

Lidar Nokta Bulutundan Ransac-Tabanlı Bina Çatı Düzlemi Çıkarımı İçin Bir Yaklaşım

An Approach for Ransac-Based Building Roof Plane Extraction from Lidar Point Cloud

Murat Güler^{1*}, Mustafa Türker²

¹Bursa Uludağ Üniversitesi, İznik Meslek Yüksekokulu, Mimarlık ve Şehir Planlama Bölümü, Harita ve Kadastro Programı, 16860, Bursa/Türkiye.

²Hacettepe Üniversitesi, Mühendislik Fakültesi, Geomatik Mühendisliği Bölümü, 06800, Ankara/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Murat Güler
muratguler@uludag.edu.tr

doi: 10.48123/rsgis.970893

Yayın süreci

Geliş tarihi: 13.07.2021
Kabul tarihi: 27.08.2021
Basım tarihi: 29.09.2021

Özet

Son yıllarda önemi hızla artan 3B şehir modellerinde bina modellemesi LiDAR verisinin en yaygın uygulama alanları arasında yer almaktadır. Bu çalışmada, hava LiDAR verisinden 3B RANSAC (RANdom SAmple Consensus) algoritması ile çatı düzlemlerinin çıkarımı ve geriçatımı için veri odaklı bir yaklaşım önerilmiş ve iki farklı alanda (A1 ve A2) test edilmiştir. İlk olarak yer filtreleme yapılmıştır. Sonra, sınıflandırma ile tespit edilen bina sınıfı nokta bulutundan her bir binaya ait nokta kümesini çıkarmak için bölge büyüme bölütleme algoritması uygulanmıştır. Çıkarılan çatı düzlemsel yüzeylerde bulunan gürültü, DBSCAN (Density Based Spatial Clustering of Applications with Noise) algoritması kullanılarak tespit edilmiş ve silinmiştir. Doğruluk analizleri için, duyarlık (precision-p), bütünlük (recall-r) ve F-skor (F-score) değerleri hesaplanmıştır. A1 çalışma alanı için ortalama p, r ve F-skor değerleri sırasıyla, %86, %87 ve %85 olarak bulunmuştur. A2 çalışma alanı için bu değerler sırasıyla, %92, %93 ve %92 olarak bulunmuştur. Nokta yoğunluğunun daha yüksek olması ve bina çatı geometrisinin daha düzgün olması, A2 çalışma alanı sonuçlarını olumlu yönde etkilemiştir. Ayrıca, A2 çalışma alanında gürültünün daha başarılı bir şekilde tespiti sağlanmış ve dolayısıyla bu da doğruluk oranlarını artırmıştır.

Anahtar kelimeler: 3B şehir modeli, LiDAR, RANSAC, Yer filtreleme, Bölütleme, Geriçatma

Abstract

In 3D city modelling, the importance of which has increased rapidly in recent years, building modelling is among the most frequently used application areas of LiDAR data. In this study, a data-driven approach was proposed for the extraction and reconstruction of roof planes from aerial LiDAR data using 3D RANSAC (RANdom SAmple Consensus) algorithm and tested in two areas (A1 and A2). First, ground filtering was performed. Then, region growing segmentation algorithm was applied to extract point set of each building from the building class detected through classification. The noise that exists on the extracted planar surfaces were detected and removed using the DBSCAN (Density Based Spatial Clustering of Applications with Noise) algorithm. For accuracy assessment, precision (p), recall (r), and F-score values were calculated. For study area A1, the mean values for p, r and F-score were computed as 86%, 87% and 85%, respectively. For study area A2, these values were computed as 92%, 93% and 92%, respectively. The higher density of point cloud and smoother roof geometry appear to have affected the results positively in study area A2. Besides, the noise was more successfully detected in study area A2, which increased the accuracy rates.

Keywords: 3D city model, LiDAR, RANSAC, Ground filtering, Segmentation, Reconstruction

1. Giriş

Bir şehri oluşturan ana nesne binedir. Binalar üç boyutlu (3B) şehir modellemesinde en çok talep gören nesnelere (Wei, 2008). Kentsel alanlar insan faaliyetleri nedeniyle hızla değişmektedir (Morgan ve Tempfli, 2000). Ayrıca, kentsel alanlarda yapılaşmanın hızlı bir şekilde artmasından dolayı, bina verileri güncel olmayabilir. Bu nedenle, güncel bina verilerini elde etmek için hızlı ve doğru veri toplama teknolojilerine ihtiyaç duyulmaktadır. 3B kent verilerinin elde edilmesinde, geleneksel fotogrametriye karşın Işık Algılama ve Mesafe Ölçme (Light Detection and Ranging-LiDAR) teknolojisini kullanmanın avantajları arasında yüksek hız, yüksek düşey doğruluk, yüksek yoğunluk ve düşük maliyet ön plana çıkmaktadır. LiDAR, bina, ağaç, zemin, yol ve enerji hatlarının özellik çıkarımı ve 3B gerçeğinde kullanılmaya uygun bir veri toplama yöntemidir (Wei, 2008).

Binaların hava görüntülerden ve / veya LiDAR verilerinden otomatik olarak gerçeğini, 3D bina modelleme gibi birçok Coğrafi Bilgi Sistemi (CBS) uygulaması için bir ön koşuldur. Literatürde yarı otomatik ve otomatik olmak üzere iki tür bina gerçeğini tekniği vardır (Awrangjeb ve Lu, 2013; Awrangjeb ve Fraser, 2013). Küçük bir yerleşim yerinde bile yarı otomatik teknikler, binaların gerçeğini için çok fazla manuel müdahale gerektirdiğinden otomatik teknikler daha ön planda tutulmuştur (Awrangjeb ve Lu, 2013).

Bina çatılarının gerçeğini için literatürde farklı yaklaşımlar tanımlanmıştır (Awrangjeb ve Fraser, 2013). Parametrik yaklaşım olarak da bilinen model odaklı yaklaşımda, önceden tanımlanmış çatı türleri kataloğu kullanılarak verilere en iyi uyan model seçilmektedir (Awrangjeb ve Lu, 2013; Awrangjeb ve Fraser, 2013). Bu yaklaşımın bir avantajı, sonuç çatı şeklinin her zaman topolojik olarak doğru olmasıdır. Dezavantajı ise karmaşık çatı şekillerinin önceden tanımlanmış katalogda bulunmadığı durumlarda gerçeğinin yapılamamasıdır (Awrangjeb ve Fraser, 2013). Genel veya çok yüzü yaklaşım olarak da bilinen veriye dayalı yaklaşımda çatı, bölütleme algoritmalarından yani düzlem algılama tekniklerinden türetilen düzlemsel yapılardan gerçeğilir (Awrangjeb ve Lu, 2013; Awrangjeb ve Fraser, 2013). Bu yaklaşımdaki zorluk komşu düzlemsel segmentleri ve bunların ilişkilerini belirlemektir. Bu yaklaşımın temel avantajı ise, rastgele şekle sahip binaların gerçeğinin yapılabilesidir. Kullanılan verinin LiDAR verisi olması durumunda bu yaklaşımda düşük nokta yoğunluğu bir dezavantaj olabilmektedir. Bu nedenle, küçük çatı pencereleri ve bacalar gibi bazı çatı özellikleri verinin çözünürlüğü düşükse, temsil edilememektedir. Yüksek yoğunluklu LiDAR ve görüntü verilerinin varlığında ise eğimli yüzeyler iyi bir şekilde tahmin edilebilmektedir (Awrangjeb ve Fraser, 2013). Bir diğer yaklaşım olan küresel strateji veya hibrit yaklaşım olarak da bilinen yapısal yaklaşım, hem model hem de veri odaklı özellikler sergiler (Awrangjeb ve Lu, 2013; Awrangjeb ve Fraser, 2013). 3B nokta bulutundan otomatik düzlem tespiti, 3B modelleme, 3B kadastr vb. uygulamalarda çok faydalı olduğundan talep gören bir araştırma konusudur (Maltezos ve Ioannidis, 2016).

3B nokta bulutundan düzlem tespitine yönelik yaygın kullanılan yöntemler arasında Bölge Büyüme (Region Growing), Hough dönüşümü ve RANdom SAMple Consensus (RANSAC) yer almaktadır (Maltezos ve Ioannidis, 2016; Tarsha-Kurdi vd. 2007). Bölge büyüme teknikleri bazen çok şeffaf değildir ve homojen olarak uygulanamazlar. RANSAC tekniği, Hough dönüşümü tekniğine kıyasla daha kısa sürede ve daha iyi sonuçlar sağlamaktadır (Tarsha-Kurdi vd. 2007).

Vosselman ve Dijkman (2001) tarafından yapılmış çalışmada, bina çatılarında düzlem noktalarını çıkarmak için Hough dönüşümü kullanılmıştır. Düzlem çatı yüzeyleri başlangıç segmentleri uzatılarak ve birleştirilerek elde edilmiştir. Geliştirilen algoritmada, tespit edilen noktaların aynı çatı düzleminde olup olmadığının kontrolü için ek kriterler kullanılmıştır. Dorninger ve Nothegger (2007) tarafından yapılmış olan çalışmada, parametre uzayında kümelenerek başlatılan bölütleme algoritması, görüntü eşleştirme ve lazer taraması ile elde edilen nokta bulutları üzerinde uygulanmış ve güvenilir sonuçlar elde edilmiştir. Costantino ve Angelini (2011) tarafından yapılan çalışmada, binaların çatı düzlemlerini çıkarmak için RANSAC yöntemi uygulanmıştır. Düzlemlerin tanımlanması için RANSAC algoritmasının uygulanması, binaların çatılarını oluşturan noktaların tespit edilmesine ve çıkarılmasına olanak sağlamıştır. Chen vd. (2012) tarafından yapılan çalışmada hava LiDAR verilerinde bina çatılarını bölütleme için yeni bir yaklaşım önerilmiştir. Öncelikle morfolojik filtreleme ile zemin ve zemin üstü noktalar ayrılmış, ardından düzlem uydurma tekniğine dayalı bölge büyüme algoritması ile bina noktaları bitki örtüsü noktalarından ayrılmıştır. Son olarak, RANSAC yaklaşımı kullanılarak tespit edilen bina çatıları iyileştirilmiştir. Karsli ve Pfeifer (2012) tarafından yapılmış olan çalışmada, yalın yer yüzeyi veya herhangi bir bina vb. detayın çıkarımı için, diğer yöntemlere göre daha etkili olan RANSAC (RANdom SAMple Consensus) algoritması uygulanarak, binaları ve arazi yüzeyini tespit eden olası en iyi düzlemler belirlenmiştir. RANSAC algoritması ile tatmin edici sonuçlar elde edildiği belirtilmiştir. Çömert ve Avdan (2014) tarafından yapılmış olan çalışmada, 3B yersel lazer tarayıcı nokta bulutu verisinden düzlem, koni, silindir ve küre gibi şekillerin yüzeylerinin RANSAC algoritması ile otomatik çıkarımı gerçekleştirilmiştir. Sonuçların doğruluğunu incelemek için elle ve otomatik çıkarılan yüzeyler karşılaştırılmıştır. Elde edilen sonuçlara göre, 3B yersel lazer tarayıcı nokta bulutu verisinden otomatik yüzey çıkarım işleminde RANSAC algoritmasının oldukça başarılı olduğu belirtilmiştir. Canaz vd. (2015) tarafından göl sınırlarının LiDAR verisinden otomatik tespiti için yapılmış olan bir çalışmada, su yüzeyi RANSAC algoritması kullanılarak çıkarılmıştır. Göl alanlarının düzlemsellik özelliği göstermesinden dolayı bu alanların RANSAC algoritmasıyla kolay bir şekilde çıkarıldığı belirtilmiştir. Demir (2016) tarafından yapılmış olan bir çalışmada, yalnız LiDAR verisi kullanılarak çatıların 3B modellemesi yapılmıştır.

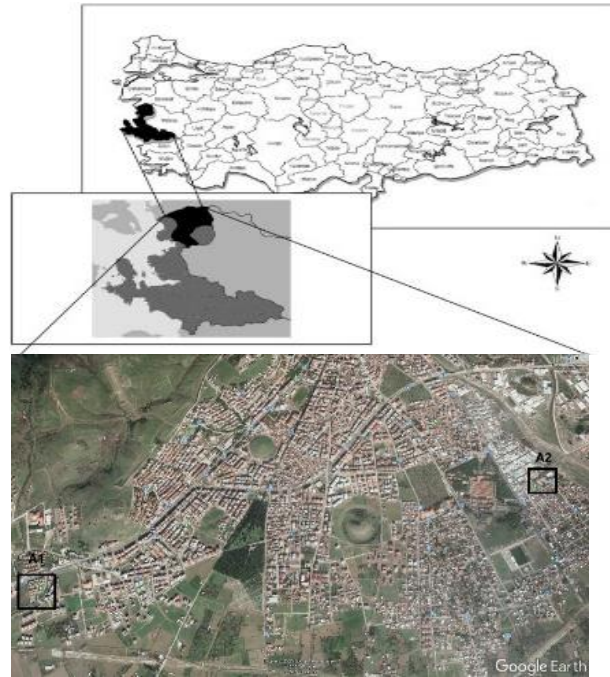
Çalışmada ayrıca görüntüden elde edilen 3B çizgilerin de kullanılmasıyla, daha kaliteli sonuçların üretilebileceği belirtilmiştir. Fan vd. (2018) tarafından yapılmış olan bir çalışmada, bölge büyüme algoritmasının aşırı bölütleme ve tutarsızlık gibi problemlerini gidermek için, farklı nokta bulutu modellerine kendinden uyarlanır (self-adaptive) bölütleme algoritması uygulanarak % 96 bölütleme doğruluk oranı elde edilmiştir. Güncel çalışmalardan olan Gönültaş vd. (2020) tarafından yapılmış olan bir çalışmada, LiDAR ve hava fotogrametrisi arasında karşılaştırma yapmak için elde edilen 3B nokta bulutu verilerine RANSAC algoritması uygulanmıştır. Hava fotogrametrisi yüksek yoğunluklu verilere sahip olmasına rağmen gürültülü verilere sahip olduğundan, RANSAC algoritması model içindeki tamlik açısından bakıldığında, hava LiDAR'dan elde edilen nokta bulutu verilerinde bina çatılarını daha iyi tespit ettiği gösterilmiştir.

Bu çalışmada, hava LiDAR nokta bulutu verisinden RANSAC algoritması ile bina çatı düzlemlerinin çıkarımını ve geriçatımını gerçekleştirmek için, otomatik ve veri odaklı bir yaklaşım önerilmiştir. Önerilen yaklaşım iki temel adımdan oluşmaktadır: (i) Bina tespitinin yapılması, (ii) binalara ait çatı düzlemlerinin çıkarılması. Ayrıca bu çalışmada, temel çatı düzlemleri yalnız 3B hava LiDAR nokta bulutu verisine uygulanan bölge büyüme bölütleme, RANSAC ve DBSCAN algoritmaları ile çıkarılmıştır. Diğer çalışmalardan farklı olarak, öncelikle bina sınıfı nokta bulutu verisine uygulanan bölge büyüme bölütleme algoritması ile çalışma alanlarında, her bir binaya ait nokta bulutu verisinin başarılı bir şekilde ayrılması sağlanmıştır. RANSAC algoritması ile bina çatı düzlemlerinin çıkarılması sonrasında gürültü olarak tanımlanan aykırı noktaların ayıklanması için üstün küme oluşturma özelliğine sahip yoğunluk tabanlı kümeleme algoritmalarından DBSCAN algoritması, düzlemi temsil eden her bir nokta bulutuna uygulanarak literatüre katkıda bulunulmuştur. Sonuçların doğruluk analizleri için, duyarlık (precision-p), bütünlük (recall-r) ve F-skor (F-scor) değerleri hesaplanmıştır.


2. Çalışma Alanı ve LiDAR Nokta Bulutu Verisi

2.1 Çalışma Alanı


Yöntemin testleri için İzmir, Bergama'dan farklı özelliklere sahip iki çalışma alanı seçilmiş ve bu alanlar çalışmada A1 ve A2 olarak adlandırılmıştır. Seçilen çalışma alanları Şekil 1'de gösterilmiştir. Çalışma alanlarına ait projeksiyon bilgileri şu şekildedir: UTM 6 Derece WGS-84 Zone 35. Yaklaşık 109 m x 224 m boyutlarında ve 2.44 hektar büyüklüğünde olan A1 çalışma alanının koordinatları X: 513639.313 m – Y: 4327873.985 m (Kuzey doğu) ve X: 513530.237 m – Y: 4327649.844 m (Güney batı) dır. Bu çalışma alanında toplam 26 bina ile birlikte binalara yakın konumda ağaçlar ve düz alanlar bulunmaktadır. A1 çalışma alanına ait LiDAR nokta bulutu verisi Şekil 2'de gösterilmiştir. Yaklaşık 91 m x 71 m boyutlarında ve 0.65 hektar büyüklüğünde olan A2 çalışma alanının koordinatları X:516922.621 m – Y:4328832.454 m (Kuzey doğu) ve X: 516831.428 m – Y: 4328760.999 m (Güney batı) dır. Bu çalışma alanında toplam 3 bina, düzlük alanlar ve binalara yakın konumda sıralı ağaçlar bulunmaktadır. A2 çalışma alanına ait LiDAR nokta bulutu verisi Şekil 3'de gösterilmiştir.



Şekil 1. İzmir, Bergama'dan seçilen çalışma alanları



Şekil 2. A1 çalışma alanına ait LiDAR nokta bulutu verisi



Şekil 3. A2 çalışma alanına ait LiDAR nokta bulutu verisi

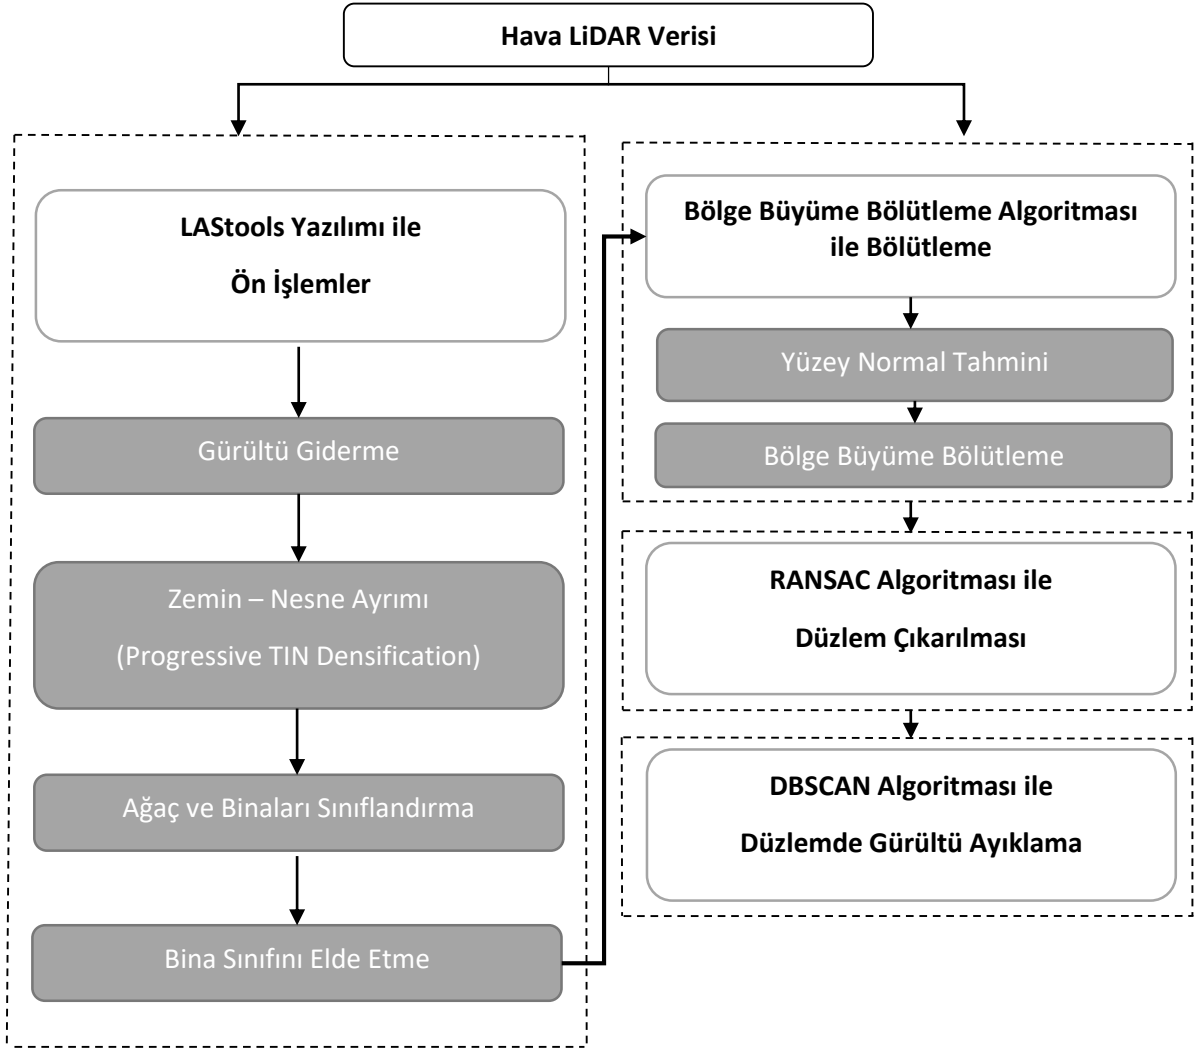
2.2 Lidar Verisi

Çalışmada kullanılan hava LiDAR verisi Harita Genel Müdürlüğü (HGM) tarafından temin edilmiştir. A1 çalışma alanına ait hava LiDAR verisi Riegl firmasının LMS-Q1560 LiDAR sistemi ile A2 çalışma alanına ait hava LiDAR verisi Optech firmasının Pegasus HA-500 LiDAR sistemi ile Ekim 2014 tarihinde ve 1200 metre yükseklikten çekilmiştir (Kayı vd. 2015). A1 ve A2 çalışma alanlarına ait nokta verisi yoğunlukları sırasıyla 18.8 nokta/m² ve 22.6 nokta/m² dir.

3. Yöntemler

Yöntem, Şekil 4'deki akış şemasında gösterildiği üzere dört temel aşamadan oluşmaktadır. Bunlar:

- 1) LAStools Yazılımı ile Ön İşlemler,
- 2) Bölge Büyüme Bölütleme Algoritması ile Bölütleme,
- 3) RANSAC Algoritması ile Düzlem Çıkarılması,
- 4) DBSCAN Algoritması ile Düzlemde Gürültü Ayıklama.



Şekil 4. Yöntemin akış şeması


3.1 Gürültü Noktalarının Kaldırılması

Bu çalışmada, çalışma alanlarını da kapsayan tüm veri görüntülediğinde gürültü içerdiği ve herhangi bir sınıflandırma yapılmadığı görülmüş olup bu nedenle filtreleme işlemine geçilmeden önce veri gürültüden arındırılmıştır. Bunun için LAStools yazılımının Lasnoise modülü kullanılmıştır.

3.2 Yer Filtreleme ve Zemin Üstü Noktaların Sınıflandırması

Yer filtreleme ile zemin üstü noktalar zemin noktalarından ayrılmış ve etiketlenmiştir. Bu işlem için Lastools nokta bulutu yazılımının Lasground modülü kullanılmıştır. Lasground modülü yer filtreleme için ilerleyen Üçgenleşmiş Düzensiz Ağ Yoğunlaştırma (Progressive Triangular Irregular Network (TIN) Densification - PTD) yöntemini kullanmaktadır (LAStools, 2021a). Bu yöntemde, tohum noktalarından, önce kaba bir TIN yüzeyi oluşturulup aşamalı olarak TIN yüzeyi yoğunlaşma işlemi gerçekleştirilmektedir (Şekil 5). Filtreleme işlemine başlarken, alan belirlenen boyutta karelalara bölünür (Şekil 5a). Kareler boyutu alanda bulunan en büyük nesne boyutundan daha büyük olacak şekilde belirlenmelidir. Karelere bölünen alanda, her kareler içerisinde yükseklik değeri en düşük olan nokta seçilerek, en az bir zemin noktası (tohum noktası) alma garantisi olacak şekilde filtreleme işlemi başlatılır. Kareler içerisinde yükseklik değeri en küçük olan bu noktalar birleştirilerek Delaunay üçgenleme yöntemi ile TIN oluşturulur. Sonra, her aşamada, hesaplanan üçgen ile noktanın birleştirildiği kenarlar arasındaki açı ve nokta ile yakınında bulunan üçgen düzlemine olan mesafe eşik değer parametrelerine dayalı kriterler karşılanırsa, üçgen sınırında bulunan noktalardan bir nokta her seferinde üçgenlemeye dahil edilir. Eşik değer parametreleri her iterasyonda yeniden hesaplanır.

Üçgen sınırı dahilindeki seçilen tek nokta (Şekil 5b), oluşan üçgene belirtilen mesafeden yakın ve açılar belli bir sınırın altında ise zemin noktası olarak kabul edilir ve üçgen sıklaştırılarak TIN yoğunlaştırılır. TIN yoğunlaştırma işlemi tüm noktalar zemin veya nesne olarak sınıflandırılana kadar devam eder (Axelsson, 2000; Meng vd. 2010; Sithole, 2003; DSM / DTM Filtering, 2021).




Şekil 5. İlerleyen TIN Yoğunlaştırma filtreleme yöntemi a) Alanın karelajlara bölünmesi b) Üçgen sınırında bulunan bir nokta ile üçgen kenarlarına olan açı eşik değeri parametresinin gösterimi


Lasground modülünün temel parametreleri arasında step size, spike, bulge, standart sapma ve maksimum offset yer almaktadır (LAsTools, 2021b). Lasground temelde step size parametresine dayanmaktadır ve bu parametre değerinin alandaki en büyük nesnenin büyüklüğünden küçük olması durumunda başarı oranı düşmektedir. Yerleşim alanlarındaki en büyük nesnelerin binalar olması nedeniyle, parametre değerinin binalardan küçük alınması sonucu etkilemektedir. Bu çalışmada step size parametre değeri, A1 ve A2 çalışma alanlarındaki binalar dikkate alınarak belirlenmiştir (LAsTools, 2021c). En uygun parametre değerlerinin belirlenmesinde deneme yanılma yöntemi tercih edilmiş ve çok sayıda deneme yapılmıştır. Bunun için, step size, standart deviation ve bulge parametreleri değerleri sabit tutulmuş, maksimum offset ve spike parametre değerleri için ise sırasıyla 0.01 ve 0.05 artırımı uygulanmıştır. Sırasıyla step size, standart sapma ve bulge parametre değerleri için, Lastools yazılımında önerilen 10 m, 1cm ve 1m, sabit alınıp, maksimum offset ve spike parametresi değerleri değiştirilmiştir. Deneme yanılma yoluyla elde edilen her parametre seti kullanılarak gerçekleştirilen yer filtreleme sonuçları görsel olarak değerlendirilmiş ve en uygun parametre değeri olarak step size için 10 m, standart deviation için 1 cm, bulge için 1 m, maksimum offset için 0.05 m ve spike için 1 m alınmıştır. A1 çalışma alanının bir bölümüne ait yer filtreleme sonucu Şekil 6'da gösterilmiştir.

Binaları ve yüksek bitki örtüsünü (ağaçlar) temsil eden zemin üstü nokta kümesinden, binaları ayırmak için sınıflandırma işlemi yapılmıştır. Sınıflandırma işlemi için Lastools yazılımının Lasclassify modülü kullanılmıştır. Sınıflandırma için önce zemin üstündeki her bir noktanın yüksekliği hesaplanmıştır. Lasclassify modülü, metre cinsinden zeminden en az verilen değer kadar yükseklikte bulunan komşu noktaları bulmaktadır (LAsTools, 2021d). Zemin noktalarından en az verilen değer kadar yukarı mesafedeki çatı ve bitki örtüsünün komşu noktalarının, standart sapma değeri ile bulunması sağlanarak, bina ve yüksek bitki örtüsü sınıflandırması yapılmıştır. Lasclassify modülünün parametreleri ground offset, search area size, building planarity ve forest ruggedness'dir. Ground offset, zeminden belirlenen eşik değeri kadar yükseklikteki komşu noktaların bulunmasını sağlar. Search area size ile nxn boyutlu kareli hücre boyutu tanımlanır. Building planarity, belirlenen standart sapmaya kadar kareli hücre noktalarından potansiyel çatıları bulmaktadır. Forest ruggedness, belirlenen standart sapmaya kadar kareli hücre noktalarından potansiyel bitki örtüsünü bulmaktadır.

Sınıflandırma için uygun parametre değerleri çok sayıda deneme yapılarak belirlenmiştir. Search area size parametresi için 1 m, 2 m ve 3 m değerleri, building planarity ve forest ruggedness parametreleri için 0.1 m artışla 0.1 m'den 1 m'ye kadar değerler ve ground offset parametresi için 1 m, 2 m, 3 m, 4 m ve 5 m değerleri uygulanmıştır. Ground offset parametre değerinin belirlenmesinde çalışma alanındaki en alçak binanın yüksekliği dikkate alınmıştır. Çünkü algoritma, komşu noktaların tespit edilmesinde, bu yükseklik değerinden daha yüksek noktaları dikkate almaktadır. Yapılan denemeler neticesinde çalışma alanları için en uygun parametre değeri; search area size için 2 m, building planarity için 0.7 m, forest ruggedness için 0.5 m ve ground offset için 4 m olarak belirlenmiştir. Şekil 7'de A1 çalışma alanının bir bölümüne ait sınıflandırma sonucu gösterilmiştir. Şekil 7'de sarı renkli noktalar binaları, yeşil renkli noktalar yüksek bitki örtüsünü göstermektedir. Sınıflandırma işleminden sonra Lastools yazılımının Las2las modülü kullanılarak sınıflandırılmış veriden bina sınıfına ait noktalar seçilmiştir.



Şekil 6. A1 çalışma alanının bir bölümüne ait yer filtreleme sonucu a) zemin noktaları b) zemin üstü noktalar



Şekil 7. A1 çalışma alanının bir bölümüne ait yüksek bitki örtüsü (ağaç) ve binalarının sınıflandırması. Sarı renkli noktalar binaları, yeşil renkli noktalar yüksek bitki örtüsünü göstermektedir.

3.3 Bina Sınıfı Nokta Bulutu Verisinin Bölütlenmesi ve RANSAC Algoritması İle Çatı Düzlemlerinin Çıkarılarak Gürültünün Ayıklanması


Sınıflandırma işleminden sonra, bina sınıfı nokta bulutu verisinden binalara ait nokta kümelerini ayırmak için bölütleme işlemi yapılmıştır. Bölge büyüme bölütleme (Region Growing Segmentation - RGS) algoritması kodları ticari ve araştırma amaçlı ücretsiz açık kaynak Nokta Bulutu Kütüphanesi'nden (PCL: Point Cloud Library) temin edilmiştir. RGS algoritması, binalara ait benzer özellikteki noktaların gruplandırmasını, eğrilik ve yüzey normalleri arasındaki açı değerleri kriterlerine göre gerçekleştirmektedir (PCL, 2021a).

Dolayısıyla, öncelikle bütün noktalarda yüzey normalleri hesaplanmıştır. Yüzey normallerinin hesaplanması, sorgu noktasının en yakın komşularının Kovaryans Matrisi analizine dayanmaktadır (PCL, 2021b). Sorgu noktasının k-komşuluğunda bulunan nokta setinin belirlenmesi için sorgu noktasının en yakın k komşularının belirlenmesi (K-Search: K-Arama) seçimi yapılmıştır (Rusu, 2010). Yüzey normallerinin hesaplanmasının ardından RGS algoritması ile bölütleme işlemi gerçekleştirilmiştir.

RGS algoritması için en uygun parametre değerlerinin belirlenmesinde deneme yanılma yöntemi kullanılmıştır. Kullanılan parametreler ve değerleri şu şekildedir: K-Search = 2, 3, 4, 5, 10, 20, 30, 50,100, Number of Neighbours = 4, 6, 8, 15, 22, 30, Angle Threshold (derece cinsinden) = 0.3, 0.5, 1, 3, 3.3, 3.7, 4, 5.5, Curvature Threshold = 0.5, 1, 3. Elde edilen sonuçlar görsel olarak incelenmiş ve çalışma alanları için en uygun parametre değerleri K-Search = 50, Number Of Neighbours = 22, Angle Threshold = 3 ve Curvature Threshold = 1 olarak belirlenmiştir (Tablo 1). Şekil 8 bu parametre değerleri kullanılarak bölütlenen binalara ait nokta kümelerini göstermektedir.

Tablo 1. A1 ve A2 çalışma alanları için kullanılan yüzey normali tahmini ve RGS algoritması parametre değerleri

	Çalışma Alanı	
	A1	A2
Yüzey Normali Tahmini		
Arama Yöntemi	k-d tree	k-d tree
K-Arama	50	50
Bölge Büyütme Bölütleme (RGS)		
En Düşük Küme Büyüklüğü	500	5000
En Yüksek Küme Büyüklüğü	15000	10800
Arama Yöntemi	k-d tree	k-d tree
Komşu Sayısı	22	22
Açı Eşik Değeri (derece)	3	3
Eğrilik Eşik Değeri	1	1



Şekil 8. A1 çalışma alanında RGS algoritması ile bölütlenmiş binalara (26 adet) ait nokta bulutu kümeleri. Her renk ayrı bir binayı temsil etmektedir

Çatı düzlemlerinin çıkarılması için RANSAC (RANdom Sample Consensus) algoritması kullanılmıştır (Zaman, 2018). RANSAC, ilk olarak Fischler ve Bolles (1981) tarafından model parametrelerinin kestirimi için geliştirilmiştir. Algoritmanın esası 3B nokta bulutu verisinden en uygun düzlemin belirlenmesine dayanmaktadır. Algoritma nokta bulutundan rastgele 3 nokta seçer ve düzlem parametrelerini hesaplar. Sonra, belirlenen bir t eşik değerine göre nokta bulutu verisinden hesaplanan düzleme ait olan tüm noktaları belirler.

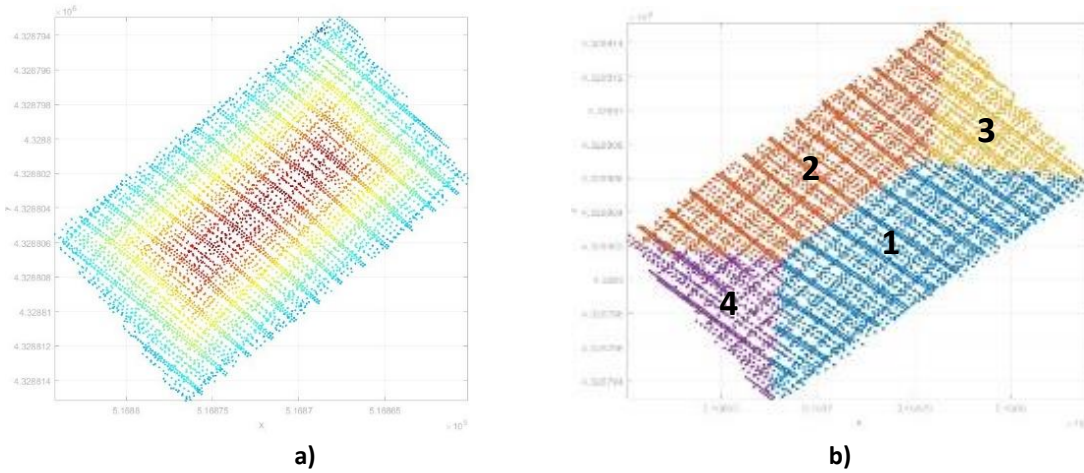
Bu işlemleri N kere tekrarlar ve her defasında, elde edilen sonucu bir önceki ile karşılaştırır. Yeni sonucun daha iyi olması durumunda, öncekinin yerine yenisi alınır. Algoritma için gerekli olan girdi verileri şunlardır: 3B nokta bulutu verisi, tolerans eşik değeri (t), bir düzlemde olası maksimum nokta sayısı (d) ve maksimum iterasyon sayısı (N). Bu çalışmada A1 ve A2 çalışma alanları için belirlenen parametre değerleri Tablo 2' de verilmiştir. Tolerans eşik değeri (t) 0.10 m olarak belirlenmiştir. Bu değer, bina çatılarında bulunan bacalara, çatı pencerelerine vb. ait noktalar ile bina çatılarından aşağıda bulunan duvarlara ait noktaların düzlem noktalarına dahil edilmemesi için, en uygun değer olarak bulunmuştur. Algoritma tarafından izin verilen maksimum iterasyon sayısı (N) Eşitlik 1' e göre 168 olarak hesaplanmıştır.

$$N = \frac{\log(1 - p)}{\log(1 - w^m)} = \frac{\log(1 - 0.99)}{\log(1 - 0.3^3)} \approx 168 \quad (1)$$

Eşitlik 1'de, m düzlem modelini tanımlamak için gerekli minimum nokta sayısını, w modele uygun olan bir noktanın seçilme olasılığını ve p başarılı bir işlemin çalışma olasılığını göstermektedir (RANSAC, 2018). Genellikle 0.90 ile 0.99 arasında alınan p değeri bu çalışmada 0.99 olarak alınmıştır (Bretar, 2008). Bu değer sabit tutularak w değeri deneme yanılma yöntemi ile belirlenmiştir. Bir düzlemde olası maksimum nokta sayısı parametresi (d) değeri, çatı düzlemlerine ait maksimum sayıda noktanın çıkarımı için minimum olacak şekilde belirlenmiştir. Bu nedenle, d parametresi değeri binalardaki çatı düzlemlerine göre farklılık göstermektedir. Düzlemlere ait noktalar tespit edildiğinde bu parametre değeri ile çatı düzlemine yakın sonuçlar veren düzlem noktaları kabul edilmiş ve düzlemsellik özelliği olmayan noktalar ise düzlem dışı noktalar olarak göz ardı edilmiştir. RANSAC algoritması ile çıkarılan A2 çalışma alanı, 1 no'lu binaya ait çatı düzlemleri Şekil 9'da gösterilmiştir.

Tablo 2. RANSAC algoritması parametre değerleri

Parametre	Değer
Düzlem modeli için gerekli en az nokta sayısı	3 (adet)
Algoritmada izin verilen iterasyon sayısı (N)	168
Tolerans eşik değeri (t)	0.10 m
Bir modelin verilere iyi uyduğunu ileri sürmek için gereken yakın veri noktalarının sayısı (d)	Çalışma alanına göre değişmektedir



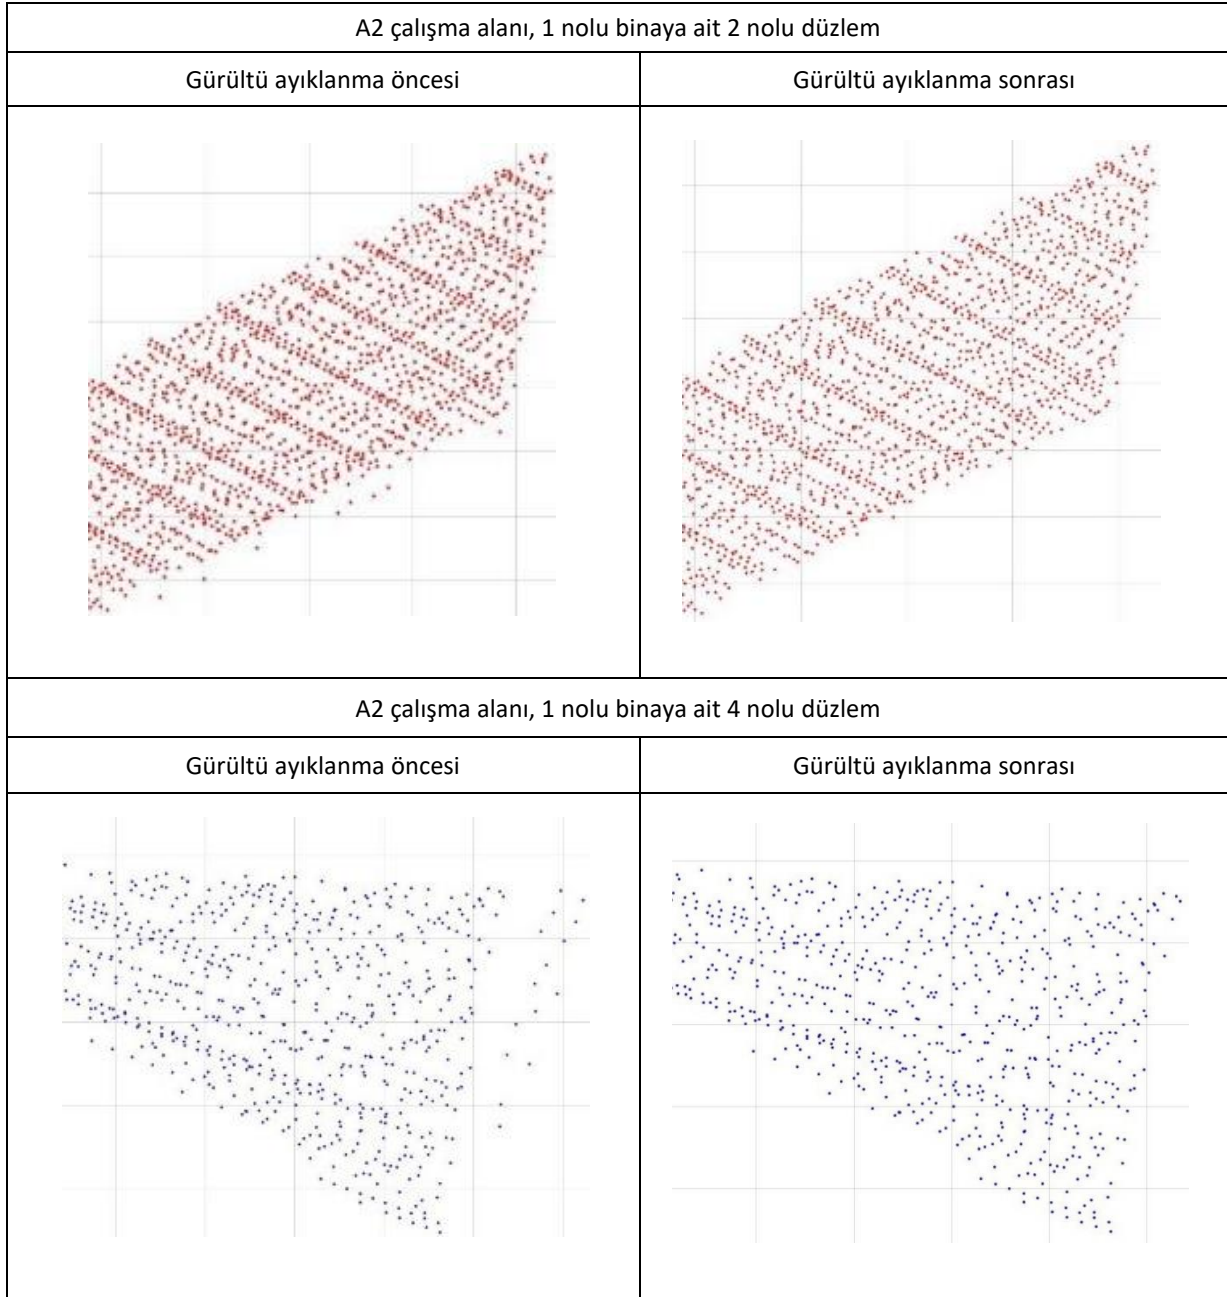
Şekil 9. A2 çalışma alanı 1 no'lu binaya ait; (a) nokta bulutu verisi, b) RANSAC algoritması ile çıkarılan çatı düzlemleri (4 adet)

Çatı düzlemlerinin çıkarılmasından sonra, başka düzlemlere ait ve gürültü olarak nitelendirilen aykırı noktalar Density-Based Spatial Clustering of Applications with Noise (DBSCAN) algoritması ile ayıklanmıştır (Yarpiz, 2021). DBSCAN algoritması düzlem temsil eden her bir nokta bulutu kümesine uygulanmıştır. Bu algoritma, nesnelerin komşuları ile olan mesafelerini hesaplayarak, belirli bir bölgede belirlenmiş bir eşik değerden fazla nesne bulunan alanları gruplandırmak suretiyle kümeleme işlemini gerçekleştirmektedir (Al-Zand, 2013). DBSCAN algoritmasının iki temel parametresi Eps (ϵ) ve MinPts dir (Bilgin ve Çamurcu, 2005). Eps (ϵ) komşu nesnelerin belirlenmesi için yakınlık mesafesini, MinPts ise Eps (ϵ) komşuluğunda bulunması gerekli minimum komşu sayısını göstermektedir (Al-Zand, 2013). Bu çalışmada en uygun parametre değerlerinin belirlenmesi için, MinPts parametresi değerleri 3, 5, 8 ve 15 olarak seçilmiş ve Eps (ϵ) parametresi değerleri 0.3 ile 1.2 arasında 0.1 artışla değiştirilmiştir.

Yapılan analizler neticesinde, A1 çalışma alanı için, MinPts ve Eps (ϵ) parametre değerleri sırasıyla 15 ve 0.7 ve A2 çalışma alanı için sırasıyla 5 ve 0.4 olarak belirlenmiştir (Tablo 3). A2 çalışma alanı, 1 no'lu binaya ait 2 ve 4 no'lu düzlemlerin gürültü ayıklanması öncesi ve sonrası yakın görüntüleri Şekil 10'da gösterilmiştir.

Tablo 3. A1 ve A2 çalışma alanları DBSCAN algoritması parametre değerleri

A1 Çalışma Alanı		A2 Çalışma Alanı	
MinPts	ϵ	MinPts	ϵ
15	0.7	5	0.4



Şekil 10. A2 çalışma alanı 1 nolu binaya ait düzlemlerin gürültü ayıklanma öncesi ve sonrası gösterimi

4. Doğruluk Analizleri

Önerilen yöntemle çıkarılan çatı düzlemleri doğruluk analizleri, 0.30 m çözünürlüklü ortofoto üzerinden manuel olarak sayısallaştırılmış referans çatı düzlemleri ile karşılaştırılmak suretiyle yapılmıştır. Bunun için, referans düzlemler ile iki boyuta indirgenmiş yöntemin çıkardığı düzlemlere ait nokta bulutu verisi karşılaştırılmış ve Eşitlik 2’de verilen Duyarlık (Precision-p), Bütünlük (Recall-r) ve F-skor (F-skor) değerleri hesaplanmıştır (Carrilho vd. 2017; Chen vd. 2019).

$$p = \frac{TP}{TP + FP} \quad r = \frac{TP}{TP + FN} \quad f - skor = \frac{2}{1/p + 1/r} \quad (2)$$

Eşitlik 2’de TP (True Positive) Doğru Pozitif, FN (False Negative) Yanlış Negatif, FP (False Positive) Yanlış Pozitif olarak ifade edilmektedir. TP, çıkarılan ve referans düzlem sınırları içerisinde bulunan nokta sayısını, FN, referans düzlem sınırları içerisinde bulunan ancak çıkarılmayan nokta sayısını ve FP, referans düzlem sınırları içerisinde olmayan çıkarılan nokta sayısını ifade etmektedir (Chen vd. 2019).

5. Bulgular

Yer filtreleme işleminden önce, zeminden aşağıda bulunan gürültü noktaları ayıklandığından ve Lasground modülünün step size parametresi değeri alandaki en büyük nesne olan bina büyüklüğüne göre 10 m olarak belirlendiğinden, filtreleme işlemi ile başarılı sonuçlar elde edilmiştir. Yer filtreleme işlemiyle ayrılan zemin üstü noktalarının temsil ettiği bina ve ağaç sınıflarının tespit edilmesi için Lasclassify modülü ground offset parametresi değeri, çalışma alanlarındaki en alçak bina yüksekliği dikkate alınarak belirlenmiştir. Bu yükseklik değerinin üzerinde hangi noktaların çatıya dahil olduğunu belirten building planarity standart sapma parametresi değeri, diğer parametreler sabit tutulurken artırıldığında, çatıya daha fazla nokta dahil olmaktadır. Bu nedenle, ağaçların bina üzerine sarkması ve arazide yükseklik farklarının olması durumlarında sınıflandırma işlemi hatalı sonuçlar üretebilmektedir. Dolayısıyla, bina sınıfına ait nokta bulutunun başarılı bir şekilde çıkarılabilmesi için yukarıdaki hususların da dikkate alınarak en uygun parametre değerlerinin belirlenmesi gerekmektedir. A1 ve A2 çalışma alanları için hesaplanan TP, FP, FN, p, r ve F-skor değerleri sırasıyla Tablo 4 ve 5’te verilmiştir.

Tablo 4. A1 çalışma alanı için hesaplanan TP, FP, FN, p, r ve F-skor değerleri

BİNA	DÜZLEM	TP	FP	FN	p	r	F-skor
4	1	478	97	120	83%	80%	82%
	2	544	20	14	%96	%97	%97
	3	111	111	79	%50	%58	%54
5	1	497	184	139	%73	%78	%75
	2	605	106	0	%85	%100	%92
	3	385	106	176	%78	%69	%73
6	1	511	208	83	%71	%86	%78
	2	481	89	0	%84	%100	%92
	3	379	10	206	%97	%65	%78
7	1	899	105	0	%90	%100	%94
	2	804	24	43	%97	%95	%96
	3	552	44	100	%93	%85	%88
8	1	693	71	0	%91	%100	%95
	2	510	22	20	%96	%96	%96
	3	255	16	19	%94	%93	%94
9	1	777	57	6	%93	%99	%96
	2	518	3	49	%99	%91	%95
	3	203	55	31	%79	%87	%83

Tablo 4'ün devamı

10	1	791	75	0	%91	%100	%95
	2	589	240	63	%71	%90	%80
	3	324	15	227	%96	%59	%73
11	1	781	67	79	%92	%91	%91
	2	567	89	0	%86	%100	%93
	3	523	6	50	%99	%91	%95
12	1	650	35	0	%95	%100	%97
	2	518	64	25	%89	%95	%92
	3	338	5	63	%99	%84	%91
13	1	511	179	1	%74	%100	%85
	2	532	21	137	%96	%80	%87
	3	284	49	46	%85	%86	%86
14	1	1208	34	29	%97	%98	%97
	2	393	294	87	%57	%82	%67
	3	253	86	265	%75	%49	%59
15	1	1126	26	7	%98	%99	%99
	2	576	59	3	%91	%99	%95
	3	499	4	44	%99	%92	%95
16	1	1168	47	0	%96	%100	%98
	2	569	132	22	%81	%96	%88
	3	479	0	131	%100	%79	%88
17	1	309	274	59	%53	%84	%65
	2	524	54	52	%91	%91	%91
	3	290	65	252	%82	%54	%65
18	1	1077	77	9	%93	%99	%96
	2	461	261	24	%64	%95	%76
	3	18	36	241	%33	%7	%12
19	1	747	96	0	%89	%100	%94
	2	582	7	57	%99	%91	%95
	3	251	47	2	%84	%99	%91
20	1	702	115	0	%86	%100	%92
	2	542	16	52	%97	%91	%94
	3	192	9	4	%96	%98	%97
21	1	1135	36	64	%97	%95	%96
	2	648	150	0	%81	%100	%90
	3	555	32	79	%95	%88	%91
22	1	866	17	39	%98	%96	%97
	2	274	209	0	%57	%100	%72
	3	211	15	168	%93	%56	%70
23	1	1167	15	10	%99	%99	%99
	2	525	243	7	%68	%99	%81
	3	396	33	233	%92	%63	%75
24	1	1124	42	32	%96	%97	%97
	2	651	213	3	%75	%100	%86
	3	307	2	178	%99	%63	%77


Tablo 4'ün devamı

25	1	908	22	12	%98	%99	%98
	2	463	140	15	%77	%97	%86
	3	149	25	130	%86	%53	%66
26	1	917	1	0	%100	%100	%100
	2	211	177	19	%54	%92	%68
	3	172	36	177	%83	%49	%62
ORTALAMA		554.42	77.10	62.06	%86	%87	%85

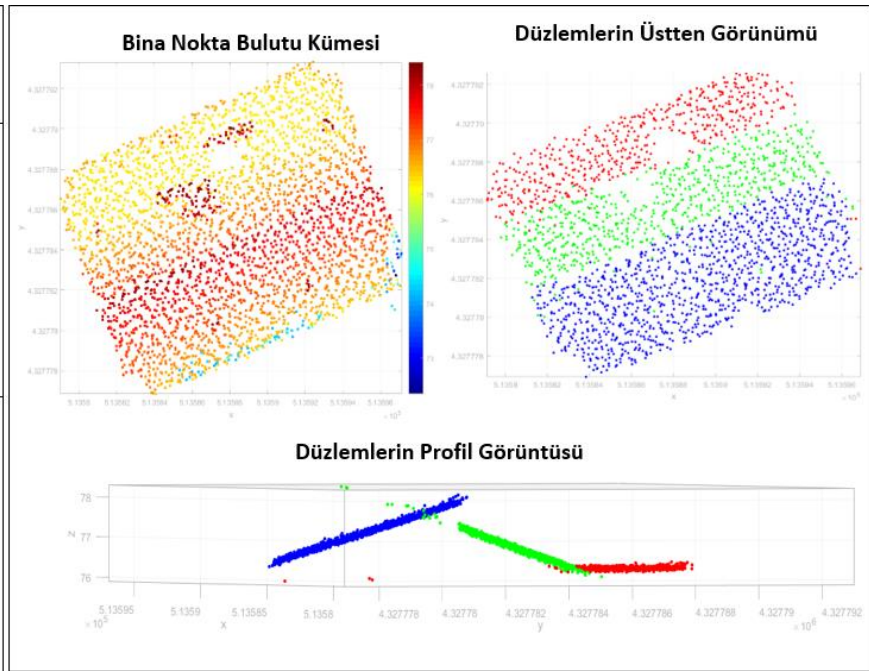
Tablo 5. A2 çalışma alanı için hesaplanan TP, FP, FN, p, r ve F-skor değerleri

BİNA	DÜZLEM	TP	FP	FN	p	r	F-skor
1	1	1853	458	0	%80	%100	%89
	2	2071	143	156	%94	%93	%93
	3	751	81	79	%90	%90	%90
	4	673	81	214	%89	%76	%82
2	1	2275	288	5	%89	%100	%94
	2	2145	197	121	%92	%95	%93
	3	1227	12	109	%99	%92	%95
	4	1137	60	34	%95	%97	%96
3	1	2877	608	16	%83	%99	%90
	2	3323	113	246	%97	%93	%95
	3	1612	53	182	%97	%90	%93
	4	1483	83	198	%95	%88	%91
ORTALAMA		1785.58	181.42	113.33	%92	%93	%92


A1 çalışma alanı için ortalama p, r ve F-skor değerleri sırasıyla, %86, %87, %85 olarak hesaplanmıştır (Tablo 4). Bu değerler A2 çalışma alanı için sırasıyla, %92, %93 ve %92 olarak hesaplanmıştır (Tablo 5). F-skor değerinin daha kullanışlı bir ölçü olduğu belirtilmektedir (Carrilho vd. 2017). Dolayısıyla, hesaplanan doğruluk değerleri F-skor değerine göre gruplandırılmıştır. Gruplandırma, Kötü (0-50), Orta (50-70), İyi (71-85) ve Çok İyi (86-100) şeklinde yapılmıştır. A1 çalışma alanındaki binaların neredeyse tamamında 3 çatı düzlemi (1 ve 3 no'lu binalarda 2 çatı düzlemi vardır) bulunurken, A2 çalışma alanındaki binalarda 4 çatı düzlemi bulunmaktadır. Binalara ait nokta bulutu kümelerine RANSAC algoritması uygulandığında, önce mavi (1 no'lu düzlem), sonra yeşil (2 no'lu düzlem) ve son olarak da kırmızı (3 no'lu düzlem) çatı düzlemlerine ait noktalar çıkarılmıştır (Şekil 11). Sonuçlar doğruluk değerlerinin gruplamasına göre analiz edildiğinde, Şekil 11a'da gösterilen A1 çalışma alanı 4 no'lu binaya ait 1. düzlem iyi, 2. düzlem çok iyi ve 3. düzlem ise orta düzey grubunda yer almaktadır. Şekil 11b'de gösterilen 15 no'lu binaya ait tüm düzlemler çok iyi düzey grubunda yer almaktadır. Şekil 11c'de gösterilen 18 no'lu binaya ait 1. düzlem çok iyi, 2. düzlem iyi ve 3. düzlem ise kötü düzey grubunda yer almaktadır. Yine, Şekil 11d'de gösterilen 25 no'lu binaya ait 1. ve 2. düzlemler çok iyi, 3. düzlem ise orta düzey grubunda yer almaktadır. Şekil 9'da gösterilen A2 çalışma alanı 1 no'lu binaya ait 4. düzlem iyi diğer düzlemler ise çok iyi düzey grubunda yer almıştır. Bu çalışma alanındaki 2 ve 3 no'lu binalara ait tüm düzlemler ise çok iyi doğruluk düzeyi grubunda yer almışlardır.




a)



b)



c)



d)


Şekil 11. A1 çalışma alanından seçilen binalara ait bina cephesi fotoğrafları, Google Earth görüntüsü ve nokta bulutu görüntüsü. a) 4 nolu bina b) 15 nolu bina c) 18 nolu bina d) 25 nolu bina. Mavi, yeşil ve kırmızı renkleri sırasıyla 1, 2 ve 3 nolu düzlemleri göstermektedir

A1 çalışma alanında bazı binalara ait çatı düzlemlerinde başarı oranının göreceli daha düşük çıkmasının nedeni, RANSAC algoritmasının komşu düzlemlere ait bazı noktaları çıkarılan düzleme dahil etmesidir. Bir düzlemin sınırsız büyüklükte olmasından dolayı bu tür noktaların olması aslında beklenen bir durumdur.

Nokta yoğunluğunun daha yüksek olması ve bina çatı geometrisinin daha düzgün olması nedeniyle, A2 çalışma alanında tüm düzlemler için p, r ve F-skor değerleri %80 üzerinde hesaplanmış ve dolayısıyla, yöntem bu çalışma alanında daha başarılı sonuçlar üretmiştir.

Bu çalışma alanında, 1 no'lu binadan çıkarılan düzlemlerden; 1 no'lu düzlem için hesaplanan p değeri %80 iken, diğer düzlemler için hesaplanan p değeri %90 mertebesindedir. Bu binaya ait düzlemlerden; en düşük r değerine (%76) 4 no'lu düzlem sahipken, diğer düzlemler için hesaplanan r değerleri %90 ve üzerindedir. Dolayısıyla, en düşük F-skor değeri de (%82) 4 no'lu düzleme ait olup diğer düzlemler için hesaplanan F-skor değerleri %90 mertebesindedir. Bu çalışma alanındaki 2 no'lu binadan çıkarılan tüm düzlemler için hesaplanan p değerleri %89 üzerindedir. Benzer şekilde, tüm düzlemler için hesaplanan r ve F-skor değerleri de %90 üzerinde olup yöntem bu binaya ait düzlemlerin çıkarılmasında oldukça başarılı sonuçlar üretmiştir. Bu çalışma alanındaki 3 no'lu binadan çıkarılan düzlemlerden 1 no'lu düzlem 83% ile en düşük p değerine sahiptir. Diğer düzlemler için hesaplanan p değerleri %95 üzerindedir. Bu binaya ait düzlemler için hesaplanan r değerleri %88 üzerinde, F-skor değerleri de %90 üzerinde hesaplanmış olup yine yöntemin başarısını göstermektedir.


RANSAC algoritması ile çıkarılan bir düzleme ait noktaların arasında ve düzlemin kenarlarında boşluklar oluşabilmektedir. Bu boşlukların oluşmasında temel etkenlerden birisi, bu çalışmada tüm binalar için tek değer olarak alınmış olan mesafe eşik değeri parametresi değeridir. Tüm binalar için aynı parametre değerinin kullanılması gürültü noktalarına neden olmuştur. Çatılardaki baca, güneş paneli, TV anteni vb. nesnelere de düzlem noktaları arasında boşlukların oluşmasına neden olmaktadır. Ayrıca, yer filtreleme işlemi sonrası ayrılan yüksek bitki örtüsü (ağaçlar) sınıfına ait noktaların binaların üzerlerine sarkan kısımları da (Şekil 12) çıkarılan çatı düzlemlerinde boşluklar oluştururken, binaların çok yakınında ve/veya binalar ile aynı yükseklikte olan bazı ağaçlara ait noktaların da bina sınıfına katıldığı görülmüştür.



Şekil 12. A1 çalışma alanında binalara bitişik konumda olan ağaçların gösterimi

A2 çalışma alanında bulunan binaların çatı geometrisinin daha düzgün olması, çatılarda daha az sayıda baca bulunması, güneş paneli olmaması ve yüksek bitki örtüsü yoğunluğunun daha düşük olmasından dolayı, yöntem bu alanda daha başarılı sonuçlar üretmiştir. Diğer taraftan, A1 çalışma alanında yer alan binaların üç düzlemden oluşması ve üçgen bir yapıya sahip olmaması (Şekil 11), çatılardaki bacaların yüksek olması, TV antenlerinin çatı üzerlerine konumlandırılmış olması ve çatıların daha karmaşık bir geometriye sahip olmasından dolayı yöntem bu alanda daha düşük doğrulukta sonuçlar üretmiştir.

Çıkarılan düzlemlerde yer alan gürültünün DBSCAN algoritması ile ayıklanması adımıyla, çalışma alanlarındaki tüm binalar için aynı parametre değeri kullanılmıştır. Bu nedenle, A2 çalışma alanına göre farklı şekil ve büyüklükte daha fazla binanın bulunduğu ve nokta yoğunluğunun daha düşük olduğu A1 çalışma alanında, düzlem nokta bulutu verisindeki gürültü noktalarının tespit başarısı beklentinin altında kalmıştır. A1 çalışma alanındaki 10 no'lu binaya ait çatı düzlemlerinde yer alan gürültü noktaları örnek olarak Şekil 13'de gösterilmiştir. Diğer taraftan, A2 çalışma alanındaki tüm binalara ait düzlemlerdeki (toplam 12 adet) gürültünün ayıklanması için aynı parametre değerinin kullanılması neticesinde ise daha başarılı sonuçlar elde edilmiştir. Bu alanda başarı oranını olumlu yönde etkileyen bir diğer etken, bina çatılarının daha düzgün bir geometriye sahip olmasıdır.



Şekil 13. A1 çalışma alanında 10 no'lu binaya ait çatı düzlemlerinde yer alan gürültü noktalarının DBSCAN algoritması ile tespit edilmesine bir örnek

A1 çalışma alanında, algoritmanın düzlem noktaları olarak çıkaramadığı çatıdaki bacaların sebep olduğu boşluklar (Şekil 13b) ve yukarıda bahsedilen diğer nedenlerden kaynaklı oluşan boşluklar (Şekil 13a ve 13c), gürültü noktalarının tespitinde sonuçları olumsuz yönde etkilemiştir. Çatı düzlemlerindeki gürültü noktalarının tespitinde her bir çalışma alanında bulunan tüm binalar için aynı parametre değerlerinin kullanılmasından dolayı, bazı binalarda gürültü olmayan noktaların (çıkarılan düzlemde olması gereken) gürültü noktaları olarak, gürültü noktalarının (çıkarılan düzlemde olmaması gereken) ise gürültü olmayan noktalar olarak tespit edildiği görülmüştür. Çıkarılan düzlemlerdeki gürültünün DBSCAN algoritması ile daha başarılı bir şekilde tespiti için, her bir düzleme ait nokta bulutu verisine ayrı parametre değerlerinin uygulanması gerekir. Ancak, bu yapılan işlemin süresini artıracaktır. Bu nedenle, bu çalışmada kullanılan parametre değerleri farklı iki çalışma alanı için farklı olup her bir çalışma alanında bulunan tüm bina düzlemleri için aynı olarak belirlenmiştir. Yöntemin çıkardığı düzlemlerin doğruluk analizleri, gürültünün temizlenmesi sonrası elde edilen düzlemler üzerinden yapılmıştır. Algoritmanın çıkardığı her bir düzlem için, ayrı DBSCAN algoritma parametre değerlerinin kullanılmaması olmasının sonuçları olumsuz yönde etkilediği düşünülmektedir.

6. Sonuçlar

Binalar 3B şehir modellerinde önemli rol oynamaktadır. Şehir alanlarında nüfusa dayalı olarak, yeni yerleşim alanlarının belirlenmesi, kentsel dönüşüm vb. yapılaşmalardan dolayı bina nesnelere güncelliğini yitirmektedir. Bu çalışmada, bina çatı düzlemlerinin hızlı, doğru ve güncel çıkarımı için hava LiDAR nokta bulutu verisi kullanılmıştır.

Çalışmada, binalara ait nokta bulutu verisi başarılı bir şekilde ayrılmıştır. Bir binayı temsil eden farklı geometrilere sahip çatı düzlemlerine ait düzlem noktalarını tespit etmek için, her bir binaya ait nokta bulutu kümesine MATLAB ortamında RANSAC algoritması uygulanarak temel büyük çatı düzlemlerinin doğru olarak tespiti sağlanmıştır.

Çalışmada kullanılan LiDAR nokta bulutu verisinin nokta yoğunluğunun yüksek olmasından dolayı, çatılardaki bacalar üzerine düşen nokta sayısı yüksektir. Ancak, RANSAC algoritması genellikle bacalara ait noktaları, çıkarılan düzlem noktalarına dahil etmemiştir. Bu da elde edilen düzlem çıkarımı sonuçlarının doğruluğunu artırmıştır.

A1 çalışma alanında bazı çatı düzlemlerine ait başarının düşük çıkmasının nedenleri arasında, bu alanda kullanılan veri nokta yoğunluğunun daha düşük olması ve çatıların çok düzgün geometriye sahip olmaması yer almaktadır. A2 çalışma alanında RANSAC algoritması daha iyi sonuçlar vermiştir. Bu çalışma alanında tüm çatı düzlemleri için p, r ve F-skor değerleri %80 üzerinde hesaplanmış olup yöntemin bu çalışma alanında daha başarılı sonuçlar ürettiği görülmüştür. A2 çalışma alanı 1 no'lu bina Şekil 9'da ve A1 çalışma alanı 4, 15, 18 ve 25 no'lu binalar Şekil 11'de örnek olarak gösterilmiştir. Bazı binalara ait çatı düzlemlerinde başarısız sonuçların elde edilmesinin ana sebepleri arasında, bina çatı düzlemleri üzerinde boşlukların olması ve bu boşlukların konumsal olarak geniş yer kaplaması, çıkarılan düzlem noktalarının aynı hizada olmaması (bir başka deyişle düzlem sınırlarının zig-zag'lı yapıda olması), her iki çalışma alanındaki tüm bina düzlemleri için aynı RANSAC parametre değerinin (Tablo 2) kullanılmış olması ve DBSCAN algoritması parametre değerlerinin (Tablo 3) her bir çalışma alanında bulunan tüm bina düzlemleri için aynı olması yer almaktadır.

Yöntemin bir avantajı, çatı düzlemi çıkarımının bölge büyüme bölütleme, RANSAC ve DBSCAN algoritmalarının entegrasyonu ortamında gerçekleştirmesidir. Yöntemin bir diğer avantajı binalara ait nokta bulutu veri kümelerinin öncelikle ayrıştırılması ve sonrasında RANSAC algoritmasının her binaya ait veriye ayrı ayrı uygulanması ve böylece çok karmaşık yapıda olmayan çatılardaki düzlemlerin çıkarılmasında oldukça yüksek performans sağlamasıdır. Dezavantajı: Bölge Büyütme Bölütleme, RANSAC ve DBSCAN algoritmaları parametre değerlerinin kullanıcı tarafından girilmesidir.

Teşekkür

Bu çalışmada kullanılan LiDAR verilerini sağlayan Harita Genel Müdürlüğü'ne çok teşekkür ederiz.

Kaynaklar

- Al-Zand, H. A. R. (2013). *Bölümleyici kümeleme algoritmalarının farklı veri yoğunluklarında karşılaştırması* (Yüksek Lisans Tezi), Gazi Üniversitesi Bilişim Enstitüsü, Ankara.
- Awrangjeb, M., & Lu, G. (2013, November). Building roof plane extraction from LiDAR data. In *International Conference on Digital Image Computing: Techniques and Applications (DICTA), 2013. Proceedings.* (pp. 1-8). IEEE.
- Awrangjeb, M., & Fraser, C. S. (2013). Rule-based segmentation of LiDAR point cloud for automatic extraction of building roof planes. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, II-3/W3, 1-6. doi: 10.5194/isprsannals-II-3-W3-1-2013.
- Axelsson, P. (2000). DEM generation from laser scanner data using adaptive TIN models. *International Archives of Photogrammetry and Remote Sensing*, 23(B4), 110–117.
- Bilgin, T. T., & Çamurcu, Y. (2005). DBSCAN, OPTICS ve K-Means kümeleme algoritmalarının uygulamalı karşılaştırılması. *Politeknik Dergisi*, 8(2), 139–145.
- Bretar, F. (2008). Feature extraction from LiDAR data in urban areas. J. Shan & C. K. Toth (Eds.), *Topographic Laser Ranging and Scanning: Principles and Processing* (pp. 403-418), CRC Press.
- Canaz, S., Karsli, F., Guneroglu A., & Dihkan, M. (2015, Mayıs). LiDAR verileri kullanılarak göl sınırlarının otomatik olarak belirlenmesi. *TUFUAB III. Teknik Sempozyumu*, 2015. (pp. 287–293).
- Carrilho, A., Ivanova, I., & Galo, M. (2017). Quality assessment for automatic LiDAR data classification methods. In *XVIII SBSR—Simpósio Brasileiro de Sensoriamento Remoto, Santos—SP, Proceedings.* (pp. 6772-6779).
- Chen, B., Shi, S., Sun, J., Gong, W., Yang, J., Du, L., Guo, K., Wang, B., & Chen, B. (2019). Hyperspectral lidar point cloud segmentation based on geometric and spectral information. *Optics Express*, 27(17), 24043-24059. doi: 10.1364/OE.27.024043.
- Chen, D., Zhang, L., Li, J., & Liu, R. (2012). Urban building roof segmentation from airborne LiDAR point clouds. *International Journal of Remote Sensing*, 33(20), 6497-6515. doi: 10.1080/01431161.2012.690083.

- Costantino, D., & Angelini, M. G. (2011). Features and ground automatic extraction from airborne lidar data. *ISPRS International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XXXVIII-5/W12, 19–24. doi : 10.5194/isprsarchives-XXXVIII-5-W12-19-2011.
- Çömert, R., & Avdan, U. (2014, Ekim). Yersel lazer tarayıcı verilerinden basit geometrik yüzeylerin otomatik olarak çıkarılması. 5. *Uzaktan Algılama-CBS Sempozyumu (UZAL-CBS 2014)*. 14-17 Ekim, İstanbul.
- Demir, N. (2016, Ekim). LiDAR Verisinden Çatı Düzlemlerinin Otomatik Çıkarılması. 6. *Uzaktan Algılama-CBS Sempozyumu (UZAL-CBS 2016)*, Proceedings. (pp. 133-138).
- Dorninger, P., & Nothegger, C. (2007). 3D Segmentation of unstructured point clouds for building modelling. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 36(3/W49A), 191–196.
- DSM/DTM Filtering. (2021, June 6). International school on LiDAR Technology. Retrieved from http://home.iitk.ac.in/~blohani/LiDARSchool2008/Downloads/DTM_pfeifer.pdf
- Fan, Y., Wang, M., Geng, N., Hu, S., Chang, J., & Zhang, J. J. (2018). A self-adaptive segmentation method for a point cloud. *Visual Computer*, 34(5), 659–673. doi: 10.1007/s00371-017-1405-6
- Fischler, M. A., & Bolles, R. C. (1981). Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography. *Graphics and Image Processing*, 24(6), 381-395.
- Gönültaş, F., Atik, M. E., & Duran, Z. (2020). Extraction of roof planes from different point clouds using ransac algorithm. *International Journal of Environment and Geoinformatics*, 7(2), 165-171. doi:10.30897/ijgeo.715510
- Karsli, F., & Pfeifer, N. (2012, Ekim). Ransac algoritması ile LiDAR verilerinden otomatik detay çıkarımı. IV. *Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZAL-CBS 2012)*. 16-19 Ekim, Zonguldak.
- Kayı, A., Erdoğan, M., & Eker, O. (2015). Optech HA-500 ve Riegl LMS- Q1560 ile gerçekleştirilen LiDAR test sonuçları. *Harita Dergisi*, 153, 42–46.
- LAStools. (2021a, Haziran 6). *ALS Filtering*. Retrieved from <http://lbi-archpro.org/als-filtering/lbi-project/results/lastools/filtering-algorithm-2>
- LAStools. (2021b, Haziran 6). *ALS Filtering. Guidelines*. Retrieved from <http://lbi-archpro.org/als-filtering/lbi-project/results/lastools/guidelines-2>
- LAStools. (2021c, Haziran 6). *Rapidlasso GmbH. lasground*. Retrieved from <https://rapidlasso.com/lastools/lasground/>
- LAStools. (2021d, Haziran 6). *Rapidlasso GmbH. lasclassify*. Retrieved from <https://rapidlasso.com/lastools/lasclassify/>
- Maltezos, E., & Ioannidis, C. (2016). Automatic extraction of building roof planes from airborne lidar data applying an extended 3d randomized hough transform. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, III-3, 209-216. doi: 10.5194/isprs-annals-III-3-209-2016.
- Morgan, M., & Tempfli, K. (2000). Automatic building extraction from airborne laser scanning data. *International Archives of Photogrammetry and Remote Sensing*, XXXIII-B3, 616–623.
- Meng, X., Currit, N., & Zhao, K. (2010). Ground filtering algorithms for airborne LiDAR data: A review of critical issues. *Remote Sensing*, 2(3), 833–860. doi: 10.3390/rs2030833.
- PCL. (2021a, Haziran 6). *Point Cloud Library (PCL) tutorials. Region growing segmentation*. Retrieved from https://pcl.readthedocs.io/projects/tutorials/en/latest/region_growing_segmentation.html#region-growing-segmentation
- PCL. (2021b, Haziran 6). *Point Cloud Library tutorials. Estimating Surface Normals in a PointCloud*. Retrieved from https://pcl.readthedocs.io/projects/tutorials/en/latest/normal_estimation.html#normal-estimation
- RANSAC. (2018, Ocak 22). *RANdom SAmple Consensus (RANSAC)*. Retrieved from <http://www.math-info.univ-paris5.fr/~lomn/Cours/CV/SeqVideo/Material/RANSAC-tutorial.pdf>
- Rusu, R. B. (2010). Semantic 3D Object Maps for Everyday Manipulation in Human Living Environments. *Künstl Intell*, 24, 345–348. doi: 10.1007/s13218-010-0059-6.
- Sithole, G., & Vosselman, G. (2003). *Report: ISPRS Comparison of Filters*. Retrieved from <https://www.itc.nl/isprs/wgIII-3/filtertest/report05082003.pdf>
- Tarsha-Kurdi, F., Landes, T., & Grussenmeyer, P. (2007). Hough-transform and extended ransac algorithms for automatic detection of 3d building roof planes from LiDAR data. *ISPRS International Archives of Photogrammetry, Remote Sensing and Spatial Information Systems*, XXXVI, 3/W52, 407-412.
- Vosselman, G., & Dijkman, S. (2001). 3D building model reconstruction from point clouds and ground plans. *International Archives of Photogrammetry and Remote Sensing*, XXXIV-3/W4, 37-43.
- Wei, S. (2008). Building boundary extraction base on LiDAR point clouds data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XXXVII-B3b, 157–161.
- Yarpiz. (2021, Haziran 6). Implementation of Density-Based Spatial Clustering of Applications with Noise (DBSCAN) in MATLAB. Retrieved from <https://www.mathworks.com/matlabcentral/fileexchange/52905-dbscan-clustering-algorithm>

Zaman, T. (2018, Ocak 22). 3D RANSAC (get planes from point clouds). Retrieved from <http://www.timzaman.com/2011/03/3d-ransacplanaire-oppervlakken-uit-puntwolken/>