

Nokta bulutu verisi ile su kütlesi tespitinde geometrik özniteliklerin etkisi

The impact of geometric features on the detection of water body from point clouds

Samed ÖZDEMİR*¹ , Fevzi KARSLI² 

¹Gümüşhane Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Harita Mühendisliği Bölümü, 29100, Gümüşhane

²Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 61080, Trabzon

• Geliş tarihi / Received: 17.09.2023

• Kabul tarihi / Accepted: 23.10.2023

Öz

Yüksek çözünürlüklü uzaktan algılama görüntülerinden su kütlelerinin hızlı ve doğru bir şekilde tespit edilmesi ve çıkarılması, su kaynakları yönetimi, su kalitesi izleme, doğal afet acil müdahaleleri gibi kritik uygulama alanlarında stratejik bir öneme sahiptir. Bununla birlikte, geleneksel su kütle çıkarma yöntemleri, özellikle görüntü dokusu ve karakteristik özelliklerin seçilmesi konusunda çeşitli zorluklar sunmaktadır. Bu çalışmada, nokta bulutu verilerinden çıkarılan geometrik öznitelikler ve hava fotoğraflarından alınan spektral bilgileri bir araya getirerek, su kütlelerinin sınırlarının daha etkin bir şekilde tanımlanmasını ve çıkarılmasını sağlayan bir metodoloji önerilmektedir. Üç boyutlu (3B) yapı tensöründen yararlanılarak nokta bulutlarından üretilen geometrik öznitelikler algılayıcı sistemin ürettiği spektral bilgiler ile birleştirilerek, yüksek boyutlu verilere uygunluğu, hızı ve aşırı uyuma direnci ile bilinen Rastgele Orman (RO) sınıflandırıcısı su kütlelerinin tespiti için eğitimde kullanılmıştır. Matlab ortamında geliştirilen metodolojinin etkinliği, Türkiye’de topografik ve bitkisel özellikleri farklı dört farklı lokasyon üzerinde test edilmiştir. Sınıflandırma işlemi ile tespit edilen su kütlesi sınırlarının doğruluk analizi F-Skoru üzerinden değerlendirildiğinde, Çalışma Alanı-1 için: %85.7, Çalışma Alanı-1 Akarsu için %76.6, Çalışma Alanı-2 için %93.7, Çalışma Alanı-3 için %94.9, ve Çalışma Alanı-4 için %73.6, olarak elde edilmiştir. Çalışma, sunulan metodolojinin farklı mekânsal ölçekler ve sensör türleri için uygulanabilir olduğunu ve çevresel ve hidrolojik araştırmalarda geniş kapsamlı kullanımlar için potansiyel taşıdığını ortaya koymaktadır.

Anahtar kelimeler: Nokta bulutu, Rastgele orman, Sayısal yükseklik modeli, Sınıflandırma, Su kütlesi çıkarımı

Abstract

High-resolution remote sensing imagery plays a strategic role in critical applications such as water resource management, water quality monitoring, and emergency responses to natural disasters for the quick and accurate identification and extraction of water bodies. However, traditional water body extraction methods present various challenges, particularly in the selection of image texture and characteristic features. In this study, a methodology is proposed that combines geometric features extracted from point cloud data with spectral information obtained from aerial photographs to more effectively define and extract the boundaries of water bodies. The geometric features generated from three-dimensional (3D) structure tensors are merged with the spectral information produced by the sensor system, and the well-known Random Forest (RF) classifier suitable for high-dimensional data, speed, and resistance to overfitting is used for training in water body detection. The effectiveness of the methodology developed in Matlab has been tested over four different locations in Turkey with varying topographic and vegetative characteristics. When the accuracy analysis of the detected water body boundaries is evaluated through the F-Score, the following were obtained: 85.7% for Study Area-1, 76.6% for Study Area-1 River, 93.7% for Study Area-2, 94.9% for Study Area-3, and 73.6% for Study Area-4. The study demonstrates that the presented methodology is applicable across different spatial scales and sensor types and carries potential for comprehensive uses in environmental and hydrological research.

Keywords: Point cloud, Random forest, Digital elevation model, Classification, Water body extraction

* Samed ÖZDEMİR; samed.ozdemir@gumushane.edu.tr

1. Giriş

1. Introduction

Ekosistemin hidrolojik döngüsü için kritik bir bileşen olmasının yanı sıra günlük yaşantıdan endüstriyel ihtiyaçlara kadar geniş bir yelpazede önemli bir rol oynayan temel bir kaynaktır. Bu bağlamda, su kütlelerinin zamansal ve hassas bir şekilde izlenmesi su kaynakları yönetimi, su kalitesi izleme ve doğal afet acil müdahaleleri gibi konulara yönelik hızlı ve doğru ölçekli bölgesel su kütle araştırmaları ve dinamik izlemeler yapılması büyük önem taşımaktadır (Pech-May vd., 2023, Wang vd., 2021). Geçtiğimiz yıllarda, uzaktan algılanmış görüntülerle gerçekleştirilen su kütlesi tespit işlemleri günümüzde İnsansız Hava Araçlarının (İHA) yaygınlaşması ile yaygın olarak hava platformlarından elde edilen görüntüler üzerinden gerçekleştirilmeye başlamıştır. Hava platformları, uzay platformlarına kıyasla hem zamansal hem de mekânsal olarak daha yüksek çözünürlüklü veriler sağlaması nedeni ile pek çok haritalama işinde tercih edilmektedir. Özellikle son yıllarda, Light Detection and Ranging (LiDAR) ve Structure from Motion (SfM) gibi uzaktan algılama ve fotogrametrik yöntemler ile üretilen nokta bulutu kaynaklı yüksek çözünürlüklü arazi verileri, zemin yüzey özelliklerinin karakterizasyonunda önemli bir ilerleme sağlamıştır (Zheng vd., 2019). Bu sayede, su kütlesi araştırmaları, sadece zamansal olarak su kütlesi sınırlarının değişiminin izlenmesi ile sınırlı kalmamakta ayrıca su kütlelerinin çevresindeki topografya ile olan etkileşimini de açığa çıkarabilmektedir.

LiDAR nokta bulutlarından su kütlesi çıkarmak, yoğunluk bilgileri, yükseklik histogramları, düşme oranı ve 3B öznitelikler kullanılarak geliştirilmiş birçok yaklaşımın olduğu aktif bir araştırma alanıdır. Vetter vd. (2009), LiDAR nokta bulutlarından elde edilen radyometrik olarak düzeltilmiş yoğunluk ve sinyal yitimi (drop-out) bilgilerini, ayrıca su kütlelerinin yerel pürüzlülük bilgilerini kullanarak eşik temelli bir sınıflandırma gerçekleştirmiştir. Benzer şekilde, Toscano vd. (2014), yükseklik histogramları ve yoğunluk bilgilerini kullanarak su kütlelerini tanımlayan iki aşamalı bir yaklaşım geliştirmiştir. Canaz vd. (2015), RANSAC algoritması kullanarak LiDAR nokta bulutundan su kütlelerini çıkarmak üzere Noktaların Açısı (AOP) ve LiDAR'dan Image (LTI) algoritmalarından faydalanan bir yaklaşım geliştirmiştir. Ancak, bu tarz yaklaşımlar, su kütlelerinin çevresindeki topografyaya göre düz ve homojen veya boş alanlar olması gibi genel varsayımlara dayanır. Bu nedenle, kentsel ve büyük ölçekli çalışma alanlarında başarılı sonuçlar almak zor olacaktır. Maksimum Olabilirlik Sınıflandırması (MLC), Temel Bileşen Analizi (PCA), Rastgele Orman (RO), Destek Vektör Makineleri (SVM) ve derin öğrenme gibi sınıflandırma tabanlı yaklaşımlar, bu eksiklikleri telafi edebilir ve su kütlelerinin tespiti için geliştirilebilir bir yaklaşım sunabilecek potansiyele sahiptir. Smeckaert vd. (2013), yükseklik bilgisi, yerel nokta yoğunluğu ve yerel şekil parametrelerini kullanarak LiDAR nokta bulutlarından su kütlelerinin sınıflandırılmasında SVM sınıflandırıcısından faydalanmıştır. Ancak, LiDAR sensörünün yaydığı lazer ışınının spektral özellikleri nedeniyle, çalışma alanındaki nesnelere (örneğin asfalt) yansıtıcı özellikleri, sınıflandırma doğruluğunu kolayca olumsuz etkileyebilmekte olduğunu belirtmişlerdir. Shaker vd. (2019) çok bantlı (MS) LiDAR (Teledyne Optech Titan) nokta bulutlarından üretilen yükseklik, yoğunluk ve 3 bant oranlarının varyansını hesaplayarak MLC sınıflandırıcısı ile su kütlelerinin tespiti üzerinde bir çalışma gerçekleştirmiştir. MS LiDAR sensörünün sağladığı farklı spektral özelliklerin bir arada kullanılmasına olanak sağlaması nedeni ile su kütlelerini tespit etmede doğruluğu artırabileceği belirtilmiştir. Ancak, MS LiDAR görece yeni bir teknoloji olması nedeni ile, bu yeni teknolojiye ve verilerine ulaşmak güçtür.

Son yıllarda, İnsansız Hava Araçları (İHA) kolay ulaşılabilmesinin yanı sıra RGB, MS ve Termal gibi çeşitli sensörlerle entegrasyonu sayesinde fotogrametri ve uzaktan algılama çalışmaları arasında popülerlik kazanmıştır. Son yıllarda, İHA platformlarının yük kapasitesinin artması ve LiDAR ve RADAR gibi aktif sensörlerin İHA platformları ile uyumlu hale gelmesi nedeniyle çoklu sensör veri üretimi gerçekleştirilebilmektedir (Tymków vd., 2019; Bandini vd., 2020). Tymków vd. (2019) RGB kamera, termal kızılötesi kamera ve LiDAR sensörü ile entegre bir İHA kullanarak denetimli bir sınıflandırma yaklaşımı kullanarak su kütlesi sınırlarını belirledikleri bir çalışma gerçekleştirmiştir. Ancak, sınırlı menzil ve yük kapasitesi nedeniyle, bu platformlar çoğunlukla küçük ölçekli uygulamalar için kullanılabilir. Bu nedenle, büyük ölçekli SYM'ler oluşturmak için büyük taşıyıcı platformlara entegre LiDAR ve hava kameraları daha faydalı ve ekonomik olacaktır.

Bu çalışmada, hava fotoğrafları ve LiDAR olmak üzere iki farklı kaynaktan elde edilen nokta bulutlarından durağan ve akarsu kütlelerinin otomatik olarak çıkarılması için yenilikçi bir yaklaşım önerilmektedir. Matlab ortamında geliştirilen yaklaşımla, hava fotoğraflarından ve LiDAR verilerinden elde edilen spektral bilgilerin, nokta bulutlarından elde edilen yerel geometrik öznitelikler ile zenginleştirilerek spektral özellikleri

değişkenlik gösteren farklı boyut ve türlerdeki su kütlelerinin daha kaliteli bir şekilde karakterize edilmesi amaçlanmaktadır. Önerilen yaklaşım üç ana adımdan oluşmaktadır: nokta bulutlarından öznitelik çıkarımı, sınıflandırma ve sınır düzeltme. İlk olarak, nokta bulutlarının yerel geometrik öznitelikleri, 3B yapı tensörü kullanılarak hesaplanmıştır. İkinci olarak, seçilen öznitelikler ile spektral bilgiler birleştirilerek çok bantlı öznitelik haritaları üretilmiş ve Basit Lineer iteratif Kümeleme (Simple Linear Iterative Clustering SLIC) algoritması kullanılarak süper-piksel segmentasyonu gerçekleştirilerek homojen görüntü parçaları oluşturulmuştur. Süper-piksel segmentasyonu, piksel tabanlı sınıflandırmaya kıyasla hem karmaşık sahnelerde bile daha başarılı olması hem gürültüye karşı olan daha yüksek toleransının olması hem de sınıflandırma işlem süresini kısaltması gibi faydaları nedeni ile tercih edilmiştir. Oluşturulan süper-pikseller, yüksek boyutlu veriyi işleyebilme, hızlı ve aşırı uyuma karşı dirençli olması ile bilinen RO sınıflandırıcısı ile su kütlelerini tespit etmek üzere sınıflandırılmıştır. Son aşamada ise, su kütlesi tespit doğruluğunu iyileştirmek amacı ile tespit edilen su kütlesi sınırlarından oluşturulan bir sahte su yüzeyinin Sayısal Arazi Modeli (SAM) ile keşif edilmesi ile yeni su kütlesi sınırları hesaplanmıştır. Önerilen yaklaşım, LiDAR ve fotogrametrik nokta bulutu verileri ile dört farklı çalışma alanında test edilmiştir. Sınıflandırma işlemi ile tespit edilen su kütlesi sınırlarının doğruluk analizi F-Skoru üzerinden değerlendirildiğinde, Çalışma Alanı-1 için: %85.7, Çalışma Alanı-1 Akarsu için %76.6, Çalışma Alanı-2 için %93.7, Çalışma Alanı-3 için %94.9, ve Çalışma Alanı-4 için %73.6, olarak elde edilmiştir. Sonuçlar, önerilen algoritmanın çeşitli senaryolara uygulanabilir olduğunu ve su kütlelerini yüksek doğrulukla tespit etmek için kullanılabileceğini göstermektedir.

2. Materyal ve metod

2. Material and method

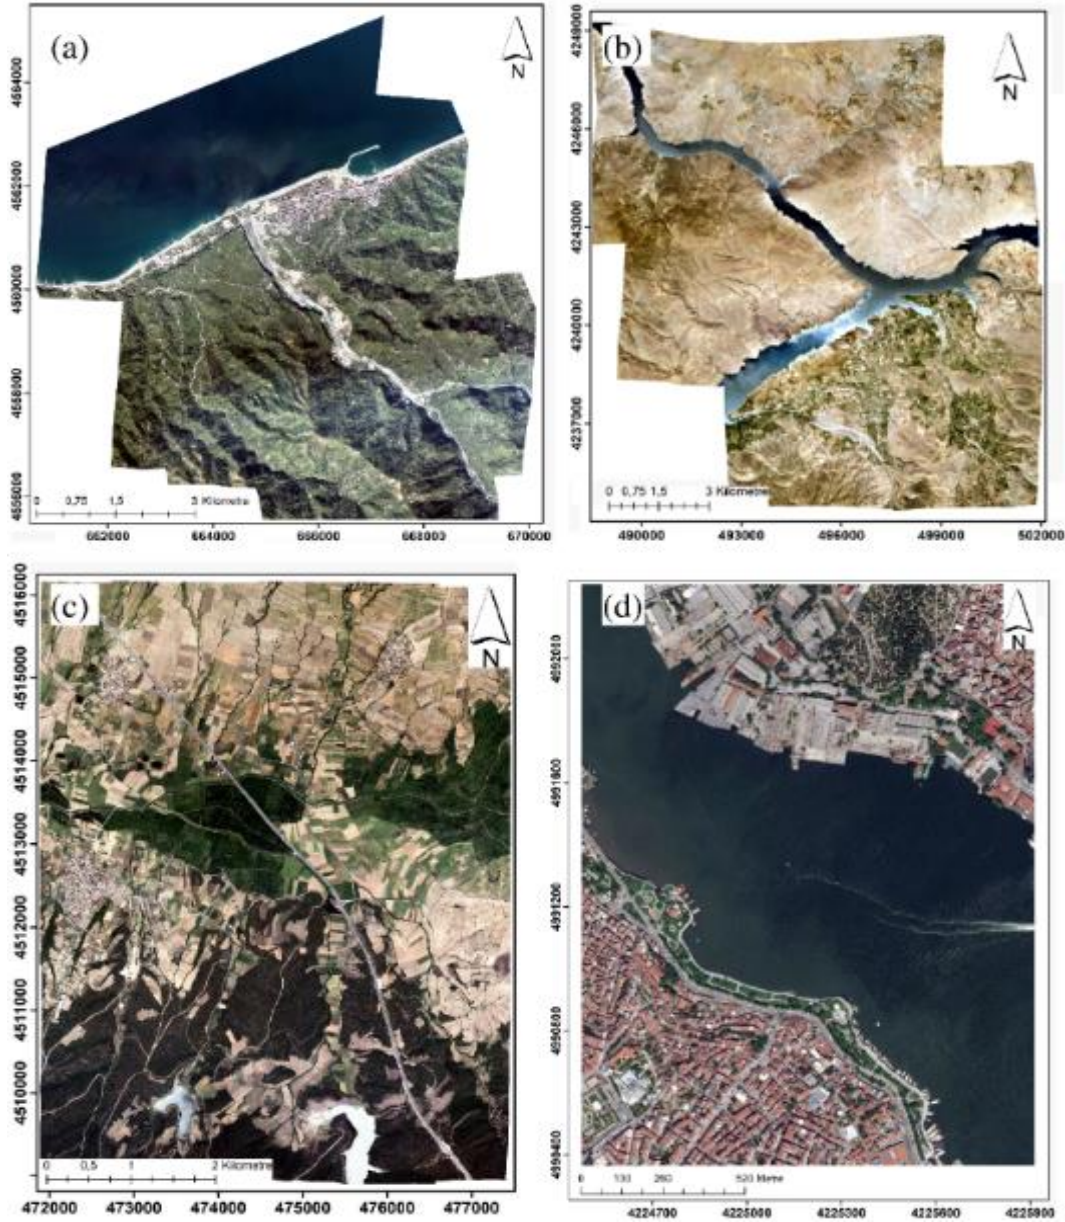
Çalışmanın bu kısmında, öncelikle çalışma alanları tanıtılmış ve ardından öznitelik haritalarının hangi aşamalardan geçerek üretildiği, su kütlesi tespitinde uygulanan sınıflandırma prosedürleri, su kütlesi tespit sınırlarının iyileştirilmesi ve elde edilen sonuçların doğruluk analizinde kullanılan ölçütlere yer verilmiştir.

2.1. Çalışma alanı

2.1. Study area

Dört çalışma alanı, Türkiye'nin topografik ve bitki örtüsü özelliklerini en iyi yansıtan farklı coğrafi bölgelerden seçilmiştir. Bu bölgeler Doğu Karadeniz, İç Anadolu ve Marmara bölgelerini içermekte ve Türkiye'nin su kütlesi özelliklerini temsil etmektedir (Şekil 1). Ek olarak, Marmara Bölgesi'ndeki Çalışma Alanı-4, önerilen yaklaşımın LiDAR nokta bulutları üzerindeki uygulanabilirliğini incelemek için veri setine eklenmiştir. Rize'nin Ardeşen ilçesinde bulunan Çalışma Alanı-1 (Şekil 1 a), deniz ve akarsu olmak üzere iki farklı tip su kütlesine sahiptir. Güneyden gelen iki akarsu kolu birleşerek su arıtma tesisi ve köprü gibi pek çok insan yapısını geçerek kuzeyde kıyıları doğal ve yapay yapılarla çevrili deniz ile birleşmektedir. Hava fotoğrafının alım tarihinde su seviyesinin düşük olmasından dolayı yatak genişliği 35-160 metre arasında değişen akarsu yatağında alüvyonlu adalar ile karşılaşmaktadır. Dağlık ve seyrek bitki örtüsünün yanı sıra az sayıda yapılaşmaya sahip olan Çalışma Alanı-2 (Şekil 1 b), Karakaya baraj gölünün Kale ve Doğanyol arasındaki bölgede bulunmaktadır. Gölün genişliği, en dar kısmında yaklaşık 360m, en geniş kısmında 650m'ye kadar çıkabilmektedir. Çalışma Alanı-3 (Şekil 1 c), Edirne'nin Keşan ilçesinde, düz topoğrafya ve yoğun orman örtüsüyle iki sulama göletine ev sahipliği yapmaktadır. İlk gölet 450 m × 550 m boyutlarına sahipken, Dokuzdere Göleti ise 350 m × 1.300 m boyutlarındadır. İstanbul Haliç bölgesinden seçilen Çalışma Alanı-4 (Şekil 1 d) hafif eğimli topoğrafyaya ve yoğun yapılaşmaya sahiptir. Çalışma alanının sınırları, sahil düzenlemeleri ve çeşitli iskeleler tarafından belirlenmektedir. Çalışma alanlarının hava görüntüleri, iç ve dış yöneltme parametreleri ve su kütlesi sınırlarının vektör verileri HGM tarafından sağlanmıştır. Güncel vektör verileri mevcut olmadığında, su kütlesi sınırları ortofoto görüntü üzerinden manuel olarak çizilmiştir. Çalışma Alanı-1, 2 ve 3 için Fotogrametrik nokta bulutlarının oluşturulmasında, HGM tarafından sağlanan hava fotoğrafları ve dış yöneltme parametreleri temel alınmıştır.

Çalışma Alanı-1,2 ve 3'e ait hava fotoğrafları, 13080×20010 piksel çözünürlüğünde RGB bantlarına sahip Vexcel UltraCam Eagle kamerası ile çekilmiştir. Bu çalışma alanlarına ait nokta bulutu, SAM ve ortofoto, HGM tarafından sağlanan iç ve dış yöneltme parametreleri kullanılarak Agisoft PhotoScan yazılımı ile üretilmiştir. Yer örnekleme aralığı (YÖA-GSD), uçuş yüksekliği, nokta bulutundaki nokta sayısı ve nokta yoğunluğu bilgileri, her bir çalışma alanı için Tablo 1'de verilmiştir. Çalışma Alanı-4'e ait LiDAR verileri için herhangi bir ek işlem uygulanmadan doğrudan sonraki aşamalarda kullanılmıştır.



Şekil 1. Çalışma alanları; a) Çalışma alanı-1 (Rize), b) Çalışma alanı-2 (Malatya), c) Çalışma alanı-3 (Edirne), d) Çalışma alanı-4 (İstanbul).


Figure 1. Study areas; a) Study area-1 (Rize), b) Study area-2 (Malatya), c) Study area-3 (Edirne), d) Study area-4 (Istanbul).

Tablo 1. Çalışma alanlarının genel veri toplama istatistikleri
Table 1. General data collection statistics of the study areas

	Uçuş yüksekliği	Ortofoto GSD	SAM GSD	Nokta sayısı	Nokta yoğunluğu	Alan
Çalışma alanı-1	~7000 m	1 m	1 m	83.387.238	1,3 nkt/m ²	74 km ²
Çalışma alanı-2	~7500 m	1 m	1 m	410.539.623	2,6 nkt /m ²	170 km ²
Çalışma alanı-3	~4500 m	1 m	1 m	126.277.462	3,8 nkt /m ²	44 km ²
Çalışma alanı-4	-	-	1 m	8.585.192	5,7 nkt /m ²	1,5 km ²

Çalışma Alanı-1, 2 ve 3 için hava fotoğraflarından nokta bulutu üretim aşamasında kullanılan SfM tekniği temel olarak; öznitelik tespiti ve demet dengeleme aşamalarından oluşur. Öznitelik tespiti aşamasında, Ölçekten Bağımsız Öznitelik Dönüşüm (Scale-Invariant Feature Transform, SIFT), Hızlandırılmış Sağlam Öznitelikler (Speeded Up Robust Features, SURF) ve Yönlendirilmiş FAST ve Döndürülmüş BRIEF (Oriented FAST and Rotated BRIEF, ORB) yöntemleri yaygın olarak kullanılmaktadır. Öznitelik tanımlayıcılar sayesinde resim çiftleri arasında, rijit dönüşümler (döndürme, ölçekleme, kaydırma vb.) veya

paralaks etkilerine karşı dayanıklı, güçlü eşleştirmeler yapılması sağlanır. Yüksek kaliteli eşleşmelere ve geometrik konfigürasyonları, 3D yapıyı güvenilir bir şekilde tahmin etmeye uygun olan az iki kamera görüşü seçilerek epipolar geometri (Şekil 2) ile 3B sahne yapısı oluşturulur. Bu aşamada ayrıca kamera konumları ve dönüklükleri de hesaplanır. Ardından demet dengeleme aşamasında tüm kamera parametreleri ve 3D nokta koordinatları eş zamanlı olarak optimize edilerek görüntüler, kamera ve 3D noktalar arasındaki tüm geometrik ilişkiler iyileştirilir. Bu aşamada genellikle en küçük kareler yöntemi kullanılır. Son olarak, birbirleri ile daha hassas bir şekilde geometrik ilişkileri tanımlanmış olan görüntü çiftlerinden yoğun nokta bulutu üretilir (Westoby vd., 2012).



Şekil 2. Epipolar geometri (Hartley & Zisserman, 2004); a) C ve C' iki farklı kamera merkezini temsil etmektedir. Bu kamera merkezleri, üç boyutlu uzayda yer alan X noktası ile aynı düzlemde bulunur. Bu düzlem, aynı zamanda X noktasının iki görüntüdeki izdüşümleri olan x ve x' noktalarını da içerir ve π olarak adlandırılır, b) Bir görüntü noktası olan x, ilk kamera merkezi C'den çıkan 3B uzaydaki bir ışınla eşleşir. Bu ışın, ikinci görüntüde l' olarak gösterilen bir çizgiye karşılık gelir. Üç boyutlu uzaydaki X noktası, bu ışının üzerinde bulunur; dolayısıyla ikinci görüntüdeki X'in izdüşümü de l' çizgisi üzerinde olmalıdır.

Figure 2. Epipolar geometry (Hartley & Zisserman, 2004); a) C and C' represent two different camera centers. These camera centers lie on the same plane with point X, which exists in three-dimensional space. This plane also includes the projections of point X in two images, represented by points x and x', and is denominated as π , b) A point in the image, denoted as x, corresponds to a ray in 3D space originating from the first camera center C. This ray translates to a line denoted as l' in the second image. The point X in the three-dimensional space must lie on this ray; therefore, the projection of X in the second image should also be on line l'.

2.2. Yöntem

2.2. Method


Su kütlesi tespiti iş akışı sırası ile; nokta bulutu filtreleme ve nokta bulutlarından yerel geometrik öznitelik çıkarma, süper-piksel segmentasyonu ve sınıflandırma ve çıkarılan su kütlesi sınırlarının düzeltilmesi olmak üzere üç adımdan oluşmaktadır. Nokta bulutu filtreleme ve nokta bulutlarından yerel geometrik öznitelik çıkarma adımı, su kütlesi tespiti için kullanılacak yerel geometrik özniteliklerin çıkarılması amacıyla nokta bulutu verileri işlenmektedir. Süper-piksel segmentasyonu ve sınıflandırma aşamasında, yerel geometrik özelliklerden türetilen öznitelik haritaları ile spektral bilgi birleştirilerek birleşik çok bantlı bir görüntü oluşturulur. Daha sonra bu çok bantlı görüntüye süper-piksel segmentasyonu uygulanır ve RO sınıflandırıcısı kullanılarak görüntü su ve su olmayan sınıflara ayrılır. Çıkarılan su kütlesi sınırlarının düzeltilmesi adımı, tespit edilen su kütlesi sınırlarının doğruluğunu ve arazi gerçeği ile uyumunu artırmak için bu sınırların rafine edilmesi; adımlarından oluşmaktadır.

2.2.1 Nokta bulutu filtreleme

2.2.1 Point cloud filtering

Üretilen nokta bulutları, zemin ve zemin üstü noktalar olarak LAStools yazılımı ile filtrelenmiştir. LAStools yazılımı, zemin çıkarımı için ilk tohum noktalarından oluşturulan bir Üçgenleştirilmiş Düzensiz Ağ

(Triangulated Irregular Network, TIN) yinelemeli olarak yoğunlaştırılmasına dayanan Aşamalı TIN Yoğunlaştırma (Progressive TIN Densification, PTD) Axelsson (2000) algoritmasını kullanmaktadır. PTD yönteminde ilk adım, kullanıcı tarafından belirlenen bir grid üzerinde çekirdek noktaların seçilmesidir. Bu noktalar genellikle grid hücrelerindeki en düşük yükseklik değerine sahip noktalar olarak belirlenir. Grid boyutu, çalışma alanındaki maksimum bina boyutuna göre seçilir ki bu, modelin doğruluğu ve hassasiyeti için önemli bir parametredir. Bu çekirdek noktaları ile oluşturulan başlangıç TIN modeli, iteratif bir şekilde sıklaştırılır. Her iterasyon için TIN'in yoğunlaştırılmasında, yoğunlaştırma parametreleri, TIN'e ait zemin noktaları kullanılarak belirlenir. Eğer bir P noktası, B_1 , B_2 ve B_3 noktaları tarafından oluşturulan TIN yüzeyine göre hem açı (α_1 , α_2 , α_3) hem de mesafe değerleri, belirlenen yoğunlaştırma parametrelerinin sınırlarında ya da altındaysa, bu nokta TIN'e eklenir (Şekil 3).



Şekil 3. PTD algoritmasının çalışma prensibi (Axelsson, 2000); a) Zemin ve zemin üstü noktaların ayrıştırılması, b) Çekirdek noktalarından üretilen TIN ve c) Yoğunlaştırılmış TIN.

Figure 3. The working principle of the PTD algorithm (Axelsson, 2000); a) Separation of ground and above-ground points, b) Generation of TIN from seed points, and c) Densification of the TIN.

Nokta bulutu filtreleme işleminden sonra, zemin üstü nokta yükseklikleri, zemin olmayan noktaların çıkarılmasıyla oluşan boşlukları doldurmak için zemin seviyesine indirilmiştir. Boşlukları doldurulan nokta bulutu kullanılarak, her çalışma alanı için 1 m GSD'li bir SAM oluşturulmuştur. Nokta bulutlarından çıkarılan yerel geometrik öznitelikler kullanarak ikili sınıflandırma yapabilmek için, yalnız zemin ve su kütleleri arasındaki etkileşimi anlamak için filtreleme işlemleri gereklidir. Filtreleme, özellikle kanopi penetrasyonunun olmaması nedeniyle fotogrametrik nokta bulutları için ve Çalışma Alanı-4 gibi kentsel alanlardaki LiDAR nokta bulutları için oldukça önemlidir. Zemin filtreleme işleminden sonra, yalnız arazi yüzeyi nokta bulutlarında boşluklar oluşabilmektedir; bu boşluklar, kesintisiz bir yüzey oluşturmak için uygun yükseklik değerleriyle doldurulmalıdır. Bu amaçla, zemin olmayan noktaların yüksekliklerini yaklaşık bir zemin yüzey yüksekliğine indirerek 3B nokta bulutundaki boşlukları dolduran *PCFill* algoritması MATLAB ortamında oluşturulmuştur (Tablo 2). Girdi olarak zemin nokta bulutu ve GSD bilgilerini alan algoritma, doldurulmuş nokta bulutunu çıktı olarak vermektedir.


Başlangıçta, algoritma boşlukları tespit etmek için nokta bulutundan bir alfa şekli (alpha shape) oluşturur ve ilgili boşluk için yerüstü noktalarını tespit eder. Daha sonra algoritma, zemin nokta bulutu verileri üzerinde bir enterpolasyon uygulayarak bu noktalar için yeni yükseklik değerleri belirler. Bu süreç, özniteliklerin hesaplanması sırasında zemin olmayan noktaların çıkarılması nedeniyle boşluklar etrafında yoğunlaşan kenar etkilerini ortadan kaldırır ve daha doğru bir topografik karakterizasyon sağlar (Şekil 4).

Tablo 2. PCFill algoritması**Table 2.** PCFill algorithm

```

1: işlem PCFill(NoktaBulut, GSD, ExtrapTercihi, AlphaYarıçap, AlphaEşik)
2: Eğer AlphaEşik ya da AlphaYarıçap tanımlı değilse:
3:   shp ← alphaShape(NoktaBulut.x, NoktaBulut.y)
4: Aksi takdirde:
5:   shp ← alphaShape(NB.x, NB.y, AlphaYarıçap, 'RegionThreshold', AlphaEşik)
6: Son
7:
8: GSD/2'yi hgsd olarak tanımla
9: X ve Y gridini belirle
10: Zgrid değerlerini interpolasyonla belirle
11: NaN değerlere sahip GridPoints'ları sil
12: shp içinde olmayan GridPoints'ları Fillers olarak kaydet
13: NoktaBulut ve EklenenNoktalar'ı birleştirerek DoldurulmuşNoktaBulutunu elde et
14:
15: Eğer tek çıktı isteniyorsa:
16:   çıktı ← DoldurulmuşNoktaBulut
17: Eğer çift çıktı isteniyorsa:
18:   çıktı ← DoldurulmuşNoktaBulut, EklenenNoktalar
19: Son
20: işlemi bitir

```



Şekil 4. Zemin üstü noktaların filtrelenmesi ve boşlukların doldurulması; a) Zemin üstü noktalar (kırmızı), b) Zemin noktaları, c) Doldurulmuş nokta bulutu.

Figure 4. Filtering of above-ground points and filling of gaps; a) Above-ground points (red), b) Ground points, c) Filled point cloud.

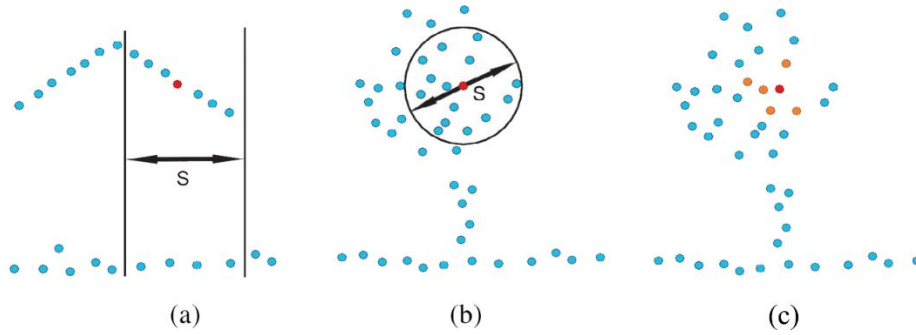
Bu çalışmada, 3B yapı tensörü nokta bulutlarından 3B geometrik öznitelikler hesaplamak için kullanılmıştır. 3B yapı tensörü, özdeğerler kullanarak yerel 3B şekli bir 3B elipsoit olarak temsil eder. 3B yapı tensörü (1) denkleminde göre hesaplanır. Burada \bar{X} komşuluğun geometrik merkezinin koordinatlarını, X_i ($i \in \{1,2,\dots,k\}$) komşu noktaların koordinatlarını, k komşu sayısını temsil etmektedir. 3B yapı tensörü S 'in $\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq 0$ olmak üzere üç adet özdeğeri λ_1 , λ_2 ve λ_3 bulunmaktadır. Bu özdeğerler $e_i = \lambda_i / \Sigma \lambda$ ($i \in \{1,2,3\}$) şeklinde normalize edilerek öznitelik çıkarımında kullanılmıştır.

$$S = \frac{1}{k+1} \sum_{i=0}^k (X_i - \bar{X})(X_i - \bar{X})^T \quad (1)$$

3B yapı tensörü ile nokta bulutlarından geometrik özniteliklerin çıkarılması; yerel komşulukların oluşturulması, optimal komşuluk boyutunun hesaplanması ve belirlenen komşuluk boyutu kullanılarak yerel özniteliklerin hesaplanması aşamalarından oluşur.

Nokta bulutları, genellikle her bir noktanın X, Y ve Z koordinatlarını içeren düzensiz bir liste şeklinde tanımlanır. Dolayısı ile mekânsal topolojik ilişkilerin hızlı ve etkili bir şekilde oluşturulabilmesi için uzay bölütleme algoritmalarına ihtiyaç duyulmaktadır. Bu çalışmada, uzay bölütleme algoritmaları arasında en yaygın olarak kullanılan Kd-tree (Bentley, 1975) algoritması kullanılmıştır. Kd-tree, k-boyutlu uzay içerisinde mekânsal ilişkileri verimli bir biçimde sorgulayabilmek amacıyla tasarlanmış bir veri yapısıdır. Sıklıkla arama ve sıralama operasyonlarında tercih edilir. Her düğümü, k-boyutlu bir noktayı temsil eder ve ağaç, her seviyesinde farklı bir boyut üzerinden alt ağaçlara bölünür. Kd-tree, belirli bir nokta için, işaretçiler aracılığıyla veri setini hızlıca tarayarak en yakın düğüme erişim sağlar. Bu sayede, bir noktanın komşularını hiçbir topolojik ilişkinin olmadığı nokta bulutlarında hızlı ve verimli bir şekilde bulmak mümkün olmaktadır.

Nokta bulutlarında, mekânsal ilişkilerin tanımlanmasından sonraki aşamada komşuluk türlerinin tanımlanması gerekmektedir. Komşuluk tipleri, silindirik, küresel ve en yakın komşuluk olmak üzere üçe ayrılabilir (Şekil 5). Öznitelik çıkarımı için küresel komşuluk tipi silindirik ve en yakın komşuluk tiplerine kıyasla daha tutal bir mekânsal bağlam sağladığı için çalışmada tercih edilmiştir.



Şekil 5. Komşuluk tipleri; a) Silindirik komşuluk, b) Küresel komşuluk ve c) En yakın komşuluk (Guo vd., 2015).

Figure 5. Neighborhood types; a) Cylindrical neighborhood, b) Spherical neighborhood, and c) Nearest neighborhood (Guo et al., 2015).

Seçilen komşuluk boyutu, öznitelik haritalarının kalitesi üzerinde doğrudan bir etkiye sahiptir. Daha büyük bir komşuluk boyutu, daha düzgün öznitelikler üretirken, daha küçük bir komşuluk boyutu daha fazla gürültülü öznitelikler üretir (Pauly vd., 2003; Guo vd., 2015; Weinmann vd., 2015). Bu nedenle, öznitelik çıkarımından önce, optimal bir komşuluk boyutu seçimi işlemi gereklidir. Bu çalışmada, nokta bulutlarından öznitelik çıkarımında en önemli parametrelerden biri olan optimal komşuluk boyutunu belirlemek amacı ile Weinmann vd. (2015) tarafından önerilen Eigen-entropi (7) tabanlı teknik benimsenmiştir.

Toplamda sekiz yerel geometrik öznitelik olan doğrusallık L_λ (2), düzlemsellik P_λ (3), saçılma S_λ (4), omnivaryans O_λ (5), anizotropi A_λ (6), eğrilik değişikliği C_λ (7) hesaplanmıştır, Eigen-entropi E_λ (8), ve özdeğerler toplamı \sum_λ (9).

$$L_\lambda = \frac{e_1 - e_2}{e_1} \quad (2)$$

$$O_\lambda = \sqrt[3]{e_1 e_2 e_3} \quad (3)$$

$$P_\lambda = \frac{e_2 - e_3}{e_1} \quad (4)$$

$$A_\lambda = \frac{e_1 - e_3}{e_1} \quad (5)$$

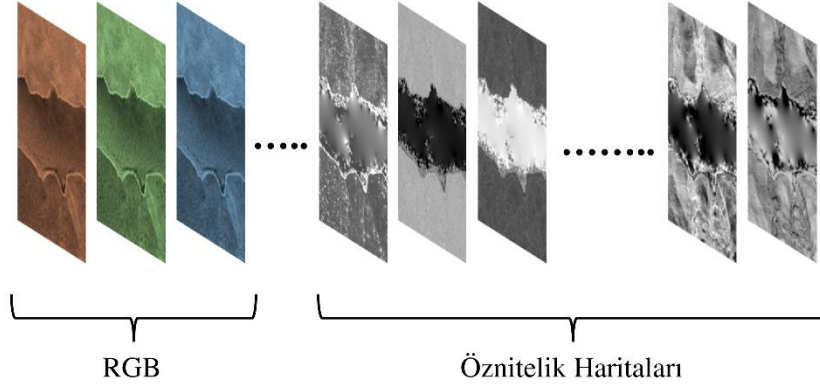
$$S_\lambda = \frac{e_3}{e_1} \quad (6)$$

$$C_\lambda = \frac{e_3}{e_1 + e_2 + e_3} \quad (7)$$

$$E_{\lambda} = -\sum_{i=1}^3 e_i \ln(e_i) \quad (8)$$

$$\Sigma_{\lambda} = e_1 + e_2 + e_3 \quad (9)$$

Daha sonra, her nokta için çıkarılan öznelikler, her bir bandın bir özneliği temsil ettiği 1 m GSD'li çok bantlı bir raster'a dönüştürülmüştür. Öznelik haritaları, ilgili çalışma alanının spektral bilgileri ile birleştirilmiştir (Şekil 6).



Şekil 6. Öznelik haritalarının RGB bantlar ile birleştirilerek çok bantlı öznelik haritalarının üretimi.

Figure 6. Production of multi-band feature maps by combining feature maps with RGB bands.

Geleneksel piksel tabanlı görüntü işleme algoritmaları, genellikle yüksek çözünürlüklü görüntüleri etkili bir şekilde kullanamaz ve nesne ilişkilerini göz ardı eder. Bu durum işleme süresi ve sınıflandırma doğruluğunda kısıtlamalara yol açar (Kavzoğlu & Tonbul, 2018; Song vd., 2020). Bu sorunu ele almak için, sınıflandırma performansını artırmak ve karmaşıklığı azaltmak amacıyla su kütlesi çıkarımı için bir Rastgele Orman modeli eğitilmeden önce birleştirilmiş öznelik haritalarından anlamlı segmentler oluşturmak üzere SLIC yöntemi kullanılmıştır. K-ortalama kümeleme yaklaşımına dayanan SLIC süper-piksel segmentasyon algoritması, yaklaşık süper-piksel boyutunu (k) tek bir parametre olarak kullanarak etkili bir şekilde süper-pikseller üretir ve belirlenen aralıklar S (10) üzerindeki örnekler aracılığıyla küme merkezlerini belirler (Achanta vd., 2012).

$$S = \sqrt{N_{pixel}/k} \quad (10)$$

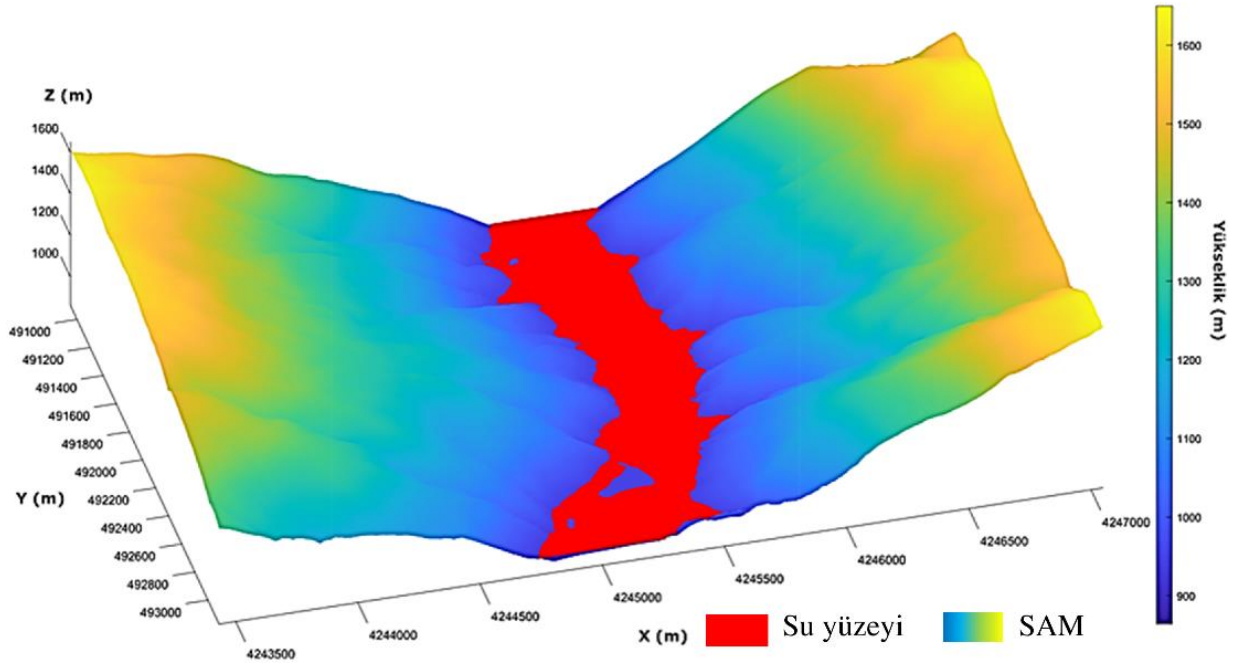
N_{pixel} , görüntüdeki piksel sayısını, k ise yaklaşık süper-piksel boyutunu temsil eder. Küme merkezleri, kenar ve gürültü içeren pikselli önlemek için 3×3 komşuluk içinde en düşük gradyanlı pozisyona kaydırılır (Achanta vd., 2012). SLIC algoritması, süper-piksel görüntüler oluşturmak için S parametresini kullanır. 5 ile 50 piksel arasında değişen S değerleri ile yapılan deneysel testler sonucunda, 20 piksel S değerinin daha uniform ve kompakt süper-piksel segmentleri ürettiği tespit edilmiştir. Sonuç olarak, tüm çalışma alanları için süper-piksel segmentasyon aşamasında 20 piksel S parametresi kullanılmıştır.

Su kütleleri sınıflandırmasında temel olarak iki sınıf bulunmaktadır: su ve su olmayan. Çalışmada, Rastgele Orman sınıflandırıcısı, yüksek boyutlu veriyi işleyebilme, hız ve aşırı uyuma dirençli olma özellikleri nedeniyle seçilmiştir (Belgiu & Drăgut, 2016; Roelens vd., 2018). Bu sınıflandırıcı, tahmin doğruluğunu artırmak ve korelasyonu azaltmak için bir torbalama yaklaşımından faydalanan çoklu karar ağaçlarını kullanır (Breiman, 2001). Su kütleleri ve su olmayan alanları sınıflandırmak için 500 ağaçlı bir RO sınıflandırıcısı kullanılmış ve eğitim, vektör su kütleleri sınırlarından türetilen öznelik haritaları ve karşılık gelen ikili referans verilerinin alt kümeleri üzerinde gerçekleştirilmiştir. Öznelik haritaları, SLIC süper-piksel algoritması kullanılarak segmente edilmiş ve eğitim verilerindeki her öznelik için tüm süper-piksel segmentlerinin ortalama değerleri hesaplanmıştır. Bu segmentler, RO sınıflandırıcısı eğitim fazı sırasında girdi olarak kullanılmış ve eğitilen RO modeli, kalan öznelik haritalarındaki her piksel için sınıfı tahmin etmek üzere uygulanmıştır.

2.2.3 Su kütlesi sınırlarının düzeltilmesi

2.2.3 Water body boundary correction

Bu aşamada, RO sınıflandırma sonuçlarından elde edilen ikili görüntüler, morfolojik işlemler uygulanarak su kütlesi ile kara arasındaki düzensizlikler ve bazı çelişkili küçük pikseller ortadan kaldırılarak düzeltilmiştir. Nokta bulutlarında yüksek saçılım ve veri kaybı nedeniyle su yüzeylerinden güvenilir yükseklik bilgisi almak mümkün değildir (Legleiter, 2012; Bandini vd., 2020). Ancak, bu tutarsızlıklar su kütlelerinin kıyılarında karşılaşmamaktadır. Bu nedenle, su kütlesi sınırlarının düzeltilmesi için su yüzey yüksekliklerinin su kütlelerinin kıyı çizgisinden alınması kararlaştırılmıştır. Bu amaçla, çıkarılan su kütlesi sınırlarına karşılık gelen SAM yükseklikleri toplanmıştır. Doğru su yüzey yüksekliğini elde etmek için bu yüksekliklerle bir yükseklik histogramı oluşturulmuştur. Daha sonra, bu yükseklik histogramının tepe değeri hesaplanmış ve su yüzey yüksekliği olarak kullanılmıştır. Elde edilen su yüzey yüksekliği ve su kütlesi sınırları ile sahte bir su yüzeyi girdi raster boyutlarında boş bir görüntüde su kütlesi sınırları içinde kalan piksellere tespit edilen su yüksekliğinin yazılması ile oluşturulmuştur. Akarsu su kütlelerinde bu işlem, tespit edilen su kütlesi sınırları boyunca belirli aralıklarla (çalışmada 100 m kesit aralığı kullanılmıştır) yerleştirilen kesit noktalarından elde edilen su yüzey yüksekliklerinin akış yönü boyunca enterpole edilmesi ile oluşturulmuştur. Oluşturulan bu sahte su yüzeyi daha sonra su kütlesi sınırlarının düzeltilmesi için kullanılmıştır. Sahte su yüzeyinin SAM ile kesişiminden elde edilen yeni sınırlar düzeltilmiş su kütlesi sınırları olarak kabul edilmiştir (Şekil 7).



Şekil 7. Sınıflandırma sonucu elde edilen su kütlesi sınırlarından üretilen sahte su yüzeyi

Figure 7. Synthetic water surface generated from the extracted water body boundaries.

2.2.4 Doğruluk ölçütleri

2.2.4 Accuracy metrics

Sınıflandırma sonuçlarının piksel tabanlı doğruluk analizinde, doğru pozitif (DP) hem sınıflandırma haritasında hem de referans haritasında bulunan pikselleri, yanlış negatif (YN) referans haritasında bulunup sınıflandırma sonucunda bulunamayan pikselleri ve yanlış pozitif (YP) sınıflandırma haritasında bulunan fakat referans haritasında olmayan pikselleri temsil etmektedir (Rutzinger vd., 2009). Piksel tabanlı doğruluk değerlendirme aşamasında, F-Skoru, Hassasiyet, Duyarlılık ve Kalite metrikleri hesaplanmıştır (11, 12).

$$\text{Hassasiyet} = \frac{DP}{DP+YP} \quad \text{Duyarlılık} = \frac{DP}{DP+YN} \quad \text{Kalite} = \frac{DP}{DP+YN+YP} \quad (11)$$

$$\text{F-Skoru} = \frac{2 \times \text{Hassasiyet} \times \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}} \quad (12)$$

3. Bulgular ve tartışma

3. Results and discussion

Bu bölümde, önerilen yaklaşım ile su kütlesi tespitinde elde edilen sonuçlar sunulmaktadır ve önerilen yaklaşımın uygulanmasıyla elde edilen temel bulgular ve kazanımlar vurgulanmaktadır.

3.1. Öznitelik haritalarının rastgele orman sınıflandırma başarımı

3.1. Classification performance of random forest using feature maps

İlk olarak, RO sınıflandırıcısının performansı analiz edilmiştir. Tablo 3, F-Skoru, Hassasiyet, Duyarlılık ve Kalite metrikleri kullanılarak çıkarılan su sınırları için doğruluk değerlendirme sonuçlarını sunmaktadır. Sonuçları iyileştirmek için, tüm ikili sınıflandırma görüntülerine morfolojik bir açma (morphological opening) işlemi uygulanmıştır, bu da 500 pikselden daha küçük yanlış sınıflandırılmış alanların çıkarılmasına yardımcı olmaktadır.

Tablo 3. Öznitelik haritalarının rastgele orman sınıflandırma doğrulukları
Table 3. Accuracy of random forest classification on feature maps

	F-Skoru	Hassasiyet	Duyarlılık	Kalite
Çalışma alanı-1	0.9231	0.8959	0.9520	0.9783
Çalışma alanı-2	0.8782	0.8701	0.8860	0.9162
Çalışma alanı-3	0.9190	0.8880	0.9530	0.9046
Çalışma alanı-4	0.6912	0.7701	0.6269	0.9007
Çalışma alanı-1 akarsu	0.7368	0.6266	0.8941	0.5620

Tablo 3, önerilen yaklaşımın, özellikle yakındaki bitki örtüsünden düşük derecede etkilenen su kütleleri nedeniyle, Çalışma Alanı-1, Çalışma Alanı-2 ve Çalışma Alanı-3 gibi çoğu çalışma alanında yüksek sınıflandırma performansı elde ettiğini göstermektedir (Şekil 8). Çalışma Alanı-4, önerilen yaklaşımın LiDAR verilerine uygunluğunu test etmek için seçilmiştir ve doğruluk analizi sonuçları, önerilen yaklaşımın LiDAR verilerine de başarıyla uygulanabileceğini göstermektedir, ancak F-Skoru yetersiz eğitim verisi nedeniyle daha düşüktür. Çalışma, önerilen yaklaşımın farklı sensörlerden ve farklı ölçeklerde elde edilen nokta bulutlarından su kütlelerini doğru bir şekilde tespit edebileceğini göstermektedir. Çalışma Alanı-1 Akarsu verileri için önerilen segmentasyon yöntemi göreceli olarak iyi sonuçlar vermiştir. Ancak, çalışma alanındaki nehir, veri toplama zamanına bağlı olarak su kütlelerinin üzerine gölgeler oluşturan yüksek tepelerle çevrilidir. SfM bir görüntü tabanlı algoritma olduğu için, bu gölgeli bölgelerden doğru yükseklik verileri çıkaramaz. Bu sorun, öznitelik çıkarma işlemine de doğrudan etki eder, böylece sınıflandırma işleminin etkinliği azalır. Başka bir dezavantaj, veri toplama sırasında nehrin yoğunlukla kurumuş olması ve görünür zemin parçalarının olmasıdır.

3.2. Su kütlelerinde sınır düzeltme işlemi

3.2. Boundary correction on water body boundaries

Tablo 4, düzeltilmiş su kütlelerinin doğruluk değerlendirmesini ve sınıflandırma sonuçları üzerinde elde edilen iyileştirmeleri göstermektedir. Sınır düzeltme işlemi kullanılarak, çıkarılan su kütleleri sınırlarının iyileştirilmesi mümkündür. Bu sayede SAM üzerindeki gerçek su kütleleri sınırlarına daha kesin bir yaklaşım sağlanabilir.

Çalışma Alanı-1 için, F-Skoru, Kesinlik ve Duyarlılık ölçütlerinde, sınıflandırma doğruluk değerlendirmesi sonuçlarıyla kıyaslandığında %1.59'dan %5.85'e kadar bir artış gözlemlenmiştir. Sınır düzeltme işlemi, F-Skoru, Kesinlik ve Duyarlılık ölçütlerini yükseltirken, Kalite ölçütünde %0.29 oranında bir düşüş yaşanmıştır. Çalışma Alanı-2'de, düzeltilmiş su kütlesi sınırları, yer yüzeyi ile olan sınırlarıyla yüksek derecede örtüşmektedir. Sınır düzeltme işlemi, eksik su kütlesi sınırlarını başarıyla tamamlayabilmiştir. Çalışma Alanı-2'nin açık topografik yapısı ve nokta bulutu verisinde su kütlesi sınırlarında gözlemlenen yükseklik değerlerinin tutarlı olması, bu başarımın elde edilmesinde önemli bir rol oynamıştır. Ancak, Çalışma Alanı-3 için su kütlesi sınırlarında gözlemlenen yükseklik değerleri, yoğun bitki örtüsü ve SfM nokta bulutlarının doğası nedeniyle tutarsızdır. Bu durum, sınır düzeltme işleminin belirli bölgelerde yetersiz kalmasına ve F-

Skoru, Duyarlılık ve Kalite ölçütlerinde %12'ye varan düşüşe neden olmuştur. Ancak, Kesinlik ölçütünde %10'luk bir iyileşme gözlemlenmiştir (Şekil 9).



Şekil 8. Sınıflandırma sonucu elde edilen su kütlesi sınırları. a) Çalışma alanı-1, b) Çalışma alanı-2, c) Çalışma alanı-3, d) Çalışma alanı-4 ve d) Çalışma alanı-1 akarsu.

Figure 8. Water body boundaries obtained as a result of classification. a) Study area-1, b) Study area-2, c) Study area-3, d) Study area-4, and e) Study area-1 river.

Tablo 4. Düzeltilmiş su kütlesi sınırlarının doğruluk analizi

Table 4. Accuracy analysis of corrected water body boundaries

	F-Skoru		Hassasiyet		Duyarlılık		Kalite	
Çalışma alanı-1	0.9576	3.74%	0.9484	5.85%	0.9670	1.59%	0.9754	-0.29%
Çalışma alanı-2	0.9991	13.77%	0.9982	14.72%	1.0000	12.82%	0.9859	7.61%
Çalışma alanı-3	0.9001	-2.09%	0.9814	10.51%	0.8313	-12.77%	0.8887	-1.76%
Çalışma alanı-4	0.9753	41.1%	0.9772	25.71%	0.9973	56.72%	0.9746	8.2%
Çalışma alanı-1 akarsu	0.8851	20.12%	0.8656	38.15%	0.9054	1.27%	0.7429	32.19%



Şekil 9. Sınır düzeltme işlemi sonucu elde edilen su kütleleri sınırları. a) Çalışma alanı-1, b) Çalışma alanı-2, c) Çalışma alanı-3, d) Çalışma alanı-4 ve d) Çalışma alanı-1 akarsu.

Figure 9. New water body boundaries obtained after the boundary correction process. a) Study area-1, b) Study area-2, c) Study area-3, d) Study area-4, and e) Study area-1 river.

3.3. Tartışma

3.3. Discussion

Bu çalışmada, HGM ve TKGM gibi kurumlar tarafından sıklıkla kullanılan sayısal hava kameralarından elde edilen verilerle, su kütlelerinin otomatik olarak tespit edilmesi ve sınır düzeltme işlemleri gerçekleştirilmiştir. Modern bilgisayarla görme teknikleri ve SfM algoritmaları sayesinde, manuel işlemlere olan ihtiyaç büyük ölçüde azaltılmıştır. MATLAB ortamında geliştirilen bu yaklaşım, farklı topoğrafik ve çevresel koşullara sahip alanlarda etkin bir şekilde uygulanmıştır. Çalışmada, yerel geometrik özniteliklerin su kütlelerinin tespitinde etkili olduğu gösterilmiştir. Ancak, LiDAR ve fotogrametrik yöntemlerle üretilen nokta bulutlarında, özellikle su yüzeyine ait yükseklik bilgilerinde tutarsızlıklar ve hatalar gözlemlenmiştir. Bu, sınıflandırma ve modelleme doğruluklarını sınırlayan bir faktör olarak ortaya çıkmıştır.

Çalışmada, veri işleme aşamasında bazı zorluklar ile karşılaşmıştır. Özellikle Kd-tree algoritması, yüksek yoğunluklu nokta bulutlarını işlerken zaman ve bellek yetersizliği sorunlarına yol açmıştır. Bu sorunu çözmek için, çalışma alanı 500×500 m'lik parçalara bölünmüş ve paralel işleme yöntemi kullanılmıştır. Öznitelik çıkarımı için bu yaklaşım, işlem süresini kısaltmış ve bellek yetersizliği sorununu gidermiştir. Ancak, nokta bulutlarından geometrik özniteliklerin çıkartılması zaman açısından maliyetli olmaya devam etmektedir. Sınıflandırma aşamasında, durağan su kütlelerinin tespiti genellikle başarılı olmuş fakat sık bitki örtüsü, gölge, parlama ve saçılım gibi pek çok olumsuz etkinin bir araya geldiği bölgelerde sınıflandırma doğruluğunda belirgin düşüşler gözlemlenmiştir.

4. Sonuçlar

4. Conclusions

Bu çalışmada, LiDAR ve fotogrametrik yöntemler ile elde edilen nokta bulutları üzerinde 3B yapı tensörü kullanarak üretilen öznetelik haritalarının su kütlelerinin tespitinde kullanım olanaklarını araştırmaktadır. Çalışma alanlarının ortofoto görüntüleri ve oluşturulan öznetelik haritalarına entegre edilmiş ve bu sayede çok bantlı öznetelik haritaları elde edilmiştir. Elde edilen bu haritalar, SLIC süper piksel segmentasyon tekniği ile işlenmiş ve RO sınıflandırıcısı kullanılarak su kütleleri tespit edilmiştir. Önerilen yaklaşım, literatürde sıkça kullanılan Normalize Edilmiş Fark Vejetasyon İndeksi (Normalized Difference Vegetation Index, NDVI) ve Normalize Edilmiş Fark Su İndeksi (Normalized Difference Water Index, NDWI) gibi indisler yerine, yerel geometrik özneteliklerin su kütlelerini tespitindeki etkinliğini araştırmaktadır. Geliştirilen bu yaklaşım, farklı algılayıcılar ve ölççeklerden elde edilen nokta bulutları için genelleştirilebilir bir çerçeve sunmaktadır.

Yalnızca yüzey öznetelikleri hedeflenerek, oluşabilecek boşluklar doldurulmuş ve spektral bantlar entegre edilerek öznetelik haritaları zenginleştirilmiştir. RO sınıflandırıcısı, her bir çalışma alanına özgü olarak 500 ağaç ile eğitilmiş ve morfolojik operasyonlar ile hatalı sınıflandırmalar düzeltilmiştir. Sınıflandırma işlemi ile tespit edilen su kütleleri sınırlarının doğruluk analizi F-Skoru üzerinden değerlendirildiğinde, Çalışma Alanı-1 için F-Ölçütü: %85.7, Çalışma Alanı-1 Akarsu için %76.6, Çalışma Alanı-2 için %93.7, Çalışma Alanı-3 için %94.9, ve Çalışma Alanı-4 için %73.6, olarak elde edilmiştir.

Elde edilen sonuçlar, özellikle durağan su kütlelerinin LiDAR veya fotogrametrik nokta bulutu fark etmeksizin başarılı bir şekilde tespit edilebildiğini göstermektedir; ancak akarsu kütlelerinin tespitinde mevsimsel nedenlerden dolayı su seviyesinin düşüklüğünün akarsu yatağında açığa çıkardığı kompleks morfolojik özellikler hem de yüksek bitki örtüsü kaynaklı bazı zorluklar ile karşılaşmıştır. Gelecekte, öznetelik çıkarım süreçlerinin optimizasyonu hedeflenmekte ve bu sayede yaklaşımın daha geniş çalışma alanlarına adapte edilebilirliği üzerinde çalışılacaktır.

Teşekkür

Acknowledgement

Bu çalışma, HGM tarafından çağrıya çıkılan ve tamamlanan “Su Kütlelerinin Sayısal Yüzey Modeli ve Sayısal Arazi Modeli Otomatik Hidro-Düzleştirme” adlı proje kapsamında gerçekleştirilmiştir. Geliştirilen yöntemin doğrulamasının yapılması amacıyla kullanılan LiDAR veri setini sağlayan BİMTAŞ A.Ş.’ye teşekkürlerimizi sunarız.

Yazar katkısı

Author contribution

Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim Dalında Fevzi KARSLI danışmanlığında yürütülen “Su Kütlelerinin Sayısal Yüzey ve Arazi Modellerinden Otomatik Olarak Çıkarılması ve Düzeltmesi” isimli Doktora Tezinden üretilen bu çalışmada; Samed Özdemir ve Fevzi KARSLI veri toplama, metodoloji, analiz ve yazım aşamalarına eşit derecede katkıda bulunmuştur.

Etik beyanı

Declaration of ethical code

Bu çalışmada, “Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesi” kapsamında uyulması gerekli tüm kurallara uyulduğunu, bahsi geçen yönergenin “Bilimsel Araştırma ve Yayın Etiğine Aykırı Eylemler” başlığı altında belirtilen eylemlerden hiçbirinin gerçekleştirilmediğini taahhüt ederiz.

Bu makalenin yazarları, bu çalışmada kullanılan materyal ve yöntemlerin etik kurul izni ve / veya yasal-özel izin gerektirmediğini beyan etmektedir.

Çıkar çatışması beyanı

Conflicts of interest

Yazarlar herhangi bir çıkar çatışması olmadığını beyan eder

Kaynaklar*References*

- Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P., & Süstrunk, S. (2012). SLIC superpixels compared to state-of-the-art superpixel methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34(11), 2274–2281. <https://doi.org/10.1109/TPAMI.2012.120>
- Axelsson, P. (2000). DEM generation from laser scanner data using adaptive TIN models. *International Archives of Photogrammetry and Remote Sensing*, 33, 110–117.
- Bandini, F., Sunding, T. P., Linde, J., Smith, O., Jensen, I. K., Köppl, C. J., Butts, M., & Bauer-Gottwein, P. (2020). Unmanned Aerial System (UAS) observations of water surface elevation in a small stream: Comparison of radar altimetry, LIDAR and photogrammetry techniques. *Remote Sensing of Environment*, 237, 111487. <https://doi.org/10.1016/j.rse.2019.111487>
- Belgiu, M., & Drăgut, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Bentley, J. L. (1975). Multidimensional binary search trees used for associative searching, *Communications of the ACM*, 18(9) 509-517.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Canaz, S., Karlı, F., Guneroglu, A., & Dihkan, M. (2015). Automatic boundary extraction of inland water bodies using LiDAR data. *Ocean and Coastal Management*, 118, 158–166. <https://doi.org/10.1016/j.ocecoaman.2015.07.024>
- Guo, B., Huang, X., Zhang, F., & Sohn, G. (2015). Classification of airborne laser scanning data using JointBoost. *ISPRS Journal of Photogrammetry and Remote Sensing*, 100, 71–83. <https://doi.org/10.1016/j.isprsjprs.2014.04.015>
- Hartley, R. & Zisserman, A. (2004). *Multiple view geometry in computer vision (2nd Ed.)*. Cambridge University Press.
- Kavzoglu, T., & Tonbul, H. (2018). An experimental comparison of multi-resolution segmentation, slic and k-means clustering for object-based classification of vhr imagery. *International Journal of Remote Sensing*, 39(18), 6020–6036. <https://doi.org/10.1080/01431161.2018.1506592>
- Legleiter, C. J. (2012). Remote measurement of river morphology via fusion of LIDAR topography and spectrally based bathymetry, *Earth Surface Processes and Landforms*, 37(5), 499-518.
- Mazzoleni, M., Paron, P., Reali, A., Juizo, D., Manane, J., & Brandimarte, L. (2020). Testing UAV-derived topography for hydraulic modelling in a tropical environment. *Natural Hazards*, May. <https://doi.org/10.1007/s11069-020-03963-4>
- Pauly, M., Keiser, R., & Gross, M. (2003). Multi-scale feature extraction on point-sampled surfaces. *EUROGRAPHICS 2003*, 22(3).
- Pech-May, F., Aquino-Santos, R., & Delgadillo-Partida, J. (2023). Sentinel-1 SAR images and deep learning for water body mapping. *Remote Sensing*, 15(12), 3009.
- Roelens, J., Höfle, B., Dondeyne, S., Van Orshoven, J., & Diels, J. (2018). Drainage ditch extraction from airborne LiDAR point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing*, 146(May), 409–420. <https://doi.org/10.1016/j.isprsjprs.2018.10.014>
- Rutzinger, M., Rutzinger, M., Rottensteiner, F., Rottensteiner, F., & Pfeifer, N. (2009). A comparison of evaluation techniques for building extraction from airborne laser scanning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2(1), 11–20. <https://doi.org/10.1109/JSTARS.2009.2012488>
- Shaker, A., Yan, W. Y., & LaRocque, P. E. (2019). Automatic land-water classification using multispectral airborne LiDAR data for near-shore and river environments. *ISPRS Journal of Photogrammetry and Remote Sensing*, 152(July 2018), 94–108. <https://doi.org/10.1016/j.isprsjprs.2019.04.005>

- Smeckaert, J., Mallet, C., David, N., Chehata, N., & Ferraz, A. (2013). Large-scale classification of water areas using airborne topographic LiDAR data. *Remote Sensing of Environment*, 138, 134–148. <https://doi.org/10.1016/j.rse.2013.07.004>
- Song, S., Liu, J., Liu, Y., Feng, G., Han, H., Yao, Y., & Du, M. (2020). Intelligent object recognition of urban water bodies based on deep learning for multi-source and multi-temporal high spatial resolution remote sensing imagery. *Sensors*, 20(2), 397. <https://doi.org/10.3390/s20020397>
- Toscano, G. J., Gopalam, U. K., & Devarajan, V. (2014). Auto hydro break line generation using lidar elevation and intensity data. *ASPRS 2014 Annual Conference: Geospatial Power in Our Pockets, Co-Located with Joint Agency Commercial Imagery Evaluation Workshop, JACIE 2014, 2009*.
- Tymków, P., Józków, G., Walicka, A., Karpina, M., & Borkowski, A. (2019). Identification of water body extent based on remote sensing data collected with unmanned aerial vehicle. *Water (Switzerland)*, 11(2). <https://doi.org/10.3390/w11020338>
- Vetter, M., Hofle, B., & Rutzinger, M. (2009). Water classification using 3D airborne laser scanning point clouds. *Vermessung & Geoinformation*, 2, 227–238.
- Wang, Y., Li, S., Lin, Y., & Wang, M. (2021). Lightweight deep neural network method for water body extraction from high-resolution remote sensing images with multisensors. *Sensors*, 21(21), 7397.
- Weinmann, M., Urban, S., Hinz, S., Jutzi, B., & Mallet, C. (2015). Distinctive 2D and 3D features for automated large-scale scene analysis in urban areas. *Computers and Graphics (Pergamon)*, 49, 47–57. <https://doi.org/10.1016/j.cag.2015.01.006>
- Westoby, M. J., Brasington, J., Glasser, N. F., Hambrey, M. J., & Reynolds, J. M. (2012). ‘Structure-from-Motion’ photogrammetry: A low-cost, effective tool for geoscience applications. *Geomorphology*, 179, 300–314.
- Zheng, X., Godbout, L., Zheng, J., McCormick, C., & Passalacqua, P. (2019). An automatic and objective approach to hydro-flatten high resolution topographic data. *Environmental Modelling and Software*, 116(February), 72–86. <https://doi.org/10.1016/j.envsoft.2019.02.007>