

# YOĞUN GÖRÜNTÜ EŞLEME ALGORİTMALARI İLE ÜRETİLEN NOKTA BULUTUNUN SINIFLANDIRILMASI

N. Yastıklı<sup>a</sup>, Z. Çetin<sup>a,\*</sup>

<sup>a</sup> Yıldız Teknik Üniversitesi, Harita Mühendisliği Bölümü, 34220, Esenler, İstanbul - (ynaci, zerisir)@yildiz.edu.tr

**ANAHTAR SÖZCÜKLER:** Fotogrametri, Hava Fotoğrafları, Görüntü Eşleme, Sınıflandırma, Nokta Tabanlı Sınıflandırma

## ÖZET:

Yer yüzeyi üzerindeki bitki örtüsü ve insan yapımı objelere ait yoğun nokta bulutları, yüksek doğrulukla ve hızlı bir şekilde hava LiDAR sistemleri kullanılarak elde edilmektedir. Günümüzde LiDAR verilerine alternatif olarak, hava fotoğraflarını kullanarak stereo görüntü eşleştirme ile nokta bulutu verilerinin otomatik olarak oluşturulması mümkündür. Gelişen kamera teknolojisi ve görüntü eşleme algoritmalarındaki son yenilikler ile yapılan araştırmalar hava fotoğrafları kullanılarak çok yoğun nokta bulutu üretimi (dense image matching) üzerine yoğunlaşmıştır. Bu çalışmalar sonucunda, hava fotoğrafındaki her bir piksel için nokta üretimi, geliştirilen yoğun görüntü eşleme yaklaşımı ile olanaklı hale gelmiştir. Bu yeni yaklaşım, daha geniş şehirler, kırsal ve ormanlık alanlar olmak üzere ülke genelinde birçok uygulama için yüksek çözünürlüklü nokta bulutu üretimi imkânı sağlamaktadır.

Bu çalışmada, yoğun görüntü eşleme algoritmaları kullanılarak elde edilen nokta bulutu verilerinin sınıflandırılması amaçlanmıştır. Nokta bulutu verilerinin otomatik olarak sınıflandırılabilmesi için hiyerarşik kurallar bütününden oluşan nokta tabanlı sınıflandırma yaklaşımı oluşturulmuştur. Test verisi olarak, İstanbul, Zekeriyaköy'e ait T.C. Çevre ve Şehircilik Bakanlığı, Coğrafi Bilgi Sistemleri Genel Müdürlüğü tarafından gerçekleştirilen Yüksek Çözünürlüklü Sayısal Yüzey Modeli (YM) ve Gerçek Ortofoto Üretimi Projesi kapsamında yoğun görüntü eşleme algoritmaları ile üretilen yoğun nokta bulutu kullanılmıştır. Çalışma alanında belirlenen farklı pilot bölgeler kullanılarak otomatik nokta tabanlı sınıflandırma yaklaşımındaki kurallara ilişkin parametre analizleri gerçekleştirilmiştir. Önerilen otomatik nokta tabanlı sınıflandırma işlemi uygulanarak elde edilen noktalar yer yüzeyi, bina ve bitki örtüsü olmak üzere üç temel sınıfta toplanmıştır. Son olarak sınıflandırma doğruluğunu test etmek amacıyla, belirlenen pilot bir bölgede doğruluk analizi çalışmaları gerçekleştirilmiştir.

## CLASSIFICATION OF THE POINT CLOUD PRODUCED BY DENSE IMAGE MATCHING ALGORITHMS

**KEYWORDS:** Photogrammetry, Aerial Photographs, Image Matching, Classification, Point Based Classification

## ABSTRACT:

The dense point clouds of the vegetation and the man-made objects on the earth surface are obtained by using the air LiDAR systems with high accuracy and in a quick way. Today, it is possible to automatically produce the point cloud data by stereo image matching using aerial photographs as an alternative to LiDAR data. Nowadays, researches have focused on dense point cloud generation using aerial photographs with the recent advances in camera technology and image matching algorithms. As a result of these studies, a point generation for each pixel in the aerial photograph has been made possible by the developed dense image matching approaches. This new approaches provide a high resolution point cloud production for many nation-wide applications, including larger cities, rural and forest areas.

In this study, classification of the point cloud data using dense image matching algorithms is aimed. A point-based classification approach depend on hierarchical rules was proposed in order to automatically classify point cloud data. The dense point cloud data in Zekeriyakoy, Istanbul generated with dense image matching algorithms within the scope of High Resolution Digital Surface Model (DSM) and Real Orthophoto Production Project by the Directorate General of Geographic Information Systems of the Republic of Turkey Ministry of Environment and Urbanization has been used as a test data. Parameter analyses, for the rules in the automatic point-based classification approach, were carried out in the different pilot regions determined in the study area. The points are classified in three basic classes as ground, building and vegetation by applying proposed automatic point-based classification process. Finally, accuracy analyses were conducted in a determined pilot area in order to test the classification accuracy.

## 1. GİRİŞ

Son yıllarda, yer yüzeyinin eksiksiz ve yüksek çözünürlüklü üç boyutlu (3B) bilgilerinin elde edilmesi fotogrametri ve uzaktan algılama gibi birçok bilim dalı için çok önemli bir konu haline gelmiştir. Havadan lazer tarama (Light Detection and Ranging –

LiDAR) sistemleri günümüzde, özellikle geniş alanlarda doğrudan 3B bilgi edinmede en üstün araçlardan biridir. Lazer tarayıcı, yüksek frekansta lazer ışınlarının algılayıcı ile obje arasındaki üç boyutlu mesafenin ölçümüne dayanan yöntemle nokta bulutunun yüksek hassasiyetle elde edilmesine olanak sağlar (Huang vd., 2018). LiDAR, koordinat verisi ile birlikte

yoğunluk (intensity) verisi gibi ek bilgiler de kaydetmekte ve çoğu zaman sayısal hava kamerası ve GPS/IMU sisteminden oluşan çoklu algılama sistemi ile veri toplanmaktadır (Yastıklı ve Bayraktar, 2014). Son yıllardaki LiDAR sistemleri öncekilerden daha küçük ve daha hafif olmasına rağmen, sayısal kameralara kıyasla hala nispeten daha hantal ve pahalıdır (Remondino vd., 2014). Yüksek maliyet ve buna bağlı olarak güncelleme sürelerinin uzun olması, zamansal çözünürlüğü geliştirme ihtiyacı 3B nokta bulutu üretmek için daha uygun maliyetli alternatifleri çekici kılmaktadır (Ali-Sisto ve Packalen, 2017; Navarro vd., 2018).

Hava fotogrametrisi ile veri toplama LiDAR'a göre daha düşük maliyetli veri toplama yöntemidir. LiDAR ile elde edilen 3B koordinat ve yoğunluk verisine kıyasla görüntü tabanlı fotogrametri yöntemi, daha düşük maliyetle kısa sürede geniş alanlarının verilerinin toplanabilmesi ve yüksek kaliteli görüntülemenin avantajları nedeniyle 3B veri elde etmede yaygın olarak kullanılmaktadır (Ye ve Wu, 2018). Görüntü eşleme algoritmalarının son zamanlardaki gelişimi hava stereo görüntülerinden yoğun görüntü eşleme ile elde edilmiş 3B nokta bulutlarının üretimini sağlamaktadır. Son yıllarda 3B nokta bulutlarının üretimi için, farklı görüntü eşleme algoritmalarından oluşan birçok yoğun nokta bulutu üretim yöntemleri geliştirilmiştir. Bu görüntü eşleme yöntemlerinden Hirschmüller (2008) tarafından geliştirilen 'Semi-Global Matching (SGM)' yaklaşımı, çok popüler ve iyi performans gösteren bir yaklaşımdır (Haala, 2013). Bu yaklaşım, sayısal fotogrametri ile otomatik Sayısal Yükseklik Modeli (SYM) ya da Yüzey Modeli (YM) üretiminde sıklıkla kullanılan öznelik tabanlı (feature based matching) görüntü eşleme tekniği yerine piksel bazında görüntü eşleşmeye (pixel-wised matching) dayanmaktadır (Haala, 2013; Yastıklı ve Bayraktar, 2014). Yoğun nokta bulutu üretimi için geliştirilen bu yöntemler (yoğun görüntü eşleme), 3B modelleme ve harita üretimi, robotik, tıbbi görüntüleme ve navigasyon gibi profesyonel ve amatör uygulamalar için giderek daha fazla kullanılabilir hale gelmiştir (Remondino vd., 2014).

Günümüzde, Sayısal Yüzey Modeli üretimi, 3B modelleme, 3B yeniden üretim, bina çıkarımı, tek ağaç ve ağaç türlerinin belirlenmesi, değişim analizleri gibi birçok çalışma, LiDAR veya hava stereo görüntülerinden yoğun görüntü eşleme ile edilmiş 3B nokta bulutları kullanılarak başarılı bir şekilde gerçekleştirilebilmektedir (Acar vd., 2019). Bu tür çalışmalarda, yüksek doğruluklu sonuçlar elde etmek için 3B nokta bulutunun hassas bir şekilde sınıflandırılması veri işleme aşamalarının ilk ve en önemli adımlarından biridir (Yastıklı ve Cetin, 2016; Yastıklı ve Cetin, 2017). LiDAR verileri ile sınıflandırma aşamasında her 3B nokta özelliklerine göre ait olduğu nesne sınıfına atanır. LiDAR nokta bulutu sınıflandırılması, nokta bulutu verisi düzenli grid yapıya örneklenerek klasik görüntü sınıflandırma yöntemleri ile ya da doğrudan ham 3B noktalar kullanılarak gerçekleştirilebilir (Yastıklı ve Cetin, 2016). Fakat özellikle orman alanlarında veri toplama aşamasında, çoklu dönüşlerin de kaydedildiği durumlarda, benzer XY koordinatına sahip fakat farklı yükseklikteki noktaların düzenli grid yapıda temsil edilmesi zor olduğundan, nokta bulutu verisi düzenli grid yapıya örneklendiğinde önemli bir veri kaybı söz konusu olmaktadır (Axelsson, 1999). Bu nedenle, enterpolasyondan kaynaklanan istenmeyen hatalardan kurtulmak için LiDAR nokta bulutu, ham olarak sınıflandırma uygulamalarında kullanılır (Maas ve Vosselman, 1999) ve nokta tabanlı sınıflandırma yöntemleri ile otomatik sınıflandırma işlemi gerçekleştirilir (Yastıklı ve Cetin, 2016). Benzer şekilde yoğun görüntü eşleme algoritmaları kullanılarak elde edilen 3B nokta

bulutu da otomatik olarak nokta tabanlı sınıflandırma yöntemleri ile doğrudan yer yüzeyini ifade edecek şekilde uygun sınıflara ayrılabilir. Bu sınıflandırmalarda en kritik nokta ise sınıflandırma aşamasında en doğru özelliklerin (features) ve çalışma alanına ait en uygun parametrelerin seçimi olarak ifade edilebilir.

Bu çalışmada sadece sayısal fotogrametri yöntemi ile elde edilen hava fotoğrafları ve yöneltme elemanları kullanılarak, yoğun görüntü eşleme algoritmaları ile elde edilen nokta bulutu verilerinin otomatik sınıflandırılmasına yönelik bir yaklaşım önerilmesi hedeflenmiştir. Bu hedef doğrultusunda, nokta bulutu verilerinin otomatik olarak sınıflandırılabilmesi için hiyerarşik kurallar bütününden oluşan nokta tabanlı bir sınıflandırma yaklaşımı geliştirilmiştir. Bu yaklaşımın test edilmesi amacıyla, çalışma alanı olarak seçilen İstanbul, Zekeriyaköy'de belirlenen farklı pilot bölgeler kullanılarak otomatik nokta tabanlı sınıflandırma yaklaşımındaki kurallara ilişkin parametre analizleri gerçekleştirilmiş ve bu parametreler kullanılarak önerilen otomatik nokta tabanlı sınıflandırma yaklaşımı ile zemin, bina ve bitki örtüsü olmak üzere üç temel sınıf elde edilmiştir. Son olarak, çalışma alanında seçilen bir pilot bölgede doğruluk analizi gerçekleştirilmiştir.

Bu çalışmada, ikinci bölümde yoğun görüntü eşleme ve sınıflandırma yaklaşımları ve sınıflandırma doğruluk analizi yöntemlerine ilişkin özet bilgiler verilmiştir. Üçüncü bölümde, Zekeriyaköy'de, T.C. Çevre ve Şehircilik Bakanlığı, Coğrafi Bilgi Sistemleri Genel Müdürlüğü tarafından gerçekleştirilen Yüksek Çözünürlüklü YM ve Gerçek Ortofoto Üretimi Projesi kapsamında yoğun görüntü eşleme algoritmaları ile üretilen yoğun nokta bulutu kullanılarak gerçekleştirilen otomatik nokta tabanlı sınıflandırma işlemi ve sınıflandırma doğruluk analizine ait ayrıntılar yer almaktadır. Yoğun nokta bulutunun sınıflandırılması ve sınıflandırmanın doğruluk analizine ilişkin irdelemeler ise sonuçlar kısmında verilmiştir.


## 2. YÖNTEM

Bu bölümde, yoğun görüntü eşleme yöntemleri, nokta bulutu sınıflandırma yaklaşımları ve bu sınıflandırma yaklaşımlarının doğruluk analizi ile ilgili özet bilgiler yer almaktadır.

### 2.1 Yoğun Görüntü Eşleme

Eşleme, çeşitli veri kümeleri (görüntüler, haritalar, 3B şekiller gibi) arasındaki benzeşmenin kurulması olarak tanımlanabilir (Remondino vd., 2014). Stereo görüntü eşleme, görüntü çiftlerindeki uyuşmanın bulunması için fotogrametri ve bilgisayarlı görselleştirme (computer vision) gibi alanlarda en eski ama yine de çözülmemiş problemlerden biri olarak ifade edilebilir (Bleyer ve Breiteneder, 2013). Geleneksel stereo eşleşme işleminde, genellikle öznelik tabanlı (feature based) algoritmalar kullanılır ve önce stereo görüntü çiftlerinden birinde öznelikler çıkarılarak sonra bu özneliklerin diğer görüntüdeki karşılıkları aranmaktadır (Haala, 2013). Hava fotogrametrisinde stereo görüntülerdeki eğiklik ve dönüklüklerin farklı olması, arazinin eğimli olması, arazi topografyasındaki ani değişimler, stereo fotoğraf çifti arasındaki renk ve ton değişimleri ise görüntü eşleme işleminin başarısını olumsuz etkilemektedir (Yastıklı ve Bayraktar, 2014). Benzer şekilde kentsel alanlarda yerden yüksek bina ve ağaçlar da görüntü eşlemede sorunlara sebep olmaktadır (Yastıklı ve Jacobsen, 2003). Geleneksel yaklaşımların aksine bu olumsuzlukların üstesinden gelmek için, son zamanlardaki eşleştirme algoritmaları piksel bazında eşleşmeye

dayanmaktadır (Haala, 2013). ‘Semi-Global Matching (SGM - Hirschmüller, 2008)’, yoğun görüntü eşleme için gerçek zamanlı uygulamalardan (örneğin sürücü destek sistemleri için 3B veri oluşturma) hava fotoğraflarının eşlemesine kadar çok farklı uygulamalar için yaygın olarak kullanılan popüler bir piksel tabanlı algoritmadır (Bethmann ve Luhmann, 2017). Her bir pikselin eşleme işleminde kullanıldığı SGM yaklaşımında, radyometrik farklılıkları modellemek için Ortak Bilgi (Mutual Information-MI) temelli bir ‘cost’ fonksiyonu kullanılmaktadır ve yaklaşım tanımlanan global ‘cost’ fonksiyonunun minimize edilmesine dayanmaktadır (Hirschmüller, 2008). Bu yaklaşımda, çok basit blok eşleştiricilerden karmaşık piksel tabanlı yaklaşımlara kadar değişen farklı ‘cost’ fonksiyonları kullanılabilir (Hirschmüller, 2009). Bu yaklaşımdaki en büyük yenilik, her bir piksel için eşleme işleminin tek bir yönde yapılması yerine eşleme işlemine konu olan piksele komşu bütün yönlerde yapılmasıdır (Yastikli ve Bayraktar, 2014). Böylece Şekil 1a’da görülebileceği gibi, her piksel ‘p’ için eşleme işlemi tüm yönlerden gelen yollar kullanılarak gerçekleştirilmekte ve en doğru konum bulunmaktadır.



Şekil 1. SGM yaklaşımında en uygun konumun bulunmasında 8 arama yönü (a), minimum ‘cost’ yolu (b) (Hirschmüller vd., 2012)

SGM yaklaşımı kullanılarak iyi bir görüntü tabanlı yoğun nokta bulutu elde etmek için yüksek geometrik çözünürlüğe sahip, çoklu, bindirilmiş görüntülere ve bu görüntülerde yüksek bindirme oranına ihtiyaç vardır (Navarro vd., 2018). Klasik yaklaşımda en az % 60 boyuna, %30 enine bindirilmiş görüntülerle eşleme işlemi gerçekleştirilirken, SGM yaklaşımında %80 boyuna ve % 60 enine bindirme talep edilmektedir ve her görüntü otomatik olarak uçuş çizgisi boyunca önceki iki ve sonraki iki modelle, yukarıdaki ve alttaki kolların ise bir modelinde olmak üzere toplamda altı komşu modelde eşleştirilir (Hirschmüller ve Bucher, 2010).

SGM yaklaşımın öne çıkan avantajlarının yanında en büyük dezavantajı, özellikle piksel sayısına bağlı olan geçici bellek gereksinimi ve uzun hesaplama süresidir (Gehrke vd., 2012; Hirschmüller vd., 2012). Bu sınırlama basit olarak girdi verilerinin bölünmesiyle aşılabılır fakat bu yaklaşım genellikle klasik işlemciler (CPU) için yeterli olsa da, grafik işlem ünitesi (GPU) ve alanda programlanabilir kapı dizininde (FPGA) yaygın olarak bulunan yüksek derecede paralellikten yararlanamaz (Hirschmüller vd., 2012). Bu nedenle, araştırmacılar yoğun görüntü eşlemede GPU (Ernst ve Hirschmüller, 2008) / FPGA (Gehrig vd., 2009) seviyesinde paralel hesaplama ve uygulama gibi ileri teknikleri kullanmaya başlamışlardır (Remondino vd., 2014).

Günümüzde, görüntü tabanlı 3B nokta bulutu üretimi için SGM gibi yoğun görüntü eşleme yaklaşımlarını kullanan yazılım araçları birkaç araştırma enstitüsü ve fotogrametrik yazılım şirketi tarafından geliştirilmektedir (Haala, 2013). Bu

yazılımlara örnek olarak Alman Uzay Ajansı (DLR) tarafından geliştirilen yazılım ve Fansa IGN tarafından geliştirilen MicMac yazılımı verilebilir. Ticari yazılımlara örnek olarak ise Microsoft tarafından geliştirilen UltraMap ve Astrium GEO-Information Services tarafından geliştirilen Pixel Factory yazılımları gösterilebilir (Yastikli vd., 2014). Yazılım teknolojisindeki hızlı ilerleme göz önüne alınarak, devam eden durumu değerlendirmek amacıyla Avrupa Mekânsal Veri Araştırma Organizasyonu (EuroSDR) tarafından 2013 yılında araştırma enstitüleri ve fotogrametrik yazılım üreticilerinin katıldığı yoğun görüntü eşleme yaklaşımları ile Sayısal Yüzey Modeli üretimi üzerine bir araştırma projesi gerçekleştirilmiştir (Haala, 2013). Bu araştırmanın sonuçları, güncel yoğun görüntü eşleme yaklaşımları hakkında önemli fikir vermektedir ve elde edilen ilk sonuçlar 13-14 Haziran 2013 tarihleri arasında düzenlenen sempozyumda paylaşılmıştır (Fritsch vd., 2013; Haala, 2013).

## 2.2 Sınıflandırma

Nokta bulutu sınıflandırma çalışmaları LiDAR sistemlerinin aktif olarak kullanılması ile ortaya çıkmıştır. Fakat günümüzde fotogrametride nokta bulutları havadan lazer tarama (ALS) yanında hava fotoğraflarının yoğun şekilde eşleştirilmesi ile de üretilebildiğinden, hangi yöntem seçilirse seçilsin, coğrafi bilgilerin çıkartılmasında ilk adım olan nokta bulutlarının sınıflandırılması giderek popüler bir konu haline almıştır (Yang vd., 2018). SYM üretimi gibi çalışmalarda, noktaların zemin ve zemine ait olmayan noktalar olmak üzere yalnızca iki sınıfa ayrılması istenirken, 3B modelleme, obje çıkarımı gibi çalışmalarda çalışmanın amacına göre ikiden fazla sınıf oluşturulması istenir. Nokta bulutunun kullanıldığı birçok çalışma için otomatik sınıflandırma zor ve önemli bir adımdır (Xu vd., 2012).

Sınıflandırma yöntemleri genel olarak piksel tabanlı (pixel-based), nesne tabanlı (object-based) ve nokta tabanlı (point-based) yöntemler olarak üç başlık altında toplanabilir (Uzar Dinlemek, 2012). Bu yöntemlerden piksel tabanlı ve nesne tabanlı yöntemler, düzensiz dağılmış nokta bulutunun düzenli dağılmış nokta bulutuna (gride) enterpolasyonu ile elde edilen verileri kullanırken, nokta tabanlı yöntemler doğrudan 3B noktalar kullanılarak sınıflandırma işlemi gerçekleştirirler. Piksel tabanlı ve nesne tabanlı sınıflandırmalar klasik görüntü sınıflandırma yöntemlerini kolaylıkla kullanabildikleri için sıklıkla tercih sebebi olsa da, gride enterpolasyon sırasında yaşanan veri kayıpları nokta tabanlı yöntemleri, sınıflandırma uygulamaları için cazip hale getirmiştir (Yastikli ve Cetin, 2016).

Nokta tabanlı sınıflandırma uygulamalarında doğru sınıflandırma sonuçlarını elde etmek için her bir 3B nokta, komşu noktalarla olan ilişkilerine dayanan özellikler (features) ya da kendi bireysel özelliklerine göre semantik bir obje sınıfa atanır (Kim ve Sohn, 2013; Niemeyer vd., 2014; Yang vd., 2018). Nokta tabanlı sınıflandırma algoritmalarının temelini oluşturan bu özellikler, geometrik (spatial-based), dönüş tabanlı (echo-based) ve sadece tam dalga boyu kaydeden LiDAR verilerinden hesaplanan dalga formuna dayanan (waveform-based) özellikler olarak üç grup altında toplanabilirler (Mallet vd., 2011). Otomatik nokta tabanlı sınıflandırma uygulamalarında sıklıkla kullanılan geometrik özelliklerin öne çıkanlarından bazıları; yükseklik (height features), yerel çevre (the local environment), yerel düzlem özellikleri (local plane features), özdeğerler (eigenvalues), yüzey tabanlı (surface-based) özellikler ve düşey profil (vertical profile) özellikleri

olarak ifade edilebilir (Chehata vd., 2009; Kim ve Sohn, 2010; Mallet vd., 2011; Kim ve Sohn, 2013). Dönüş tabanlı özellikler, bitki örtüsü gibi lazer sinyallerinin çoklu yansımalarına sebep olan yüzeylerden dönen sinyaller kullanılarak elde edilir ve tekli dönen (single return), ilk dönen (first return), ortada dönen (intermediate return) ve son dönen (last return) noktaların farklı kombinasyonlarıyla oluşturulur. Dönüş genliği (echo amplitude), dönüş genişliği (echo width), dönüş şekli (echo shape) ve dönüş enine kesiti (echo cross-section) özellikleri ise dalga formuna dayanan özelliklerdir ve sadece tam dalga boyu kaydeden lazer sistemleri ile elde edilen verilere özgüdürler (Chehata vd., 2009). LiDAR ile elde edilen 3B noktaların sınıflandırılmasında bu üç grupta yer alan tüm özellikler kullanılabilirken, yoğun görüntü eşleme algoritmaları ile gerçekleştirilen sınıflandırma uygulamalarında sadece geometrik özelliklerden faydalanılır. Çalışmanın amacına göre hedeflenen sınıflara ulaşmak için seçilen özelliklerin uygun parametreleri genellikle detaylı eğitim (training) aşamaları sonucunda belirlenir (Yastikli ve Cetin, 2016).

### 2.3 Doğruluk Analizi

Doğruluk analizi, sınıflandırma ile elde edilen sınıfların doğruluklarını değerlendirmek amacı ile gerçekleştirilen önemli bir işlem adıdır. Sınıflandırma işleminde, dokuların gerçekten ait oldukları sınıflara atanması sınıflandırma doğruluğunu, yanlış sınıflara atanması sınıflandırma hatasını ifade eder (Erişir, 2015). Sınıflandırma doğruluğunu belirlemek için kullanılan en yaygın yaklaşımlardan biri doğruluğun istatistiksel olarak ölçümüdür (O'Neil-Dunne vd., 2014). Hata matrisi (confusion matrix), içerme hatası (error of comission), dâhil etmeme hatası (error of omission), üretici doğruluğu (producer's accuracy), kullanıcı doğruluğu (user's accuracy), genel doğruluk (overall accuracy) ve kappa katsayısı (Kappa coefficient) sınıflandırmada doğruluk değerlendirmesi için öne çıkan bazı yöntemlerdir (Navulur, 2007).

Nokta tabanlı yöntemlerle otomatik olarak sınıflandırılan 3B nokta bulutlarının doğruluğu, noktaların kullanılacağı diğer çalışmalar için kritik öneme sahiptir. Günümüzde, klasik görüntü sınıflandırma yöntemlerinin doğruluğunu test etmek için birçok yaklaşım mevcut olmasına rağmen nokta tabanlı sınıflandırma yöntemlerinin doğruluk değerlendirmesi için literatürde bir yaklaşıma rastlanmamıştır. Bu nedenle doğruluk değerlendirmesi için pikseller kullanılarak hesaplanan hata matrisinin yerine noktalar kullanılarak oluşturulan hata matrisinin ve bu matristen hesaplanan değişkenlerin nokta tabanlı sınıflandırmanın doğruluğunu test etmek için uygun bir yaklaşım olabileceği değerlendirilmektedir.

## 3. NOKTA BULUTUNUN SINIFLANDIRILMASI

Bu bölümde, bu çalışma kapsamında gerçekleştirilen uygulamaya ilişkin çalışma alanı ve veri seti, çalışmanın iş akışı, önerilen sınıflandırma yaklaşımı için parametre analizleri, gerçekleştirilen sınıflandırma uygulaması ve son olarak gerçekleştirilen doğruluk analizine ilişkin detaylı bilgiler yer almaktadır.

### 3.1 Çalışma Alanı ve Veri Seti

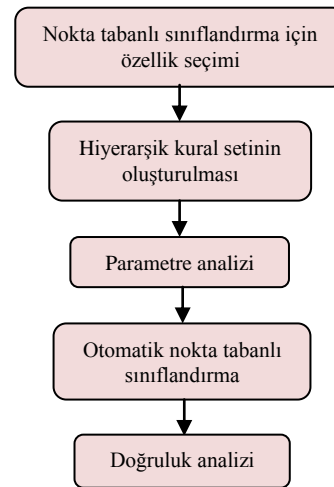
Bu çalışmada, İstanbul, Avrupa yakasında bulunan Sarıyer ilçesine bağlı Zekeriyaköy'de yerleşim alanı, ormanlık alan ve açık alanları içeren, farklı türde binaların yer aldığı ve yer yer eğimin de değiştiği kentsel bir bölge çalışma alanı olarak

belirlenmiştir (Şekil 2). Test verisi olarak, T.C. Çevre ve Şehircilik Bakanlığı, Coğrafi Bilgi Sistemleri Genel Müdürlüğü tarafından 2014 yılında gerçekleştirilen 'Yüksek Çözünürlüklü (10 cm grid aralıklı) YM ve Gerçek Ortofoto Üretimi Projesi' kapsamında Alman Uzay Ajansı DLR'ın geliştirdiği yoğun görüntü eşleme yazılımı kullanılarak üretilen yoğun nokta bulutu kullanılmıştır. Test verisi ile ilgili detaylar Yastikli ve Bayraktar (2014)'te yer almaktadır.



Şekil 2. Zekeriyaköy'de yer alan çalışma alanının genel görünümü

Çalışma bölgesinde belirlenen kentsel alana ait yoğun nokta bulutu verilerinin sınıflandırılması için otomatik sınıflandırmaya olanak sağlayan hiyerarşik kurallar bütününden oluşan nokta tabanlı bir yaklaşım önerilmiştir. Önerilen yaklaşımın iş adımları Şekil 3'de verildiği gibidir.




Şekil 3. Önerilen nokta bulutu sınıflandırma iş akışı

### 3.2 Parametre Analizi ve Nokta Tabanlı Sınıflandırma


Bu çalışma kapsamında, çalışma alanına ilişkin yoğun nokta bulutunu önerilen nokta tabanlı yöntemle sınıflandırma yaklaşımında, sınıflandırılacak her bir 3B nokta bireysel özelliklerine göre analiz edilmekte ve oluşturulan kural setlerine göre ait olduğu sınıfa otomatik olarak atanmaktadır. Otomatik nokta tabanlı sınıflandırma için en kritik nokta, kural setlerinde kullanılan parametrelerin gerçekçi bir yaklaşımla



belirlenmesidir. Bu nedenle, nokta tabanlı sınıflandırma için öncelikle özellik seçimi gerçekleştirilmiş, ardından kural setleri oluşturulmuş ve son aşama olarak bu kural setlerinde yer alan parametrelerin belirlenmesi amacıyla parametre analizi çalışmaları gerçekleştirilmiştir. Sınıflandırma doğruluğunun yüksek olması amacıyla çalışmanın hedefi doğrultusunda elde edilecek üç sınıf (zemin, bina ve bitki örtüsü) için çok detaylı analizler yapılmıştır. Zemin ve bitki örtüsü sınıflarının parametre analizlerinin gerçekleştirildiği pilot bölgenin noktalarının gerçek rengine göre renklendirilmiş hali, analiz öncesi ve sonrasının nokta bulutları Şekil 4'te, bina sınıfının parametre analizlerinin gerçekleştirildiği pilot bölgenin noktalarının gerçek rengine göre renklendirilmiş hali, analiz öncesi ve sonrasının nokta bulutları ise Şekil 5'te yer almaktadır.

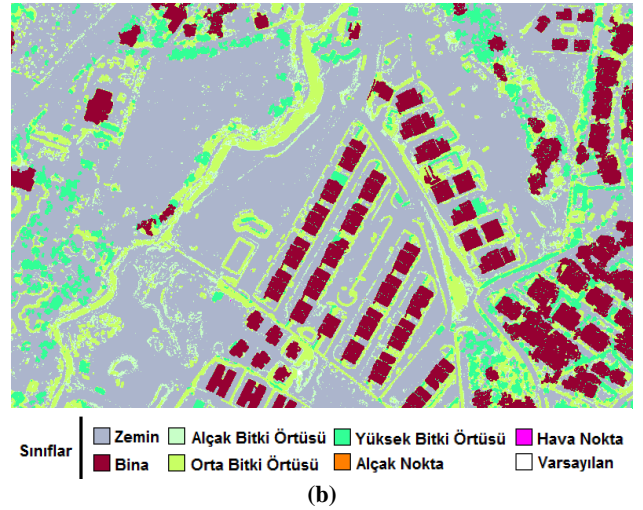


Şekil 4. Zemin ve bitki örtüsü sınıflarının nokta rengine göre renklendirilmiş hali (a), parametre analizi öncesi (b) ve analiz sonrası (c)




Şekil 5. Bina sınıfının nokta rengine göre renklendirilmiş hali (a), parametre analizi öncesi (b) ve analiz sonrası (c)

Detaylı parametre analizlerinin ardından belirlenen en uygun parametreler kullanılarak, sadece geometrik özelliklerin kullanıldığı önerilen hiyerarşik kurallar bütününden oluşan otomatik nokta tabanlı sınıflandırma yaklaşımı ile sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma işlemi sonucunda zemin, bina, alçak, orta ve yüksek bitki örtüsü, alçak nokta, hava nokta ve varsayılan (default) olmak üzere sekiz sınıf elde edilmiştir. Bu çalışmada sadece zemin, bina ve bitki örtüsü sınıflarının elde edilmesi hedeflendiğinden sınıflandırma işlemi tamamlandıktan sonra sınıflandırılmış nokta bulutlarındaki alçak, orta ve yüksek bitki örtüsü sınıfları birleştirilerek tek bir bitki örtüsü sınıfı altında toplanmıştır. Benzer şekilde alçak nokta, hava nokta ve varsayılan sınıfları da diğer sınıfı altında toplanmıştır. Çalışma alanının gerçek nokta rengine göre renklendirilmiş hali, geometrik özelliklerin kullanıldığı önerilen otomatik nokta tabanlı yaklaşım ile sınıflandırılan ve tüm sınıfların yer aldığı sınıflandırma sonuçları Şekil 6'da verilmiştir. Çalışmanın asıl hedefi doğrultusunda elde edilen zemin, bina, bitki örtüsü ve diğer olarak isimlendirilen sınıfların yer aldığı sınıflandırma sonuçları ise Şekil 7'de yer almaktadır. Bu çalışmada ortaya konan sınıflandırma işlemi, nokta bulutu yönetim ve işlemeye olanak sağlayan TerraSolid yazılımının TerraScan modülü aracılığıyla gerçekleştirilmiştir.



Şekil 6. Çalışma alanının nokta rengine göre renklendirilmiş hali (a) ve tüm sınıfların yer aldığı nokta tabanlı sınıflandırma sonucu (b)



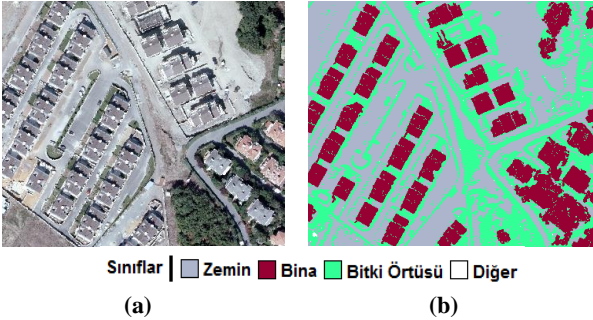
Şekil 7. Üç sınıfın (zemin, bina, bitki örtüsü) yer aldığı nokta tabanlı sınıflandırma sonucu

Çalışma alanında yoğun görüntü eşleme ile elde edilen nokta bulutunun, geometrik özelliklerin kullanıldığı nokta tabanlı sınıflandırma yaklaşımı ile gerçekleştirilen sınıflandırma sonuçları incelendiğinde, yolları ve açık alanları da içeren zemin sınıfının oldukça iyi sınıflandırıldığı görülmektedir. Çalışma alanındaki bitki örtüsü sınıfı incelendiğinde ise doğru sınıflandırmanın yanında, yerden belirli yükseklikteki, zemine


ait kısımların bazılarının alçak bitki örtüsü sınıfına atıldığı ve yüksek bitki örtüsü olarak isimlendirilen binalara yakın bitki örtüsünün de bina sınıfına atıldığı görülmektedir. Yüksek bitki örtüsünün bina olarak sınıflandırılan kısımları göz ardı edilerek bina sınıfı analiz edildiğinde, çalışma alanında mevcut binaların neredeyse eksiksiz bir şekilde sınıflandırıldığı göze çarpmaktadır. Bununla birlikte Şekil 7’de çalışma alanının güney doğu (sol alt) köşesinde yer alan binaların gerçek şekillerinden farklı ve bitki örtüsü sınıfını da içeren daha büyük bir şekilde sınıflandırıldığı görülmektedir. Elde edilen sonuçlar genel olarak, yoğun görüntü eşleme algoritmaları ile üretilen 3B nokta bulutunun, bu çalışmada önerilen geometrik özelliklerin kullanıldığı otomatik nokta tabanlı sınıflandırma yaklaşımı ile başarılı bir şekilde sınıflandırıldığı gerçeğini ortaya koymaktadır.

### 3.3 Nokta Tabanlı Sınıflandırmanın Doğruluk Analizi

Nokta tabanlı sınıflandırmaların doğruluk değerlendirmesi için literatürde herhangi bir yaklaşım bulunmadığından bu çalışmada, pikseller yerine noktalar kullanılarak oluşturulan hata matrisi nokta tabanlı sınıflandırmanın doğruluğunu test etmek için kullanılmıştır. Çalışma alanında, yoğun görüntü eşleme yaklaşımları ile oluşturulan 3B nokta bulutunun doğruluk değerlendirmesinin gerçekleştirildiği 4517360 noktadan oluşan pilot bölge Şekil 8’de görülmektedir. Zemin, bina ve bitki örtüsü sınıfları için kullanılan referans veri 1/1000 ölçekli fotogrametrik haritaların elle sayısallaştırılması sonucu elde edilmiştir (Şekil 9). Oluşturulan hata matrisinde (Tablo 1) yer alan değerler kullanılarak üretici doğruluğu, kullanıcı doğruluğu ve genel doğruluk hesaplanmıştır.



Şekil 8. Doğruluk analizi gerçekleştirilen pilot bölgenin nokta rengine göre renklendirilmiş hali (a) ve nokta tabanlı sınıflandırma sonucu (b)



Şekil 9. Doğruluk analizi için kullanılan referans veri

Referans/ Sınıflandırma	Zemin	Bina	Bitki Örtüsü	Kullanıcı Doğruluğu (%)
Zemin	2021101	41081	675064	<b>73.84</b>
Bina	36430	753316	105834	<b>84.11</b>
Bitki Örtüsü	326615	165374	386060	<b>43.98</b>
Üretici Doğruluğu (%)	<b>84.77</b>	<b>78.49</b>	<b>33.08</b>	Genel Doğ. (%): <b>70.06</b>

Tablo 1. Nokta tabanlı sınıflandırmanın hata matrisi

Tablo 1’de görüldüğü üzere yoğun görüntü eşleme ile üretilen nokta bulutu geometrik özellikler kullanılarak %70 genel doğrulukla sınıflandırılmıştır. Yüksek sınıflandırma doğruluğuna sahip olan sınıflardan zemin sınıfı %85 üretici doğruluğu, %74 kullanıcı doğruluğu; bina sınıfı ise %78 üretici doğruluğu, %84 kullanıcı doğruluğu ile sınıflandırılmıştır. Yerden belirli yükseklikteki zemin noktalarının alçak bitki örtüsü ile yüksek bitki örtüsü sınıfının da bina sınıfı ile karışmasından dolayı bitki örtüsü sınıfı ise %33 üretici, %44 kullanıcı doğruluğu ile en düşük sınıflandırma doğruluğuna sahiptir.

## 4. SONUÇLAR

Bu çalışmada, Sayısal Yüzey Modeli üretimi, 3B modelleme, 3B yeniden üretim, bina çıkarımı, tek ağaç ve ağaç türlerinin belirlenmesi, değişim analizleri gibi birçok çalışmada kullanılmak üzere, yoğun görüntü eşleme algoritmaları kullanılarak elde edilen 3B nokta bulutu verilerinin otomatik nokta tabanlı sınıflandırılması ve bu sınıflandırmanın doğruluk analizi gerçekleştirilmiştir. Zemin, bina ve bitki örtüsü sınıfları için belirlenen pilot bölgelerde detaylı parametre analizleri sonucunda hiyerarşik kurallar bütününden oluşan nokta tabanlı bir sınıflandırma yaklaşımı önerilmiştir. İstanbul, Zekeriyaköy’e ait 3B nokta bulutu verileri, geometrik özelliklerin kullanıldığı yaklaşım ile zemin, bina, bitki örtüsü sınıflarını içerecek şekilde otomatik olarak sınıflandırılmıştır. Sınıflandırma doğruluğunu test etmek için noktaların kullanıldığı bir hata matrisi oluşturulmuş ve sınıflandırmanın genel doğruluğu %70 olarak belirlenmiştir. Zemin ve bina sınıfları sırasıyla %85 ve %78 üretici doğruluğu, %74 ve 84 kullanıcı doğruluğu ile en yüksek doğrulukla sınıflandırılan iki sınıf olmuşlardır. Sınıf karışmalarının en çok yaşandığı bitki örtüsü sınıfı ise sırasıyla %33 üretici ve %44 kullanıcı doğruluğu ile nispeten düşük doğrulukla sınıflandırılmıştır.

Bu çalışma sırasında geometrik özelliklerin kullanıldığı nokta tabanlı yaklaşımla, daha pahalı bir yöntem olan LiDAR’a kıyasla daha uygun maliyetle yoğun görüntü eşleme ile üretilen 3B nokta bulutlarının sınıflandırılması başarılı bir şekilde gerçekleştirilmiştir. Önerilen otomatik sınıflandırmaya olanak sağlayan hiyerarşik kurallar bütününden oluşan nokta tabanlı sınıflandırma yaklaşımının başarısı, geometrik özelliklerin belirlenmesi ve sınıflandırma aşamasında kullanılacak parametrelerin detaylı analizlerine bağlıdır. Bu çalışmanın sonraki adımında yer yer karışan zemin ve bitki örtüsü, bina ve bitki örtüsü sınıflarının doğruluğunun artırılması için nokta geometrik özelliklerine ek olarak gerçek nokta renklerinin kullanılması planlanmaktadır.

## TEŞEKKÜR

Bu çalışmada kullanılan, Yüksek Çözünürlüklü YM ve Gerçek Ortofoto Üretimi Projesi kapsamında görüntü eşleme algoritmaları ile üretilen yoğun nokta bulutu verisini sağladıkları için T.C. Çevre ve Şehircilik Bakanlığı, Coğrafi Genel Müdürlüğü’ne teşekkür ederiz.

## KAYNAKLAR

- Acar, H., Karsli, F., Ozturk, M., Dihkan, M., 2018. Automatic detection of building roofs from point clouds produced by the dense image matching technique. *International Journal of Remote Sensing*, <https://doi.org/10.1080/01431161.2018.1508915>.
- Ali-Sisto, D., Packalen, P., 2017. Forest Change Detection by Using Point Clouds from Dense Image Matching Together with a LiDAR-Derived Terrain Model. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 99:1–10.
- Axelsson, P., 1999. Processing of Laser Scanner Data - Algorithms and Applications. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54(2-3): 138-147. PII: S0924- 2716 99 00008-8.
- Bethmann, F., Luhmann, T., 2017. Object-based semi-global multi-image matching. In: *PFQ – Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 85:349–364 Springer Ed. (2017).
- Bleyer M., Breiteneder C., 2013. Stereo Matching—State-of-the-Art and Research Challenges. In: Farinella G., Battiato S., Cipolla R. (eds) *Advanced Topics in Computer Vision. Advances in Computer Vision and Pattern Recognition*. Springer, London.
- Chehata, N.; Guo, L.; Mallet, C., 2009. Airborne LiDAR Feature Selection For Urban Classification Using Random Forests. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 39 (Part 3/W8): 207–212.
- Erişir, Z., 2015. Nokta Tabanlı Sınıflandırma Yöntemleri ile LiDAR Verilerinin Sınıflandırılması, Yüksek Lisans Tezi, YTÜ Fen Bilimleri Enstitüsü, İstanbul.
- Ernst, I., Hirschmüller, H., 2008. Mutual information based semi-global stereo matching on the GPU. In: Bebis, G., Boyle, R., Parvin, B., Koracin, D., Remagnino, P., Porikli, F., Peters, J., Klosowski, J., Arns, L., Chun, Y.K., Rhyne, T.-M., Monroe, L. (eds.) *ISVC 2008, Part I. LNCS*, vol. 5358, pp. 228–239. Springer, Heidelberg (2008)
- Fritsch, D., Pfeifer, N., Franzen, M. (Eds.), 2013. *Proceedings of the 2nd EuroSDR workshop on High Density Image Matching for DSM Computation*. EuroSDR Publication Series, No. 63.
- Gehrig, S. K., Eberli, F., Meyer, T., 2009. A real-time low-power stereo vision engine using semiglobal matching. *Lecture Notes in Computer Science*, 5815: 134–143.
- Gehrke, A. S., Morin, B. K., Downey, A. M., Boehrer, C. N., Fuchs, C. T., 2012. Semi-global matching: An alternative to lidar for DSM generation?. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*. 38.
- Haala, N., 2013. The Landscape of Dense Image Matching Algorithms. In: Fritsch, D. (Ed.): *Photogrammetric Week '13*, Wichmann, Berlin/Offenbach, 271-284.
- Hirschmüller, H., 2008. Stereo processing by semi-global matching and mutual information. *IEEE Transactions On Pattern Analysis And Machine Intelligence*, 30(2), pp. 328–341.
- Hirschmüller, H., 2009. Evaluation of stereo matching costs on images with radiometric differences. *Proc Inst Electr Electron Eng Trans Pattern Anal Mach Intell (TPAMI)*, 31(9):1582–1599.
- Hirschmüller, H., Bucher, T., 2010. Evaluation of Digital Surface Models by Semi-Global Matching. *DGPF 2010*, 01-02 July 2010, Vienna, Austria.
- Hirschmüller, H., Buder, M., Ernst, I., 2012. Memory efficient semi-global matching. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 1(3): 371–376.
- Huang, X., Qin, R., Xiao, C., Lu, X., 2018. Super resolution of laser range data based on image-guided fusion and dense matching. *ISPRS Journal of Photogrammetry and Remote Sensing*, Volume 144, October 2018, Pages 105-118.
- Kim, H. B., Sohn, G., 2010. 3D Classification of Power-Line Scene From Airborne Laser Scanning Data Using Random Forests. *ISPRS Archives*, September 1-3, Saint-Mandé, France, 38(3A): 126-132.
- Kim, H. B., Sohn, G., 2013. Point-Based Classification of Power Line Corridor Scene Using Random Forests. *Photogrammetric Engineering and Remote Sensing*, 79: 821–33.
- Maas, H.-G., Vosselman, G., 1999. Two Algorithms For Extracting Building Models From Raw Laser Altimetry Data. *ISPRS J. Photogramm. Rem. Sens.*, 54(2/3): 153–163.
- Mallet, C., Bretar, F., Roux, M., Soergel, U., Heipke, C., 2011. Relevance Assessment of Full-Waveform Lidar Data For Urban Area Classification, *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(6): 71–S84.
- Navarro, J. A., Fernández-Landa, A., Tomé, J. L., Guillén-Climet, M. L., Ojeda, J. C., 2018. Testing the quality of forest variable estimation using dense image matching: a comparison with airborne laser scanning in a Mediterranean pine forest. *International Journal of Remote Sensing*, 39 (14): 4744-4760. <https://doi.org/10.1080/01431161.2018.1471551>
- Navulur, K., 2007. *Multispectral Image Analysis Using The Object-Oriented Paradigm*. CRC Press, Taylor and Frances Group, New York.
- Niemeyer, J., Rottensteiner, F., Soergel, U., 2014. Contextual Classification of LiDAR Data and Building Object Detection In Urban Areas, *ISPRS Journal of Photogrammetry and Remote Sensing*, 87: 152–165.
- O’Neil-Dunne, J., MacFaden, S., Royar, A., 2014. A Versatile, Production-Oriented Approach To High-Resolution Tree-Canopy Mapping In Urban And Suburban Landscapes Using GEOBIA and Data Fusion. *Remote Sensing*, 6: 12837-12865.
- Remondino, F., Spera, M. G., Nocerino, E., Menna, F., Nex, F., 2014. State of the art in high density image matching. *The Photogrammetric Record*, 29(146), 144–166. <http://dx.doi.org/10.1111/phor.12063>.

Uzar Dinlemek, M., 2012. Otomatik Bina Çıkarımı Uygulamalarında Çoklu Algılama Sistemi Kullanım Olanaklarının Analizi, Doktora Tezi, YTÜ Fen Bilimleri Enstitüsü, İstanbul.

Xu, S., Oude Elberink, S., Vosselman, G., 2012. Entities and features for classification of airborne laser scanning data in urban area. *ISPRS Ann. Photogramm., Remote Sens., Spatial Inf. Sci.*, Vol. I-4, pp. 257–2662, 2012.

Yang, Z., Tan, B., Pei, H., Jiang, W., 2018. Segmentation and Multi-Scale Convolutional Neural Network-Based Classification of Airborne Laser Scanner Data. *Sensors*, 18 (10): 3347.

Yastikli N, Jacobsen K, 2003. Automatic digital elevation model generation, problems and restrictions in urban areas. *Journal of Yıldız Technical University*, 2003(2): 38–46.

Yastikli, N., Bayraktar, H., 2014. Yoğun Görüntü Eşleme Algoritmaları ile Yüksek Çözünürlüklü Sayısal Yüzey Modeli Üretimi. *V. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZAL-CBS 2014)*, 14-17 Ekim, İstanbul, Türkiye.

Yastikli N., Bayraktar H., Cetin Z., 2014. Performance Validation of High Resolution Digital Surface Models Generated by Dense Image Matching with the Aerial Images. *ISPRS Technical Commission I Symposium*, Denver, Colorado, A.B.D., 17-20 Kasım 2014, vol.40-1, pp.429-433

Yastikli, N., Cetin, Z., 2016. Classification of LiDAR data with Point Based Classification Methods. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLI-B3, 2016, XXIII Congress, 12-19 July 2016, Prague, Czech Republic, 441-445.

Yastikli, N., Cetin, Z., 2017. Automatic 3D Building Model Generations with Airborne LiDAR Data. *ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci.*, IV-4/W4, 411-414, <https://doi.org/10.5194/isprs-annals-IV-4-W4-411-2017>, 2017.

Ye, L., Wu, B., 2018. Integrated Image Matching and Segmentation for 3D Surface Reconstruction in Urban Areas. *Photogrammetric Engineering & Remote Sensing*. 84. 135-148. 10.14358/PERS.84.3.135.