖA (cm)</i>	<i>9</i>	<i>5</i>	<i>10 nokta/m<sup>2</sup></i>
<i>Uçuş Yüksekliği (m)</i>	<i>1175</i>	<i>400</i>	<i>1400</i>
<i>Bindirme Oranları</i>	<i>65/25</i>	<i>80/70</i>	<i>-</i>

Her bir test alanı için üretilmiş fotogrametrik ve LiDAR nokta bulutları verisi Şekil 3.5'te gösterilmektedir. Bu veri seti seçilen çalışma alanlarına ait nokta bulutunu içermekte olup, alanın genel görüntüsünü sunmaktadır.



Şekil 3.5. Test alanları nokta bulutu verisi; a) Test\_Alanı\_1, b) Test\_Alanı\_2 ve c) Test\_Alanı\_3

Dijital hava kamerası kullanmak suretiyle 1. ve 2. test alanı için renkli/üç bantlı hava fotoğrafları çekilmiştir. Bu hava fotoğraflarına takip eden alt başlıkta anlatıldığı üzere görüntü eşleştirme metodu uygulanarak yoğun nokta bulutları üretilmiştir (Çizelge 3.2). Bu test alanları için fotogrametrik eşleştirme yöntemi ile üretilen nokta bulutu yoğunluğu sırasıyla 49,50 nokta/m<sup>2</sup> ve 171,81 nokta/m<sup>2</sup>'dir. Bunun yanı sıra, 3. test alanı için ise aktif yöntem lazer tarama teknolojisi ile nokta bulutu üretilmiştir. Bu sistem ile üretilen nokta bulutu 10 nokta/m<sup>2</sup> yoğunluğuna sahiptir. Özellikle ifade etmek gerekirse, fotogrametrik görüntü eşleştirmesi yöntemi sonucu üretilen nokta bulutları LiDAR veri yoğunluğuna göre çok daha yüksek sayısal bir değere sahiptir.

**Çizelge 3.2.** Test alanları için üretilen nokta bulutu yoğunlukları (nokta/m<sup>2</sup>) ve sayıları

Veri (Nokta Bulutu)	Fotogrametrik	LiDAR	Nokta Sayısı
Test_Alanı_1	49,50	-	186.894.974
Test_Alanı_2	171,81	-	127.742.941
Test_Alanı_3	-	10	13.154.449

#### 3.4 Eşleştirme Metodu İle Yoğun Nokta Bulutu Üretimi

Tez çalışması için seçilen test alanlarına ait dijital hava fotoğrafları üzerinde mevcut bina detaylarının nokta bulutu üzerinden çıkarımı için ilk aşama, bu fotoğraflardan görüntü eşleştirme teknikleri kullanılarak nokta bulutu verisinin üretilmesidir. Bu sebeple seçilen iki farklı alan Beyhan (Palu/Elazığ) ve Horasan (Erzurum) bölgelerine ait veri setleri Agisoft Metashape Profesyonel Yazılımı ile detay eşleştirme işlemine tabi tutularak yoğun nokta bulutu üretimi gerçekleştirilmiştir. İlgili yazılım, literatürde yaygın olarak bilinen detay çıkarma yaklaşımı SIFT eşleştirme algoritması matematik temeline dayalı olarak eşleştirme yapılabilmektedir. Eşleştirme için görüntülerin dış yöneltme elemanları ve kamera iç yöneltme elemanları girdi verisi olarak kullanılmıştır. Girdi verileri kullanılarak bindirmeli görüntüler yardımıyla ışın demetleri yöntemi esasına göre 3B derinlik haritaları (nokta bulutu) oluşturulur. Üretilen nokta bulutu doğruluğu, detay yüzeyi kalitesine, bindirme oranı ve yöneltme parametrelerinin doğruluğuna direkt bağlıdır. Bu açıdan mümkün olduğunca yüksek bindirmeli görüntülerin kullanımı hem birim alana düşecek nokta sayısını hem de koordinatı hesaplanacak noktaların mutlak doğruluğunu ciddi düzeyde etkilemektedir.

Eşleştirme işlemi çok yoğun nokta bulutu üretecek şekilde planlanmış, Beyhan veri setinde 49,50 nokta/m<sup>2</sup> yoğunlukta ve toplam 186.894.974 nokta üretilirken, Horasan veri seti için m<sup>2</sup>'ye 171,81 nokta düşecek yoğunlukta toplamda 127.742.941 nokta üretilmiştir. Her iki çalışma alanı için üretilen yoğun nokta bulutu örneği Şekil 3.5'te sunulmuştur.


### 3.5 Zemin Sınıfının Çıkarılması

Fotogrametrik görüntülerden üretilen nokta bulutu veya LiDAR nokta bulutu üzerinden zemin çıkarım işlemi için öncelikle veri setleri üç boyutlu olarak Matlab ortamında görsel hale getirilmiştir (Şekil 3.6a ve 3.6c). Bu işlemi takiben SMRF algoritması ile nokta bulutu zemin ve zemin üstü noktalar olmak üzere iki gruba ayrılmıştır (Şekil 3.6b ve 3.6d). SMRF algoritması Matlab yazılımında mevcut “*segmentGroundSMRF*” fonksiyonu ile çalıştırılmıştır. Bu algorithmada dört adet parametre yer almaktadır. Bu parametreler;

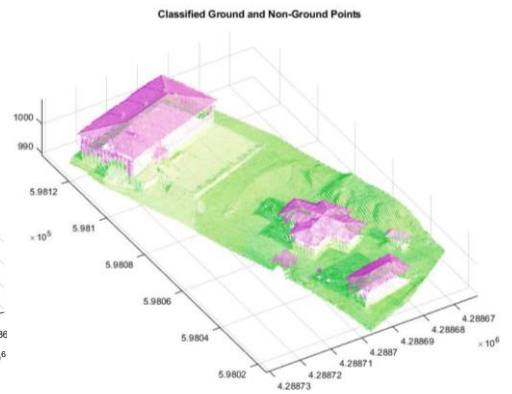
- **Max Window Radius:** Yapılandırma elemanının maksimum yarıçapı,
- **Slope Threshold:** Zemin dışı elemanları tanımlamak için eğim eşiği,
- **Elevation Threshold:** Zemin dışı noktaları belirlemek için yükseklik eşiği,
- **Elevation Scale:** Yükseklik eşiği ölçekleme faktörü,

şeklinde tanımlanmaktadır. Bu dört parametre farkı veri setlerine göre değişiklik göstermektedir. Bu aşama kullanıcı tarafından değerlendirilerek arazi topoğrafyasına göre en uygun parametre değerleri seçilmelidir. Tez çalışması içeriğinde mevcut uygulamada sadece “*Elevation Scale*” değişkeni sabit bırakılmış, diğer parametreler farklı olacak şekilde veri setine göre seçilmiştir.


(a)



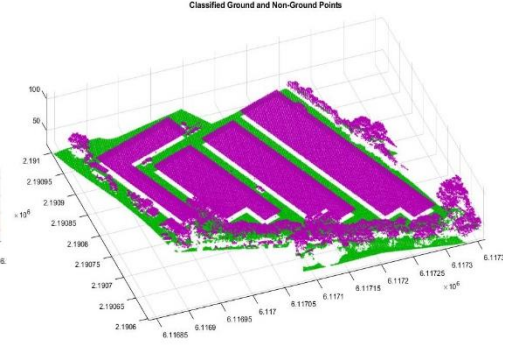
(b)



(c)



(d)



**Şekil 3.6.** SMRF algoritması ile zemin ve zemin üstü noktaların ayrılması; a ve b) Fotogrametrik nokta bulutu üzerinde SMRF uygulaması, c ve d) LiDAR nokta bulutunda SMRF uygulaması

Şekil 3.6b ve 3.6d'de mor renkli bölgeler zemin üstü noktaları gösterirken, yeşil renkli bölgeler zemin noktalarını temsil etmektedir.

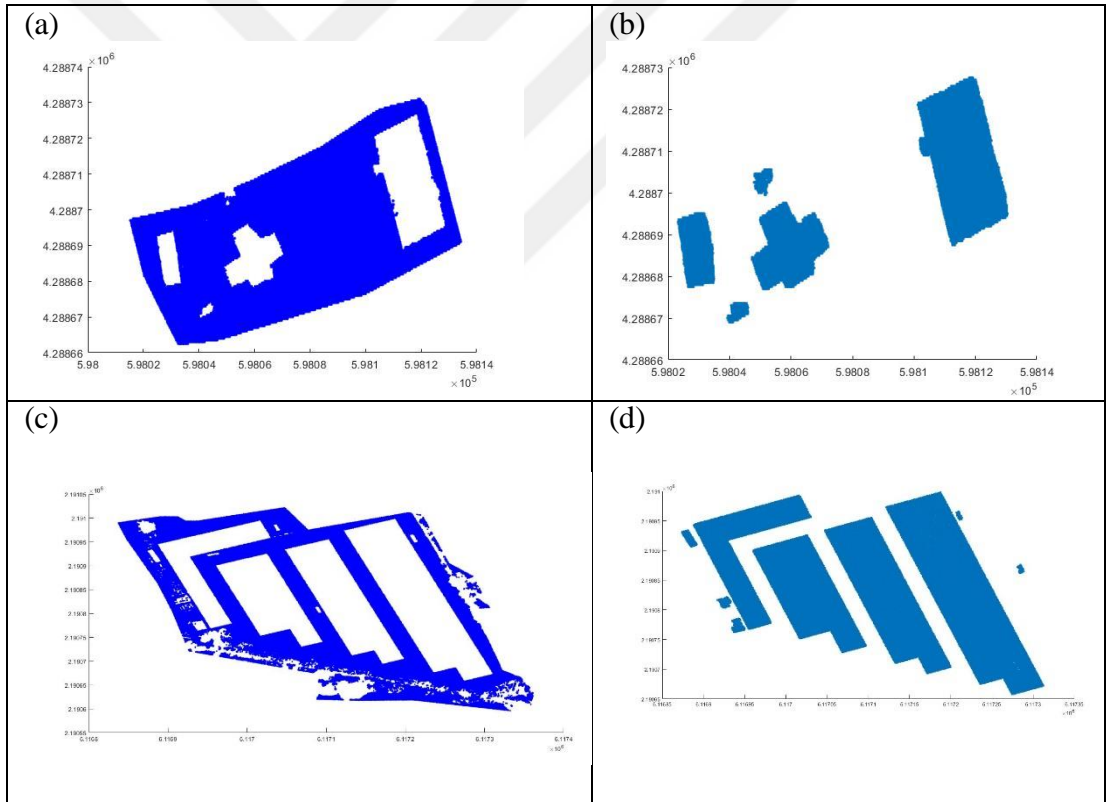
### 3.6 Yeşil Alanların Nokta Bulutundan Ayıklanması

SMRF metodu ile iki sınıfa ayrılan nokta bulutlarına ait geometrik özellikler (eğrilik, normal ve komşuluk) Matlab ortamında mevcut "*helperExtractFeatures*" fonksiyonu kullanılarak çıkarılmıştır. Bu aşamada nokta bulutuna ait her bir nokta komşu noktalarla ilişkilendirilerek temel yapı bilgisi elde edilmiştir. Sözü edilen fonksiyonla her bir nokta için *eğrilik*, *normal* ve *komşuluk* indeksleri belirlenmiştir. Uygulama aşamasında komşu nokta sayısı (neighbors points) 15 olarak alınmıştır. Bu aşamada normaller ve eğrilikleri kullanarak SMRF sonucu üretilen zemin üstü noktalar, bina ve bitki örtüsü olmak üzere iki sınıfa ayrılabilir. Bina noktaları genellikle düzlemseldir. Bu sebeple binaya ait olabilecek noktalarda eğrilik değişimi ve komşular arasındaki normallerin bağıl farkı oldukça azdır. Bitki örtüsüne ait noktalar ise herhangi bir düzlem ya da bilinen geometrik şekil belirtmeksizin dağınık bir düzene sahiptir. Dolayısıyla bitki örtüsü noktalarının bina noktalarına göre eğriliklerinde daha yüksek bir değişim söz konusudur.

Zemin üstü noktalarını, bitki örtüsü ve bina noktası olarak ayırmak için "*helperClassify*" fonksiyonu kullanılmaktadır. Bu fonksiyonun çalışabilmesi için "*curveThresh*" ve "*normalThresh*" eşik değerleri belirlenmelidir. Bu fonksiyonun çalışma prensibine göre, eğer bir noktanın eğriliği belirtilen eğrilik eşliğinden küçük ve komşu noktaların normalleri arasındaki kosinüs benzerliği, belirtilen normal eşikten

daha büyük ise bu nokta bina noktası olarak kabul edilir ve etiketlenir. Bu kriterlerin dışındaki zemin üstü noktalar bitki örtüsü olarak etiketlenir. Bütün bu işlemler sonucunda nokta bulutu, zemin noktaları, bina noktaları ve bitki örtüsü noktaları olmak üzere üç sınıfa ayrılır. Tezde gerçekleştirilen uygulamada normal eşik değeri 0,85 sabit değeri ile çalışırken, eğrilik eşığı ise değişiklik gösterebildiği tespit edilmiştir. Buradaki değer veri seti veya arazi topografyasına göre değişkenlik gösterebilmektedir.

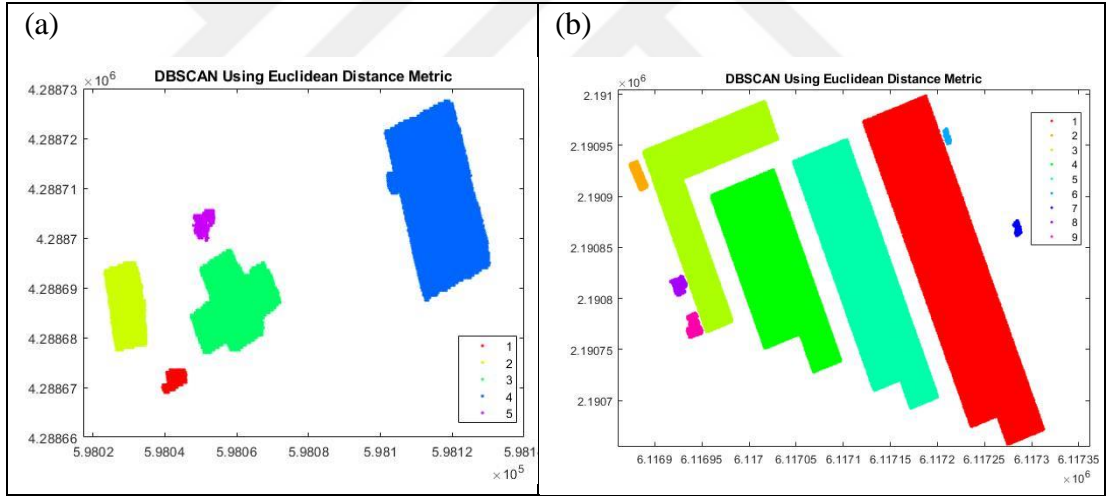
Sınıflandırılan zemin noktaları Şekil 3.7a ve 3.7c'de, "helperClassify" fonksiyonu ile çıkarılan bina noktaları ise Şekil 3.7b ve 3.7d'de gösterilmektedir. Şekil 3.7'den görüldüğü üzere, sınıflandırma işlemi için belirlenen eşik değerleri uygun sonuca ulaşılmasını engelleyebilmektedir. Ayrıca bitki örtüsüne veya diğer bina dışı nesnelere ait olabilecek noktaları da bina noktası olarak etiklemektedir.



**Şekil 3.7.** Zemin ve bina noktalarının sınıflandırılması; a ve b) Fotogrametrik nokta bulutu üzerinde sınıflandırma, c ve d) LiDAR nokta bulutunda sınıflandırma

### 3.7 DBSCAN ile Binaların Sınıflandırılması

Sınıflandırılan bina noktaları içinde belirlenen eşik değerine göre çeşitli gürültülerle karışabilmektedir. Bu türdeki gürültülerden kurtulabilmek için öncelikle DBSCAN kümeleme algoritması ile bina noktaları kümelendirilir (Şekil 3.8). DBSCAN kümelemesi için “*Epsilon*” ve “*Minpts*” parametrelerinin belirlenmesi gerekmektedir. Uygulamada “*Minpts*” parametresi veri setinin nokta yoğunluğu ile eşleştirilmiştir ve hesaplanan nokta yoğunluğu en yakın tam sayıya yuvarlanıp otomatik olarak o değişkene atanmaktadır. “*Epsilon*” parametresi ise genellikle 1, 2 veya 3 değerleri seçildiğinde kümeleme sorunsuz bir biçimde çalışmaktadır. DBSCAN algoritması bitişik sınır nesnelere kümelendirmesinde kararsız hale gelebilmektedir (Ester vd., 1996; T. N. Tran vd., 2013). Bu durum kümeleme algoritmasının tam otomatik olmadığını ve veri setine göre değışiklik gösterebileceğini ortaya koymaktadır. Fakat uygulamada genellikle sabit değşerler ile sonuca ulaşılabildiği de gözlemlenmiş ve tespit edilmiştir.

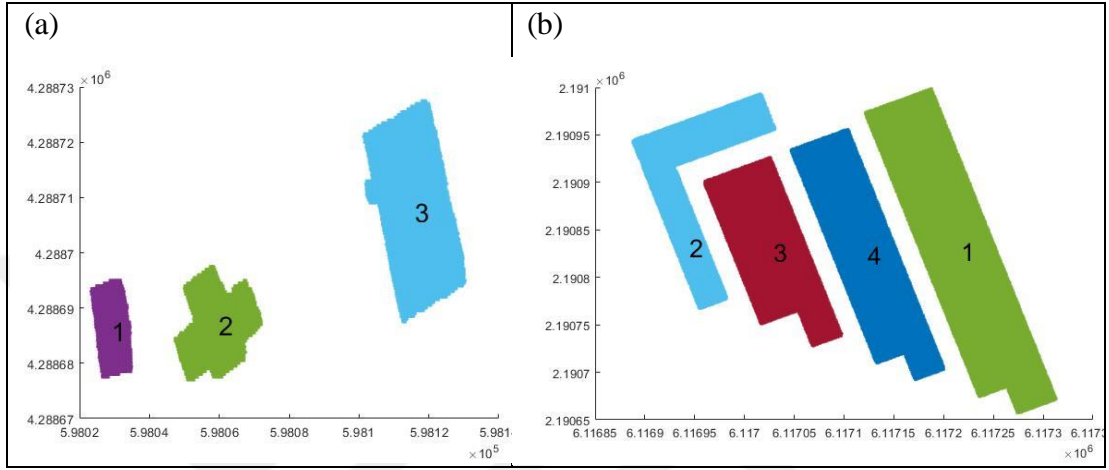


**Şekil 3.8.** DBSCAN algoritması ile bina nokta kümelendirmesi; a) Fotogrametrik nokta bulutunda kümeleme, b) LiDAR nokta bulutunda kümeleme

DBSCAN algoritması ile gerçekleştirilen kümeleme sonucu gürültü oluşturabilecek kümelerin tespit edilip ayıklanması gerekmektedir. Bu durumda veri setinin nokta yoğunluğu, bir binanın oluşturabileceği minimum alan ile çarpılır. Uygulama için minimum bina alanı  $70 \text{ m}^2$  olarak seçilmiştir. Çarpım sonucu çıkan sayısal değşer, DBSCAN tarafından belirlenen bütün kümeler ile karşılaştırılmıştır. Bu karşılaştırma aşğıdaki kuralları esas almaktadır.

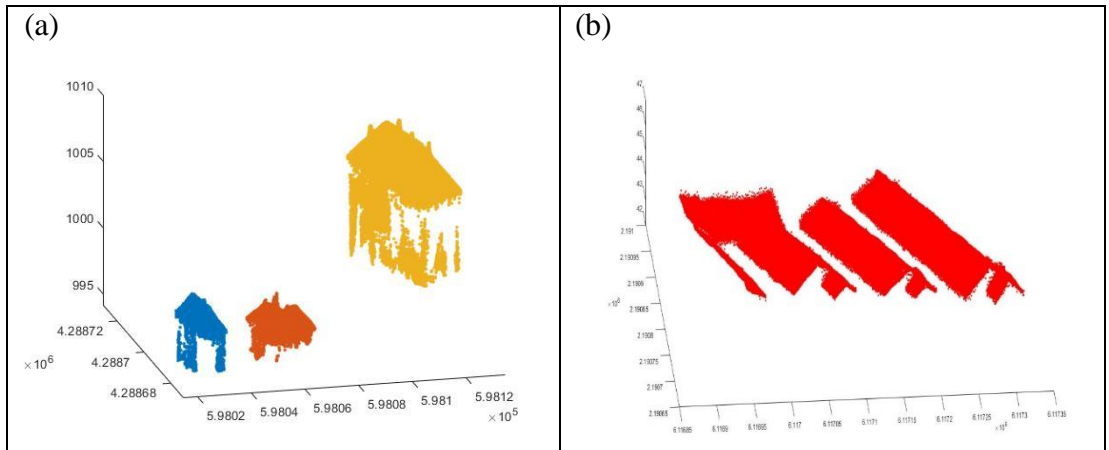
- Eğer ilgili kümedeki nokta sayısı hesaplanan sayısal değerden küçük ise, otomatik bir biçimde bu küme gürültü olarak belirlenir ve silinir.
- Eğer ilgili kümedeki nokta sayısı hesaplanan sayısal değerden büyük ise, bu küme bina kümesi olarak otomatik olarak belirlenmektedir.

Önerilen bu yöntemin çıktıları Şekil 3.9’da gösterilmektedir. Belirlenen bu yöntem ile nokta bulutundan çoklu bina çıkarımının ilk aşaması tamamlanmıştır.



**Şekil 3.9.** Gürültülü kümelerin ayıklanması; a) Fotogrametrik nokta bulutu, b) LiDAR nokta bulutu

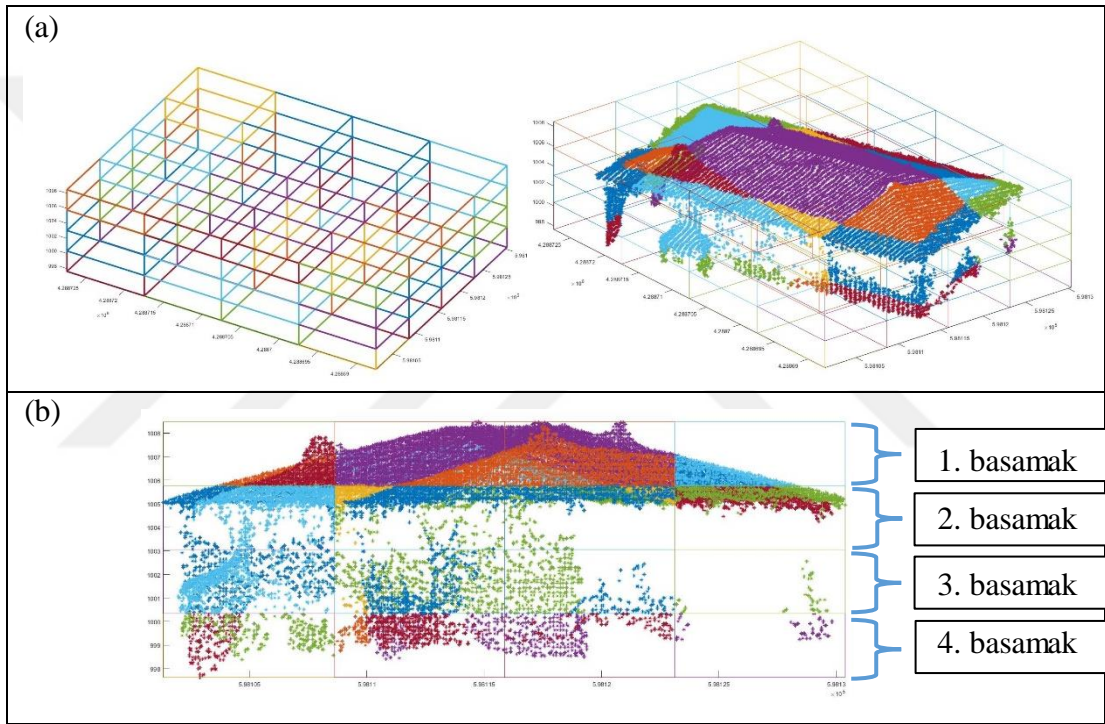
Şekil 3.9’da görüldüğü üzere sadece binalara ait noktalar elde edilmiştir. Geriye kalan bina noktaları üç boyutlu olarak Şekil 3.10’da gösterilmektedir.



**Şekil 3.10.** Çıkarılan bina noktalarının üç boyutlu gösterimi; a) Fotogrametrik nokta bulutu, b) LiDAR nokta bulutu

### 3.8 İyileştirilmiş Octree (I-Octree) ile Bina Detaylarının Çıkarılması

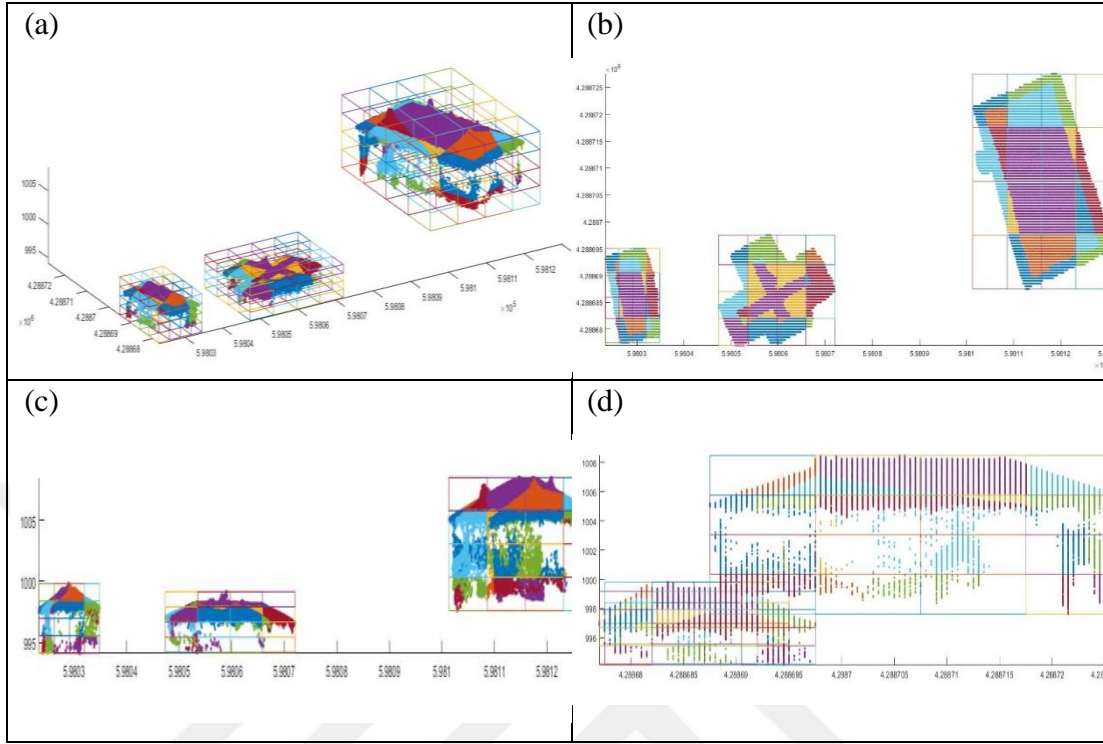
Bu aşamaya kadar uygulanan yöntemlerle üretilen üç boyutlu bina noktaları incelendiğinde, binanın çatı noktalarının dışında duvar noktalarının da varlığı tespit edilmiştir. Bu aşama sonrası belirlenen bina kümelerinden sadece çatıya ait noktaların seçilmesi ve duvar noktalarının olabildiğince bu kümelerden ayıklanmasını gerekmektedir. Bu problemin çözümü için literatürde mevcut “Octree” metodu iyileştirilmek/geliştirilmek suretiyle “İyileştirilmiş Octree” (I-Octree) adıyla yeni bir yöntem geliştirilmiş ve önerilmiştir. Octree yönteminin temeli binaya ait nokta bulutunun farklı sayıda eş prizmalar ile temsil edilmesine dayanmaktadır (Şekil 3.11).



**Şekil 3.11.** Octree yöntemi ile prizmalara ayırma; a) Oluşturulan prizmalar, b) Octree için oluşturulan basamak sırası

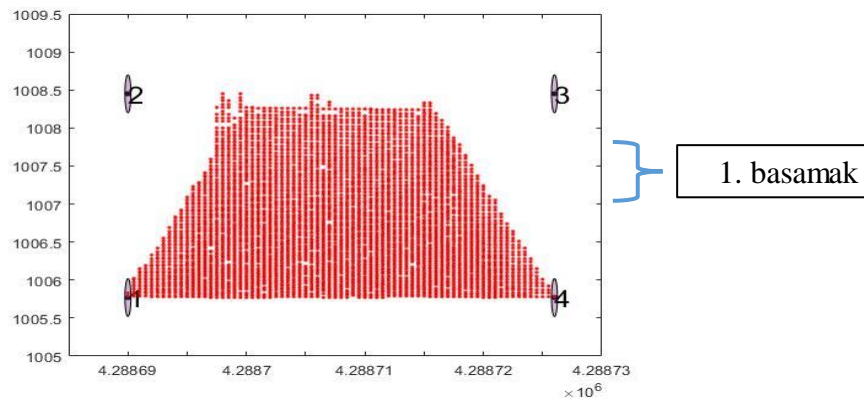
Şekil 3.11'deki örneğe göre, Octree yöntemi ile nokta bulutu 4 basamak ve her basamakta 16 prizma olmak üzere 64 eşit prizmaya bölünmüştür. Basamak sayısı “Depths” parametresi ile doğru orantılıdır. Uygulamada bu değer 3 olarak seçilmiştir. Matlab ortamında yazılan kod ile her bir prizmanın içindeki ve her bir basamaktaki noktalar otomatik olarak kümelerle ayrılmıştır. Fakat belirlenen basamakların hepsi çatı noktalarını içermediği için tüm basamaklar arasında bir karar mekanizması oluşturulması gerekmektedir. Özetle, her bina için Octree yöntemi uygulanır (Şekil

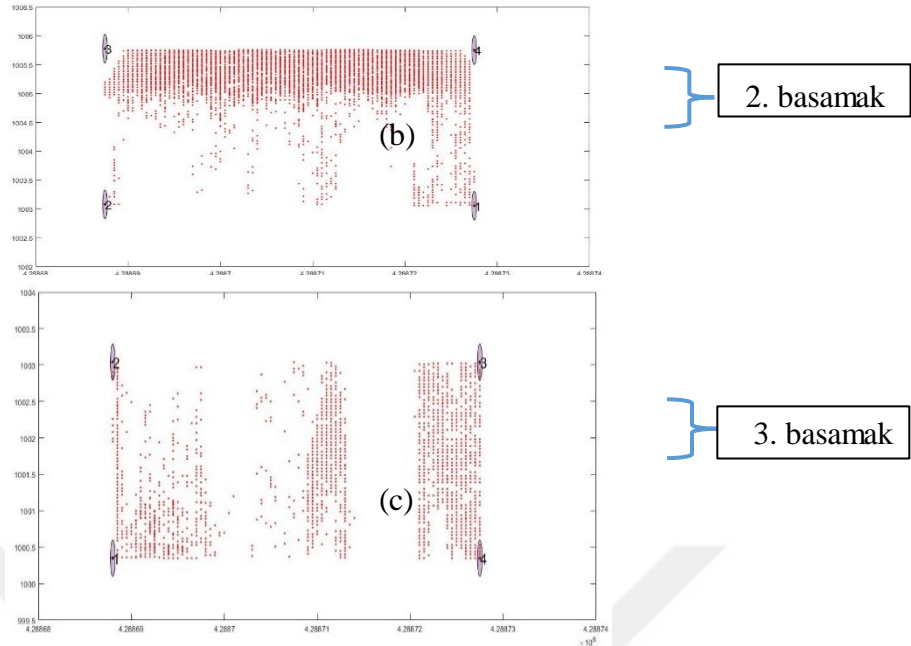
3.12). Oluşan her binada hangi basamağın çatıya ait olabileceği tespit edilmesi gerekmektedir.



**Şekil 3.12.** Çoklu Octree uygulama; a) 3B gösterim, b) X-Y düzlemi gösterimi, c) Y-Z düzlemi gösterimi, d) X-Z düzlemi gösterimi

İyileştirilmiş Octree (*I-Octree*) yaklaşımı detayları aşağıda açıklanmıştır. Şekil 3.12c ve 3.12d'de gösterildiği üzere nokta bulutu Y-Z düzlemi, X-Z düzleminde analiz edildiği çatı profillerinin iki boyutta çıkardığı gözlemlenmiştir. Bunun için her basamağın profili incelenmiştir. Sonra her bir basamak için MBR (Minimum Bounding Rectangle) algoritması ile basamak profillerinin köşe noktaları tespit edilmiştir (Şekil 3.13).





**Şekil 3.13.** MBR algoritması ile basamak analizi; a) 1. basamak, b) 2. basamak, c) 3. basamak


Şekil 3.13'te binanın ilk üç basamağına ait (X-Z) düzleminde profil gösterilmiştir. Şekillerdeki 1, 2, 3 ve 4 numaralı köşe noktaları MBR algoritmasının ilgili nokta bulutunun (2 boyutta) minimum alana sahip olacak dörtgenin köşe noktalarını göstermektedir. Bu köşe noktalarından “*polybuffer*” fonksiyonu ile 0.1 m yarıçapında buffer zonları geçirilmiştir.

Her bir basamaktaki bufferlardan sadece en üstteki iki buffer ele alınmıştır. Bu iki buffer içinde nokta bulunmuyorsa, ilgili basamak ele alınan bina çatı noktalarını içermektedir. Eğer ilgili basamağın üstünde bulunan iki buffer içinde de nokta bulunuyorsa, incelenen bu basamak binanın duvarını temsil etmektedir. Örneğin, Şekil 3.13'teki görselde 1. ve 2. basamakta üstte bulunan iki buffer içine herhangi bir nokta bulunmadığı için bu iki basamak ilgili bina için çatı noktası olarak otomatik bir şekilde belirlenmektedir. Fakat 3. basamağa bakıldığında MBR algoritmasının bulduğu köşe noktaları nokta bulutundaki bina noktalarına yakın geldiği için geçirilen buffer içinde çok yüksek ihtimalle nokta bulunacaktır. Bu durumda ilgili basamak duvar noktası olarak değerlendirilmektedir.

Genellikle binaların 1. basamaklarındaki profiller üçgen, ters yamuk, eğrisel veya çatısı olmayan bina tipinde ortaya çıkmaktadır. Üçgen, ters yamuk ve eğrisellik içeren

çatılarda ilk birkaç basamak bu koşulu sağlar iken, çatısız binalarda daha ilk basamak dahil tüm basamakları duvar olarak algılayacaktır. Bu yüzden eğer ilk basamaktan buffer içinde kalan nokta var ise bu durumda ilgili binanın 1.veya ilk 2 basamağı alınması gereklidir. Çatısı olmadığı için profilden tüm basamaklar aşağıya doğrusal bir şekilde inmektedir.

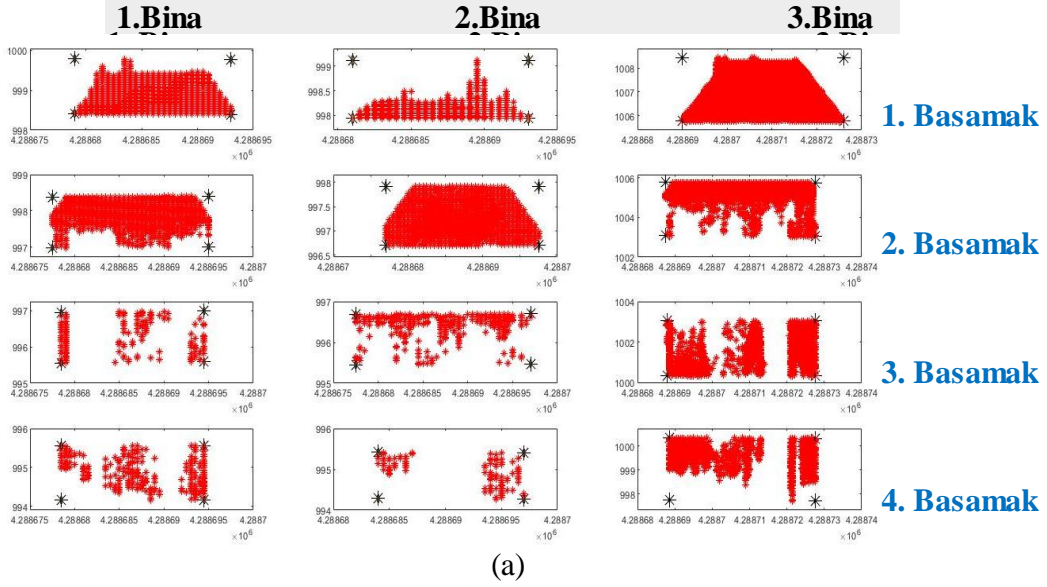
Tüm bu koşulların dışında göz ardı edilmemesi gereken bir diğer husus ise uygulamada hangi düzlemin doğru sonucu verebileceğine karar verebilmektir. Örneğin eğrisel bir bina tipi (X-Z) düzleminde profili incelendiğinde, üçgene yakın sonuç vereceği için koşullandırma doğru çalışabilecektir. Fakat (X-Z) eksenini binanın çatısındaki eğriselliği gösteremediği durumda sonuç doğru olmayacaktır (Şekil 3.14). Kısacası oluşturulan algoritma (X-Z) veya (Y-Z) düzlemlerinden birini temel alarak koşullandırmasını tamamlamalıdır.



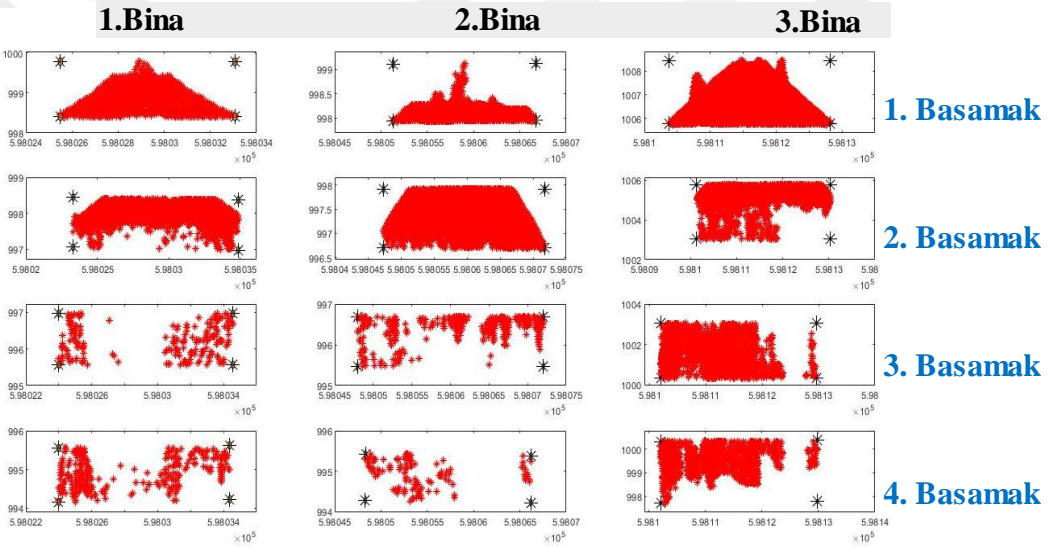
**Şekil 3.14.** Düzlemler arası fark analizi

Şekil 3.14'teki örneğe bakıldığında yeşil ok ile gösterilen kısımdan profil oluşturulduğu zaman ilk basamakta yarı daireye benzer şekilde noktalar dağılacakken, mavi ok ile gösterilen kısımdan çıkarılan profilden ise dörtgen şeklinde noktaların dağılımı söz konusu olacaktır. Bu görsele göre yeşil ok tarafından oluşturulacak düzlem seçilmelidir.

Hangi düzlemin istenilen çatı profilini doğru şekilde yansıttığını belirlemek için binaların her basamağı için hem Y-Z hem de X-Z düzleminde sonuçlar üretilmiştir (Şekil 3.15).



(a)



(b)

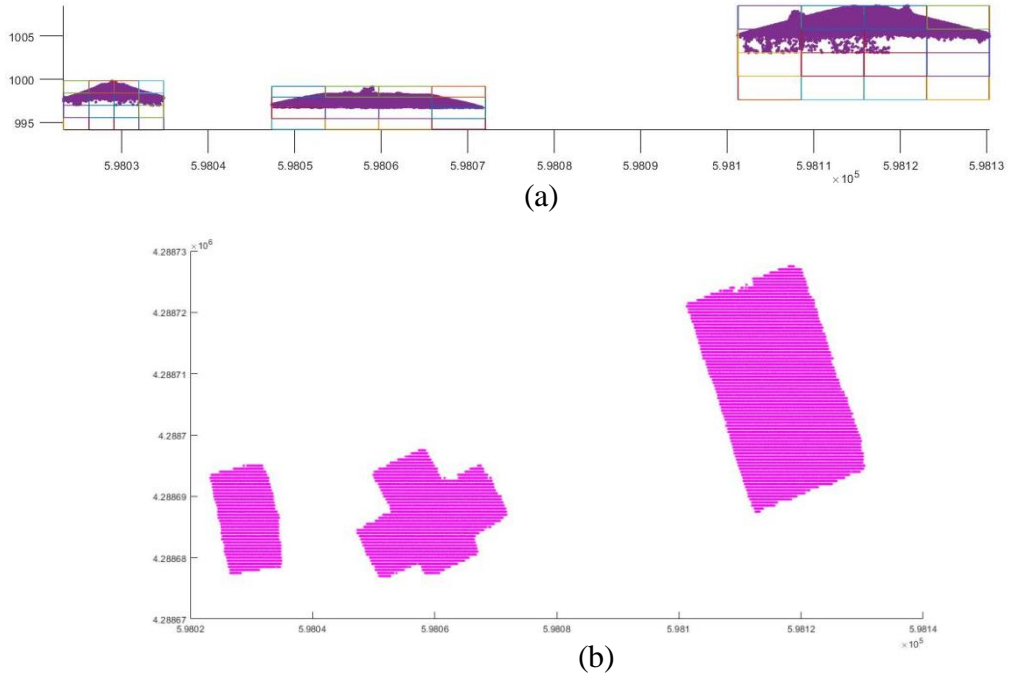
**Şekil 3.15.** Düzlemlerin karşılaştırılması; a) (X-Z) düzlemindeki basamak analizi, b) (Y-Z) düzlemindeki basamak analizi

Şekil 3.15'te görüldüğü üzere ele alınan bina sayısı kadar sütun, basamak sayısı kadar satırdan oluşan bir resim otomatik olarak her iki düzlem içinde oluşturulmuştur. Bu düzlemlerden sadece 1. basamaklar ele alındıktan sonra her bir bina için hangi düzlemin uygun olacağı seçilecektir. Aynı şekilde koşul her bir basamağın üstündeki iki buffer üzerinden gerçekleştirilecektir. Buna göre aşağıda I-Octree yaklaşımının temelinin oluşturulan düzlem belirleme koşulları sıralanmıştır.

- Her iki düzlem sonucunda da binanın, ilk basamağının üstteki iki buffer'ında da nokta bulunmuyorsa iki düzlemden herhangi bir tanesi seçilebilir,

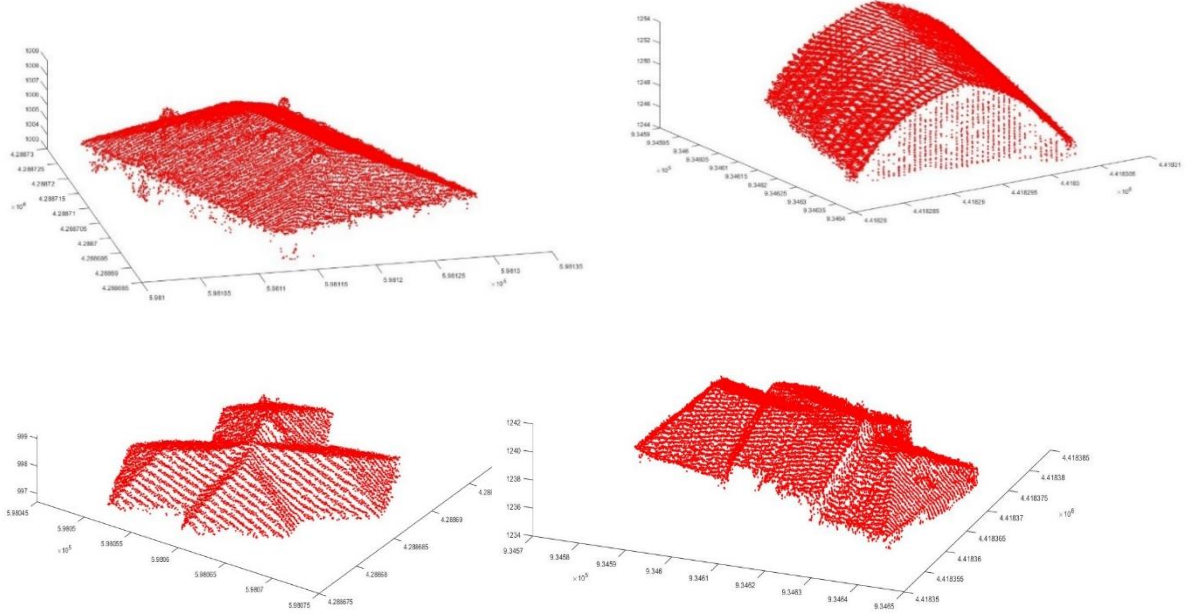
- (X-Z) düzleminin ilk basamağının üstteki iki buffer'ında nokta bulunuyor ve (Y-Z) düzleminde nokta bulunmuyorsa, ilgili bina (Y-Z) düzleminde işleme devam eder,
- (Y-Z) düzleminin ilk basamağının üstteki iki buffer'ında nokta bulunuyor ve (X-Z) düzleminde nokta bulunmuyorsa, ilgili bina (X-Z) düzleminde işleme devam eder,
- Her iki düzlemde de buffer içinde nokta bulunuyorsa bu bina çatısız bina tipindedir, herhangi bir düzlem seçilebilir.

Düzlem koşulları ve basamak analizleri tamamlandıktan sonra her bir binanın çatısına ait olabilecek noktalar I-Octree yaklaşımı ile otomatik bir şekilde belirlenmektedir (Şekil 3.16). Böylece Octree ile üretilen eş prizma ve basamak sayısının otomatizasyonunu sağlayan I-Octree yaklaşımı ortaya konmuştur. Önerilen bu yaklaşıma ilişkin sözde (pseudo) kod, ekler bölümünde sunulmuştur.



Şekil 3.16. I-Octree ile basamak analizi sonuçları; a) Y-Z düzlemi, b) Y-X düzlemi

Çıkarılan bina çatıları olabildiğince duvar noktalarından arındırılmaya çalışılmıştır. Bundan sonraki aşamalarda ise I-Octree ile çıkarılan bina noktalarından sınır çizdirilip bina sınırının regülarizasyonu yapılacaktır. Çıkarılan bina tiplerine örnekler Şekil 3.17’de gösterilmiştir.



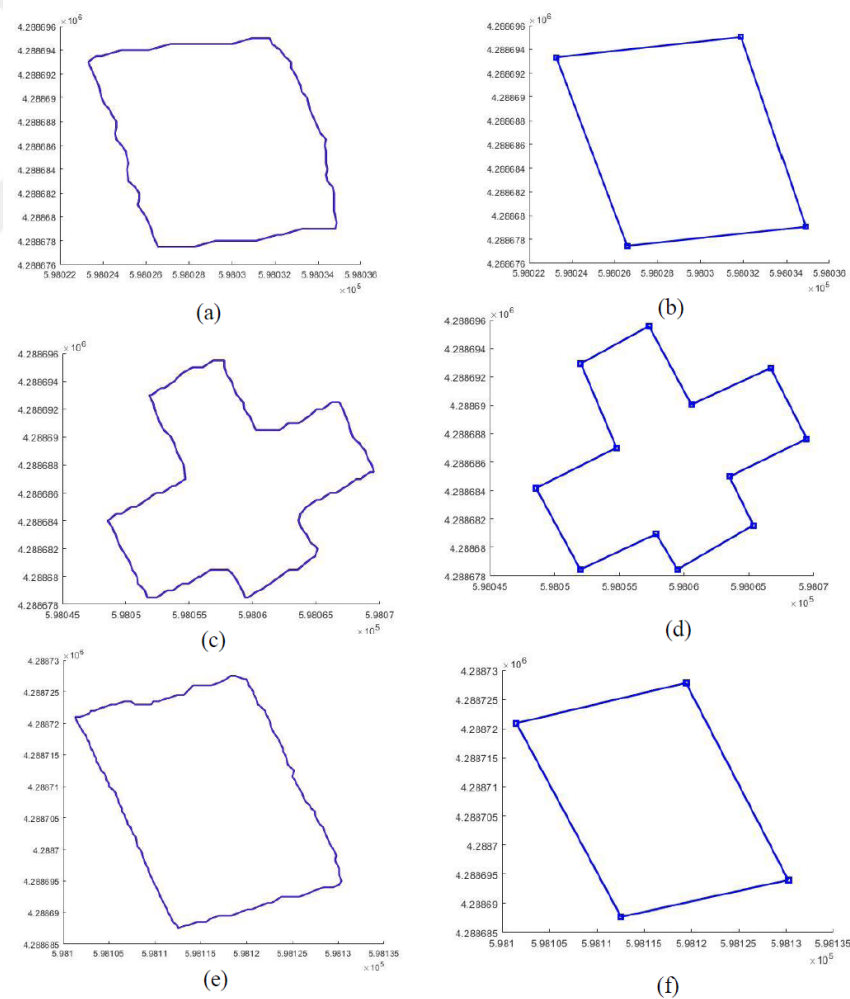
Şekil 3.17. I-Octree ile çıkarılan bina çatı tipleri

### 3.9 Bina Kenarlarının Regülarizasyonu

I-Octree yöntemi ile bina çatısına ait noktalar çıkarılmıştır. Bu noktalar içerisinde seçilecek noktalar ile bina çatısının dış sınırının çıkarılması ve ardından düzenlenmesi gerekmektedir. Bu işlem için öncelikle “*boundary*” fonksiyonu ile bina çatısının dış sınırı çizdirilmiştir (Şekil 3.18a, 3.18c ve 3.18e). Bu sınır düzensiz bir yapıya sahiptir. Ancak temel harita katmanı olan binanın dış sınırının zikzaklı ya da düzgün olmayan bir yapıda temsil edilmesi yanlıştır. Bu sebeple bina sınırının düzensiz yapıdan ortogonal (dik) yapıya dönüşümü sağlanmalıdır. Bina çatı sınırının regülarizasyonu ya da düzleştirilmesi için literatürde mevcut ABORE metodu kullanılmıştır (Ozdemir vd., 2021). ABORE metodu iki aşamadan oluşmaktadır.

Birinci aşamada yaklaşık bina köşe noktalarını, ikinci aşamada ise kesin köşe noktalarını belirlemektedir. Öncelikle her bir sınır noktasının öncesi ve sonrasından doğrular geçirilir. Bu doğrular arasındaki açı ve kesişim noktalarından aday köşe noktaları belirlenir. Bütün sınır noktaları için bu doğrular arasındaki açılar ve

doğruların kesişim noktaları belirlenir. Bina köşesine ait olabilecek aday sınır noktaları açı koşullandırması ile seçilir. İdeal köşe noktalarını belirlemek için aday köşe noktalarından belirlenen köşe seçme koşulunu sağlayan en iyi noktalar seçilir. İdeal köşe noktaları belirlendikten sonra hesaplanan doğru kesişim noktaları kullanılarak bina köşe noktaları belirlenir. Bu yöntem ile “*boundary*” fonksiyonun ürettiği sınır noktaları yerine hesaplanan köşe noktaları kullanılır. Böylece daha kesin köşe noktaları temsil edilir. Bu aşama ile esasen binanın yaklaşık köşe noktalarını tespit edilir. ABORE yöntemi ikinci aşaması ile bina kenar noktaları da düzenleme işlemine tabi tutulur. Hesaplanan yaklaşık köşe noktaları arasından her bir kenar için buffer geçirilir. Bu buffer’ların içindeki noktalara en iyi uyan doğrular çizilir ve bu doğruların kesişim noktaları ile kesin bina köşe noktaları belirlenir. Şekil 3.18’de ABORE yöntemi ile düzenlenen bina sınırına ait örnekler sunulmaktadır (Şekil 3.18b, 3.18d ve 3.18f).



Şekil 3.18. ABORE yöntemi ile bina regülarizasyonu

#### 4. BULGULAR VE TARTIŞMA

Tez çalışmasında seçilen üç farklı çalışma alanında ve yine farklı bina adedi ile belirlenen alt çalışma bölgelerinde, yöntem bölümünde detayları anlatılan I-Octree yöntemi ile bina detayları otomatik olarak çıkarılmış, çıkarılan bina kenarları ABORE yöntemi ile regularize edilmiştir. Uygulama için seçilen test alanı verileri fotogramterik nokta bulutu ile LiDAR nokta bulutundan oluşmakta olup, buradan amaç farklı özellikleri yönüyle birbirine rakip olan verilerden üretilen sonuçların karşılaştırılmasıdır.

Bu bölümde öncelikle, her bir veri setine yönelik nokta bulutlarından çıkarılan bina detaylarına ilişkin nicel ve nitel sonuçlar sunulmuştur. Nicel analiz literatürde genel geçer ve kabul görmüş piksel tabanlı değerlendirme tamlık ( $C_p$ ), doğruluk ( $C_r$ ), kalite ( $Q$ ) ve F-skor ( $F-1$ ) metrikleri kullanılarak gerçekleştirilmiş olup, nitel değerlendirme ise her bir çalışma alanı için temin edilen büyük ölçekli (1/1000 ve 1/5000) halihazır haritalar ile yapılmıştır. İkinci olarak, nitel sonuç bağlamında bina kenar detayı çıkarımı ya da vektörleştirme sonuçları değerlendirilmiştir. Son olarak ise, iki farklı veri ile elde edilen sonuçlar karşılaştırılmak suretiyle değerlendirilmiştir.

Test alanı verilerinin bir bölümünü oluşturan fotogramterik nokta bulutları, fotogramterik görüntülerden yoğun eşleştirme yöntemi ile elde edilmiştir. Bu işlemin gerçekleştirilebilmesi için görüntülerin yönlendirilmesi ve eşleştirme aşamalarına ihtiyaç vardır. Özellikle eşleştirme aşamasında, özellik seçimi, karşılıklı eşleşmeler, yama eşleşmesi ve yönlendirme parametrelerinin hassas tespiti gibi birçok faktör nokta bulutlarının kalitesini etkilemektedir. Bununla birlikte, LiDAR mesafeleri doğrudan ölçülebilir, dolayısıyla teorik olarak daha az faktör geometrik doğruluğu etkilemektedir. Fotogramterik nokta bulutlarının nokta yoğunluğu yüksek olmasına rağmen, daha fazla gürültü nedeniyle düşük geometrik doğruluğa sahiptirler.

##### 4.1 Test\_Alanı\_1 için Elde Edilen Bulgular ve Tartışma

Bu test alanı verileri Beyhan (Palu, Elazığ) bölgesine ait olup, fotogramterik yöntemle hâlihazır harita üretimi için çekilen görüntüler üzerinde fotogramterik eşleştirme yöntemi kullanılarak üretilmiştir. Çalışma alanı nokta bulutu üretimi Agisoft Metashape Profesyonel programı yardımıyla bölgeye ait bindirmeli görüntüler ile gerçekleştirilmiştir. Proje sahası için yönlendirme bilinmeyenleri temin edilerek 3B nokta

bulutuna ait her noktanın ilgili datum ve projeksiyonda koordinatları üretilmiştir. Bu test alanı farklı sayıda ve geometrik yapıda binaları içerecek şekilde üç alt çalışma alanına bölünmüştür. Bu alt alanlarda binalar *A1-A3*, *B1-B5* ve *C1-C5* harfleri ile gösterilmektedir. 1/1000 ve 1/5000 ölçekli halihazır haritalar nicel doğrulama metrikleri hesabı için kullanılmış, ayrıca üretilen bina sınırları bu haritalarla aynı referansa getirilmek suretiyle de görsel yorumlama ve değerlendirme yapılmıştır.

Bu test alanında seçilen alt çalışma bölgeleri için yapılan nicel değerlendirmede Cp, Cr, Q ve F-skor değerleri elde edilmiştir (Çizelge 4.1). Çizelge 4.1’de iki farklı yersel doğrulama verisi kullanılarak dört farklı metrik sonuçları üretilmiştir. Çizelge 4.1 incelendiğinde, 1/1000 ölçekli doğrulama haritası kullanılarak yapılan değerlendirmede, bütün bina gruplarının mevcut olduğu alt çalışma alanlarında tamlik metriğinin maksimum 0.9949, ortalama değer ise 0.9324, doğruluk metriğinin maksimum 0.9818, ortalama değer ise 0.9021, kalite metriği için maksimum 0.9470, ortalama değer ise 0.8471, F-1 metriğinin ise maksimum 0.9728, ortalama değer ise 0.9158 olduğu tespit edilmiştir. 1/5000 ölçekli doğrulama haritası kullanılması durumunda aynı test alanları için tamlik metriğinin maksimum 0.9958, ortalama değer ise 0.9339, doğruluk metriğinin maksimum 0.9637, ortalama değer ise 0.9115, kalite metriği için maksimum 0.9526, ortalama değer ise 0.8558, F-1 metriğinin ise maksimum 0.9757, ortalama değer ise 0.9216 olduğu tespit edilmiştir.

Her iki doğrulama haritası ve tüm bina alt gruplarının seçimi ile yapılan değerlendirmelerde önerilen iyileştirilmiş Octree (I-Octree) yaklaşımı sonuçları literatürle karşılaştırıldığında ideal düzeyde sonuçların elde edildiği görülmektedir (Çizelge 4.1). Seçilen bina grupları arasında A ile temsil edilen grubun geometrik olarak düzgün oluşu ve binaları temsil eden noktaların özellikle kenar bölgelerde mevcut oluşu doğruluk düzeyini artıran önemli bir etkidir.

**Çizelge 4.1.** Test\_Alanı\_1 doğruluk analizi sonuçları

Çalışma Alanı- Bina No	1/1000 Ölçekli Referans				1/5000 Ölçekli Referans			
	Cp	Cr	Q	F-1	Cp	Cr	Q	F-1
A-1	0.9266	0.9689	0.8998	0.9473	0.9148	<b>0.9637</b>	0.8843	0.9386
A-2	<b>0.9949</b>	0.8684	0.8645	0.9273	<b>0.9958</b>	0.8881	0.8848	0.9389
A-3	0.9640	<b>0.9818</b>	<b>0.9470</b>	<b>0.9728</b>	0.9681	0.9835	<b>0.9526</b>	<b>0.9757</b>
B-1	0.9311	0.9451	0.8833	0.9380	0.8976	0.9185	0.8314	0.9079
B-2	0.9295	0.9662	0.9002	0.9475	0.9053	0.9540	0.8675	0.9290
B-3	0.9254	0.8573	0.8019	0.8901	0.9551	0.9092	0.8720	0.9316

**Çizelge 4.1 (devam).** Test\_Alanı\_1 doğruluk analizi sonuçları

B-4	0.9097	0.9506	0.8686	0.9297	0.8984	0.9435	0.8525	0.9204
C-1	0.9398	0.9302	0.8778	0.9349	0.9428	0.9333	0.8833	0.9380
C-2	0.9877	0.8818	0.8722	0.9317	0.9871	0.8767	0.8667	0.9286
C-3	0.8789	0.8702	0.7771	0.8745	0.9008	0.8937	0.8136	0.8972
C-4	0.8633	0.8080	0.7163	0.8347	0.8920	0.8455	0.7670	0.8681
C-5	0.9374	0.7970	0.7567	0.8615	0.9495	0.8285	0.7935	0.8849
<b>Ortalama</b>	<b>0.9324</b>	<b>0.9021</b>	<b>0.8471</b>	<b>0.9158</b>	<b>0.9339</b>	<b>0.9115</b>	<b>0.8558</b>	<b>0.9216</b>

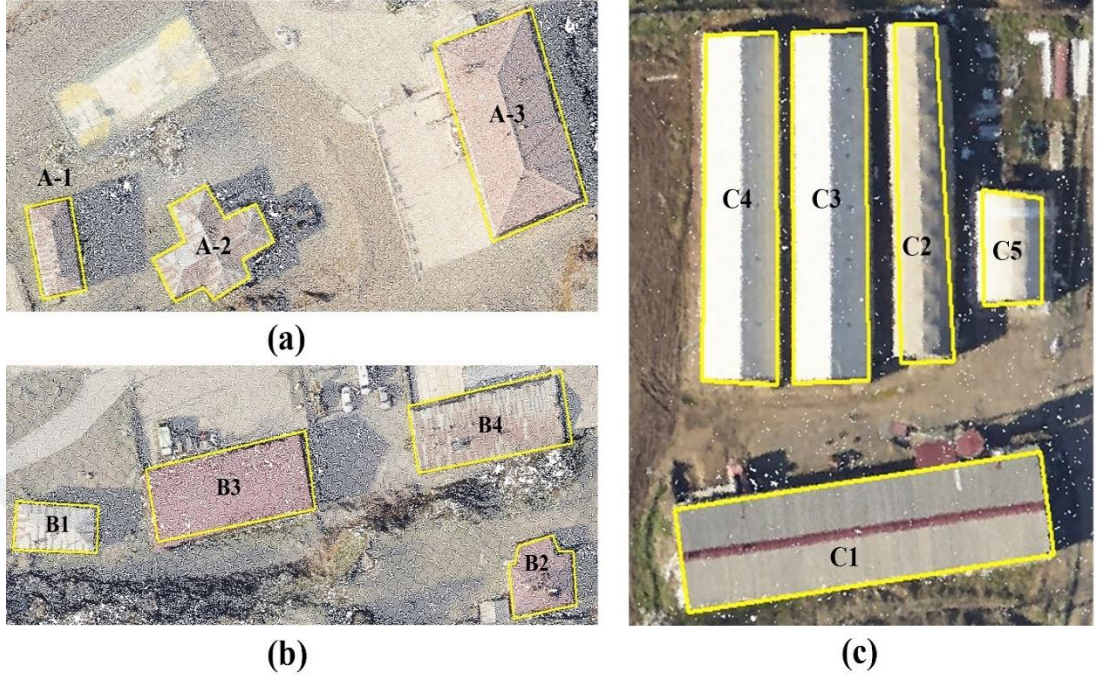
Klasik sekizdal veri organizasyon yönteminde veri içerisinde binayı temsil eden noktaların otomatik çıkarımı mümkün olmamakta ve basamak sayısı bu sebeple tespit edilememektedir. Önerilen yöntemin temel özelliği Çizelge 4.1’de sunulan doğruluk düzeylerine ulaşmada binaya ait noktaların kaçınıcı basamak ya da seviyede olabileceğinin otomatik tespit etmesidir. Çalışmada önerilen yaklaşımla Test\_Alanı\_1 için seçilen binaların hangi basamakta tespit edildiği Çizelge 4.2’de sunulmaktadır. Çizelge 4.2’ye göre bina çatı en üst noktası esas alınmak suretiyle üretilen basamak sayısı A ve B ile temsil edilen binalarda maksimum 3 iken C ile temsil edilen binalarda ise maksimum 4 basamak olarak belirlenmiştir. Böylece klasik sekizdal yönteminde nokta bulutu içerisinde binaya ait noktaların tespiti için sınırlandırılmayan basamak seviyesi de önerilen yöntemle otomatize edilerek sınırlandırılmıştır.

**Çizelge 4.2.** Test\_Alanı\_1 bina sınır tespiti basamak sayıları

Test Alanı	Bina No	Bina Çatı Çıkarımı Basamak Sayısı (i-Octree)
1	A-1	1-2
	A-2	1-2
	A-3	1-3
	B-1	1-2
	B-2	1-3
	B-3	1-2
	B-4	1-2
	C-1	1-2
	C-2	1-2
	C-3	1-4
	C-4	1-4
	C-5	1-4

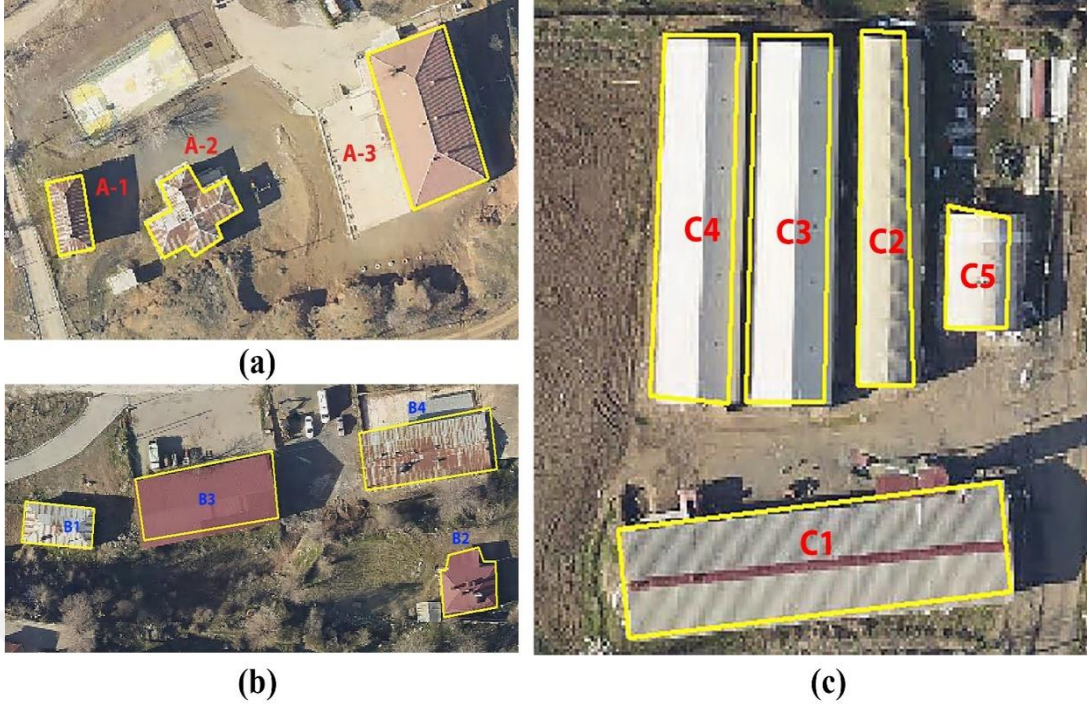
Nitel değerlendirme açısından Test\_Alanı\_1 alanında seçilen alt çalışma alanlarında mevcut binalar için üretilen sınırlar sırasıyla nokta bulutu, ortofoto ve 1/1000 ve 1/5000 ölçekli vektörel harita ile aynı referans sisteminde temsil edilmiştir. İlgili sonuçlar nokta bulutu için Şekil 4.1, ortofoto için Şekil 4.2 ve referans harita için Şekil

4.3'te sunulmuştur. Üç farklı sonuç ürün görsel yorumlandığında, nicel sonuçları destekler nitelikte sonuç değerlere ulaşıldığı net bir biçimde görülmektedir.



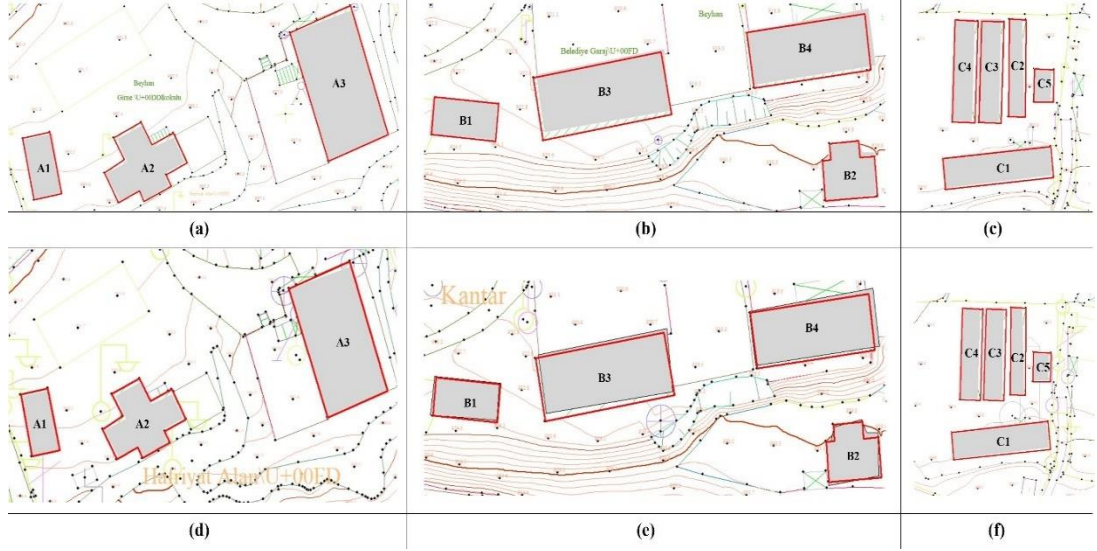
**Şekil 4.1.** Test\_Alanı\_1 bina kenar bilgileri ve nokta bulutu; a) A1-A3 alt bölgesi, b) B1-B4 alt bölgesi, c) C1-C5 alt bölgesi

Şekil 4.1 incelendiğinde özellikle B ve C ile temsil edilen binaların çıkarımının A ile temsil edilen binalara göre nispeten daha düşük doğrulukta olduğu görülmektedir. Buna sebep, nokta bulutu verisinin hem yoğunluğu hem de ilgili bölgede özellikle eşleşme problemlerinin varlığı gösterilebilir.



**Şekil 4.2.** Test\_Alanı\_1 bina kenar bilgileri ve ortofoto; a) A1-A3 alt bölgesi, b) B1-B4 alt bölgesi, c) C1-C5 alt bölgesi

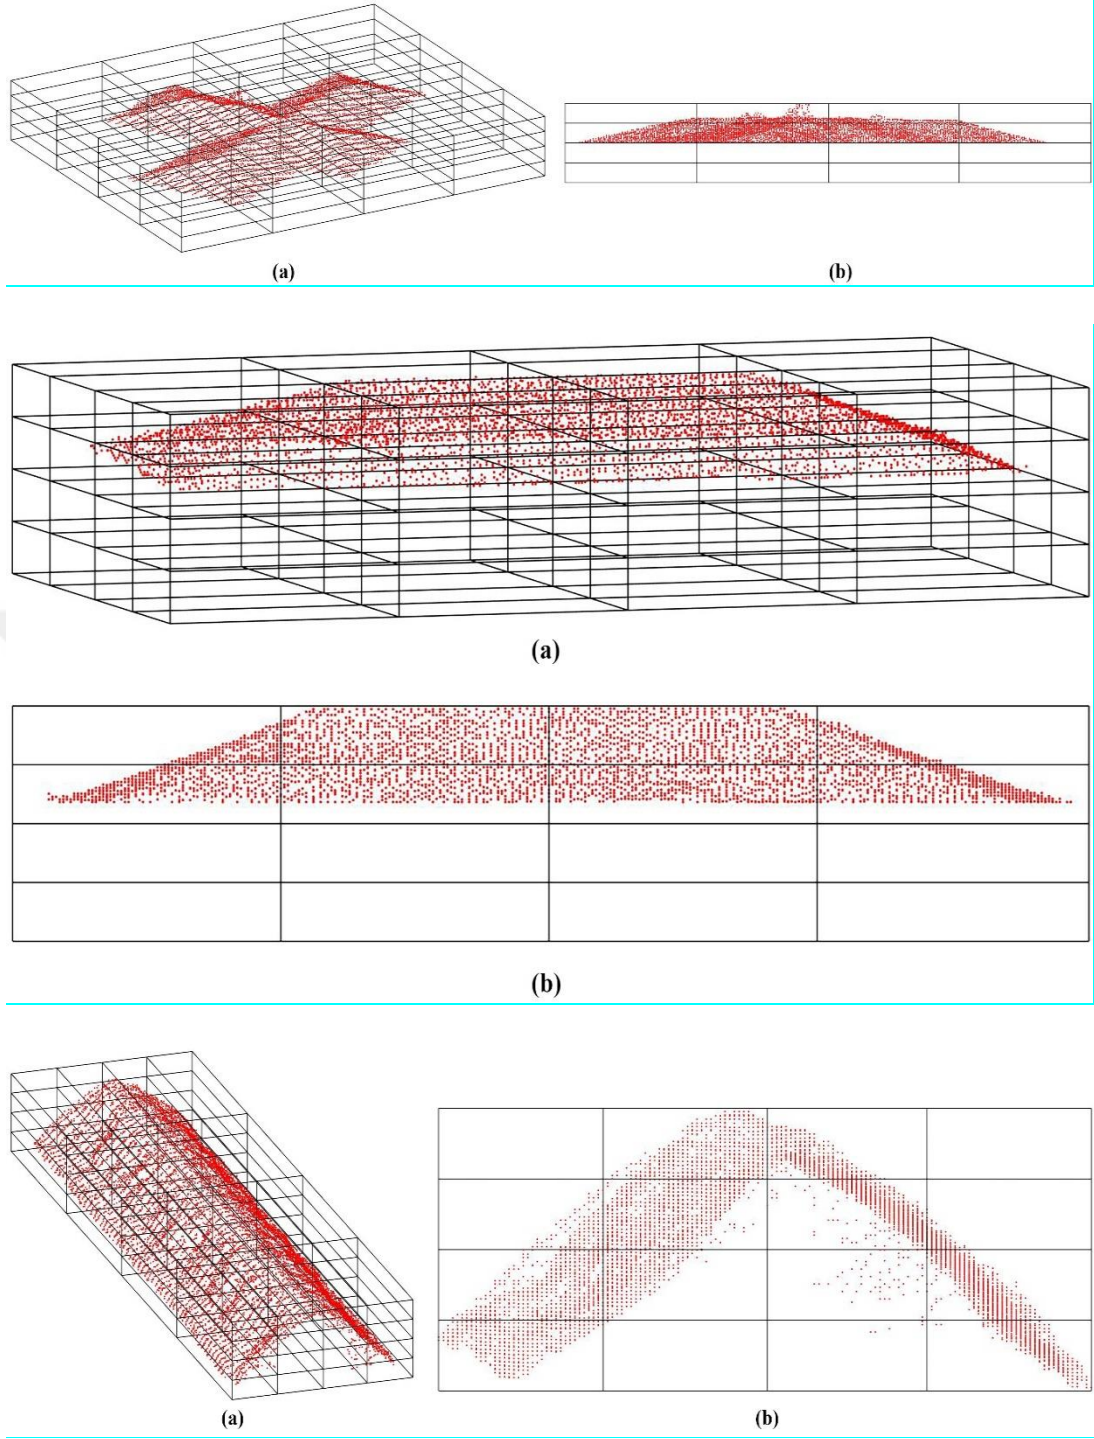
Şekil 4.2'den de görüldüğü üzere nicel analizlerle hesaplanan metriklere göre en ideal bina çıkarımının A ile temsil edilen binalarda olmaktadır. Ortofoto ile önerilen yaklaşım ile üretilen bina detaylarının kusursuz çakışması teorik olarak mümkün değildir. Dolayısıyla görselde belli miktar çakışmama hatası ortofoto doğruluğundan kaynaklanmaktadır.



**Şekil 4.3.** Test Alanı\_1 bina kenar bilgileri ve halihazır harita (1/1000 ve 1/5000); a) A1-A3 alt bölgesi, b) B1-B4 alt bölgesi, c) C1-C5 alt bölgesi, d) A1-A3 alt bölgesi, e) B1-B4 alt bölgesi, f) C1-C5 alt bölgesi

Şekil 4.3'te referans harita 1/1000 (a, b ve c) ve 1/5000 (d, e ve f) olması durumunda üretilen bina sınırlarının konumu gösterilmektedir. Her iki ölçekteki referans haritada, nicel analizlerle hesaplanan metriklere göre en ideal bina çıkarımının A ile temsil edilen binalarda olduğu görülmektedir. Ortofoto harita üzerindeki gösterime göre daha yüksek doğrulukta önerilen yaklaşım ile üretilen bina detaylarının çakıştığı ortadadır.

Bu test alanındaki her bina grubu için önerilen yöntemle otomatik tespit edilen basamak sayıları Şekil 4.4'te sunulmuştur. Şekil 4.4'ten her bir binanın sekizdal objelerinin yerleşimi sonucu kaçınıcı basamakta tespit edildiği net bir biçimde görülmektedir. Buna göre, 1. test alanında seçilen örnek binalardan A2 ve B1 için önerilen yöntemin bina sınır noktalarını 2. basamakta (Şekil 4.4a-4d), C3 binası için ise sınırları 4. basamakta (Şekil 4.4e-4f) tespit ettiği görülmektedir. Test alanlarında her bina için farklı basamak seviyelerinde tespit yapıldığı görülmektedir ki bu durum önerilen yöntemin ayrıca esnek ve her bina tipine göre sonuç üretebildiğini de ortaya koymaktadır.



**Şekil 4.4.** Test\_Alanı\_1 bina kenar bilgileri ve basamak durumları; a, b) A2 binası, c, d) B2 binası, e, f) C3 binası

#### 4.2 Test\_Alanı\_2 için Elde Edilen Bulgular ve Tartışma

Bu test alanı verileri Horasan (Erzurum) bölgesine ait olup, fotogrametrik yöntemle halihazır harita üretimi için İHA ile çekilen görüntüler üzerinde görüntü eşleştirme yöntemi kullanılarak üretilmiştir. Çalışma alanı için nokta bulutu Agisoft Metashape

Profesyonel programı yardımıyla bölgeye ait bindirmeli görüntüler üzerinden üretilmiştir. Yönelme bilinmeyenleri temin edilerek nokta bulutuna ait her noktanın ilgili datum ve projeksiyonda 3B uzay koordinatları üretilmiştir. İlgili test alanı farklı sayıda ve geometrik yapıda binaları içerecek şekilde iki alt test alanına ayrılmıştır. Bu alt alana ait binalar *DI-D4* ve *E1-E2* harfleri ile gösterilmektedir. 1/1000 ölçekli referans harita nicel doğrulama metrikleri hesabı için kullanılmış, ayrıca üretilen bina sınırları bu harita ile aynı referansa getirilmek suretiyle de görsel yorumlama ve değerlendirme yapılmıştır.

Bu test alanı için seçilen alt çalışma bölgeleri için yapılan nicel değerlendirmede  $C_p$ ,  $C_r$ ,  $Q$  ve  $F-1$  değerleri elde edilmiştir (Çizelge 4.3). Çizelge 4.3’de yersel doğrulama verisi kullanılarak dört farklı metrik sonuçları üretilmiştir. Çizelge 4.3 incelendiğinde, 1/1000 ölçekli doğrulama haritası kullanılarak yapılan değerlendirmede, bütün bina gruplarının mevcut olduğu alt test alanlarında tamlik metriğinin maksimum 0.9884, ortalama değer ise 0.97286, doğruluk metriğinin maksimum 0.9951, ortalama değer ise 0.9670, kalite metriği için maksimum 0.9754, ortalama değer ise 0.9467,  $F-1$  metriğinin ise maksimum 0.9875, ortalama değer ise 0.9725 olduğu tespit edilmiştir. Doğrulama haritası ve tüm bina alt gruplarının seçimi ile yapılan değerlendirmelerde önerilen iyileştirilmiş Octree (I-Octree) yaklaşımı sonuçları literatürle karşılaştırıldığında ideal düzeyde sonuçların elde edildiği görülmektedir (Çizelge 4.3). Seçilen bina grupları arasında D ve E ile temsil edilen grubun geometrik olarak düzgün oluşu ve binaları temsil eden noktaların özellikle bina kenar bölgelerde mevcut oluşu doğruluk düzeyini artıran önemli bir etkidir.

**Çizelge 4.3.** Test\_Alanı\_2 doğruluk analizi sonuçları

Çalışma Alanı Bina No	1/1000 Ölçekli Referans			
	$C_p$	$C_r$	$Q$	$F-1$
D-1	0.9858	0.9892	<b>0.9754</b>	<b>0.9875</b>
D-2	0.9814	0.9825	0.9646	0.9820
D-3	0.9816	0.9442	0.9278	0.9625
D-4	0.9666	<b>0.9951</b>	0.9620	0.9807
E-1	0.9677	0.9809	0.9498	0.9743
E-2	<b>0.9884</b>	0.9103	0.9007	0.9478
<b>Ortalama</b>	<b>0.9786</b>	<b>0.9670</b>	<b>0.9467</b>	<b>0.9725</b>


Önerilen yöntemin temel özelliği Çizelge 4.3’te sunulan doğruluk düzeylerine ulaşmada binaya ait noktaların kaçmıcı basamak ya da seviyede olabileceğinin

otomatik tespit edebilmesidir. Önerilen yaklaşımla Test\_Alanı\_2’de seçilen binaların hangi basamakta tespit edildiği Çizelge 4.4’te sunulmaktadır. Çizelge 4.4’e göre bina çatı en üst noktası esas alınmak suretiyle üretilen basamak sayısı D ve E ile temsil edilen binalarda maksimum 4 ve 3 basamak olarak belirlenmiştir. Böylece klasik sekizdal yönteminde nokta bulutu içerisinde binaya ait noktaları tespiti için sınırlandırılmayan basamak seviyesi de önerilen yöntemle bu çalışma alanında da otomatize edilmiştir.

**Çizelge 4.4.** Test\_Alanı\_2 bina sınır tespiti basamak sayıları

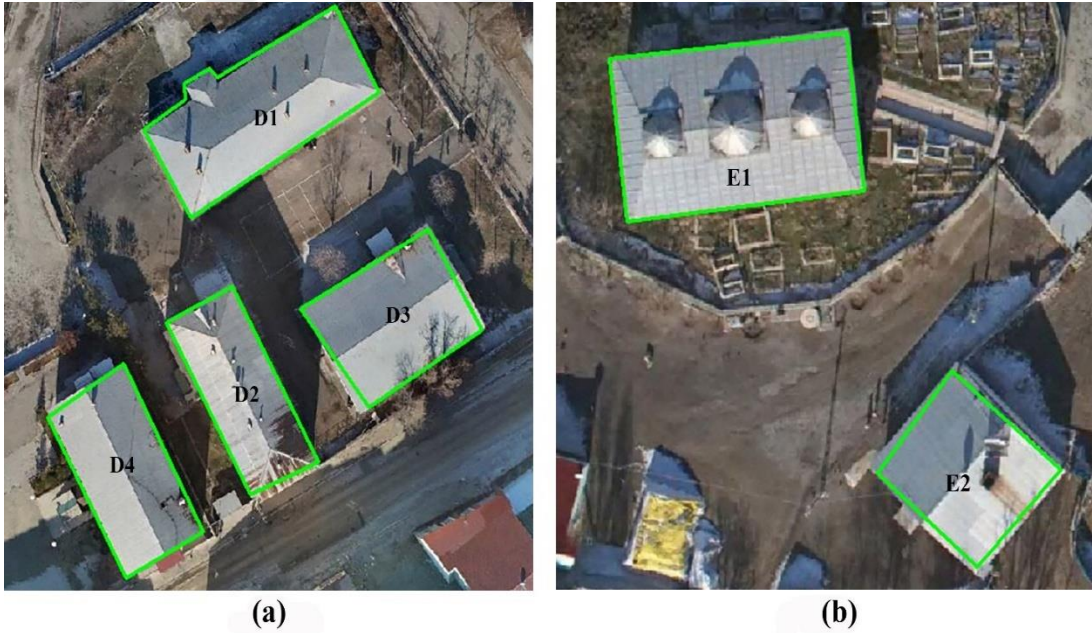
Test Alanı	Bina No	Bina Çatı Çıkarımı Basamak Sayısı (i- Octree)
2	D-1	1-3
	D-2	1-3
	D-3	1-4
	D-4	1-3
	E-1	1-3
	E-2	1-3

Nitel değerlendirme açısından Test\_Alanı\_2 alanında seçilen alt çalışma alanlarında mevcut binalar için üretilen sınırlar sırasıyla nokta bulutu, ortofoto ve 1/1000 ölçekli vektörel harita ile aynı referans sistemde temsil edilmiştir. İlgili sonuçlar nokta bulutu için Şekil 4.5, ortofoto için Şekil 4.6 ve referans harita için Şekil 4.7’de sunulmuştur. Üç farklı sonuç ürün görsel yorumlandığında, nicel sonuçları destekler nitelikte sonuç değerlere olduğu görülmektedir.



**Şekil 4.5.** Test\_Alanı\_2 bina kenar bilgileri ve nokta bulutu; a) D1-D4 alt bölgesi, b) E1-E2 alt bölgesi

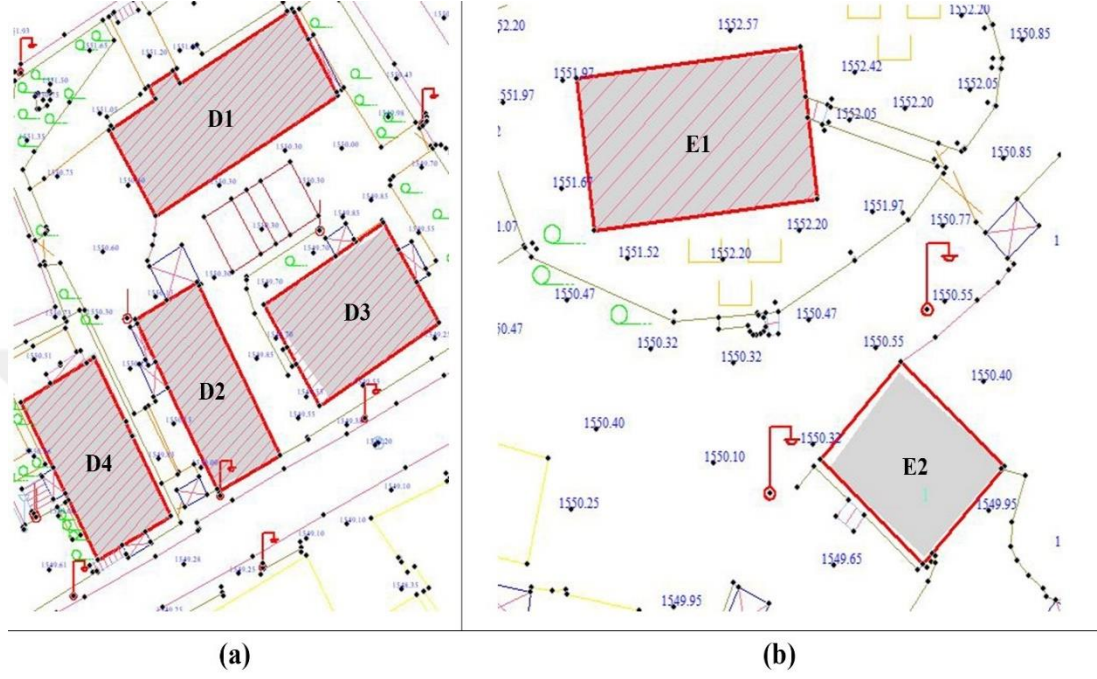
Şekil 4.5 incelendiğinde özellikle D ve E ile temsil edilen binaların çıkarımının yüksek doğrulukta olduğu görülmektedir. Nokta bulutu verisinin hem yoğunluğu hem de ilgili bölgede özellikle eşleşme problemi olmadığı değerlendirilmektedir.



**Şekil 4.6.** Test\_Alanı\_2 bina kenar bilgileri ve ortofoto; a) D1-D4 alt bölgesi, b) E1-E2 alt bölgesi

Şekil 4.6'dan da görüldüğü üzere nicel analizlerle hesaplanan metriklere göre D ve E ile temsil edilen binalarda ideal çıkarım mümkün olmaktadır. Ortofoto ile önerilen

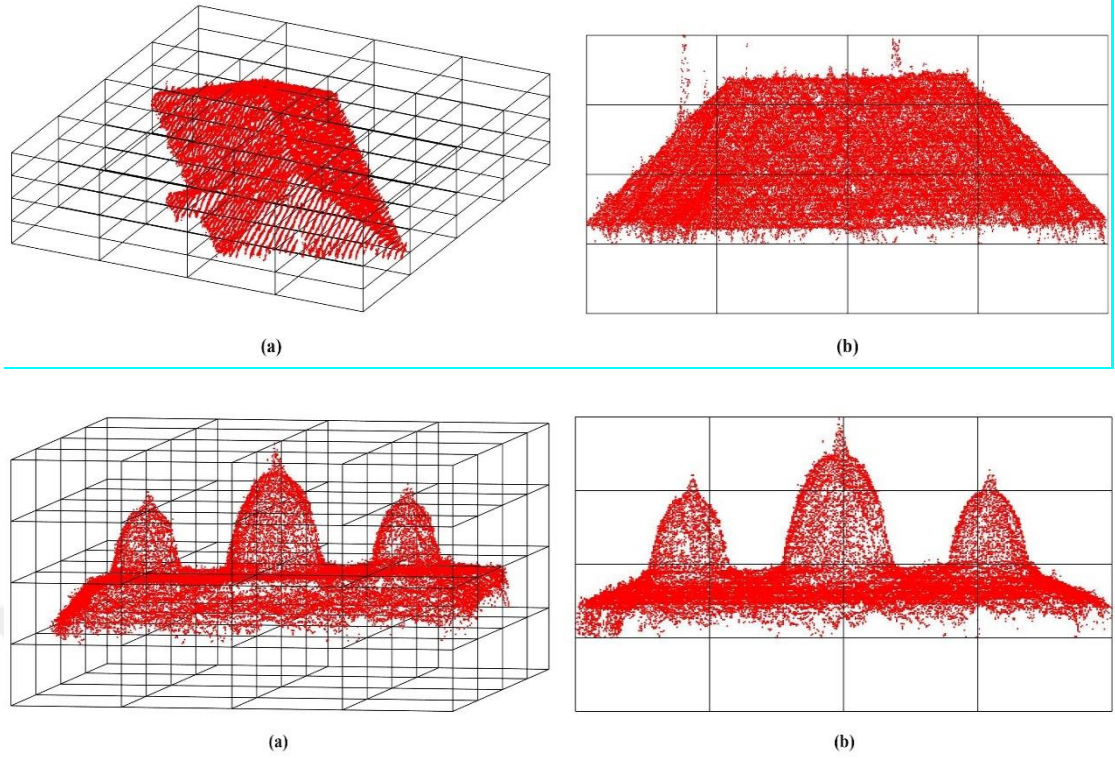
yaklaşım ile üretilen bina detaylarının kusursuz keşişmesi teorik olarak mümkün değildir. Dolayısıyla görselde belli miktar çakışmama hatası ortofoto doğruluğundan kaynaklanmaktadır.



**Şekil 4.7.** Test Alanı\_2 bina kenar bilgileri ve 1/1000 ölçekli halihazır harita; a) D1-D4 alt bölgesi, b) E1-E2 alt bölgesi

Şekil 4.7’de referans harita 1/1000 olması durumunda üretilen bina sınırlarının konumu gösterilmektedir. İlgili referans haritada, nicel analizlerle hesaplanan metriklere göre bina çıkarımının bütün binalarda ideal olduğu görülmektedir. Ortofoto harita üzerindeki gösterime göre daha yüksek doğrulukta önerilen yaklaşım ile üretilen bina detaylarının çakıştığı ortadadır.

Bu test alanındaki her bina grubu için önerilen yöntemle otomatik tespit edilen basamak sayıları Şekil 4.8’de sunulmuştur. Şekil 4.8’den her bir binanın sekizdal objelerinin yerleşimi sonucu kaçınıcı basamakta tespit edildiği net bir biçimde görülmektedir. Bu test alanında seçilen örnek binalardan D1 ve E1 için önerilen yöntemin bina sınır noktalarını 3. basamakta (Şekil 4.8a-8d) tespit ettiği görülmektedir. Bu çalışma alanında da elde edilen bulgular, test alanlarında her bina için farklı basamak seviyelerinde tespitin yapıldığını göstermektedir.



**Şekil 4.8.** Test\_Alanı\_2 bina kenar bilgileri ve basamak durumları; a, b) D1 binası, c, d) E1 binası

### 4.3 Test\_Alanı\_3 için Elde Edilen Bulgular ve Tartışma

Bu test alanı verileri Kaliforniya (Amerika) bölgesine ait olup, LiDAR ile halihazır harita üretimi için elde edilen nokta bulutunu içermektedir. Bütün veri setine ait nokta bulutu ilgili datum ve projeksiyonda 3B uzay koordinatları mevcuttur. İlgili test alanı farklı sayıda ve geometrik yapıda binaları içermektedir. Bu test alanında seçilen binalar *F1-F4* harfleri ile gösterilmektedir. 1/1000 ölçekli referans harita nicel doğrulama metrikleri hesabı için kullanılmış, ayrıca üretilen bina sınırları bu harita ile aynı referansa getirilmek suretiyle de görsel yorumlama ve değerlendirme yapılmıştır.

Bu test alanı için yapılan nicel değerlendirmede  $C_p$ ,  $C_r$ ,  $Q$  ve  $F-1$  değerleri elde edilmiştir (Çizelge 4.5). Çizelge 4.5'te yersel doğrulama verisi kullanılarak dört farklı metrik sonuçları üretilmiştir. Çizelge 4.5 incelendiğinde, 1/1000 ölçekli doğrulama haritası kullanılarak yapılan değerlendirmede, bütün bina gruplarının mevcut olduğu alt test alanlarında tamlik metriğinin maksimum 0.9999, ortalama değer ise 0.9966, doğruluk metriğinin maksimum 0.9997, ortalama değer 0.9939, kalite metriği için maksimum 0.9967, ortalama değer 0.9906,  $F-1$  metriğinin ise maksimum 0.9983,

ortalama deęerin 0.9953 olduęu tespit edilmiřtir. Bu veri setinin LiDAR verisi olması özellikle her metrik aısından st dzey doęruluk elde edilmesini saęlamıřtır. Fotogrametrik nokta bulutu verisine gre kalite aısından bu veri tipinin stn olduęunu ifade etmek mmkndr.

Doęrulama haritası ve tm binaların seimi ile yapılan deęerlendirmelerde nerilen iyileřtirilmiř Octree (I-Octree) yaklařımı ile literatrle karřılařtırıldıęında ideal dzeyde sonuların elde edildięi grlmektedir (izelge 4.5). Seilen binaların geometrik olarak dzgn oluřu ve binaları temsil eden noktaların zellikle kenar blgelede mevcut oluřu doęruluk dzeyini artıran nemli bir etkidir.

**izelge 4.5.** Test\_Alanı\_3 doęruluk analizi sonuları


alıřma Alanı- Bina No	1/1000 lekli Referans			
	Cp	Cr	Q	F-1
F-1	0.9977	0.9990	<b>0.9967</b>	<b>0.9983</b>
F-2	<b>0.9999</b>	0.9861	0.9861	0.9930
F-3	0.9945	0.9909	0.9855	0.9927
F-4	0.9945	<b>0.9997</b>	0.9942	0.9971
<b>Ortalama</b>	<b>0.9966</b>	<b>0.9939</b>	<b>0.9906</b>	<b>0.9953</b>

nerilen yntemin temel zellięi izelge 4.5'te sunulan doęruluk dzeylerine ulařmada binaya ait noktaların kaıncı basamak ya da seviyede olabileceęinin otomatik tespit edebilmesidir. nerilen yaklařımla Test\_Alanı\_3'te seilen binaların hangi basamakta tespit edildięi izelge 4.6'da sunulmaktadır. izelge 4.6'ya gre bina atı en st noktası esas alınmak suretiyle retilen basamak sayısı F ile temsil edilen binalarda maksimum 4 basamak olarak belirlenmiřtir. Bylece klasik sekizdal ynteminde nokta bulutu ierisinde binaya ait noktaları tespiti iin sınırlandırılmayan basamak seviyesi de nerilen yntemle bu alıřma alanında da otomatize edilmiřtir.

**izelge 4.6.** Test\_Alanı\_3 bina sınır tespiti basamak sayıları

Test Alanı	Bina No	Bina atı ıkarmı Basamak Sayısı (i-Octree)
3	F-1	1-4
	F-2	1-4
	F-3	1-4
	F-4	1-4

Nitel deęerlendirme aısından Test\_Alanı\_3 alanında seilen alıřma alanında mevcut binalar iin retilen sınırlar sırasıyla nokta bulutu, ortofoto ve 1/1000 lekli vektrel harita ile aynı referans sistemde temsil edilmiřtir. İlgili sonular nokta bulutu iin řekil 4.9, ortofoto iin řekil 4.10 ve referans harita iin řekil 4.11’de sunulmuřtur.  farklı sonu rnn grselleri yorumlandığında, nicel sonuları destekler nitelikte sonu deęerleri olduęu grlmektedir.



**řekil 4.9.** Test\_Alanı\_3 bina kenar bilgileri ve nokta bulutu (F1-F4 binaları)

řekil 4.9 incelendiğinde zellikle F ile temsil edilen binaların ıkarımının yksek doęrulukta olduęu grlmektedir. Nokta bulutu verisinin nokta yoęunluęunun dřk olmasına raęmen, LiDAR teknięi ile retilmiř olması en nemli etkendir.



**Şekil 4.10.** Test\_Alanı\_3 bina kenar bilgileri ve ortofoto (F1-F4 binaları)


Şekil 4.10'dan da görüldüğü üzere nicel analizlerle hesaplanan metriklere göre F ile temsil edilen binalarda ideal ve üst düzey çıkarım mümkün olmaktadır. Ortofoto ile önerilen yaklaşım ile üretilen bina detaylarının kusursuz örtüşmesi teorik olarak mümkün değildir. Dolayısıyla görsekte belli miktar çakışmama hatası ortofoto doğruluğundan kaynaklanmaktadır.



**Şekil 4.11.** Test Alanı\_3 bina kenar bilgileri ve 1/1000 ölçekli halihazır harita (F1-F4 binaları)

Şekil 4.11’de referans harita 1/1000 olması durumunda üretilen bina sınırlarının konumu gösterilmektedir. İlgili referans haritada, nicel analizlerle hesaplanan metriklere göre en ideal bina çıkarımının bütün binalarda olduğu görülmektedir. Ortofoto harita üzerindeki gösterime göre daha yüksek doğrulukta önerilen yaklaşım ile üretilen bina detaylarının çakıştığı ortadadır.

Bu test alanındaki her bina grubu için önerilen yöntemle otomatik tespit edilen basamak sayıları Şekil 4.12’de sunulmuştur. Şekil 4.12’den her bir binanın sekizdalı objelerinin yerleşimi sonucu kaçınıcı basamakta tespit edildiği net bir biçimde görülmektedir. Bu test alanında da seçilen örnek bina F3 için önerilen yöntemin bina sınır noktalarını 4. basamakta (Şekil 4.12a-12b) tespit ettiği görülmektedir. Dolayısıyla, bu çalışma alanında da elde edilen bulgular, test alanlarında her bina için farklı basamak seviyelerinde tespitin yapıldığını göstermektedir.



**Şekil 4.12.** Test\_Alanı\_3 bina kenar bilgileri ve basamak durumları; a, b) F3 binası



## 5. SONUÇLAR VE ÖNERİLER

Bu çalışmada, uzaktan algılanmış verilerden bina detayları/sınırlarını çıkarmak için fotogrametrik teknikle eşleştirme ve LiDAR teknolojisi ile üretilmiş nokta bulutları kullanılmıştır. Çalışmanın metodolojik temeli, voksel mantığı ile çalışan sekizdal (Octree) veri organizasyon metodunun otomatize edilmesi sonucu geliştirilen ve önerilen yeni yaklaşıma (iyileştirilmiş Octree, I-Octree) dayanmaktadır. Fotogrametrik görüntülerden üretilen nokta bulutları ile LiDAR nokta bulutları kullanılarak bina detay bilgilerinin önerilen yöntemle otomatik çıkarımı, düzgünleştirilmesi ve dolayısıyla sayısallaştırılması gerçekleştirilmiştir.

Çalışmada 3B fotogrametrik nokta bulutları görüntülerden üretilmiş, LiDAR nokta bulutu ise temin edilmiştir. Nokta bulutlarından zemin ve zemin üstü objeler SMRF metodu ile ayrılmış ve DBSCAN algoritması ile bina objeleri gürültülerden aykılanarak sınıflandırılmıştır. Sekizdal ve iyileştirilmiş sekizdal (I-Octree) veri organizasyonunun sınıflandırılan objelere uygulanması ile bina detaylarına ait sınır veya kenar bilgileri çıkarılmasını takiben ABORE metodu ile bina kenarlarının düzgünleştirilmesi gerçekleştirilmiştir.

Önerilen yaklaşım (I-Octree) ile, üç farklı test bölgesi için alt çalışma alanlarına ait nokta bulutu üzerinden bina detayları çıkarılmış ve her bir bölge için doğrulama amaçlı olarak kullanılan referans hâlihazır harita verileri ile nicel ve nitel açıdan doğruluk analizi işlemi gerçekleştirilmiştir. Objeye tabanlı doğrulama için, Cp, Cr, Q ve F-1 metrikleri/ölçütleri kullanılmıştır. Nicel değerlendirme aşamasında, fotogrametrik görüntülerden eşleştirme yöntemi ile üretilen farklı nokta yoğunluğuna sahip nokta bulutu kullanılması durumunda test alanlarında doğrulama sonuçları her bir metrik için maksimum değer %94 üzerinde elde edilirken, LiDAR nokta bulutunun mevcut olduğu test alanında ise bu değer %99 üzerinde hesaplanmıştır. Görsel açıdan yapılan değerlendirmelerde ise, önerilen yöntemle çıkarılan bina sınırlarının çalışma bölgelerine ait ortofoto, nokta bulutu ve farklı ölçekteki referans harita verileri ile karşılaştırılması sonucu üst düzeyde eşleşmenin olduğu sonucuna varılmıştır. Bunun bir sonucu olarak, referans verileri ile yapılan doğrulama sonucunda, önerilen yaklaşımın test alanlarında farklı sayıda ve kombinasyonda seçilen tüm binaları yüksek doğrulukla çıkarabildiği görülmüştür.

Yaklaşımın fotogrametrik eşleştirme yöntemi ile üretilen nokta bulutundan elde edilen bina verilerine kıyasla, LiDAR verileri üzerinde daha yüksek doğruluk sağladığı sonucu ayrıca ortaya konulmuştur. Çalışma ile, gerek fotogrametrik yöntemle üretilmiş nokta bulutları gerekse LiDAR nokta bulutları üzerinden sekizdal veri organizasyon yöntemini otomatize eden yaklaşımla (I-Octree) daha hızlı, etkin ve ucuz bir harita üretimi sürecine katkıda bulunabileceği sonucuna varılmıştır.

Gerçekleştirilen kapsamlı analizler iki veri türü arasında iyi bir tutarlılık olduğunu göstermiştir. Bununla birlikte, LiDAR verileriyle karşılaştırıldığında, fotogrametrik nokta bulutları optik veriden üretilmiş olmaları sebebiyle kısmen daha düşük bina çıkarma doğruluğu sağlamaktadır. Ancak nicel doğruluk düzeyi her metrik için yaklaşık olarak %95 seviyelerinde olduğu gerçeği de yadsınmazdır. Yöntemin gerçek kentsel alanların LiDAR ve fotogrametrik verilerine uygulanması sonucu bina detaylarının çıkarılmasındaki etkinliği niceliksel ve niteliksel olarak görülmüştür. Fotogrametrik nokta bulutlarının LiDAR bulutlarından daha düşük geometrik doğruluk sağladığına dikkat edilmelidir. Bununla birlikte, fotogrametrik nokta bulutlarının nokta yoğunluğu çok daha yüksektir ve çok daha fazla gereksiz veri içermektedirler.

Sonuç olarak, bu çalışma ile değişik kaynaklarca üretilmiş farklı yoğunluktaki nokta bulutlarından otomatik bir biçimde bina detay çıkarımı ve sayısallaştırma işleminin gerçekleştirilebileceği ortaya çıkarılmıştır.

Gerçekleştirilen bu çalışma ile nokta bulutlarından özellikle harita temel katmanı bina detayının etkin, otomatik ve hızlı bir biçimde çıkarılabileceği ortaya konmuştur. Son yıllarda görüntü tabanlı sistemlerdeki gelişmeler ve İHA tabanlı optik veri üretimindeki kolaylıklar, bu platformlardan alınan görüntülerden üretilen nokta bulutları üzerinden bina çıkarma işlemini daha da önemli konuma getirmiştir. Bu bağlamda günümüz ve yakın gelecekte 3B veri üzerinden ölçüm ve analiz işleminin öneminin çalışma sonuçları dikkate alındığında artacağı değerlendirilmektedir.

Bina detayı çıkarımı ve sayısallaştırılması, 3B Coğrafi Bilgi Sistemleri, kentsel temel coğrafi veri tabanı güncelleme, kentsel planlama, çevresel benzetim, afet yönetimi, dijital haritalama, ulaşım planlaması, arazi ve kadastral yönetim, turizm, mobil navigasyon, enerji çalışmaları ve telekomünikasyon ağ tasarımı gibi farklı alanlarda bilgi edinmenin en önemli yolu olduğu düşünüldüğünde, uzaktan algılama

teknolojileri arasında, 3B özellikler sağlama yeteneği ile LiDAR ve fotogrametrik görüntülerden eşleştirme ile üretilen nokta bulutları bina çıkarımı için en önde gelen önemli araçlardır.

Özet olarak, binaları 3B nokta bulutu veri kümelerinden çıkarırken, LiDAR verileri kullanılmıyorsa, fotogrametrik eşleştirme yöntemi ile üretilmiş nokta bulutlarının kullanımı iyi bir seçenek olarak değerlendirilmelidir. Bununla birlikte, fotogrametrik nokta bulutlarına dayalı kentsel bina çıkarımı için çoklu görüntüler dikkate alınmalı ve gürültü giderme işlemi ciddi bir biçimde yapılmalıdır.

Eğrisel ve çok ayrıntılı geometriye sahip binalar üzerinde önerilen yöntemin uygulanması ve performans değerlendirmesi gelecekte yapılması gereken bina çıkarımı çalışmaları açısından önem arz etmektedir. Ayrıca, binaların ayak izi çıkarımının yanında otomatik 3B bina modeli üretimi de bu çalışmanın gelecekte evrilmesi gereken nokta olarak değerlendirilebilir.

Sonuç olarak bir değerlendirme yapmak gerekirse, herhangi bir otomasyon işleminin %100 doğruluk ve bütünlük sağlaması olası değildir. Bu nedenle, veri denetimi ve düzenlemesinin operatör desteğiyle yapılması mutlaka gereklidir. Rutin üretim için, bu düzenleme görevini kolaylaştırmak ve hızlandırmak için yöntemler veya araçların geliştirilmesi bilimsel açıdan her zaman değerli olacaktır.

## KAYNAKLAR

- Abdollahi, A., Pradhan, B., Gite, S. ve Alamri, A. 2020. Building footprint extraction from high resolution aerial images using generative adversarial network (GAN) architecture. *IEEE Access*, 8.
- Acar, H. 2012. Nokta belirleme algoritmaları ile otomatik görüntü eşleştirme. Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Karadeniz Teknik Üniversitesi.
- Acar, H. 2018. Bina çatı noktalarının yüksek çözünürlüklü görüntülerden üretilen 3B nokta bulutu verileri ile otomatik tespit edilmesi ve gerçek ortofoto üretimi. Doktora Tezi, Fen Bilimleri Enstitüsü, Karadeniz Teknik Üniversitesi.
- Acar, H., Karsli, F., Ozturk, M. ve Dihkan, M. 2019. Automatic detection of building roofs from point clouds produced by the dense image matching technique. *International Journal of Remote Sensing*, 40(1), 138–155.
- Akbulut, Z., Özdemir, S., Acar, H. ve Karşlı, F. 2018. Automatic building extraction from image and LiDAR data with active contour segmentation. *Journal of the Indian Society of Remote Sensing*, 46(12), 2057-2068.
- Alidoost, F. ve Arefi, H. 2015. An image-based technique for 3D building reconstruction using multi-view UAV images. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XL-1/W5, Kish Island, Iran, 43-46.
- Alidoost, Fatemeh, Arefi, H. ve Tombari, F. 2019. 2D image-to-3D model: knowledge-based 3D building reconstruction (3DBR) using single aerial images and convolutional neural networks (CNNs). *Remote Sensing*, 11(19), 1-25.
- Awrangjeb, M., Zhang, C. ve Fraser, C. S. 2012. Automatic reconstruction of building roofs through effective integration of LiDAR and multispectral imagery. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, I-3, XXII ISPRS Congress, Melbourne, Australia, 203-208.
- Awrangjeb, M., Gilani, S. A. N. ve Siddiqui, F. U. 2018. An effective data-driven method for 3D building roof reconstruction and robust change detection. *Remote Sensing*, 10(10), 1-31.
- Awrangjeb, M., Ravanbakhsh, M. ve Fraser, C. S. 2010. Automatic building detection using LiDAR data and multispectral imagery. *Digital Image Computing: Techniques and Applications*, DICTA 2010, 45-51.
- Axelsson, P. 2000. DEM Generation from laser scanner data using adaptive TIN models. *International Archives of Photogrammetry and Remote Sensing*, 23(B4), Amsterdam, Netherlands, 110-117.
- Baatz, M. ve Schape, A. 2000. Multiresolution segmentation - an optimization approach for high quality multi-scale image segmentation. *Angewandte Geographische Informations-Verarbeitung*, XII, Wichmann Verlag, Karlsruhe, Germany, 12-23.
- Benciolini, B., Ruggiero, V., Vitti, A. ve Zanetti, M. 2018. Roof planes detection via a second-order variational model. *ISPRS Journal of Photogrammetry and Remote Sensing*, 138, 101-120.

- Brédif, M., Tournaire, O., Vallet, B. ve Champion, N. 2013. Extracting polygonal building footprints from digital surface models: A fully-automatic global optimization framework. *ISPRS Journal of Photogrammetry and Remote Sensing*, 77, 57-65.
- Bulatov, D., Häufel, G., Meidow, J., Pohl, M., Solbrig, P. ve Wernerus, P. 2014. Context-based automatic reconstruction and texturing of 3D urban terrain for quick-response tasks. *ISPRS Journal of Photogrammetry and Remote Sensing*, 93, 157-170.
- Cao, R., Zhang, Y., Liu, X. ve Zhao, Z. 2017. Roof plane extraction from airborne lidar point clouds. *International Journal of Remote Sensing*, 38(12), 3684-3703.
- Cao, Z., Fu, K., Lu, X., Diao, W., Sun, H., Yan, M., Yu, H. ve Sun, X. 2019. End-to-end DSM fusion networks for semantic segmentation in high-resolution aerial images. *IEEE Geoscience and Remote Sensing Letters*, 16(11), 1766-1770.
- Chen, C., Guo, J., Wu, H., Li, Y. ve Shi, B. 2021. Performance comparison of filtering algorithms for high-density airborne lidar point clouds over complex landscapes. *Remote Sensing*, 13(14), 1-19.
- Chen, R., Li, X. ve Li, J. 2018. Object-based features for house detection from RGB high-resolution images. *Remote Sensing*, 10(3), 1-24.
- Chen, S., Shi, W., Zhou, M., Zhang, M. ve Chen, P. 2020. Automatic building extraction via adaptive iterative segmentation with LiDAR data and high spatial resolution imagery fusion. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 2081-2095.
- Christian Rose, J., Paulus, S. ve Kuhlmann, H. 2015. Accuracy analysis of a multi-view stereo approach for phenotyping of tomato plants at the organ level. *Sensors (Switzerland)*, 15(5), 9651-9665.
- Dal Poz, A. P. ve Yano Ywata, M. S. 2020. Adaptive random sample consensus approach for segmentation of building roof in airborne laser scanning point cloud. *International Journal of Remote Sensing*, 41(6), 2047-2061.
- Dehbi, Y., Henn, A., Gröger, G., Stroh, V. ve Plümer, L. 2021. Robust and fast reconstruction of complex roofs with active sampling from 3D point clouds. *Transactions in GIS*, 25(1), 112-133.
- Dong, Y., Zhang, L., Cui, X., Ai, H. ve Xu, B. 2018. Extraction of buildings from multiple-view aerial images using a feature-level-fusion strategy. *Remote Sensing*, 10(12), 1-30.
- Dorninger, P. ve Pfeifer, N. 2008. A comprehensive automated 3D approach for building extraction, reconstruction, and regularization from airborne laser scanning point clouds. *Sensors*, 8(11), 7323-7343.
- Du, S., Zhang, Y., Zou, Z., Xu, S., He, X. ve Chen, S. 2017. Automatic building extraction from LiDAR data fusion of point and grid-based features. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 294-307.
- Dybedal, J., Aalerud, A. ve Hovland, G. 2019. Embedded processing and compression of 3D sensor data for large scale industrial environments. *Sensors*, 19(3), 1-20.

- Egels, Y. ve Kasser, M. 2001. Digital photogrammetry. 1st Edition, CRC Press, London, 376 pp.
- Ester, M., Kriegel, H.-P., Sander, J. ve Xu, X. 1996. A density-based algorithm for discovering clusters in large spatial databases with noise. Proceedings of the 2nd International Conference on Knowledge Discovery and Data Mining, Portland, United States, 405 pp.
- Gao, X., Shen, S., Zhou, Y., Cui, H., Zhu, L. ve Hu, Z. 2018. Ancient Chinese architecture 3D preservation by merging ground and aerial point clouds. ISPRS Journal of Photogrammetry and Remote Sensing, 143, 72-84.
- Gilani, S. A. N., Awrangjeb, M. ve Lu, G. 2016. An automatic building extraction and regularisation technique using LiDAR point cloud data and orthoimage. Remote Sensing, 8(3), 1-27.
- Guerra-Hernández, J., Cosenza, D. N., Rodriguez, L. C. E., Silva, M., Tomé, M. ve Díaz-Varela, R. A., González-Ferreiro, E. 2018. Comparison of ALS- and UAV(SfM)-derived high-density point clouds for individual tree detection in Eucalyptus plantations. International Journal of Remote Sensing, 39(15–16), 5211-5235.
- Guo, L., Deng, X., Liu, Y., He, H., Lin, H., Qiu, G. ve Yang, W. 2021. Extraction of dense urban buildings from photogrammetric and LiDAR point clouds. IEEE Access, 9, 111823-111832.
- Haala, N. ve Kada, M. 2010. An update on automatic 3D building reconstruction. ISPRS Journal of Photogrammetry and Remote Sensing, 65(6), 570-580.
- Hartley, R. ve Zisserman, A. 2004. Multiple view geometry in computer vision. 2nd Edition, Cambridge University Press, 532 pp.
- Hermosilla, T., Ruiz, L. A., Recio, J. A. ve Estornell, J. 2011. Evaluation of automatic building detection approaches combining high resolution images and LiDAR data. Remote Sensing, 3(6), 1188-1210.
- Hirschmüller, H. 2008. Stereo processing by semiglobal matching and mutual information. IEEE Transactions on Pattern Analysis and Machine Intelligence, 30(2), 328-341.
- Hirschmüller, H. 2011. Semi-global matching motivation, developments and applications. Photogrammetric Week, DLR, 173-184.
- Huang, X., Han, Y. ve Hu, K. 2020. An improved semi-global matching method with optimized matching aggregation constraint. IOP Conference Series: Earth and Environmental Science, 569, 1-9.
- Hui, Z., Li, Z., Cheng, P., Ziggah, Y. Y. ve Fan, J. 2021. Building extraction from airborne lidar data based on multi-constraints graph segmentation. Remote Sensing, 13(18), 1-21.
- Iman Zolanvari, S. M., Ruano, S., Rana, A., Cummins, A., Da Silva, R. E., Rahbar, M. ve Smolic, A. 2020. DublinCity: Annotated LiDAR point cloud and its applications. 30th British Machine Vision Conference 2019, 1-13.
- Jayaraj, P. ve Ramiya, A. M. 2018. 3D CityGML building modelling from lidar point

- cloud data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-5, Dehradun, India, 175-180.
- Ji, S., Wei, S. ve Lu, M. 2019. A scale robust convolutional neural network for automatic building extraction from aerial and satellite imagery. *International Journal of Remote Sensing*, 40(9), 3308-3322.
- Karsli, F., Dihkan, M., Acar, H. ve Ozturk, A. 2016. Automatic building extraction from very high-resolution image and LiDAR data with SVM algorithm. *Arabian Journal of Geosciences*, 9, 1-12.
- Kendall, A., Martirosyan, H., Dasgupta, S., Henry, P., Kennedy, R., Bachrach, A. ve Bry, A. 2017. End-to-end learning of geometry and context for deep stereo regression. *Proceedings of the IEEE International Conference on Computer Vision*, 1-10.
- Konecny, G. 2003. *Geoinformation, remote sensing, photogrammetry and geographical information systems*. 1st Edition, CRC Press, London, 264 pp.
- Kulawardhana, R. W., Popescu, S. C. ve Feagin, R. A. 2014. Fusion of LiDAR and multispectral data to quantify salt marsh carbon stocks. *Remote Sensing of Environment*, 154, 345-357.
- Kwak, E. ve Habib, A. 2014. Automatic representation and reconstruction of DBM from LiDAR data using Recursive Minimum Bounding Rectangle. *ISPRS Journal of Photogrammetry and Remote Sensing*, 93, 171-191.
- Lai, X., Yang, J., Li, Y. ve Wang, M. 2019. A building extraction approach based on the fusion of LiDAR point cloud and elevation map texture features. *Remote Sensing*, 11(14), 1-18.
- Li, H., Qin, J., Xiang, X., Pan, L., Ma, W. ve Xiong, N. N. 2018. An efficient image matching algorithm based on adaptive threshold and RANSAC. *IEEE Access*, 6, 66963-66971.
- Li, X., Ling, F., Foody, G. M. ve Du, Y. 2016. A superresolution land-cover change detection method using remotely sensed images with different spatial resolutions. *IEEE Transactions on Geoscience and Remote Sensing*, 54(7), 3822-3841.
- Li, Y., Zheng, S., Wang, X. ve Ma, H. 2016. An efficient photogrammetric stereo matching method for high-resolution images. *Computers and Geosciences*, 97, 58-66.
- Li, Z., Zhang, W. ve Shan, J. 2020. Holistic parametric reconstruction of building models from point clouds. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLIII-B2, XXIV ISPRS Congress, 689-695.
- Limandal, P. Y. 2019. Dijital hava görüntülerinden üretilen nokta bulutu ile yarı otomatik bina detayı çıkarımı. Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Karadeniz Teknik Üniversitesi.
- Lin, J., Jing, W., Song, H. ve Chen, G. 2019. ESNNet: Efficient network for building extraction from high-resolution aerial images. *IEEE Access*, 7, 54285-54294.
- Linder, W. 2009. *Digital photogrammetry: A practical course*. 4th Edition, Springer

Berlin, Heidelberg, 209 pp.

- Liu, J. ve Ji, S. 2020. A novel recurrent encoder-decoder structure for large-scale multi-view stereo reconstruction from an open aerial dataset. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1-10.
- Lohani, B. ve Ghosh, S. 2017. Airborne LiDAR technology: A review of data collection and processing systems. *Proceedings of the National Academy of Sciences India Section A: Physical Sciences*, 87, 567-579.
- Lohmann, G. 1998. *Volumetric image analysis*. 1st Edition, John Wiley, Chichester, England, 265 pp.
- Ma, W., Wan, Y., Li, J., Zhu, S. ve Wang, M. 2019. An automatic morphological attribute building extraction approach for satellite high spatial resolution imagery. *Remote Sensing*, 11(3), 1-24.
- Maalek, R., Lichti, D. D. ve Ruwanpura, J. 2015. Robust classification and segmentation of planar and linear features for construction site progress monitoring and structural dimension compliance control. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, II-3/W5, La Grande Motte, France, 129-136.
- Maktav, D., Erbek, F. S. ve Jürgens, C. 2005. Remote sensing of urban areas. *International Journal of Remote Sensing*, 26(4), 655-659.
- Malihi, S., Valadan Zoej, M. J., Hahn, M., Mokhtarzade, M. ve Arefi, H. 2016. 3D building reconstruction using dense photogrammetric point cloud. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLI-B3, Prague, Czech Republic, 71-74.
- Maltezos, E., Doulamis, A., Doulamis, N. ve Ioannidis, C. 2019. Building extraction from LiDAR data applying deep convolutional neural networks. *IEEE Geoscience and Remote Sensing Letters*, 16(1), 155-159.
- Marullo, S., Patsaeva, S. ve Fiorani, L. 2018. Remote sensing of the coastal zone of the European seas. *International Journal of Remote Sensing*, 39(24), 9313-9316.
- Melo, A. G., Pinto, M. F., Honório, L. M., Dias, F. M. ve Masson, J. E. N. 2020. 3D correspondence and point projection method for structures deformation analysis. *IEEE Access*, 8, 177823-177836.
- Muja, M. ve Lowe, D. G. 2012. Fast matching of binary features. *2012 9th Conference on Computer and Robot Vision, CRV 2012*, 404-410.
- Nan, L. ve Wonka, P. 2017. PolyFit: polygonal surface reconstruction from point clouds. *IEEE International Conference on Computer Vision*, 2372-2380.
- Ni, H., Lin, X. ve Zhang, J. 2017. Classification of ALS point cloud with improved point cloud segmentation and random forests. *Remote Sensing*, 9(3), 1-34.
- Nie, S., Wang, C., Dong, P., Xi, X., Luo, S. ve Qin, H. 2017. A revised progressive TIN densification for filtering airborne LiDAR data. *Measurement*, 104, 70-77.
- Nurunnabi, A., Belton, D. ve West, G. 2016. Robust segmentation for large volumes of laser scanning three-dimensional point cloud data. *IEEE Transactions on*

Geoscience and Remote Sensing, 54(8), 4790-4805.

- Oh, S., Lee, D., Kim, M., Kim, T. ve Cho, H. 2021. Building component detection on unstructured 3d indoor point clouds using ransac-based region growing. *Remote Sensing*, 13(2), 1-20.
- Ozdemir, E., Karsli, F., Kavzoglu, T., Bahadir, M. ve Yagmahan, A. 2021. A novel algorithm for regularization of building footprints using raw LiDAR point clouds. *Geocarto International*, DOI: 10.1080/10106049.2021.1974104.
- Pingel, T. J., Clarke, K. C. ve McBride, W. A. 2013. An improved simple morphological filter for the terrain classification of airborne LiDAR data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 77, 21-30.
- Qin, R. ve Fang, W. 2014. A hierarchical building detection method for very high resolution remotely sensed images combined with DSM using graph cut optimization. *Photogrammetric Engineering and Remote Sensing*, 80(9), 37-47.
- Rabbani, G. V. G. S. 2004. Recognising structure in laser scanner point clouds. *International archives of photogrammetry, remote sensing and spatial information sciences*, 46(8), 33-38.
- Rau, J. Y., Jhan, J. P. ve Hsu, Y. C. 2015. Analysis of oblique aerial images for land cover and point cloud classification in an Urban environment. *IEEE Transactions on Geoscience and Remote Sensing*, 53(3), 1304-1319.
- Remondino, F., Spera, M. G., Nocerino, E., Menna, F. ve Nex, F. 2014. State of the art in high density image matching. *Photogrammetric Record*, 29(146), 144-166.
- Reutebuch, S. E., Andersen, H. E. ve McGaughey, R. J. 2005. Light detection and ranging (LiDAR): An emerging tool for multiple resource inventory. *Journal of Forestry*, 286-292.
- Rutzinger, M., Rottensteiner, F. ve Pfeifer, N. 2009. A Comparison of evaluation techniques for building extraction from airborne laser scanning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2(1), 11-20.
- Sampath, A. ve Shan, J. 2007. Building boundary tracing and regularization from airborne lidar point clouds. *Photogrammetric Engineering and Remote Sensing*, 73(7), 805-812.
- Schlosser, A. D., Szabó, G., Bertalan, L., Varga, Z., Enyedi, P. ve Szabó, S. 2020. Building extraction using orthophotos and dense point cloud derived from visual band aerial imagery based on machine learning and segmentation. *Remote Sensing*, 12(15), 1-28.
- Shao, Z., Yang, N., Xiao, X., Zhang, L. ve Peng, Z. 2016. A multi-view dense point cloud generation algorithm based on low-altitude remote sensing images. *Remote Sensing*, 8(5), 1-16.
- Siddiqui, F. U., Teng, S. W., Awrangjeb, M. ve Lu, G. 2016. A robust gradient based method for building extraction from LiDAR and photogrammetric imagery. *Sensors*, 16(7), 1-24.
- Su, Y., Guo, Q., Xue, B., Hu, T., Alvarez, O., Tao, S. ve Fang, J. 2016. Spatial distribution of forest aboveground biomass in China: Estimation through

- combination of spaceborne LiDAR, optical imagery, and forest inventory data. *Remote Sensing of Environment*, 173, 187-199.
- Sun, W. ve Wang, R. 2018. Fully convolutional networks for semantic segmentation of very high resolution remotely sensed images combined with DSM. *IEEE Geoscience and Remote Sensing Letters*, 15(3), 474-478.
- Tran, T. H. G., Ressel, C. ve Pfeifer, N. 2018. Integrated change detection and classification in urban areas based on airborne laser scanning point clouds. *Sensors*, 18(2), 1-21.
- Tran, T. N., Drab, K. ve Daszykowski, M. 2013. Revised DBSCAN algorithm to cluster data with dense adjacent clusters. *Chemometrics and Intelligent Laboratory Systems*, 120, 92-96.
- Vo, A. V., Truong-Hong, L., Laefer, D. F. ve Bertolotto, M. 2015. Octree-based region growing for point cloud segmentation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 104, 88-100.
- Vosselman, G. 2002. Fusion of laser scanning data, maps, and aerial photographs for building reconstruction. *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 85-88.
- Vosselman, G., Kessels, P. ve Gorte, B. 2005. The utilisation of airborne laser scanning for mapping. *International Journal of Applied Earth Observation and Geoinformation*, 6(3-4), 177-186.
- Weinmann, M., Schmidt, A., Mallet, C., Hinz, S., Rottensteiner, F. ve Jutzi, B. 2015. Contextual classification of point cloud data by exploiting individual 3D neighbourhoods. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, II-3/W4, Munich, Germany, 271-278.
- Wen, C., Li, X., Yao, X., Peng, L. ve Chi, T. 2021. Airborne LiDAR point cloud classification with global-local graph attention convolution neural network. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173, 181-194.
- Widyaningrum, E. 2021. Automatic object extraction from airborne laser scanning point clouds for digital base map production. Doctoral Thesis, Delft University of Technology, Netherlands.
- Wu, Z., Wu, X., Zhang, X., Wang, S. ve Ju, L. 2019. Semantic stereo matching with pyramid cost volumes. *IEEE International Conference on Computer Vision (ICCV)*, 7484-7493.
- Xiong, B., Jancosek, M., Oude Elberink, S. ve Vosselman, G. 2015. Flexible building primitives for 3D building modeling. *ISPRS Journal of Photogrammetry and Remote Sensing*, 101, 275-290.
- Xu, Y., Tuttas, S., Hoegner, L. ve Stilla, U. 2017. Geometric primitive extraction from point clouds of construction sites using VGS. *IEEE Geoscience and Remote Sensing Letters*, 14(3), 424-428.
- Yan, Y., Gao, F., Deng, S. ve Su, N. 2017. A hierarchical building segmentation in digital surface models for 3D reconstruction. *Sensors*, 17(2), 1-14.
- Yu, Y., Liu, X. ve P. Buckles, B. 2010. A cue line based method for building modeling

from LiDAR and satellite imagery. 2nd International Conference on Computing, Communication and Networking Technologies, ICCCNT 2010, 1-8.

- Ywata, M. S. Y., Dal Poz, A. P., Shimabukuro, M. H. ve de Oliveira, H. C. 2021. Snake-based model for automatic roof boundary extraction in the object space integrating a high-resolution aerial images stereo pair and 3D roof models. *Remote Sensing*, 13(8), 1-22.
- Zhang, F., Prisacariu, V., Yang, R. ve Torr, P. H. S. 2019. GA-net: Guided aggregation net for end-to-end stereo matching. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1-11.
- Zhang, J. ve Lin, X. 2013. Filtering airborne LiDAR data by embedding smoothness-constrained segmentation in progressive TIN densification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 81, 44-59.
- Zhang, P., Du, P., Lin, C., Wang, X., Li, E., Xue, Z. ve Bai, X. 2020. A hybrid attention-aware fusion network (Hafnet) for building extraction from high-resolution imagery and lidar data. *Remote Sensing*, 12(22), 1-20.
- Zhang, Wenyan, Li, Z. ve Shan, J. 2021. Optimal model fitting for building reconstruction from point clouds. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 9636-9650.
- Zhang, Wuming, Qi, J., Wan, P., Wang, H., Xie, D., Wang, X. ve Yan, G. 2016. An easy-to-use airborne LiDAR data filtering method based on cloth simulation. *Remote Sensing*, 8(6), 1-22.
- Zhixin Li, J. S. 2022. RANSAC-based multi primitive building reconstruction from 3D point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing*, 185, 247-260.
- Zhou, G. ve Zhou, X. 2014. Seamless fusion of LiDAR and aerial imagery for building extraction. *IEEE Transactions on Geoscience and Remote Sensing*, 52(11), 7393-7407.
- URL-1. 2022. <https://www.usgs.gov/media/images/lidar-point-cloud-pittsburgh-pa-0>. Eriřim tarihi: 23.03.2022.
- URL-2. 2022. <https://oceanservice.noaa.gov/facts/lidar.html>. Eriřim tarihi: 23.03.2022.

## EKLER

### EK A. Önerilen Algoritmanın (I-Octree) Sözde (Pseudo) Kod Şeması

**Girdi:**  $m$ , Octree voksellerinin oluşturulması için maksimum derinlik parametresi (*max Depth*)

$(P_x \& P_y)$ , SMRF ve DBSCAN sonucu çıkarılan bina noktalarının koordinatları

**Çıktı:**  $V_{\min}$ , Octree yaprak-düğüm noktalarının minimum yükseklikteki köşesi

$V_{\max}$ , Octree yaprak-düğüm noktalarının maksimum yükseklikteki köşesi

$V_1$ , Octree ağaç yapısının kök hücresindeki vokselin  $V_{\min}$  değeri

$V_2$ , Octree ağaç yapısının kök hücresindeki vokselin  $V_{\max}$  değeri

$r$ , Octree vokselleri için basamak aralığı

$$r \leftarrow \frac{V_2 - V_1}{m + 1}$$

$r$  basamak aralığına göre nokta bulutunu dört basamağa ayır.

$$d_1 \leftarrow V_2 - r$$

$$d_2 \leftarrow V_2 - 2r$$

$$d_3 \leftarrow V_2 - 3r$$

$r_1$ ,  $V_2$  ile  $d_1$  arasındaki noktalar (birinci basamak)

$r_2$ ,  $d_1$  ile  $d_2$  arasındaki noktalar (ikinci basamak)

$r_3$ ,  $d_2$  ile  $d_3$  arasındaki noktalar (üçüncü basamak)

$r_4$ ,  $d_3$  ile  $V_1$  arasındaki noktalar (dördüncü basamak)

**for**  $i = 1 : 4$

A,  $r_i$ . basamak için uygulanan MBR algoritmasının hesapladığı üstteki iki köşenin koordinatları

B, A değişkeninde bulunan noktalardan geçirilen buffer zon'un içinde kalan noktalar

**if** length (B) > 1

C { $i, 1$ }  $\leftarrow \emptyset$

**else**

C { $i, 1$ }  $\leftarrow r_i$  (ilgili basamaktaki noktaların tamamı)

**end**

print C

C değişkeninde bulunan bina noktaları için sınır geçir ve küçültme faktörü ( $s$ ) belirle.

boundary ( $C_x, C_y, s$ )

ABORE yöntemi ile düzensiz bina sınırlarını regülarize et ve çıkan sonuçları referans harita ile değerlendir.

## ÖZGEÇMİŞ

**Adı ve Soyadı** : Buray KARSLI

### EĞİTİM BİLGİLERİ (Kurum ve Yıl)

**Lisans** : Gümüşhane Üniversitesi, Harita Mühendisliği Bölümü,  
2015-2019

Karadeniz Teknik Üniversitesi- Harita Mühendisliği  
Bölümü- 2018/2019 (Farabi Değişim Programı)

**Yüksek Lisans** : Aksaray Üniversitesi, Harita Mühendisliği Anabilim  
Dalı, 2019- 2022

### MESLEKİ DENEYİM VE ÖDÜLLERİ

1. KOLİN İNŞ-2016 (Ankara-Sivas Hızlı Tren Raylı Sistem Projesi/Kırıkkale-Yerköy Kesimi) /Yaz Stajı
2. Harita Genel Müdürlüğü/ANKARA- 2018/ Yaz Stajı
3. KOLİN İNŞAAT-2020/Aktif (Ankara-İzmir Hızlı Tren Raylı Sistem Projesi/Eşme-Salihli Kesimi)

### TEZDEN ÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER

Ulusal Hakemli Dergilerde Yayınlanan Makaleler

1. Karşlı, B., Yılmaztürk, F, 2022. Görüntü Eşleştirme Kaynaklı Nokta Bulutu Üzerinden Otomatik Bina Çıkarımı ve Düzgünleştirme, *Türkiye Uzaktan Algılama Dergisi (TUZAL)*, Makale No: 1098240, DOI: 10.51489/tuzal.1098240.