

YO UN NOKTA BULUTUNDA B NA ÇATI YÜZEYLER N N TESP T

N. Polat ^{a,*}, M. Uysal^a

^aAfyon Kocatepe Üniversitesi Mühendislik Fakültesi Harita Mühendisli i Bölümü, 03200 Afyonkarahisar/TÜRK YE
npolat@aku.edu.tr

Anahtar Kelimeler: Nokta bulutu, Yüzey tespit, RANSAC

ÖZET

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

Bu çalı mada ilk olarak Afyon Kocatepe üniversitesi ANS kampüsünde, insansız hava araçlarıyla (HA) çekilen foto raflar çekilmi tir. Daha sonra bu foto raflar kullanılarak çok yo un nokta bulutları üretilmi tir. Sonuçta, üretilen nokta bulutunda kampüsteki seçilen binalara ait en uygun çatı yüzeyleri ve bu yüzeylere ait noktaları elde etmek için Rastgele Örnek Uzla ımı (RANSAC) algoritması kullanılmı ve çatı yüzeyleri ba arılı bir ekilde elde edilmi tir.

Keywords: Point cloud, Surface detection, RANSAC

ABSTRACT

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.

1. Giri

Günümüzde, nokta bulutu olarak ifade edilen 3 boyutlu (3B) veri, nesne modelleme, topografik haritalama, hacim hesaplama, ormancılık vb. gibi çe itli uygulamalarda çok yaygın ekilde kullanılmaktadır. Bu geni kullanım alanının arkasında 3B veri üretimine imkân sa layan Fotogrametri, bilgisayarlı görü , lazer tarayıcı ve nsansız Hava Aracı (HA) gibi bilimsel dalı ve teknolojilerdeki geli meler bulunmaktadır. Günümüzde 3B nokta bulutu elde etme i i ço unlukla lazer tarayıcılar ve foto raflar ile yapılmaktadır (Uysal ve di erleri, 2015; Porway ve di erleri, 2008; Bhagavathy & Manjunath, 2006; Charaniya ve di erleri, 2004; Chen & Zakhor, 2009). Özellikle yaygınla an HA kullanımı sayesinde esnek zamanlı ve dü ük maliyetli çok yüksek çözünürlüklü görüntülerin elde edilen nokta bulutu üretimi lazer tarayıcılara rakip haline gelmi tir (Thiel & Schmulius, 2016). HA, kullanım kolaylı ı, daha ta inabilir olması ve lazer tarayıcılara göre daha ekonomik olması sebebiyle çok sık kullanılmaktadır. Dahası, çalı manın amacına göre kullanılacak ekipman seçimi ve planlama açısında da daha kolaydır (Suomalainen ve ark., 2014).

Farklı kaynaklardan elde edilen 3B nokta bulutu kullanımındaki bu popülerlik, sadece geomatik disiplininden kaynaklanmamaktadır. Özellikle bilgisayarlı görü disiplinindeki ara tırmacılar karma ık nokta bulutlarından obje çıkarımı, arkeologlar tarihi eserlerin dokümantasyon ve modellemesi ve sanal gerçeklik üreticileri bilgisayar oyunları için nokta bulutunu yaygın bir ekilde kullanmaktadır (Nevalainen ve di erleri, 2017; Zhang ve di erleri, 2015; Polat & Uysal, 2015; Uysal ve di erleri, 2015). Bu çalı mada Afyon Kocatepe üniversitesi mühendislik fakültesi labratuvar binasının HA ile çekilmi foto raflarından elde edilmi yo un nokta bulutundan çatı yüzeylerinin Rastgele Örnek Uzla ımı (RANSAC) algoritması ile tespit edilmesi ve do ruluk analizi sunulmaktadır.

2. Yöntem

Çalı ma, HA ile foto raf çekiminden, çatı yüzeylerinin tespitine kadar süren bir i lem akı ı içermektedir.

2.1. Veri Toplama

Çalı ma da DJI Phantom pro kullanılmı tir. Kampus içinde mühendislik fakültesi çevresinde toplam 297 foto raf

çekilmi tir. ayrıca referanslandırma için yer kontrol noktaları da ölçülmü tür.

2.2. Veri leme

Foto raflardan nokta bulutu üretimi için temelde bir görüntü eleme algoritması kullanan agisoft yazılımı kullanılmı tür. Literatürde Structure from Motion (SfM) diye adlandırılan yakla ım temel olarak foto raflar arasındaki eleme noktalarını kullanarak foto rafları ilikendirir ve neredeyse her piksele bir 3B konum atar. Yer kontrol noktaları kullanarak üretilen bu noktalar referanslandırılır.

2.3. Çatı Yüzey Tespit

Giri bölümünde anlatıldı ı üzere, nokta bulutundan obje tespit çok çalı ılan bir konudur. Bunun için sık kullanılan bir yakla ım da rasgele örnek konsensüs'tür (RANSAC) (Fischler & Bolles, 1981). Bu algoritma birçok uygulamada oturma-uyuma (Hyypä ve di erleri, 2001), sa lamlık ve verimlilik (Elseberg ve ark., 2013) açısından ba arılıdır. RANSAC yöntemi geleneksel bir obje tespit yakla ımından farklıdır. Geleneksel yakla ımda maksimum sayı giri i girdi olarak kullanılır ve daha sonra girilen veriler uygun olmayan noktalar filtrelenerek veri azaltılır. Fakat RANSAC'da, ilgili ekli tarif edebilecek minimum nokta sayısı rastgele seçilir ve girdi olarak kullanılır. Daha sonra kalan noktalar ilgili ekle uyacak ekilde test edilir. Tüm noktalar test edilene kadar algoritma devam etmez. Bunun yerine, seçilen bir p olasılık de erine uyan s sayısı, modelin hesaplanmasında kullanılır ve bu seçim, iyi bir ekilde ekli belirlenene kadar N kez tekrar eder. N, denklemle (1) (Hartly & Andrew, 2003; Fischler & Bolles, 1981) kararlı tırılmı tür.

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

P do ru modeli seçme olasılı ı, ϵ seçilen noktaların modelin dışına çıkma olasılı ı, s en az rasgele seçilecek noktanın sayısıdır. Do ru modelin seçilme olasılı ı genellikle 0.99 olarak seçilir (Hartly & Andrew, 2003; Fischler & Bolles, 1981).

Rasgele örnekleme yakla ımı olan RANSAC, pek çok uygulamada tatmin edici sonuçlara ulaşmayı ba arılmı tür. Bununla birlikte, küçük bölgesel ya da bireysel yapı parametreleri, tüm veri setine uygulanıyorsa sonuç yetersiz olmaktadır çünkü neredeyse bütün nokta seti RANSAC'a aykırı de erler olarak görünmektedir (Boesch, 2013). Bununla birlikte, RANSAC algoritmasının ba arıdaki avantajlara sahip oldu u unutulmamalıdır:

- Mantıksal olarak basittir ve kolayca uygular,
- Geni bir uygulama alanında kullanılabilen genel bir paradigması vardır
- % 50 den fazla aykırı de er içeren verilerde de çalı maktadır (Schnabel ve di erleri, 2006; Roth & Levine, 1993).


3. Uygulama

Çalı ma da DJI Phantom pro kullanılmı tür. Kampus içinde mühendislik fakültesi çevresinde toplam 297 foto raf çekilmi tir. 6 milyondan fazla referanslandırılmı nokta elde edilmi tir. Sadece labratuvar binasına ait ise 1,075,247 nokta bu çalı ma da kullanılmı tür (ekil 1).



ekil 1. Labratuvar binasına ait gerçek renkli nokta bulutu.

RANSAC algoritması açık kaynak kodlu cloud compare yazılımında ba arıyla uygulanmı ve bina çatı yüzeylerine ait noktalar bulunmu tür (ekil 2).



ekil 2. Bulunan ba ımsız çatı yüzeyleri.

Labratuvar binasında bulunan 18 çatı yüzeyinin 16 tanesi tespit edilebilmi tir.


4. Analiz

Sonuçları analiz etmek için, Üretici do rulu u olarak da adlandırılan Tamlik (Completeness) ve Kullanıcı Do rulu u olarak da adlandırılan Doğ ruluk (Correctness) de erleri a a ıdaki formüllere göre hesaplanmı tür.

$$Comp = tp / ((tp + fn)) \quad (2)$$

$$Corr = tp / ((tp + fp)) \quad (3)$$

(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 ba ka bir düzleme ait) bir noktanın yüzeye ait olarak yanlış bulunmasıdır. Labratuvar binasına ait yüzeylerin numaralandırılması ekil 3 de gösterilmektedir.



ekil 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.

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

Yüzeyler	Referans	RANSAC	tp	fp	fn	Üretici Do .	Kullanıcı Do .
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
P10	16345	8911	8110	801	8235	0.50	0.91
P11	29754	19978	18766	1212	10988	0.63	0.94
P12	31008	25994	22958	3036	8050	0.74	0.88
P13	25925	18167	16554	1613	9371	0.64	0.91
P14	15861	8738	8674	64	7187	0.55	0.99
P15	46668	35484	34190	1294	12478	0.73	0.96
P16	12525	8276	7796	480	4729	0.62	0.94

Labratuvar binasına ait 18 çatı yüzeyinden 16 tanesi başarıyla tespit edilmiştir. Tespit edilen yüzeyler ise ortalama %60 üretici doğruluk ve %87 kullanıcı doğruluğuna sahiptir. Nokta bazlı yapılan bu analizi dikkate alındığında, üretici doğruluk ikinci planda alınabilir. Çünkü, yöntem bölümünde de bahsedildiği gibi, bir yüzeye ait tüm noktaların aynı anda RANSAC parametreleriyle uyumu 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 HA dan elde edilen hava foto rafları kullanılarak üretilen nokta bulutları, girdi veri olarak kullanılmış ve çatı yüzeylerine ait noktalar tespit edilmeye çalışılmıştır.

Çalışmada Rastgele Örnek Uzlaşımı (RANSAC) algoritması kullanılmış ve labratuvar binasına ait 18 çatı yüzeyinden 16'sı başarıyla bir şekilde elde edilmiştir. Çalışmanın başarılarını nümerik ifade edebilmek için ifade üretici ve kullanıcı doğrulukları hesaplanmıştır. Sonuç olarak görüntü tabanlı yöntem nokta bulutundan RANSAC algoritması ile ortalama %60 üretici doğruluk ve %87 kullanıcı doğruluğuna ulaşılabilmektedir. RANSAC algoritması parametrelere bağlı çalışması için elde edilen sonuç farklı veri tipi ve farklı parametrelerde de değişiklik gösterebilir.

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.

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.

Hartley, 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. & Schmallius, 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.