

Çok yüksek çözünürlüklü renkli İHA görüntülerinden kentsel alanlarda araç tespiti

Vehicle detection in urban areas from very high resolution UAV color images

Müslüm ALTUN^{1*}, Mustafa TÜRKER²

^{1,2}Geomatik Mühendisliği Bölümü, Mühendislik Fakültesi, Hacettepe Üniversitesi, Ankara, Türkiye.
altunmuslum06@gmail.com, mturker@hacettepe.edu.tr

Geliş Tarihi/Received: 11.06.2018
Kabul Tarihi/Accepted: 25.03.2019

Düzeltilme Tarihi/Revision: 19.03.2019

doi: 10.5505/pajes.2019.69649
Araştırma Makalesi/Research Article

Öz

Kentsel alanlarda uzaktan algılama görüntülerinden bina, ağaç, araç, vb. coğrafi nesnelerin otomatik olarak tespiti oldukça gerekli ve önemlidir. Bu çalışmada, çok yüksek konumsal çözünürlüklü renkli (Kırmızı, Yeşil, Mavi) stereo insansız hava aracı (İHA) görüntülerinden kentsel alanlarda sabit araçların tespiti yapılmıştır. Kullanılan yaklaşımın ilk adımında stereo İHA görüntülerinden sayısal yüzey modeli (SYM) oluşturulmaktadır. Sonra, SYM verisinden sayısal arazi modeli (SAM) ve SYM kullanılarak İHA görüntülerinden ortofoto oluşturulmaktadır. Ardından, yalnız yer üstü nesnelere elde etmek için SYM ve SAM verilerinin farkı alınarak normalize edilmiş sayısal yüzey modeli (nSYM) hesaplanmaktadır. Daha sonra, elde edilen nSYM verisi ek bant olarak kullanılmak suretiyle ortofotonun çoklu çözünürlük segmentasyonu ve ardından nesne-tabanlı sınıflandırması yapılmaktadır. Yaklaşım, Hacettepe Üniversitesi, Beytepe Yerleşkesi'nde farklı özelliklere sahip iki alan üzerinde uygulanmıştır. Oluşturulan referans veriyle yapılan karşılaştırma neticesinde, araç tespiti doğruluğu birinci test alanı (Alan#1) için %78.53 ve ikinci test alanı (Alan#2) için %92.15 olarak hesaplanmıştır. Elde edilen sonuçlar, önerilen yaklaşımla sabit araçların çok yüksek konumsal çözünürlüklü İHA görüntülerinden tespitinin yüksek doğrulukla yapılabildiğini göstermiştir.

Anahtar kelimeler: İnsansız hava aracı (İHA), Ortofoto, Sayısal yüzey modeli (SYM), Sayısal arazi modeli (SAM), Segmentasyon, Sabit araç tespiti.

Abstract

It is very essential and important in urban areas for the automatic detection of geographical objects such as buildings, trees, and vehicles by using remotely sensed images. In this study, the stationary vehicles were detected from very high spatial resolution stereo color (Red, Green, Blue) unmanned aerial vehicles (UAV) images in urban areas. In the first step of the approach used, digital surface model (DSM) is generated from the stereo images. Then, digital terrain model (DTM) is generated from the DSM, and by using the DSM orthophotos are generated from IHA images. Next, the normalized digital surface model (nDSM) is calculated by taking the difference between the DSM and DTM to obtain only the ground objects. After that, using the obtained nDSM data as an additional band, the multi-resolution segmentation and then object-based classification of the orthophoto are carried out. The approach was applied on two areas with different characteristics at Hacettepe University, Beytepe Campus. After comparing the results with the reference data, the vehicle detection accuracy was computed as 78.53% for the first test field (Field # 1) and it was computed as 92.15% for the second test field (Field # 2). The results show that the detection of stationary vehicles from very high spatial resolution UAV images can be performed with high accuracy using the proposed approach.

Keywords: Unmanned aerial vehicle (UAV), Orthophoto, Digital surface model (DSM), Digital terrain model (DTM), Segmentation, Detection of stationary vehicle.

1 Giriş

Kentsel alanlarda, banliyö bölgelerinde ve yoğun yerleşim alanları içinde kalan şehirlerde uydu görüntülerinden ve hava fotoğraflarından otomatik olarak bina, ağaç, vb. coğrafi nesnelerin tespiti ve değişim analizi günlük hayatta pratik olarak kullanılabilir hale gelmiştir. Bunun yanı sıra, yüksek konumsal çözünürlüklü uydu görüntülerinden ve hava fotoğraflarından otomatik araç tespiti de son zamanların önemli bir çalışma konusu olmuştur. Araç nesnelere, bina, ağaç ve diğer zemin üstü nesnelere göre geometrik şekil ve boyut itibarıyla daha küçüktür. Hem kapladığı alanın küçük olması hem de yerden yüksekliğinin düşük olması nedeniyle, araçları tespit etmek için kullanılan görüntülerin zemin üstü nesnelere ne kadar detaylı bir şekilde gösterdiği oldukça önemlidir. Dolayısıyla, araç tespiti çalışmalarında kullanılan verilerde yüksek konumsal ve spektral çözünürlük özelliklerinin bulunması önem arz etmektedir. Bu nedenle, uydu görüntüleri ve hava fotoğraflarına göre çok daha alçaktan görüntü alınması

ve daha yüksek konumsal çözünürlük sağlama özelliğine sahip olması nedeniyle, İnsansız Hava Aracı (İHA) görüntülerinden sabit araç tespiti günümüzün ilgi çeken araştırma konuları arasında yer almaktadır. Sabit araçların tespiti için yaklaşık son on yıldır, LiDAR (Light Detection and Ranging) verileri, uydu görüntüleri ve hava fotoğraflarının sıklıkla kullanıldığı görülmektedir. Ancak, son zamanlarda sabit araçları tespit etmek için yapılan çalışmalarda uzaktan algılanmış görüntüler ve sayısal yüzey modeli (SYM) verilerinin birlikte kullanıldığına sıklıkla rastlanmaktadır [1]-[4]. Tespit edilen araç nesnelere Coğrafi Bilgi Sistemi (CBS) faaliyetlerinde kullanılarak birçok uygulamaya olanak sağlamaktadır [5]-[9].

Bu çalışmanın amacı, insansız hava araçları (İHA) ile çekilen çok yüksek konumsal çözünürlüklü üç bantlı (Kırmızı-K, Yeşil-Y ve Mavi-M) renkli görüntülerden kentsel alanlarda sabit araçların tespitini bir yaklaşım kullanarak gerçekleştirmektir. Günümüzde sabit duran araçların tespiti ile otopark bilgi sistemi kurulması, anlık kullanılabilir görüntüler yardımıyla


*Yazışılan yazar/Corresponding author

aracın park durumunda iken geçen sürenin belirlenebilmesi, araç trafiğinin yoğun olduğu yerlerde yanlış park etmiş olan araçların tespiti ile trafik bilgi sistemi kurulabilmesi sebeplerinden dolayı sabit duran araçların tespiti önem arz etmektedir. Çalışmanın diğer amacı, stereo İHA görüntülerinden sayısal yüzey modeli (SYM) oluşturmak ve oluşturulan SYM'yi de kullanmak suretiyle araç tespiti doğruluğunu artırmaktır. Ayrıca, çalışmada gerçekleştirilecek çoklu-çözünürlük görüntü segmentasyonu (multi resolution image segmentation) için, bu çalışmada kullanılan test alanlarına ait en uygun segmentasyon parametre değerleri belirlenecektir.

1.1 Çalışmada kullanılan veriler ve test alanları

Çalışmada, Hacettepe Üniversitesi, Beytepe yerleşkesinde, 18.3 mm odak uzaklığına sahip kalibre edilmiş kompakt dijital kameranın bulunduğu SmartOne-C marka İHA ile yaklaşık 90 m yükseklikten %80 boyuna ve %40 enine bindirmeli olarak çekilen renkli üç bantlı (K, Y, M) görüntüler (toplam 116 adet) kullanılmıştır. Çekilen her görüntü 4928 satır x 3264 sütun boyutlarında olup 0.022 m x 0.022 m konumsal çözünürlüğe sahiptir.

Projeksiyon bilgileri WGS84 UTM-Zone; 36 N olan çalışma sahasının (Şekil 1) yaklaşık koordinatları; 476620.00 m, 441535.00 m (Kuzey Batı); 476620.00 m, 4412241.00 m (Güney Batı); 477999.00 m, 441535.00 m (Kuzey Doğu) ve 477999.00 m, 4412241.00 m (Güney Doğu) dur. Çalışma sahasından farklı özelliklere sahip iki test alanı (Alan#1 ve Alan#2) seçilmiştir.



Şekil 1. Çalışma bölgesine ait renkli İHA genel görüntüsü.

Figure 1. The UAV colored image for the whole study area.

Şekil 2 ve Şekil 3'te sırasıyla Alan#1 ve Alan#2'ye ait renkli İHA görüntüleri gösterilmektedir. Test alanlarının belirlenmesinde özellikle araçların park alanlarındaki yoğunluğu, büyüklüğü ve sayısı dikkate alınmıştır. Çalışmada ayrıca, Alan#1 ve Alan#2 için sayısal yüzey modeli (SYM) ve sayısal arazi modeli (SAM) verileri oluşturulup kullanılmıştır.

Bu çalışmada kullanılan ortofoto, gerçek (true) ortofoto olup, çalışmanın bundan sonraki kısmında yalnız "ortofoto" ismiyle kullanılacaktır.

Alan#1 çalışma alanında toplam 175 adet sabit araç bulunmaktadır (Şekil 2). Bu araçların çoğu park alanında, bir kısmı ise yol kenarındadır. Sabit araçların yanı sıra bu test alanında ayrıca binalar da yer almaktadır. Binaların çatı sundurmalarının bazı araçları kısmen kapatması yöntemin başarısının testi için önem arz etmektedir. Alanda bulunan farklı türde ve yükseklikteki ağaçların dallarının da bazı araçları kısmen kapattığı görülmektedir. Yine, küçük çalılıklar, oturma bankları, çardak, araçların yakınında bulunan eğimli şev (hendek) gibi coğrafi nesnelere de bu çalışma alanında yöntemin başarısının testi için önem arz etmektedir. Çalışma alanında yer alan istinat duvarı topografyanın eğimli olduğunu göstermektedir ve bu durumun sonuçlara etkisini ölçmek için, SYM verisine yer filtreleme işlemi uygulanarak SAM oluşturulmuştur. Yer filtreleme işleminin hata metrikleri hesaplanmış olup "3. Bulgular" bölümünde verilmektedir.



Şekil 2. Alan#1'e ait renkli İHA görüntüsü.

Figure 2. The UAV colored image for Area #1.



Şekil 3. Alan#2'ye ait renkli İHA görüntüsü.

Figure 3. The UAV colored image for Area #2.

Alan#2 çalışma alanında toplam 217 adet sabit araç bulunmaktadır (Şekil 3). Bu araçların da büyük çoğunluğu park alanında ve bir kısmı ise yol kenarında konumlanmıştır. Bu çalışma alanında diğer alandan farklı olarak yol kenarında

ayrıca bir adet otobüs bulunmaktadır. Yine, çimenlik alan üzerinde beton zemin, futbol sahası ve hemen yanında yer alan kulübe benzeri bir sundurma ve boyları oldukça yüksek farklı türdeki ağaçların da bu çalışma alanında bulunması yöntemin başarısının testleri için önemlidir. Bu çalışma alanı Alan#1 çalışma alanına göre nispeten daha düz bir topografyaya sahiptir ve bu çalışma alanına da ait nSYM verisi oluşturularak eğitim etkisi giderilmiştir.

1.2 Literatür taraması ve geçmişte yapılan çalışmalar

Geçmişte yapılan çalışmalar incelendiğinde, araç tespit etmek için genellikle farklı çözünürlükteki uydu görüntüleri veya hava fotoğraflarının kullanıldığı dikkat çekmektedir. Bu çalışmada farklı olarak araç tespit etmek için çok yüksek konumsal çözünürlüklü renkli İHA görüntüleri kullanılmıştır. Dolayısıyla bu özelliği ile yapılan bu çalışma geçmişte yapılmış olan çalışmalardan ayrılmaktadır. [10] tarafından yapılan çalışmada Bayesian Network algoritması ile 12 adet hava fotoğrafı üzerinde bulunan 320 adet aracın tespiti denenmiştir. Araçların düzey konum olarak ağaç dalları altında kalarak görülebilmesi, gölge, fotoğrafların çekim açısına bağlı olarak fotoğraf eğikliğinden kaynaklı araçların yan cepheden görülmesi etkenlerinin tespit edilme doğruluğunu olumsuz etkilediği söylenmiştir. Doğruluk analizi Bayesian minimum risk classifer tekniği kullanılarak yapılmış ve %80 başarı oranı elde edilmiştir. [11] tarafından yapılan çalışmada araç tespiti için 15 cm konumsal çözünürlüklü hava fotoğrafları kullanılmıştır. Kullanılan yöntem görüntü üzerindeki araç nesnelere kenarlarına gelen piksellerin bulunmasıyla başlanmakta ve piksellerin benzer spektral değerlerine göre yönleri ve dolayısıyla kenarlar tespit edilmektedir. Bu çalışmada araç ve araç camları renklerine göre farklı birer sınıf olarak tanımlanıp, işleme dahil edilmiştir. Kullanılan maksimum olabilirlik sınıflandırma yöntemi piksellerin yön ve kenar tespiti ön kuralına göre çalışarak, %80 oranında araç tespit doğruluğu sağladığı ifade edilmiştir. [12] tarafından yapılan çalışmada araç tespiti için İkonos ve Quickbird uydu görüntüleri kullanılmış olup, bu tür çalışmalar için çok yüksek çözünürlüklü görüntüleri kullanmanın önemi vurgulanmıştır. Bu çalışmada görüntüdeki yolların güncel vektör verisi kullanılmış olup, yol içerisinde kalan araçlar tespit edilmiştir, böylece araç dışı nesnelere hiç işleme katılmamıştır. Bu çalışmada araçların kenarlarını çıkararak "inductive learning" tekniği kullanılmış ve %95 doğruluk oranı elde edilmiştir. [13] tarafından yapılan çalışmada araç tespiti için 60 cm konumsal çözünürlüklü Quickbird uydu görüntüleri kullanılmıştır. Bu çalışmada karşıt ağ yaklaşımı (Antibody Network Concept) algoritması kullanılmış, bu algoritmaya dört tane kural tanımlanarak, işlem toplam altı adımda tamamlanmış olup ve %90 doğruluk oranı elde edilmiştir. [14] tarafından yapılan çalışmada 1 m çözünürlüklü İkonos uydu görüntüleri ve hava fotoğrafları ana bileşenler analizi yöntemiyle iyileştirilmiştir. Bir diğer adımda ise Bayesian background transformation algoritması ile sınıflandırma yapılmıştır. Son adım olarak gradyan eşikleme tekniği ile uygun eşik değerleri belirlenerek, kaldırımlar ve diğer araç dışı nesnelere ayrı ayrı ayıklanıp, araçlar %88 doğruluk oranı ile tespit edilmiştir. [15] tarafından yapılan çalışmada yer örnekleme aralığı 10 cm olan pankromatik hava fotoğraflarından ortalama öteleme (mean shift) kümeleme metodu ile araç tespiti yapılmış ve %82 başarı oranı elde edilmiştir. [16] tarafından hareketli araçların tespitine yönelik yapılan çalışmada önerilen yöntem iki adımdan oluşmaktadır. Birinci adımda Bayes sınıflandırma algoritması kullanılarak piksel tabanlı sınıflandırma yapılmış, diğer adımda ise kenar

haritaları ve dalgacık dönüşümü katsayısı (edge maps and coefficient of wavelet transform) tekniği ile araç nesnelere şekli çıkarılmıştır. Bu çalışmada kentsel alanlardaki bina detaylarının varlığı, bu çalışmada kullanılan algoritmayı olumsuz yönde etkilediği ifade edilmiştir. Bu iki adımda yapılan işlemler birlikte değerlendirilerek doğruluk analizleri yapılmış ve doğruluk oranı %94.5 olarak hesaplanmıştır. [17] tarafından yapılan çalışmada Kırmızı, Yeşil ve Mavi (KYM) bantlı ve 0.17 m çözünürlüklü altı adet hava fotoğrafı kullanılarak araç tespiti yapılmıştır. Bu çalışmada eCognition Developer yazılımında çoklu çözünürlük segmentasyon algoritması ile segmentasyon işlemi ve ardından nesne tabanlı sınıflandırma yapılarak %90 oranında araç tespit doğruluğu ve %78.7 oranında sınıflandırma doğruluğu elde edilmiştir. Bu çalışmada otomobil, kamyonet ve tır olarak araç tipleri belirlenmiş olup, araçların geometrik olarak şekli ve yüksekliği büyüdükçe araç tespit doğruluğu artabilir şeklinde varsayım yapılmıştır. [18] hareketli araçların tespiti için aynı alanın 0.2 sn. aralıklarla çekilen Quickbird renkli ve siyah beyaz uydu görüntülerini kullanmıştır. Araçların ardışık çekilen görüntüler üzerinde ne kadar yer değiştirdiği tespit edilerek, görüntüler üzerinden araçların hızları hesaplanmıştır. Çalışmada bulanık C-means algoritması kullanılmış olup, sonuçları iyileştirmek amacıyla 3×3, 5×5 ve 7×7 pencere boyutundaki morfolojik filtreler denenmiş ve en uygun filtrenin 5×5 pencere boyutlu filtre olduğuna karar verilmiştir. Bu filtreleme işlemi ile yol orta çizgileri ve işaret levhaları ortadan kaldırılmış olup, sonuçlar iyileştirilmiş ve toplam 268 araçtan 221 adedi tespit edilmiştir. Ayrıca, çalışmanın sonunda bu işlemin İnsansız Hava Araçları (İHA) verileri kullanılarak yapılabileceği belirtilmiştir. [19] yaptığı çalışmada, araç tespiti için Google Earth uydu görüntülerini kullanmıştır. Bu çalışmada color probability maps verisi kullanılarak araçların ve çevresindeki renklerin dağılımını görmek için ön sınıflandırma yapılmıştır. En küçük kareler yöntemi (A Partial Least Square Analysis) ve çift üstel fonksiyon türevi (Derivative of the Double Exponential) algoritmasının kullanıldığı çalışmada araçlar %80 doğruluk oranı ile tespit edilmiştir. [20] tarafından hareketli araç tespitinin yapıldığı çalışmada 50 cm çözünürlüklü WorldView-2 uydu görüntüleri kullanılmış olup daha yüksek konumsal ve spektral çözünürlüklü görüntüleri kullanmanın önemi vurgulanmıştır. Çalışmada izlenen yöntem, nesne tabanlı yol çıkarımı, hareketli araçların tespiti ve araçların hız kestirimi olmak üzere, üç adımdan oluşmaktadır. Elde edilen sonuçların tespit edilme doğruluğu (Correctness) %92 ve tespit edilme bütünlüğü (Completeness) %77 olarak hesaplanmıştır. Bu çalışmada kullanılan yöntemin otomatik olarak trafik gözetleme sistemi olarak kullanılabilmesi ifade edilmiştir. [21] tarafından yapılan çalışmada Quickbird uydu görüntülerine ait renkli ve siyah beyaz görüntülerden hareketli araçların tespitine yönelik yeni bir matematiksel yöntem önerilmiştir. Yöntemde aracın konumuna göre hız parametresi belirlenmektedir. Yöntemin uygulaması sonucunda %90 doğruluk oranına ulaşıldığı belirtilmiştir. Bu yöntemin uygulanabilmesi için, en az iki fotoğraftan bir üç boyutlu (stereo) model oluşturulması için, bu yöntemde girdi verisi olarak en az iki tane hava fotoğrafı verilerek işe başlanması gerekmektedir. [22] hareketli araçların tespiti için araçların şekil ve renk özelliklerini dikkate alan Cascade sınıflandırma yöntemini kullanmıştır. Sınıflandırma işleminin ardından araçların geometrik şekline göre seçilen morfolojik aşınma ve genişleme filtreleri uygulanmıştır. Doğruluk değeri yanlış tespit edilme oranına (False Positive Rate) göre %80 olarak hesaplanmıştır. Bu çalışmada kullanılan yöntem, işlem alanının

belirlenmesi, algoritma parametre değerlerinin girilmesi, tanımlanan kuralların işleme dahil edilmesi, tespit edilemeyen araçların belirlenmesi, tespit edilemeyen araçlar için daha küçük lokal alanlarda algoritmanın tekrar çalıştırılması ve tespit edilen araçların doğruluk analizi üzere toplam altı adımdan oluşmaktadır. [23] tarafından yapılan çalışmada, kentsel, kırsal ve ormanlık alanların değişik mevsimlerde çekilmiş 22 cm çözünürlüklü hava fotoğraflarından hareketli, duran ve park halindeki araçların tespiti yapılmıştır. İlk olarak görüntü üzerinde manuel olarak seçilen bir başlangıç pikseli (seed pixel) ile yöntemin uygulaması başlatılıp, görüntü segmentasyonu yapılmıştır. Ardından, yapay sinir ağları sınıflandırma algoritması kullanılmış ve %75.8 doğruluk oranı elde etmiştir. Önerilen bu yöntemin park alanlarını gözetleme ve akan trafiği izleme yerlerinde kullanılabileceği belirtilmiştir. [24] tarafından yapılan çalışmada Google Earth uydu görüntüleri kullanılmıştır. İkili normlu gradyanlar (Binary Normed Gradients) algoritması ile çalışma alanında yer alan tüm detaylar çıkarılmış ve evrişimli sinir ağları (Convolutional Neural Networks) sınıflandırma algoritması ile sabit araçların tespiti gerçekleştirilmiştir. Çalışmada %96 doğruluk değeri elde edilmiştir. Ancak, bu yöntemin günlük hayatta kullanılabilecek pratik bir yöntem olmadığı, oldukça zaman alıcı ve uzun işlem adımlarından oluştuğu ve bu nedenle bilimsel çalışmalar için uygun olabileceği belirtilmiştir.

1.3 Çalışmada kullanılan yazılımlar

Çalışmada Agisoft Photoscan, Lastools, ArcGIS, MATLAB ve eCognition Developer yazılımları kullanılmıştır. İHA görüntülerinden ortofoto oluşturulması işlemi Agisoft Photoscan yazılımı ortamında gerçekleştirilmiştir. Elde edilen ortofoto verisi kullanılarak nokta bulutu şeklinde sayısal yüzey modeli (SYM) oluşturulmuştur. Agisoft Photoscan yazılımı "dense stereo matching" algoritmasını kullanarak her bir pikselin görüntü üzerindeki diğer tüm piksellere olan derinlik değerini (depth value) hesaplamaktadır ve bu da yüksek derecede detaylı ve doğru SYM üretimine olanak sağlamaktadır.

Oluşturulan SYM verisinden zemin ve zemin üstü nesnelere ayrılması işlemi (yer filtreleme) için Lastools nokta bulutu işleme ve analizi yazılımı kullanılmıştır. Bu işlem neticesinde elde edilen zemini temsil eden yükseklik verisi sayısal arazi modelidir (SAM). SYM ve SAM verilerinden normalize edilmiş sayısal yüzey modeli (nSYM) hesaplanması, nSYM verisine eşik değeri uygulanması ve elde edilen sonuçların doğruluk analizlerinde kullanılacak referans verilerin hazırlanması işlemleri için ArcGIS yazılımı kullanılmıştır. nSYM verisine morfolojik filtreleme uygulaması için MATLAB yazılımı kullanılmıştır. Ortofotonun çoklu çözünürlük segmentasyonu ve ardından nesne-tabanlı sınıflandırma işlemleri eCognition nesne-tabanlı görüntü işleme yazılımı ortamında yapılmıştır.

2 Yöntem

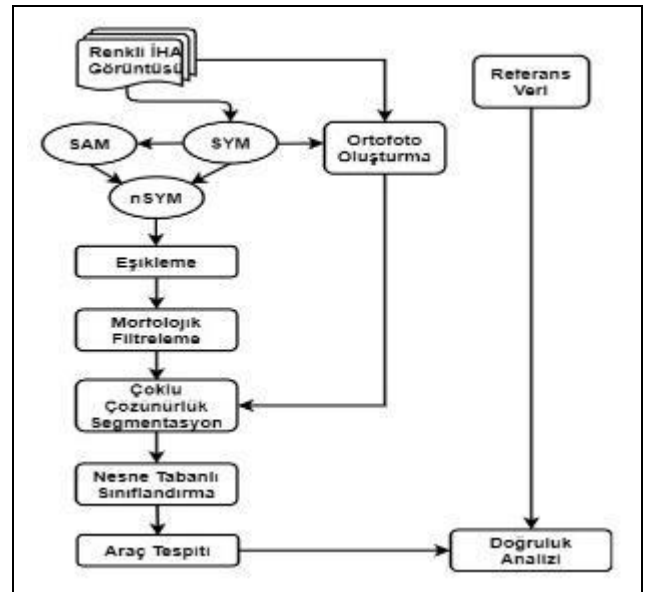
Yöntemin adımlarını özetleyen akış diyagramı Şekil 4'te gösterilmiştir. Yöntem iki temel adımdan oluşmaktadır. Bu adımlardan ilki veri ön işlemleridir. Önce, hava triangülasyonu işlemi ile renkli İHA görüntülerinden, belirlenen datum ve projeksiyon sisteminde çalışma sahasının stereo modelleri oluşturulmuştur. Sonra, oluşturulan stereo modellerden sayısal yüzey modeli (SYM) hesaplanmış ve elde edilen SYM kullanılarak İHA görüntülerinden ortofoto oluşturulmuştur. Ardından, SYM verisine yer filtreleme işlemi uygulanarak Sayısal Arazi Modeli (SAM) elde edilmiştir. Sonra, SYM ve SAM

verilerinden normalize edilmiş sayısal yüzey modeli (nSYM) hesaplanmıştır. Yöntemin ikinci adımında, nSYM verisi de ek bant olarak kullanılarak, renkli ortofotonun, çoklu çözünürlük segmentasyonu yöntemi ile önce segmentasyonu, ardından nesne-tabanlı sınıflandırması yapılmıştır. Son olarak, elde edilen sonuçların doğrulukları hesaplanmıştır.

2.1 Ön işlemler

İlk olarak, çalışma alanlarını da kapsayan bölgenin toplam 116 adet İHA görüntüsünden Agisoft Photoscan yazılımı ortamında SYM verisi üretilmiştir. Bunun için önce, her bir görüntü için iç yöneltme işlemi yapılmıştır. Bu kapsamda, kamera kalibrasyon raporundan alınan kamera bilgileri, köşe markaları koordinatları ve İHA'da kullanılan dijital kameraya ait merceğe distorsiyon değerleri programa tanıtılmıştır. İç yöneltme işleminden sonra, görüntüler ile yer koordinat sistemi arasında geometrik ilişkiyi oluşturmak için dış yöneltme işlemine geçilmiş ve her bir görüntü için toplam 6 adet dış yöneltme elemanı olan çekim merkezi koordinatları (X, Y, h) ve dönüklük açıları ω (roll), ϕ (pitch) ve κ (yaw) değerleri sistem tarafından hesaplanmıştır. Çalışmada kullanılan gerekli projeksiyon bilgileri de (Projeksiyon: Transverse Mercator; Elipsoid: WGS84; Dilim Orta Meridyeni: 33) sisteme girilmiştir. Bu işlemlerden sonra, toplam 116 İHA görüntüsünün hava triangülasyonu ve blok dengelemesi işlemleri yapılarak sahanın stereo modelleri oluşturulmuştur. Stereo modellerin oluşturulmasından sonra, her bir modelin yerde kapladığı alanda, otomatik görüntü korelasyonu yöntemi ile SYM verisi nokta bulutu olarak (yaklaşık 16 milyon nokta) ve ".las" formatında üretilmiştir. Üretilen nokta bulutu verisinin çözünürlüğü 0.095708 m/piksel ve yoğunluğu 192.12 nokta/m²'dir. Ardından, 2.4 cm x 2.4 cm boyutlu piksellere sahip ortofoto üretilmiştir.

SYM verisinin oluşturulmasından sonra, Lastools yazılımı Lasground yer filtreleme modülü kullanılarak, SYM verisinden SAM verisi üretilmiştir. Genellikle yer filtreleme veya sınıflandırma olarak adlandırılan bu işlem ile, zemin üstü nesnelere örn., bina, ağaç, araç, vb. zeminden ayrılmış ve yalnız zemine ait noktaların oluşturduğu yüzey modeli olan SAM elde edilmiştir.



Şekil 4. Yöntemin akış diyagramı.

Figure 4. The flowchart of the method.

Lasground modülünde sınıflandırma işlemi üçgenleme (Triangulated Irregular Network-TIN) veri modeline dayanmaktadır [25]-[27]. "Step", "Bulge", "Spike", ve "Offset" parametrelerinin yer aldığı Lasground modülünde, en uygun parametre değerleri yapılan denemelerle belirlenmiştir. Test alanlarında bulunan nesnelere geometrik özellikleri (şekil, büyüklük ve yükseklik) birbirinden farklı olduklarından, her bir alan için parametre değerleri alana özgü olarak belirlenmiştir. "Step" parametresi, TIN veri modelinde her bir üçgen kenarının olabilecek en büyük uzunluğunu ifade etmektedir [28],[29] ve bu parametre değerinin, çalışma alanında bulunan boyutu en büyük nesneye göre belirlenmesi gerekir. Dolayısıyla, bu çalışmada "Step" parametresi değeri Alan#1'de en büyük nesne olan bina büyüklüğüne göre, Alan#2'de ise en büyük nesnelere araçların ve ağaçların büyüklüklerine göre metre cinsinden belirlenmiştir.

Diğer parametreler "Spike" ve "Offset" de yer filtreleme işleminde önemli rol oynamaktadır. "Step" parametresi ile oluşturulan en kaba TIN (the coarsest TIN) modelinde, "spike" ve "offset" parametreleri ile tespit edilen eşik değeri kullanılarak model yüzeyi tekrarlı bir şekilde sıklaştırılmaktadır. Ancak, çalışma alanında bulunan dar ve yüksek arazi detayları yanlış sınıflandırmaya yol açabilir. Dolayısıyla, bu çalışmada, "Spike" ve "Offset" parametreleri değerleri sırasıyla, 0.01 m ve 0.05 m olarak tanımlanmıştır. Bunun anlamı, oluşturulan TIN veri modelinde, +0.05 m ile -0.01 m aralığında bulunan yükseklik noktaları seçilerek tekrarlı bir şekilde nokta sıklaştırması yapılacak demektir.

"Bulge" parametresi, TIN veri modelinin içerisinde bulunan ve düzeltmeye mevzu olan noktalardaki yukarı yöndeki çıkıntı miktarına ne kadar izin verileceğini belirlemektedir. 1.0 m ile 2.0 m arasında bir değerin belirlenmesi gerektiği bu parametre için 1.0 m değeri kullanılmıştır. Standart sapma parametresi (Stddev) değeri iterasyon işlemi kullanılmaktadır. Yer filtreleme işlemi için gerekli parametre değerlerinin belirlenmesinden sonra zemin ve zemin üstü noktaların sınıflandırması işlemi yapılmıştır [30].

Bu tür yer filtreleme veya sınıflandırma işlemlerinde Tip I ve Tip II olmak üzere iki tür hata ortaya çıkabilmektedir [31],[32]. Tip I hatası gerçekte zemini temsil etmesi gereken noktaların, zemin üstü olarak sınıflandırılması ile ilişkili iken, Tip II hatası ise gerçekte zemin üstünü temsil etmesi gereken noktaların, zemin olarak sınıflandırılması ile ilişkilidir [32]. Bu çalışmada zemin filtrelemesinin doğruluğunu niceliksel olarak ölçebilecek referans bir veri bulunmamaktadır. Referans veri temini sağlansa bile yer filtreleme sonucunun başarısını tüm çalışma alanına ait yaklaşık on altı milyar noktayı içerisinde barındıran nokta bulutu verisini kullanarak ölçmek özellikle bu çalışma için pratik ve kullanışlı değildir. Dolayısıyla bu çalışmadaki Tip I ve Tip II hataları rastgele seçilmiş olan örneklem noktaları kullanılarak hesaplanmıştır.

[31] tarafından önerilen hatalar formüle edilmiştir (Eşitlikler 1-3).

$$\text{Tip I Hatası} = o / GP \quad (1)$$


$$\text{Tip II Hatası} = c / NGP \quad (2)$$

$$\text{Toplam Hata} = o + c / GP + NGP \quad (3)$$

Eşitlikler 1-3'te yer alan o (omission error) değeri, yer noktaları içerisindeki yanlış olarak sınıflandırılan yere ait olmayan noktaların sayısını, c (commission error) değeri ise yere ait


olmayan noktalar içerisindeki yanlış olarak sınıflandırılan yer noktalarının sayısını ifade etmektedir. GP (Ground Points) değeri yere ait olan noktaların sayısını, NGP (Non-Ground Points) değeri ise yere ait olmayan noktaların sayısını ifade etmektedir [33]. Bu çalışmada Alan#1 ve Alan#2 içerisinde Tip I, Tip II ve Toplam Hata değerlerini hesaplamak için nokta bulutu olarak üretilen SYM verisi üzerinde her bir test alanına dağılmış bir şekilde 1000 adet rastgele örneklem noktası işaretlenmiştir.

Yer filtreleme işleminden sonra SYM verisinden SAM verisi çıkarılarak (nSYM=SYM-SAM) normalize edilmiş sayısal yüzey modeli (nSYM) elde edilmiştir. Bu işlem için ArcGIS coğrafi bilgi sistemi yazılımının "Raster Calculator" fonksiyonu kullanılmıştır. Alan#1 ve Alan#2 çalışma alanları için hesaplanmış olan nSYM verileri sırasıyla Şekiller 5 ve 6'da gösterilmektedir.



Şekil 5. Alan#1 için oluşturulan nSYM.

Figure 5. The nDSM generated for Area #1.



Şekil 6. Alan#2 için oluşturulan nSYM.

Figure 6. The nDSM generated for Area #2.


nSYM verisinin oluşturulmasından sonra bu veriye alt ve üst değerler olmak üzere ikili eşik değeri uygulanmıştır. Bu eşikleme işlemde varsayım, alt ve üst eşik değerleri dışında kalan nSYM verisinin araç nesnelere temsil etmediğidir. Dolayısıyla, nSYM verisinde alt ve üst eşik değerleri dışında kalan pikseller sonraki adımlarda işlem dışı bırakılmıştır. Test alanları için en uygun alt ve üst eşik değerleri yapılan denemeler sonucunda belirlenmiştir (Tablo 1). Test alanları için belirlenen alt ve üst eşik değerleri arasındaki yükseklik farkı, ilgili test alanında bulunan yaklaşık standart bir aracı yüksekliği kadardır. Alan#2'de otobüs aracı bulunmasından dolayı, bu alan için üst eşik değeri 3m olarak alınmıştır.

Tablo 1. Test alanları için belirlenen alt ve üst eşik değerleri.
Table 1. The low and high threshold values defined for the test areas.

Test alanları	Alt eşik değer (m)	Üst eşik değer (m)
Alan#1	0.50	2.00
Alan#2	0.50	3.00

nSYM verisine eşikleme işlemi uygulanmasından sonra, veride istenmeyen boşluk alanların, çıkıntıların ve parazitlerin olduğu görülmüştür. Buna bir örnek Şekil 7(a)'da gösterilmiştir. Şekil 7(a)'da kırmızı ile gösterilen alanın içinde yer alan kısımlar çalılık alanlara ait olup eşikleme işlemi ile giderilememiştir. Dolayısıyla, istenmeyen bu detaylar nSYM verisine Matlab yazılımı ortamında morfolojik açılma filtresi uygulanmak suretiyle giderilmiştir (Şekil 7(b)). Morfolojik açılma filtresi için dikdörtgen yapı elemanı kullanılmıştır.

Şekil 7'de morfolojik işlem için seçilen bölge kırmızı renkli elips ve daireler içerisinde alınarak üç farklı durumda gösterilmiştir. Ayrıca, morfolojik işlemin bazı araçların kaybına sebep olduğu Doğru Pozitif (True Positive-TP) alanları (Şekil 16) hesaplanırken ve buna bağlı olarak araç tespit yüzdesi hesaplanırken dikkate alınmıştır.



Şekil 7. Alan#1'den seçilen bir bölgeye ait nSYM.

(a): Morfolojik filtreleme öncesi durumu ve (b): Morfolojik filtreleme sonrası durumu.

Figure 7. The nDSM that belongs to a region selected from Area #1. (a) before morphological filtering; and (b) after morphological filtering.

2.2 Referans verilerin hazırlanması

Sonuçların doğruluk analizleri için yukarıda oluşturulan ortofoto verisi üzerinden her iki test alanında bulunan araçların dış sınırları ArcGIS yazılımı ortamında kapalı poligon şeklinde çizilmiştir (Şekiller 8 ve 9). Şekiller 8 ve 9'da gösterilen kırmızı renkli poligonlar araçların dış sınırlarını temsil etmektedir. Bu çalışmada doğruluk analizleri alan bazlı mantıkla yapılmıştır. Alan bazlı yaklaşımda, oluşturulan referans veri setindeki araç alanları ile yöntemin otomatik tespit ettiği araç alanları

çakıştırılmakta ve elde edilen sonuçlar oransal ve sayısal olarak hesaplanmaktadır.



Şekil 8. Alan#1'e ait ortofoto üzerinden çizilerek oluşturulan referans veri (Kırmızı).

Figure 8. The reference data generated by drawing on the orthophoto of Area #1 (Red colour).



Şekil 9. Alan#2'ye ait ortofoto üzerinden çizilerek oluşturulan referans veri (Kırmızı).

Figure 9. The reference data generated by drawing on the orthophoto of Area #2 (Red colour).

2.3 Görüntü segmentasyonu ve sınıflandırması

Oluşturulan renkli ortofoto verisine önce segmentasyon işlemi uygulanmıştır. Renkli bantlara nSYM verisi de ayrı bir bant olarak eklenerek segmentasyon işlemi toplam dört bant (K, Y, M, nSYM) kullanılarak yapılmıştır. Segmentasyon ve sınıflandırma işlemleri için eCognition nesne-tabanlı görüntü işleme yazılımı kullanılmıştır. Görüntü segmentasyonu, çoklu çözünürlük (multi resolution) segmentasyon yöntemi ile yapılmıştır. [34] tarafından geliştirilen çoklu çözünürlük segmentasyon algoritması, alan büyüme mantığına dayalı çalışan bir algoritmadır. Bu algoritmada, görüntüdeki nesnelerin heterojenliği lokal olarak minimize edilirken, homojenlik maksimize edilir. Nesnelerin heterojen yapısı homojen hale getirilirken, piksellerin komşuluk ilişkisi kriter olarak alınır. Komşuluk ilişkisi ile ifade edilmek istenen,

görüntüde birbirine komşu olan piksellerin benzer spektral ve konumsal özelliğidir [35]-[38].

Ölçek, (scale), şekil (shape) ve yoğunluk (compactness), çoklu çözünürlük görüntü segmentasyonu algoritmasının önemli parametreleri arasında yer almaktadır. Segmentasyon işleminde orijinal görüntü bantları için ağırlık değeri olarak 1, nSYM bantı için ağırlık değeri olarak 2 kullanılmıştır. Dolayısıyla, düşey konum itibarıyla yer yüzeyinden yüksekte olan araç nesnelerinin doğru segmente edilebilmesi için, yükseklik verisine daha fazla ağırlık verilmiştir.

Ölçek parametresi, görüntünün çözünürlüğüne bağlı olarak belirli bir nesneyi tanımlamak için kullanılır. Görüntüdeki nesnelerin maksimum izin verilen heterojenliği tespit edilerek nesnenin ne ölçüde homojen hale geleceği ölçek parametresi değerine göre belirlenir. Ölçek parametresi ne kadar büyük seçilirse nesne detayları o ölçüde azalır. Bu nedenle, görüntünün konumsal çözünürlüğü dikkate alınarak bir nesneyi en iyi şekilde belirleyecek en uygun parametre değeri seçimi yapılmalıdır. Şekil parametresi şekil ve renk arasındaki bağlantının belirlenmesi temeline dayanır. Burada homojenlik ölçütüne katkı sağlayacak olan görüntüdeki spektral değerlerin yüzdesi tanımlanır. Yoğunluk parametresi ise nesnelerin sınırlarını ve bu nesnelerin diğer nesnelere olan geçişini tarif etmektedir [39],[40].

Bu çalışmada, test alanları için en uygun ölçek parametre değerleri ESP-2 (Estimation of Scale Parameters) eklenti aracı ile belirlenmiştir [41],[42]. Ölçek parametresi değerinin belirlenmesinde, ESP-2 eklenti aracının grafik çıktısında görülen lokal varyans değerinin değişim oranının en yüksek olduğu noktalar (tepe noktaları) dikkate alınmıştır. ESP-2 eklenti aracının sonuç ürünü olan grafik çıktıların görsel analizleri yapılmış ve Alan#1 ve Alan#2 için en uygun ölçek parametre değerleri sırasıyla 75 ve 70 olarak belirlenmiştir. Her iki çalışma alanı için şekil ve yoğunluk parametreleri değerleri ise sırasıyla 0.5 ve 0.8 olarak belirlenmiştir (Tablo 2).


Tablo 2. Alan#1 ve Alan#2 test alanları için belirlenen en uygun ölçek, şekil ve yoğunluk parametreleri değerleri.

Table 2. The optimum values for the scale, shape and compactness parameters for Area #1 and Area #2.

Çalışma alanı	Ölçek	Şekil	Yoğunluk
#1	75	0.5	0.8
#2	70	0.5	0.8


Ölçek, şekil ve yoğunluk parametreleri değerlerinin belirlenmesinden sonra görüntü segmentasyonu işlemi yapılmıştır. Alan#1 ve Alan#2'ye ait görüntü segmentasyonu sonuçları sırasıyla Şekiller 10 ve 11'de gösterilmiştir.

Segmentasyon işleminden sonra nesne-tabanlı sınıflandırma işlemi gerçekleştirilmiştir. Bunun için önce yol, bina, yeşil alan, halı saha, beyaz araç, kırmızı araç, mavi araç, sarı araç ve araç camı olmak üzere toplam 10 sınıf belirlenmiştir. Sonra, tanımlanan her bir sınıf için, segmentasyon işlemi ile elde edilen segmentlerden homojen dağılımlı eğitim alanı örnekleri seçilmiştir. Eğitim alanı örneklerinin seçilmesinden sonra eCognition yazılımının "Nearest Neighbor Feature Space" algoritması ile görüntünün sınıflandırması yapılmıştır. Sınıflandırma işleminde, segmentleri oluşturan piksellerin ortalama parlaklık değerleri kullanılmıştır [43]-[49]. Alan#1 ve Alan#2 için elde edilen sınıflandırma sonuçları sırasıyla Şekiller 12 ve 13'te gösterilmiştir.



Şekil 10. Alan#1 renkli ortofoto verisi segmentasyonu sonucu.

Figure 10. The result of colour orthophoto segmentation for Area #1.




Şekil 11. Alan#2 renkli ortofoto verisi segmentasyonu sonucu.

Figure 11. The result of colour orthophoto segmentation for Area #2.



Şekil 12. Alan#1'e ait sınıflandırma sonucu.

Figure 12. The classification result for Area #1.



Şekil 13. Alan#2' ye ait sınıflandırma sonucu.

Figure 13. The classification result for Area #2.

Sınıflandırma işleminde görüntünün üç bandının ortalama piksel parlaklık değerleri esas alınmıştır. Test alanları için tanımlanan sınıflar ve görüntü üzerinden seçilerek toplanan eğitim alanı örnekleri birbirlerinden farklılık göstermektedir. Bunun nedeni her iki test alanındaki nesnelere piksel parlaklık değerlerinin, şekillerinin, boyutlarının ve yüksekliklerinin farklı olmasıdır. Çünkü sınıflandırma sonucu elde edilen tematik çıktılar görsel olarak yorumlandığında, her iki test alanı için birbirinden farklı olarak tanımlanmış sınıfların olması gerektiği varsayımını haklı çıkarmaktadır.

2.4 nSYM verisi ve sınıflandırılmış görüntünün birlikte değerlendirilmesi

Bu aşamada nSYM verisinden ve sınıflandırılmış görüntüden elde edilen yalnız araç sınıfı bölümleri birlikte analiz edilmiştir. nSYM verisi ve sınıflandırılmış görüntünün birlikte analiz edilmesindeki amaç araç tespiti doğruluğunu arttırmaktır. Bunun için, morfolojik filtre uygulanması sonrası elde edilen ve yalnız araçları temsil eden nSYM verisi ile sınıflandırılmış görüntüdeki araç nesnelere vektör poligon olarak dışarı aktarılmıştır. Sonra, bu iki veri seti arasında birleşim konumsal analizi yapılmış ve elde edilen sonuçlar dışarı aktarılmıştır. Buradan elde edilen sonuç verisi bu çalışmada kullanılan yöntem ile tespit edilen araçları göstermektedir.

Doğruluk analizleri için, elde edilen sonuç verisi ile referans verinin karşılaştırması yapılmıştır. Karşılaştırma işlemi için iki veri seti arasında kesişim işlemi uygulanmıştır. Sonuç verisinde tespit edilen araçların geometri tipi kapalı alan olduğu için, verideki tüm kapalı alanların (segment) alanları öznelik tablosundan birimi metrekare olarak hesaplanmıştır [50]. Ayrıca, doğruluk analizleri için kullanılan referans verilerin de geometri tipi kapalı alan olduğu için, öznelik tablosundan birimi metrekare olarak alanları hesaplanmıştır. Bu işlem ArcGIS yazılımı ortamında gerçekleştirilmiştir [53].

3 Bulgular

Alan#1 için nokta bulutu olarak üretilen SYM verisi üzerinde işaretlenen rastgele örneklem noktaları görsel olarak yorumlandığında 524 tanesinin yer noktası (ground points-GP), 476 tanesinin ise yere ait olmayan noktalar (non-ground

points-NGP) olduğu tespit edilmiştir. İşaretlenen bu noktalar SYM verisinden yer filtrelemesi ile elde edilmiş olan SAM verisi ile karşılaştırıldığında, 524 adet yer noktasının 29 tanesinin yere ait olmayan nokta (omission error-o); 476 adet yere ait olmayan noktanın 91 tanesinin yer noktası (commission error-c) olarak sınıflandırıldığı tespit edilmiştir.

Alan#2 için nokta bulutu olarak üretilen SYM verisi üzerinde işaretlenen rastgele örneklem noktaları görsel olarak yorumlandığında 591 tanesinin yer noktası (ground points-GP), 409 tanesinin ise yere ait olmayan noktalar (non-ground points-NGP) olduğu tespit edilmiştir. İşaretlenen bu noktalar SYM verisinden yer filtrelemesi ile elde edilmiş olan SAM verisi ile karşılaştırıldığında, 591 adet yer noktasının 14 tanesinin yere ait olmayan nokta (omission error-o); 409 adet yere ait olmayan noktanın 58 tanesinin yer noktası (commission error-c) olarak sınıflandırıldığı tespit edilmiştir.

Alan#1 ve Alan#2 için oluşturulan sınıflandırılmış noktaların hata matrisleri sırasıyla Tablo 3 ve Tablo 4'te, bu değerlerden hesaplanan, yer noktalarının ve yere ait olmayan noktaların üretici doğruluğu, kullanıcı doğruluğu, genel doğruluk ve kappa katsayısı doğruluk değerleri ise sırasıyla Tablo 5 ve Tablo 6'da verilmiştir. Eşitlikler 1-3 kullanılarak hesaplanan Tip I hatası, Tip II hatası ve Toplam hata metrikleri Tablo 7' de verilmiştir.

Tablo 3. Alan#1' e ait filtrelenmiş noktaların hata matrisi.

Table 3. The error matrix of the filtered points for Area # 1.

		Rastgele örneklem noktaları		
		Yer noktası	Yere ait olmayan nokta	Toplam nokta
Sınıflandırılmış noktalar	Yer noktası	495	91	586
	Yere ait olmayan nokta	29	385	414
	Toplam nokta	524	476	1000

Tablo 4. Alan#2' ye ait filtrelenmiş noktaların hata matrisi.

Table 4. The error matrix of the filtered points for Area # 2.

		Rastgele örneklem noktaları		
		Yer noktası	Yere ait olmayan nokta	Toplam nokta
Sınıflandırılmış noktalar	Yer noktası	577	58	635
	Yere ait olmayan nokta	14	351	365
	Toplam nokta	591	409	1000

Tablo 5. Alan#1' e ait yer filtrelemesi sonucu doğrulukları.

Table 5. The accuracy results of ground filtering for Area # 1.

Çalışma alanı	Nokta türü	Üretici doğruluğu (%)	Kullanıcı doğruluğu (%)	Kappa katsayısı
Alan#1	Yer noktası	84.77	94.46	0.76
	Yere ait olmayan nokta	92.99	80.88	
		Genel doğruluk (%) : 88.00		

Tablo 6. Alan#2' ye ait yer filtrelemesi sonucu doğrulukları.

Table 6. The accuracy results of ground filtering for Area # 2.

Çalışma alanı	Nokta türü	Üretici doğruluğu (%)	Kullanıcı doğruluğu (%)	Kappa katsayısı
Alan#2	Yer noktası	90.86	97.63	0.85
	Yere ait olmayan nokta	96.16	85.81	
Genel doğruluk (%) : 92.80				

Tablo 7. Alan#1 ve Alan#2 için hesaplanan Tip I hatası, Tip II hatası ve Toplam hata değerleri.

Table 7. Type I error, Type II error and Total error values computed for Area # 1 and Area # 2.


Çalışma alanı	Tip I hatası (%)	Tip II hatası (%)	Toplam hata (%)
Alan#1	5.53	19.12	12.00
Alan#2	2.37	14.18	7.20

Tablolarda verilen sonuçlar yorumlandığında, Alan#1 ve Alan#2 için sırasıyla 0.76 ve 0.85 olarak hesaplanan Kappa katsayısı değeri yer filtrelemesi işleminin performansının oldukça iyi olduğunu göstermektedir. Benzer şekilde Alan#1 ve Alan#2 için hesaplanan Tip I ve Tip II hataları, bu çalışmanın bir ara adımı olan yer filtrelemesi işleminin oldukça başarılı olduğunun bir göstergesidir. Alan#1 için toplam hata %12.00, Alan#2 için ise toplam hata %7.20 olarak hesaplanmıştır. Bir başka deyişle nokta bulutu şeklindeki SYM verisinden yer filtrelemesi ile üretilen SAM verisinin, Alan#1 ve Alan#2 için sırasıyla %88 (1-0.12) ve %92.80 (1-0.072) oranlarında doğru olarak filtrelediğini ifade etmektedir. eCognition yazılımında, çoklu çözünürlük görüntü segmentasyonu parametrelerinden en önemlisi olan ölçek parametresi için en uygun parametre değeri ESP-2 eklenti aracı ile elde edilmiştir. Alan#2 için farklı ölçek parametre değerleri denenerek elde edilen sonuçlar görsel olarak yorumlandıklarında, bu alan için en uygun değer 70 olduğu ve bu değer ESP-2 sonucu ile uyum sağladığı görülmüştür. Alan#2 görüntüsünün 70 ölçek parametre değeri ile segmentasyonu sonucuna bir örnek Şekil 14'te gösterilmiştir. Nesne-tabanlı görüntü sınıflandırma doğruluğu değerleri Tablo 8'de verilmiştir. Bu değerler sınıflandırma çıktılarından hesaplanarak elde edilen hata matrisinden türetilen istatistik değerlerdir [51]. Üretici doğruluğu, her sınıf için, doğru olarak sınıflandırılmış piksellerin sayısının bu sınıf için kullanılan referans veri setindeki piksel sayısına bölünerek hesaplanmaktadır. Kullanıcı doğruluğu, her sınıf için, doğru sınıflandırılmış piksel sayısının, bu kategori içinde sınıflandırılan piksellerin toplam sayısına bölünmesiyle hesaplanmaktadır ve herhangi bir sınıfa atanan bir pikselin bu sınıfı gerçekte temsil etme olasılığını gösterir. Genel doğruluk, doğru olarak sınıflandırılan piksellerin toplam sayısının referans veri setindeki piksellerin toplam sayısına bölünmesiyle elde edilir.

Tablo 8. Görüntü sınıflandırması doğrulukları.

Table 8. The image classification accuracies.

Çalışma alanı	Üretici doğruluğu (%)	Kullanıcı doğruluğu (%)	Genel doğruluk (%)	Kappa katsayısı
Alan#1	85.72	84.26	76.71	0.79
Alan#2	91.24	89.66	87.06	0.81



Şekil 14: Alan#2'ye ait görüntünün ölçek parametresi 70 değeri ile gerçekleştirilen segmentasyon sonucuna bir örnek.


Figure 14. An example for the output of segmentation of the image of Area#2 which was carried out using the scale parameter value of 70.

Alan#1'e ait nesne-tabanlı sınıflandırma genel doğruluk, üretici ve kullanıcı doğruluk değerleri sırasıyla, %76.71, %85.72 ve %84.26 olarak hesaplanmıştır (Tablo 8). Alan#2 için bu değerler sırasıyla, %87.06, %91.24 ve %89.66 olarak hesaplanmıştır (Tablo 8). Genel doğruluk değerlerine göre karşılaştırma yapıldığında, Alan#2 sınıflandırma sonucunun Alan#1 sınıflandırma sonucuna göre yaklaşık %10 daha iyi olduğu görülmektedir.

Yaygın kullanılan bir diğer sınıflandırma doğruluk ölçümü Kappa katsayısına (Cohen's Kappa) göredir. Kappa katsayısı referans veri setindeki pikseller ile sınıflandırılmış pikseller arasındaki gerçek uyumu gösterir ve değeri 0 ile 1 arasında değişir. Kappa katsayısı değeri 0.00 ise sınıflandırılmış ve referans veriler arasında uyum olmadığını, 0.40 ve altı değerler performansın yetersiz olduğunu, 0.75 ve yukarı değerler performansın çok iyi olduğunu, 1.00 ise tam uyum olduğunu gösterir [52]. [52] tarafından verilen aralıklara göre, bu çalışmada elde edilen kappa katsayı değerlerinin (Tablo 8) oldukça yüksek değerler oldukları görülmektedir. Bir başka deyişle, çalışma alanlarına ait görüntü sınıflandırma çıktıları ile referans veriler arasında yüksek oranda uyum olduğu görülmektedir.

Çalışmada tespit edilen araçların doğruluk analizleri için, sonuçlar referans veriler ile karşılaştırılmıştır. Tespit edilen araç nesnelere alansal nesnelere nedeniyle, doğruluk analizleri alan-tabanlı yapılmıştır. Alan-tabanlı analizlerde, tespit edilen araçlar ile referans veri seti arasındaki

örtüşme/örtüşmeme oranı alansal olarak hesaplanmaktadır. Bunun için, öncelikle Doğru Pozitif (True Positive - TP), Yanlış Pozitif (False Positive - FP) ve Yanlış Negatif (False Negative - FN) değerleri metrekare olarak hesaplanmıştır (Şekil 15). Doğru Pozitif (TP) (Şekil 15b), hem referans veri setinde hem de sonuçlarda aynı olan segment grubudur. Yanlış Pozitif (FP) (Şekil 15d), yöntemin tespit ettiği ancak referans veri setinde bulunmayan segment gruplarıdır. Bu segment grupları yöntemin yanlış tespit ettiği segment gruplarıdır. Yanlış Negatif (FN) (Şekil 15c) referans veri setinde olan ancak tespit edilemeyen segment gruplarıdır. Bu segment grupları yöntemin hiçbir şekilde tespit edemediği segment gruplarıdır.



Şekil 15(a): Tespit edilen örnek durum, (b): Doğru Pozitif (True Positive-TP), (c): Yanlış Negatif (False Negative-FN), (d): Yanlış Pozitif (False Positive-FP), (e): Doğru Negatif (True Negative-TN).

Figure 15(a): An example case for the detection, (b): True Positive-TP, (c): False Negative-FN, (d): False Positive-FP, (e): True Negative-TN.

Doğru Pozitif (TP), Yanlış Pozitif (FP) ve Yanlış Negatif (FN) değerlerinin hesaplanmasından sonra, bu değerler kullanılarak, Sapma Faktörü (SF), Başarısızlık Faktörü (BF), Araç Tespit Yüzdesi (ATY) ve Kalite Yüzdesi (KY) değerleri (Eşitlikler 4-7) hesaplanmıştır [53],[54].

$$\text{Sapma Faktörü (SF)} = \text{FP} / \text{TP} \quad (4)$$

$$\text{Başarısızlık Faktörü (BF)} = \text{FN} / \text{TP} \quad (5)$$


$$\text{Araç Tespit Yüzdesi (ATY)} = 100 * \text{TP} / (\text{TP} + \text{FN}) \quad (6)$$

$$\text{Kalite Yüzdesi (KY)} = 100 * \text{TP} / (\text{TP} + \text{FP} + \text{FN}) \quad (7)$$

SF, tespit edilmiş ancak referans veri setinde bulunmayan araçların oranını göstermektedir. Bir başka deyişle, fazladan tespit edilen araçları veya araç diye tespit edip referans veride araç olmayan nesnelere ifade eder. BF, referans veri setinde olan ancak tespit edilemeyen araçların oranını göstermektedir. Bir başka deyişle, tespit edilemeyen kaçan araçları ifade eder. ATY, doğru tespit edilen araçların yüzdesini ifade ederken, KY, genel performans ölçüsüdür ve hem doğru tespit edilen araçları hem de yanlış tespit edilen ve tespit edilemeyen araçların yüzdesini göstermektedir.

Alan#1 test alanında tespit edilen araçlar (mavi renk) ile çıkarılmış referans veri seti (kırmızı renkli sınırlar) Şekil 16'da gösterilmiş olup, bu alan için tespit edilen Doğru Pozitif (TP) alanları ifade etmektedir.

Alan#1'de bulunan toplam 175 araçtan ne kadarının doğru tespit edildiği görsel olarak da anlaşılabilir. Bu çalışmada bir aracın doğru tespit edilme kararı, o araç için hesaplanan Doğru Pozitif (TP) alanın aracın toplam alanının %50'sinin üzerinde kalıp kalmadığına göre verilmiştir. Şöyle ki, eğer araç %50 ve üstü bir alansal oranla tespit edilmiş ise, bu araç doğru tespit edilmiş kabul edilmiştir.



Şekil 16. Alan#1 için bulunan Doğru Pozitif (TP) alanlar.
Figure 16. The True Positive (TP) areas detected for Area #1.

Her iki test alanında tespit edilen ve edilemeyen araçlara ait sayısal değerler Tablo 9'da, hesaplanan Sapma Faktörü (SF), Başarısızlık Faktörü (BF), Araç Tespit Yüzdesi (ATY) ve Kalite Yüzdesi (KY) değerleri Tablo 10'da verilmiştir. Tablo 9'da verilen sonuçlara göre Alan#1'de yer alan toplam 175 araçtan 167 tanesi doğru tespit edilmiş 8 tanesi ise tespit edilememiştir.

Tablo 9. Tespit edilen ve edilemeyen araç sayıları.

Çalışma alanı	Toplam araç sayısı		
	Referans veri	Tespit edilen	Tespit edilemeyen
Alan#1	175	167	8
Alan#2	217	214	3

Tablo 10: Hesaplanan sapma faktörü (SF), başarısızlık faktörü (BF), Araç tespit yüzdesi (ATY) ve kalite yüzdesi (KY) değerleri.

Table 10. The computed Branching Factor (BF), Miss Factor (MF), Vehicle Detection Percentage (VDP) and Quality Percentage (QP) values.

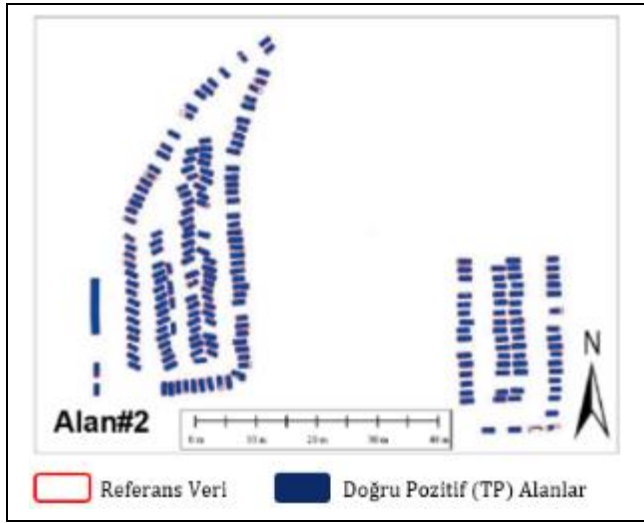
Çalışma alanı	Referans veri (m ²)	Tespit edilen araç alanı (m ²)	SF	BF	ATY	KY
Alan#1	1211.67	951.43	0.78	0.27	78.53	55.17
Alan#2	1517.88	1398.72	0.38	0.08	92.15	72.43

Araç olarak tespit edilen ancak referans veri setinde araç olmayan alanlar yöntemin yanlış olarak tespit ettiği segment gruplarıdır. Söz konusu bu alanların çoğunun yanlış olarak tespit edilmesinin nedeni, bu alanlar ile araç alanlarının neredeyse aynı spektral yansıma değerine sahip olmaları ve ayrıca bu alanların zeminden olan yüksekliklerinin araç yüksekliklerine yakın olmasıdır. Örneğin, Alan#1'de bulunan binaların yansıma değerleri ile gri renkli araçların yansıma değerleri birbirine yakındır. Benzer şekilde, Alan#1'de yer alan binaların oluşturulan yükseklik modelinin kalitesini etkileyip araç olmayan nesnelere araç olarak tespit edilmesine neden oldukları görülmüştür. Ayrıca, yöntemin yanlış tespit ettiği ya

da iki ayrı aracı tek araç olarak tespit etmesinin nedenleri arasında; araçların birbirine göre konumları, park edilme şekilleri, birbirlerine olan mesafeleri (sıklık veya seyreklik) ve aracın bir kısmının bina çatısı veya ağaç altında kalması yer almaktadır. Bu durum ağaçların altına park etmiş olan araçların kısmi olarak ağaçların gölgesinde kalmış olmaları şeklinde yorumlanabilir.

Diğer taraftan, yanlış tespit edilen bu alanlar (segmentler) geometrik şekil itibarıyla da araç nesnelere benzememektedir. Bu alanların çoğu, araç nesnelere dikdörtgen şeklinin aksine, biçimsiz şekle sahiptir. Bu alanların çoğunun geometrik şekli biçimsiz bozuk veya yuvarlak şeklindedir. Dolayısıyla, yanlış tespit edilmiş olsalar dahi, biçimsiz geometrik şekil özellikleri itibarıyla bu alanların araç olmadıkları görsel olarak da kolaylıkla anlaşılmaktadır. Ancak, sayısal sonuçlar yorumlandığında, yöntemin yanlış tespit ettiği bu alanlar doğruluk analizlerinde sonuçları olumsuz yönde etkileyerek doğruluk yüzdesini düşürmüştür.

Yine, Alan#2'de araç olarak tespit edilen alanlar ile referans veri seti karşılaştırılmış ve Doğru Pozitif (TP), Yanlış Pozitif (FP) ve Yanlış Negatif (FN) alanlar birimi metrekare olarak hesaplanmıştır. Şekil 17'de Alan#2'de tespit edilen Doğru Pozitif (TP) alanlar mavi renk ile gösterilmiştir. Şekil 17'de verilen sonuçlar görsel olarak yorumlandığında, bir tanesi otobüs olan araçların (toplam 217 adet) büyük oranda doğru tespit edildiği anlaşılmaktadır.



Şekil 17: Alan#2 için bulunan Doğru Pozitif (TP) alanlar.

Figure 17. The True Positive (TP) areas detected for Area #2.

Alan#2'de yöntemin tespit ettiği ancak referans veride bulunmayan alanlar yanlış tespit edilen segment gruplarını göstermektedir. Bu alanların birçoğunun yanlış tespit edilmesinin nedeni, araçlar ile benzer spektral yansımaya sahip olmaları ve yüksekliklerinin de araç yüksekliğine yakın olmasıdır. Örneğin, Alan#2'de çimenlik alan üzerinde yüksekliği yaklaşık 1 metre olan beton zemine ait piksellerin yansımaya değerleri ile gri renkli araçlara ait piksellerin yansımaya değerleri arasında önemli oranda örtüşme vardır. Yine, Alan#2'de yer alan futbol sahasının hemen yanında bulunan sundurma ile araç camları benzer yansımaya özelliklerine sahiptir. Ayrıca, alanda yer alan yüksek ağaçlar, üretilen SYM'nin kalitesini etkileyip araçların yanlış tespit edilmesine neden olmuştur.

Bu çalışmanın SYM ve ortofoto üretimi adımlarında kullanılan parametreler "align photo accuracy", "pair preselection", "dense cloud quality" ve "mesh type" dir. SYM verisinden yer filtrelemesi ve ardından SAM üretilirken, "Step", "Bulge", "Spike", "Offset" ve "Stddev" olmak üzere beş parametre kullanılmıştır. Çoklu çözünürlük segmentasyon işlemi ve bunu izleyen nesne ve kural tabanlı sınıflandırma adımı ise ölçek (scale), şekil (shape) ve yoğunluk (compactness) olmak üzere üç parametre kullanılmıştır. Sınıflandırma algoritması olarak en yakın komşuluk (Nearest Neighbor Classifier) tekniği kullanılmıştır. Bu çalışmada yapılan yer filtreleme başarım göstergesi Tip I ve Tip II hata metrikleri kullanılarak, nesne tabanlı sınıflandırma adımının başarım göstergesi hata matrisi oluşturulup üretici doğruluğu, kullanıcı doğruluğu, genel doğruluk ve kappa katsayısı sayısal değerleri ile ifade edilmiştir. Araç tespiti için alansal olarak Araç Tespit Yüzdesi (ATY) ve Kalite Yüzdesi (KY) sayısal değerleri ve tespit edilen ve tespit edilemeyen araç sayıları olarak iki farklı cinsten başarım göstergesi ölçülmüştür.

Geçmiş çalışmalar ile karşılaştırıldığında, bu çalışmada elde edilen sonuçların doğruluk değerleri, [10],[11],[15],[19],[20],[22] ve [23] tarafından yapılan çalışmalarda elde edilen sonuçların doğruluk değerlerinden daha yüksek, [14] ve [18] tarafından yapılan çalışmalarda elde edilen sonuçların doğruluk değerleri ile hemen hemen aynı, [12],[13],[16],[17],[21] ve [24] tarafından yapılan çalışmalarda elde edilen sonuçların doğruluk değerlerinden nispeten düşüktür. [12],[13],[16],[17],[21] ve [24] tarafından yapılan çalışmalardan elde edilen sonuçların doğruluk değerinin, bu çalışmadan elde edilen doğruluk değerinden nispeten yüksek olmasının nedeni söz konusu geçmiş çalışmaların yöntem kısmında kullanılan verilere radyometrik olarak çeşitli iyileştirme teknikleri uygulanması ve çalışma alanına ait daha önceden denemeler yapmak suretiyle oluşturulmuş ve referans veri olabilecek kadar doğruluğu yüksek, mevcutta olan hazır verilerin (yüzey modelleri, yükseklik verileri vb. kullanılmasıdır.

4 Sonuçlar

Bu çalışmadan elde edilen sonuçlara göre, çok yüksek konumsal çözünürlüklü İHA görüntülerinden oluşturulan SYM verisinden SAM üretilmesi işlemi, çalışma alanı için en uygun parametre değerlerinin belirlenmesi gerekmektedir ve bu önem arz etmektedir. Dolayısıyla, bu çalışmada kullanılan yaklaşımın farklı alanlarda başarılı bir şekilde uygulanabilmesi için, çalışma alanına uygun parametre değerlerinin belirlenmesi gerekir.

nSYM (nSYM=SYM-SAM) verisinin doğruluğu, SYM ve SAM verilerinin doğruluğuna bağlıdır. Dolayısıyla, araç tespiti doğruluğunu önemli ölçüde etkileyen nSYM verisinin yüksek doğrulukta olabilmesi için, SYM verisinin ve ondan üretilen SAM verisinin doğruluğunun yüksek olması gerekir. Çünkü çoklu çözünürlük görüntü segmentasyonu ve ardından nesne-tabanlı sınıflandırma işlemi kullanılacak nSYM verisi sonuçları etkilemektedir. Ayrıca, yüksek doğrulukla üretilen bir nSYM, gerçek zemin üstünü temsil edeceği için zemin altında kalan yanlış enterpole edilmiş görüntü etkisinden de arınmış olacaktır.

Yöntemin adımlarından birisi nSYM verisinin ikili eşik değer ile eşiklenmesi işlemidir. Eşik değerlerinin belirlenmesinde test alanlarında bulunan zemin üstü nesnelere yerden yükseklikleri dikkate alınmıştır. Çalışmada kullanılan iki ayrı test alanında farklı nesnelere bulunması ve bu nesnelere

farklı yüksekliklere sahip olmasından dolayı, test alanları için belirlenen eşik değerleri farklı değerler olmuştur.

nSYM verisinin eşiklenmesi sonrası elde edilen çıktıya morfolojik filtre uygulanmıştır. Çalışmada tespit edilen nesnelerin dikdörtgen şekilli araçlar olması nedeniyle, dikdörtgen şekilli morfolojik filtre fonksiyonu kullanılmıştır. Sonuçlar görsel olarak yorumlandığında, nSYM verisine morfolojik filtre uygulamanın sonuçları olumlu etkilediği görülmektedir.

Test alanlarına ait referans verilerin oluşturulması sırasında, bazı araçların bir bölümünün ağaçların altında kaldığı görülmüştür. Bu durumda, aracın yalnız görünen kısmı çizilmiş ve referans veride bu şekilde kullanılmıştır. Elde edilen sonuçlar, kullanılan yöntemin sözü edilen bu kısmi araçların da başarılı bir şekilde tespit ettiğini göstermektedir.

Renkli ortofotonun çoklu çözünürlük segmentasyonu için belirlenen parametre değerleri, her bir test alanı için farklı değerler olmuştur. Bunun nedeni, test alanlarında yer alan nesnelerin farklı özelliklere sahip olmasıdır. Dolayısıyla, bu çalışmada kullanılan test alanları için belirlenmiş olan parametre değerlerinin, gerçekleştirilecek benzer çalışmalarda kullanılması durumunda elde edilecek sonuçlarda başarı oranı düşebilir. Bu nedenle, daha başarılı sonuçların elde edilebilmesi için, segmentasyon parametreleri değerlerinin çalışma alanına özgü olarak belirlenmesi gerekir.

Çalışmada kullanılan yaklaşım, park alanlarında yan yana duran komşu araçları tespit edebilmiştir. Burada önemli diğer faktör kullanılan görüntünün konumsal çözünürlüğüdür. Düşük konumsal çözünürlüklü görüntülerin kullanılması durumunda, komşu araçlar birleşik tek segment olarak segmente edilecek, sınıflandırılacak ve neticede komşu araçlar birleşik tek araç olarak tespit edilecektir. Dolayısıyla, birbirine yakın konumdaki sabit araçların doğru tespiti için yüksek konumsal çözünürlüklü görüntü kullanılmalıdır.

nSYM verisinin nesne-tabanlı görüntü sınıflandırma işleminde ek bant olarak kullanılması sonuçları olumlu yönde etkilemiştir. Örneğin, Alan#1 çalışma alanında bulunan binaların yansıma değeri ile gri renkli araçların yansıma değeri arasında önemli oranda benzerlik vardır. Bundan dolayı, sınıflandırma çıktısında bina alanları ile gri araçları temsil eden sınıflar arasında karışma olmuştur. Ancak, sınıflandırma işleminde nSYM verisi üzerinden tanımlanan bir kural ile (Kural: Eğer PD parlaklık değerine sahip bir segmentin yüksekliği 2 m'den düşük ise bu segment araç sınıfını, 2 m'den yüksek ise bina sınıfını temsil eder) bu karışıklık ortadan kaldırılmıştır.

5 Teşekkür

Bu çalışmada kullanılan İHA görüntüleri, Hacettepe Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından desteklenen proje (Proje No: 1069) kapsamında temin edilmiştir.

6 Kaynaklar

[1] Xiong Z, Zhang Y. "An initial study on vehicle information extraction from single-pass quickbird satellite imagery". *Photogrammetric Engineering & Remote Sensing*, 74(11), 1401-1411, 2008.

- [2] Mancini F, Dubbini M, Gattelli M, Stecchi F, Fabbri S, Gabbianelli G. "Using unmanned aerial vehicles (uav) for high resolution reconstruction of topography: The structure from motion approach on coastal environments". *International Journal of Remote Sensing*, 5(10), 6880-6898, 2013.
- [3] Stilla U, Michaelsen E, Soergel U, Hinz S, Ender J. "Airborne monitoring of vehicle activity in urban areas". *International Society For Photogrammetry And Remote Sensing, Commission III, Muenchen, Germany WG III/4*, 2015.
- [4] Bulatov D, Schilling H. "Segmentation methods for detection of stationary vehicles in combined elevation and optical data". *23rd International Conference on Pattern Recognition (ICPR)*, Cancun Center Mexico, 4-8 December, 2016.
- [5] Leithloff J, Hinz S, Stilla U. "Automatic vehicle detection in space images supported by digital map data". *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 36(3), 75-80, 2005.
- [6] Jin X, Davis CH. "Vehicle detection from high resolution satellite imagery using morphological shared-weight neural networks". *Science Direct Image and Vision Computing*, 25(12), 1422-1431, 2006.
- [7] Leitloff J, Hinz S, Stilla U. "Vehicle detection in very high resolution satellite images of city areas". *The Institute of Electrical and Electronics Engineers Transactions On Geoscience And Remote Sensing*, 48(7), 2795-2806, 2010.
- [8] Zheng Z, Wang X, Zhou G, Jiang L. "Vehicle detection based on morphology from highway aerial images". *32nd International Geoscience And Remote Sensing Symposium*, Munich, Germany, 24 July 2012.
- [9] Kaynarca M, Demir N. "Nesne tabanlı sınıflandırma ile karayolunda bulunan araçların tespiti". *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 17(Özel Sayı), 12-17, 2017.
- [10] Zhao T, Nevatia R. "Car detection in low resolution aerial image". *8th Institute of Electrical and Electronics Engineers Conference*, Vancouver, Canada, 7-14 July 2001.
- [11] Schlosser C, Reitberger J. "Automatic car detection in high resolution urban scenes based on an adaptive 3D model". *5th Institute of Electrical and Electronics Engineers Conference*, Alushta, Ukraine, 5-11 June 2003.
- [12] Gerhardinger A, Ehrlich D, Pesaresi M. "Vehicles detection from very high resolution satellite imagery". *The International Archives of the Photogrammetry Remote Sensing and Spatial Information Sciences*, 36(3), 83-88, 2005.
- [13] Zheng H, Li L, "An artificial immune approach for vehicle detection from high resolution space imagery". *International Journal of Computer Science and Network Security*, 7(2), 170-179, 2007.
- [14] Sharma G, Merry C J, Poel P, McCord M. "Vehicle detection in 1 m resolution satellite and airborne imagery". *International Journal of Remote Sensing*, 27(4), 779-797, 2007.
- [15] Nguyen TT, Grabner H, Gruber B, Bischof H. "On-line boosting for car detection from aerial images". *International IEEE Conference on Computer Science*, Paris, France, 22-28 April 2007.

- [16] Tsai L W, Hsieh J W, Fan K C. "Vehicle detection using normalized color and edge map". *IEEE Transactions on Image Processing*, 16(3), 850-853, 2007.
- [17] Holt A C, Seto E Y W, Rivard T, Gong P. "Object based detection and classification of vehicles from high resolution aerial photography". *Photogrammetric Engineering & Remote Sensing*, 75(7), 871-880, 2009.
- [18] Liu W, Yamazaki F, Thuy VT. "Automated vehicle extraction and speed determination from quickbird satellite images". *The Institute of Electrical and Electronics Engineers Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 4(1), 75-82, 2011.
- [19] Kembhavi A, Harwood D, Davis LS. "Vehicle detection using partial least squares". *The Institute of Electrical and Electronics Engineers Transactions on Pattern Analysis and Machine Intelligence*, 33(6), 1250-1265, 2011.
- [20] Salehi B, Zhang Y, Zhong M. "Automatic moving vehicles information extraction from single-pass worldview-2 imagery". *The Institute of Electrical and Electronics Engineers Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(1), 135-145, 2012.
- [21] Zhang Y, Xiong Z. "Moving vehicle detection using a single set of quickbird imagery-an initial study". *International Society for Photogrammetry and Remote Sensing, Commission VII, İstanbul, Turkey, 29 September-2 October, 2014*.
- [22] Sejal R, Charadva M, Sarwade N. "Review on moving vehicle detection in aerial surveillance". *International Journal of Research in Engineering and Technology*, 3(6), 281-284, 2014.
- [23] Sincha D, Chervonenkis M, Skriptsov P, "Vehicle detection and classification in aerial images". *Indian Journal of Science and Technology*, 9(48), 295-303, 2016.
- [24] Qu S, Wang Y, Meng G, Pan C. "Vehicle detection in satellite images by incorporating objectness and convolutional neural network". *Journal of Industrial and Intelligent Information*, 4(2), 158-162, 2016.
- [25] Ludwig Boltzmann Institute Archaeological Prospection and Virtual Archaeology. "ALS filtering". http://lbiarchpro.org/alsfiltering/lbiproject/results/lastools/filtering_algorithm-2 (16.11.2017).
- [26] Axelsson P. "DEM generation from laser scanner data using adaptive tin models". *International Society For Photogrammetry And Remote Sensing*, 33(1), 110-117, 2000.
- [27] Axelsson P. "Processing of laser scanner data algorithms and applications". *International Journal of Photogrammetry & Remote Sensing*, 54 (1999), 138-147, 1999.
- [28] Ludwig Boltzmann Institute Archaeological Prospection and Virtual Archaeology. "ALS filtering". <http://lbiarchpro.org/alsfiltering/lbiproject/results/lastools/guidelines-2> (16.11.2017).
- [29] University of North Carolina at Chapel Hill. "Fast Tools to Catch Reality". https://www.cs.unc.edu/~isenburg/lastools/download/lasground_README.txt (16.11.2017).
- [30] University of North Carolina at Chapel Hill. "Fast Tools to Catch Reality". https://www.cs.unc.edu/~isenburg/lastools/download/lasclassify_README.txt (16.11.2017).
- [31] Sithole G, Vosselman G. "Experimental comparison of filter algorithms for bare earth extraction from airborne laser scanning point clouds". *ISPRS Journal of Photogrammetry & Remote Sensing*, 59(1-2), 85-101, 2004.
- [32] Montealegre AL, Lamelas MT, de la Riva J. "A comparison of open source lidar filtering algorithms in a mediterranean forest environment". *The Institute of Electrical and Electronics Engineers Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(8), 4072-4085, 2015.
- [33] Yılmaz V, Konakoğlu B, Şerifoğlu Ç, Güngör O, Gökalp E. "Image classification based ground filtering of point clouds extracted from uav based aerial photos". *Geocarto International*, 33(3), 310-320, 2018.
- [34] Baatz M, Arno S. *Multiresolution Segmentation-An Optimization Approach for High Quality Multi-Scale Image Segmentation*. Editor: Strobl J. Angewandte Geographische Informationsverarbeitung, 12-23, Salzburg, Germany, Herbert Wichmann Verlag Publisher, 2000.
- [35] Jähne B. *Digital Image Processing*. 6th ed. Berlin, Germany, Springer Heidelberg Press, 2005.
- [36] Marangoz AM. *Fotogrametri I Geometrik ve Matematik Temeller*. Birinci baskı, Zonguldak, Türkiye, Bülent Ecevit Üniversitesi Yayınları, 2012.
- [37] Zhang Y, Maxwell T, Tong H, Dey V. "Development of supervised software tool for automated determination of optimal segmentation parameters for e-cognition". *International Society for Photogrammetry And Remote Sensing Technical Commission VII*. Vienna, Austria, 5-7 July 2010.
- [38] Dass R, Priyanka P, Devi S. "Image segmentation techniques". *International Journal Of Electronics & Communication Technology*, 3(1), 66-70, 2012.
- [39] Strobl J, Blaschke T, Griesebner G. *Angewandte Geographische Informations Verarbeitung*. 12th ed. Heidelberg, Germany, Wichmann-Verlag, 2003.
- [40] Kavzoğlu T, Yıldız M. "Parameter based performance analysis of objects based image analysis using aerial and quickbird-2 images". *International Society For Photogrammetry and Remote Sensing and Spatial Information Sciences*, 2(7), 31-37, 2014.
- [41] Dragut L, Tiede D, Levick SR. "ESP is a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data". *International Journal of Geographical Information Science*, 24(6), 859-871, 2010.
- [42] Dragut L, Csillik O, Eisank C, Tiede D. *ESP 2 (Estimation of Scale Parameters 2)-User Guide*. 2nd ed. Salzburg, Austria, Elsevier, 2014.
- [43] Dey V. "A Supervised Approach for the Estimation of Parameters of Multiresolution Segmentation and Its Application in Building Feature Extration from VHR Imagery". Department of Geodesy and Geomatics Engineering, University of New Brunswick, Fredericton, Canada, Technical Report, 278, 2011.
- [44] Meyer GE, Neto JC. "Verification of color vegetation indices for automated crop mapping applications". *Computers and Electronics In Agriculture*, 6(3), 282-293, 2008.
- [45] Benz UC, Hofmann P, Willhauch G, Lingenfelder I, Heynen M. "Multiresolution object oriented fuzzy analysis of remote sensing data for gis ready information". *International Society For Photogrammetry and Remote Sensing*, 58(3-4), 239-258, 2004.

- [46] Brodsky L, Boruvka L. "Object oriented fuzzy analysis of remote sensing data for bare soil brightness mapping". *Department of Soil Science and Geology, Faculty of Agrobiolgy, Czech University of Agriculture in Prague*, 1(3), 79-84, 2006.
- [47] MATLAB Software Documentation Home. "Image Processing Toolbox". <http://mathworks.com/help/images/arcpy/gray-level-co-occurrence-matrix-glcm.html> (16.11.2017).
- [48] Collins MJ, Dymond C, Johnson EA. "Mapping Subalpine Forest Types Using Networks of Nearest Neighbour Classifiers". *International Journal of Remote Sensing*, 9(25), 1701-1721, 2004.
- [49] Yu Q, Gong P, Clinton N, Biging G, Kelly M, Schrokauer D. "Object based detailed vegetation classification with airborne high spatial resolution remote sensing imagery". *Photogrammetric Engineering & Remote Sensing*, 72(7), 799-811, 2006.
- [50] ArcGIS Software 10.3 Documentation Library. "Calculating Field Values" <http://desktop.arcgis.com/en/arcmap/10.3/managedata/tables/calculating-area-length-and-other-geometric-properties.html> (16.11.2017).
- [51] Oruç M. *Uydu Görüntülerinin Sınıflandırılması ve Doğruluk Değerlendirmesi*, Birinci baskı, Zonguldak, Türkiye, Bülent Ecevit Üniversitesi Yayınları, 2010.
- [52] Mather PM, Koch M. *Computer Processing of Remotely Sensed Images*. 4th ed. Nottingham, United Kingdom, Wiley, 2011.
- [53] Hermosilla T, Ruiz AR, Recio A, Estornell J. "Evaluation of automatic building detection approaches combining high resolution images and lidar data". *Remote Sensing*, 3(1), 1188-1210, 2011.
- [54] Rishikeshan CA, Ramesh H. "An ann supported mathematical morphology based algorithm for lakes extraction from satellite images". *ISH Journal of Hydraulic Engineering*, 20(4), 222-229, 2017.