

## Yoğun Nokta Bulutunda Bina Çatı Yüzeylerinin Tespiti

Nizar Polat<sup>1</sup>, Murat Uysal<sup>1</sup>

<sup>1</sup>Afyon Kocatepe Üniversitesi, mühendislik Fakültesi, Harita Mühendisliği Bölümü, Afyonkarahisar.

e-posta:[npolat@aku.edu.tr](mailto:npolat@aku.edu.tr), [muysal@aku.edu.tr](mailto:muysal@aku.edu.tr)

Geliş Tarihi: 06.02.2017 ; Kabul Tarihi: 26.07.2017

### Özet

#### Anahtar kelimeler

Nokta bulutu;  
Yüzey tespiti;  
RANSAC.

Yüksek detay seviyesinde 3B bina modellerinin üretilmesi ve bunların güncel tutulması birçok disiplin için önemli konulardandır. 3B bina modelinin hızlı, otomatik ve doğru şekilde üretilmesi modeli ifade eden her bir detayın (çatı, pencere vb.) modellenmesiyle doğrudan ilgilidir. Günümüzde, 3B bina modelleri için farklı sistemlerle elde edilen farklı veriler kullanılmaktadır. Bu çalışmada ilk olarak Afyon Kocatepe üniversitesi ANS kampüsünde, insansız hava araçlarıyla (İHA) çekilen fotoğraflar çekilmiştir. Daha sonra bu fotoğraflar kullanılarak çok yoğun nokta bulutları üretilmiştir. Sonuçta, üretilen nokta bulutunda kampüsteki seçilen binalara ait en uygun çatı yüzeyleri ve bu yüzeylere ait noktaları elde etmek için Rastgele Örnek Uzlaşımı (RANSAC) algoritması kullanılmış ve çatı yüzeyleri başarılı bir şekilde elde edilmiştir.

## Building Roof Plane Detection from Point Cloud Data

### Abstract

#### Keywords

Point cloud;  
Plane detection;  
RANSAC.

The production and maintenance of 3D building models at high level of detail is an important issue for many disciplines. Rapid, automatic and accurate production of a 3D building model is directly related to modeling every detail (roof, window, etc.) that expresses the model. Today, different data obtained by different systems are used for 3D building models.

In this study, firstly photographs were taken at Afyon Kocatepe University ANS campus with unmanned aerial vehicles (UAV). Later, using these photographs, very dense point clouds were produced. As a result, in the produced point cloud, the most suitable roof surfaces of the selected buildings in the campus and the Random Sample Proposal (RANSAC) algorithm were used to obtain the oints of these surfaces and the roof surfaces were successfully obtained.

© Afyon Kocatepe Üniversitesi

### 1. Giriş

Günümüzde, nokta bulutu olarak ifade edilen 3 boyutlu (3B) veri, nesne modelleme, topografik haritalama, hacim hesaplama, ormancılık vb. gibi çeşitli uygulamalarda çok yaygın şekilde kullanılmaktadır. Bu geniş kullanım alanının arkasında 3B veri üretimine imkân sağlayan Fotogrametri, bilgisayarlı görüş, lazer tarayıcı ve insansız Hava Aracı (İHA) gibi bilimsel dalı ve teknolojilerdeki gelişmeler bulunmaktadır. Günümüzde 3B nokta bulutu elde etme işi çoğunlukla lazer tarayıcılar ve fotoğraflar ile yapılmaktadır (Uysal ve diğerleri, 2015; Porway ve diğerleri, 2008; Bhagavathy & Manjunath, 2006;

Charaniya ve diğerleri, 2004; Chen & Zakhor, 2009). Özellikle yaygınlaşan İHA kullanımı sayesinde esnek zamanlı ve düşük maliyetli çok yüksek çözünürlüklü görüntülerin elde edilen nokta bulutu üretimi lazer tarayıcılara rakip haline gelmiştir (Thiel & Schullius, 2016). İHA, kullanım kolaylığı, daha taşınabilir olması ve lazer tarayıcılara göre daha ekonomik olması sebebiyle çok sık kullanılmaktadır. Dahası, çalışmanın amacına göre kullanılacak ekipman seçimi ve planlama açısından da daha kolaydır (Suomalainen ve ark., 2014). Farklı kaynaklardan elde edilen 3B nokta bulutu kullanımındaki bu popülerlik, sadece geomatik disiplininin kaynaklanmamaktadır. Özellikle

bilgisayarlı görüş disiplinindeki araştırmacılar karmaşık nokta bulutlarından obje çıkarımı, arkeologlar tarihi eserlerin dokümantasyon ve modellemesi ve sanal gerçeklik üreticileri bilgisayar oyunları için nokta bulutunu yaygın bir şekilde kullanmaktadır (Nevalainen ve diğerleri, 2017; Zhang ve diğerleri, 2015; Polat & Uysal, 2015; Uysal ve diğerleri, 2015). Bu çalışmada Afyon Kocatepe üniversitesi mühendislik fakültesi labratuvar binasının İHA ile çekilmiş fotoğraflarından elde edilmiş yoğun nokta bulutundan çatı yüzeylerinin Rastgele Örnek Uzlaşımı (RANSAC) algoritması ile tespit edilmesi ve doğruluk analizi sunulmaktadır.

## 2. Yöntem

Çalışma, İHA ile fotoğraf çekiminden, çatı yüzeylerinin tespitine kadar süren bir işlem akışı içermektedir.

### 2.1. Veri Toplama

Çalışma da DJI Phantom pro kullanılmıştır. Kampus içinde mühendislik fakültesi çevresinde toplam 297 fotoğraf çekilmiştir. Ayrıca referanslandırma için yer kontrol noktaları da ölçülmüştür.

### 2.2. Veri İşleme

Fotoğraflardan nokta bulutu üretimi için temelde bir görüntü eşleştirme algoritması kullanan agisoft yazılımı kullanılmıştır. Literatürde Structure from Motion (SfM) diye adlandırılan yaklaşım temel olarak fotoğraflar arasındaki eşleme noktalarını bularak fotoğrafları ilişkilendirir ve neredeyse her piksele bir 3B konum atar. Yer kontrol noktaları kullanarak üretilen bu noktalar referanslandırılır.

### 2.3. Çatı Yüzey Tespit

Giriş bölümünde anlatıldığı üzere, nokta bulutundan obje tespit çok çalışılan bir konudur. Bunun için sık kullanılan bir yaklaşım da rasgele örnek konsensüs'tür (RANSAC) (Fischler & Bolles, 1981). Bu algoritma birçok uygulamada oturma-uyuma (Hyppä ve diğerleri, 2001), sağlamlık ve verimlilik (Elseberg ve ark., 2013) açısından başarılıdır. RANSAC yöntemi geleneksel bir obje

tespit yaklaşımından farklıdır. Geleneksel yaklaşımda maksimum sayı girişi girdi olarak kullanılır ve daha sonra girilen veriler uygun olmayan noktalar filtrelenerek veri azaltılır. Fakat RANSAC'da, ilgili şekli tarif edebilecek minimum nokta sayısı rastgele seçilir ve girdi olarak kullanılır. Daha sonra kalan noktalar ilgili şekle uyacak şekilde test edilir. Tüm noktalar test edilene kadar algoritma devam etmez. Bunun yerine, seçilen bir p olasılık değerine uyan s sayısı, modelin hesaplanmasında kullanılır ve bu seçim, iyi bir şekilde şekli belirlenene kadar N kez tekrar eder. N, denklemlerle (1) (Hartly & Andrew, 2003; Fischler & Bolles, 1981) kararlaştırılmıştır.

$$N = \log(1-p) / \log(1-(1-\epsilon)^s) \quad (1)$$

P doğru modeli seçme olasılığı, E seçilen noktaların modelin dışına çıkma olasılığı, s en az rasgele seçilecek noktanın sayısıdır. Doğru modelin seçilme olasılığı genellikle 0.99 olarak seçilir (Hartly & Andrew, 2003; Fischler & Bolles, 1981). Rasgele örnekleme yaklaşımı olan RANSAC, pek çok uygulamada tatmin edici sonuçlara ulaşmayı başarmıştır (Çömet, 2014). Bununla birlikte, küçük bölgesel ya da bireysel yapı parametreleri, tüm veri setine uygulanıyorsa sonuç yetersiz olmaktadır çünkü neredeyse bütün nokta seti RANSAC'a aykırı değerler olarak görünmektedir (Boesch, 2013). Bununla birlikte, RANSAC algoritmasının aşağıdaki avantajlara sahip olduğu unutulmamalıdır:

- Mantıksal olarak basittir ve kolayca uygular,
- Geniş bir uygulama alanında kullanılabilen genel bir paradigması vardır
- % 50 den fazla aykırı değer içeren verilerde de çalışmaktadır (Schnabel ve diğerleri, 2006; Roth & Levine, 1993).

## 3. Uygulama


Çalışma da DJI Phantom pro kullanılmıştır. Kampus içinde mühendislik fakültesi çevresinde toplam 297 fotoğraf çekilmiştir. 6 milyondan fazla referanslandırılmış nokta elde edilmiştir. Sadece

labratuvar binasına ait ise 1,075,247 nokta bu çalışmada kullanılmıştır (Şekil 1).



Şekil 1. Labratuvar binasına ait gerçek renkli nokta bulutu.

RANSAC algoritması açık kaynak kodlu cloud compare yazılımında başarıyla uygulanmış ve bina çatı yüzeylerine ait noktalar bulunmuştur (şekil 2).



Şekil 2. Bulunan bağımsız çatı yüzeyleri.

Labratuvar binasında bulunan 18 çatı yüzeyinin 16 tanesi tespit edilebilmiştir.

#### 4. Analiz

Sonuçları analiz etmek için, Üretici doğruluğu olarak da adlandırılan Tamlik (Completeness) ve Kullanıcı Doğruluğu olarak da adlandırılan Doğruluk

Tablo 1. Bulunan yüzeylere ait kullanıcı ve üretici doğruluk değerleri.


Yüzeyler	Referans	RANSAC	tp	fp	fn	Üretici Doğ.	Kullanıcı Doğ.
P1	71545	58719	54890	3829	16655	0.77	0.94
P2	51133	31870	30056	1814	21077	0.59	0.94
P3	3645	4301	1003	3298	2642	0.28	0.23
P4	30121	17861	16374	1487	13747	0.54	0.92
P5	5645	3002	1540	1462	4105	0.27	0.51
P6	53700	40184	39165	1019	14535	0.73	0.98
P7	59884	46519	44628	1891	15256	0.75	0.96
P8	13383	8723	8678	45	4705	0.65	0.99
P9	42011	31529	28559	2970	13452	0.68	0.91

(Correctness) değerleri aşağıdaki formüllere göre hesaplanmıştır.

$$\text{Comp} = \frac{tp}{(tp+fn)} \quad (2)$$

$$\text{Corr} = \frac{tp}{(tp+fp)} \quad (3)$$

(Tp), bir düzleme ait olarak tespit edilen noktanın gerçekten de referans veride o düzleme ait olmasıdır. (Fn), referansta mevcut bir noktanın bulunamama durumudur. (Fp), referans düzleminde bulunmayan (ya da başka bir düzleme ait) bir noktanın yüzeye ait olarak yanlış bulunmasıdır. Labratuvar binasına ait yüzeylerin numaralandırılması şekil 3 de gösterilmektedir.



Şekil 3. Labratuvar binasında bulunan çatı yüzeyleri.

Bu şekilde bulunan 16 yüzeye ait noktalar manuel olarak elde edilen referans düzlemler ile kıyaslanarak analiz edilmiş ve sonuçlar tablo 1 de verilmiştir.

<b>P10</b>	16345	8911	8110	801	8235	0.50	0.91
<b>P11</b>	29754	19978	18766	1212	10988	0.63	0.94
<b>P12</b>	31008	25994	22958	3036	8050	0.74	0.88
<b>P13</b>	25925	18167	16554	1613	9371	0.64	0.91
<b>P14</b>	15861	8738	8674	64	7187	0.55	0.99
<b>P15</b>	46668	35484	34190	1294	12478	0.73	0.96
<b>P16</b>	12525	8276	7796	480	4729	0.62	0.94

Laboratuvar binasına ait 18 çatı yüzeyinden 16 tanesi başarıyla tespit edilmiştir. Tespit edilen yüzeyler ise ortalama %60 üretici doğruluğu ve %87 kullanıcı doğruluğuna sahiptir.

Nokta bazlı yapılan bu analizi dikkate alındığında, üretici doğruluğu ikinci planda alınabilir. Çünkü yöntem bölümünde de bahsedildiği gibi, bir yüzeye ait tüm noktaların aynı anda RANSAC parametreleriyle uyuşması beklenemez. Ayrıca, referans veride bulunan ve veriden çıkarılamayan baca, anten vb. gibi nesnelere de üretici doğruluk değerini düşürmektedir. Bu nedenle doğruluk değeri daha önemlidir. Yani, bir düzleme ait olarak tespit edilen noktaların gerçekten de o yüzeye ait olma yüzdesi, bu çalışmada çok yüksektir.

## 5. Sonuç

Yüksek detay seviyesinde 3B bina modellerinin üretilmesi ve bunların güncel tutulması birçok disiplin için önemli konulardandır. 3B bina modelinin hızlı, otomatik ve doğru şekilde üretilmesi modeli ifade eden her bir detayın (çatı, pencere vb.) modellenmesiyle doğrudan ilgilidir. Günümüzde, 3B bina modelleri için farklı sistemlerle elde edilen farklı veriler kullanılmaktadır.

Bu çalışmada İHA dan elde edilen hava fotoğrafları kullanılarak üretilen nokta bulutları, girdi veri olarak kullanılmış ve çatı yüzeylerine ait noktalar tespit edilmeye çalışılmıştır.

Çalışmada Rastgele Örnek Uzlaşımı (RANSAC) algoritması kullanılmış ve laboratuvar binasına ait 18 çatı yüzeyinden 16'sı başarılı bir şekilde elde edilmiştir. Çalışmanın başarısını nümerik ifade

edebilmek için ifade üretici ve kullanıcı doğrulukları hesaplanmıştır. Sonuç olarak görüntü tabanlı yoğun nokta bulutundan RANSAC algoritması ile ortalama %60 üretici doğruluğu ve %87 kullanıcı doğruluğuna ulaşılabilmektedir. RANSAC algoritması parametrelere bağlı çalıştığı için elde edilen sonuç farklı veri tipi ve farklı parametrelerde değişiklik gösterebilir.

## 6. Kaynaklar

- Bhagavathy, S. & Manjunath, B.S., 2006. Modeling and Detection of Geospatial Objects Using Texture Motifs. *Transactions on Geoscience And Remote Sensing*, 44(12), pp.3706–3715.
- Boesch, R., 2013. Model based automatic segmentation of tree stems from single scan data. In *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. pp. 49–53.
- Charaniya, A.P., Manduchi, R. & Lodha, S.K., 2004. Supervised Parametric Classification of Aerial LiDAR Data. In *Conference on Computer Vision and Pattern Recognition Workshop*. IEEE, pp. 30–30.
- Chen, G. & Zakhor, A., 2009. 2d Tree Detection In Large Urban Landscapes Using Aerial Lidar Data. In *international conference on Image processing*. IEEE, pp. 1693–1696.
- Çömert, R., 2014. Yersel Lazer Tarayıcılardan Elde Edilen Veriler Kullanılarak Otomatik Nesne Çıkarımı. Yüksek lisans tezi. Anadolu üniversitesi. 177.

- Elseberg, J., Borrmann, D. & Nüchter, A., 2013. One billion points in the cloud – an octree for efficient processing of 3D laser scans. *ISPRS Journal of Photogrammetry and Remote Sensing*, 76, pp.76–88.
- Fischler, M.A. & Bolles, R.C., (1981). Graphics and Image Processing Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography. *Graphics and Image Processing*, 24(6), pp.381–395.
- Hartly, R. & Andrew, Z., (2003). *Multiple View Geometry in Computer Vision* 2nd ed., Cambridge University Press.
- Hyypä, J. et al., (2001). A segmentation-based method to retrieve stem volume estimates from 3-D tree height models produced by laser scanners. *IEEE Transactions on Geoscience and Remote Sensing*.
- Nevalainen, O. et al., (2017). Individual Tree Detection and Classification with UAV-Based Photogrammetric Point Clouds and Hyperspectral Imaging. *Remote Sensing*.
- Polat, N. & Uysal, M., (2015). Investigating performance of Airborne LiDAR data filtering algorithms for DTM generation. *Measurement*, 63, pp.61–68.
- Porway, J. et al.,(2008). A hierarchical and contextual model for aerial image understanding. In *2008 IEEE Conference on Computer Vision and Pattern Recognition*. IEEE, pp. 1–8. Available at: <http://ieeexplore.ieee.org/document/4587359/> [Accessed February 28, 2017].
- Roth, G. & Levine, M.D., (1993). Extracting Geometric Primitives. *CVGIP: Image Understanding*, 58(1), pp.1–22.
- Schnabel, R. et al., (2006). *Shape Detection in Point Clouds*, Bonn.
- Suomalainen, J. et al., (2014). A Lightweight Hyperspectral Mapping System and Photogrammetric Processing Chain for Unmanned Aerial Vehicles. *Remote Sensing*, 6(11), pp.11013–11030.
- Thiel, C. & Schullius, C., (2016). Comparison of UAV photograph-based and airborne lidar-based point clouds over forest from a forestry application perspective. *International Journal of Remote Sensing*, 0(0), pp.1–16.
- Uysal, M., Toprak, A.S. & Polat, N., 2015. Dem generation with uav photogrammetry and accuracy analysis in sahitler hill. *Measurement*, 73, pp.539–543.
- Zhang, C., Zhou, Y. & Qiu, F., 2015. Individual Tree Segmentation from LiDAR Point Clouds for Urban Forest Inventory. *Remote Sensing*, 7, pp.7892–7913.