

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

**SU KÜTLELERİNİN SAYISAL YÜZEY VE ARAZİ MODELLERİNDEN
OTOMATİK OLARAK ÇIKARILMASI VE DÜZELTİLMESİ**

DOKTORA TEZİ

Samed ÖZDEMİR

**ŞUBAT 2021
TRABZON**





KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

**SU KÜTLELERİNİN SAYISAL YÜZEY VE ARAZİ MODELLERİNDEN
OTOMATİK OLARAK ÇIKARILMASI VE DÜZELTİLMESİ**

Samed ÖZDEMİR

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"DOKTOR (HARİTA MÜHENDİSLİĞİ)"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 20 / 01 / 2021

Tezin Savunma Tarihi : 16 / 02 / 2021

Tez Danışmanı : Prof. Dr. Fevzi KARSLI

Trabzon 2021



ÖNSÖZ

“Su Kütlelerinin Sayısal Yüzey ve Arazi Modellerinden Otomatik Olarak Çıkarılması ve Düzeltilmesi” adlı bu çalışma, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim Dalında Doktora Tezi olarak hazırlanmıştır.

Tez çalışmam sürecinde danışmanlığımı üstlenen, değerli fikirleri ve önerileriyle çalışmalarına yön veren ve her türlü desteğini esirgemeyen değerli hocam Sayın Prof. Dr. Fevzi KARSLI'ya sonsuz teşekkürlerimi sunarım.

Doktora tez çalışmasının tez izleme komitesinde görev alan, değerli fikirleri ile tez çalışmama katkılarda bulunan, değerli hocalarım Prof. Dr. Abdulaziz GÜNEROĞLU ve Dr. Öğr. Üyesi Mustafa DİHKAN'a teşekkür ederim.

Tez çalışması süresince yöntem ve tez içeriğinin geliştirilmesinde desteklerini esirgemeyen Arş. Gör. Zeynep AKBULUT'a teşekkür ederim.

Çalışmalarımda kullandığım veri setlerini sağlayan Harita Genel Müdürlüğü'ne, Albay Altan Yılmaz ve Albay Orhan FIRAT'a teşekkürlerimi sunarım. Geliştirilen yöntemin doğrulamasının yapılması amacıyla kullanılan LiDAR veri setlerini sağlayan BİMTAŞ A.Ş.'ye teşekkür ederim.

Bugünlere gelmemde bana sürekli destek olan, maddi ve manevi hiçbir fedakârlıktan kaçınmayan değerli aileme sonsuz teşekkürlerimi sunarım.

Samed Özdemir
Trabzon 2021



TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduğum “Su Kütlelerinin Sayısal Yüzey ve Arazi Modellerinden Otomatik Olarak Çıkarılması ve Düzeltilmesi” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Fevzi KARSLI’nın sorumluluğunda tamamladığımı, verilerimi kendim topladığımı, analizleri kendim yaptığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallarına uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 16/02/2021

Samed ÖZDEMİR



İÇİNDEKİLER

Sayfa No

ÖNSÖZ	III
TEZ ETİK BEYANNAMESİ	IV
İÇİNDEKİLER	V
ÖZET.....	VI
SUMMARY	VII
ŞEKİLLER DİZİNİ.....	VIII
TABLolar DİZİNİ	XII
KISALTMALAR DİZİNİ	XIII
1. GENEL BİLGİLER	1
1.1. Giriş	1
1.1.1. Çalışmanın Motivasyonu	4
1.1.2. Literatür Taraması	5
1.1.3. Çalışmanın Amacı	12
1.2. Çalışmada Kullanılan Yöntemler.....	13
1.2.1. Fotogrametri	14
1.2.2. Hava Fotoğraflarından Ortofoto Üretimi	17
1.2.3. Görüntü Eşleme ile Nokta Bulutu Üretimi	19
1.2.4. Nokta Bulutlarının Filtrelenmesi	22
1.2.5. Sayısal Yükseklik Modelleri.....	24
1.2.6. Nokta Bulutlarından Geometrik Özniteliklerin Çıkartılması.....	25
1.2.6.1. Komşu Noktaların Tespit Edilmesi.....	26
1.2.6.2. Uygun Komşuluk Boyutunun Seçilmesi.....	27
1.2.6.3. Nokta Bulutlarından Özniteliklerin Çıkartılması.....	31
1.2.7. Öznitelik Seçimi	33
1.2.8. Akış Yönü ve Akış Toplanma Alanları	35
1.2.9. Öznitelik Haritalarının Süper Pikseller ile Bölütlenmesi.....	38
1.2.9.1. SLIC Süper Piksel Algoritması.....	39
1.2.10. Özniteliklerin Sınıflandırılması	41
1.2.10.1. Rastgele Orman Sınıflandırıcısı.....	41
1.2.11. Sınıflandırma Doğruluklarının Analizi	43
1.2.12. Hidrolojik Düzleştirme İşlemi	45
1.2.12.1. Su Kütlesi Yüzey Yüksekliklerinin Belirlenmesi	45



2.	YAPILAN ÇALIŞMALAR.....	47
2.1.	Çalışma Alanları	48
2.1.1.	Çalışma Alanı-1 (Rize)	49
2.1.2.	Çalışma Alanı-2 (Malatya)	53
2.1.3.	Çalışma Alanı-3 (Edirne).....	56
2.1.4.	Çalışma Alanı-4 (İstanbul).....	57
2.2.	Hava Fotoğraflarından Nokta Bulutu Üretimi	58
2.3.	Nokta Bulutlarından Öznitelik Haritalarının Üretilmesi.....	61
2.3.1.	En Uygun Komşuluk Boyutu Seçimi.....	62
2.3.2.	Özniteliklerin Hesaplanması.....	64
2.3.3.	Öznitelik Seçimi	66
2.3.4.	Akış Toplanma Alanlarının Belirlenmesi	71
2.3.5.	Ortofoto ve Öznitelik Haritalarının Birleştirilmesi.....	72
2.4.	Öznitelik Haritalarının Sınıflandırılması	73
2.4.1.	SLIC Süper Pikselleri	74
2.4.2.	Öznitelik Haritalarının Rastgele Orman ile Sınıflandırılması.....	75
2.5.	Hidrolojik Düzleştirme	79
2.5.1.	Durağan Su Kütlelerinin Hidrolojik Düzleştirmesi	79
2.5.2.	Akarsu Kütlelerinin Hidrolojik Düzleştirmesi.....	83
3.	BULGULAR.....	89
3.1.	Sınıflandırma Sonucunda Tespit Edilen Su Sınırları ve Doğruluk Analizi	89
3.2.	Hidrolojik Düzleştirme İçin Su Kütlesi Sınırlarının Tespit Edilmesi	96
3.3.	Hidrolojik Düzleştirilmiş SAM	103
3.4.	Su Ayırma Çizgilerinin Oluşturulması	112
4.	TARTIŞMA.....	114
5.	SONUÇ VE ÖNERİLER.....	126
6.	KAYNAKLAR.....	129
ÖZGEÇMİŞ		



Doktora Tezi

ÖZET

SU KÜTLELERİNİN SAYISAL YÜZEY VE ARAZİ MODELLERİNDEN OTOMATİK OLARAK ÇIKARILMASI VE DÜZELTİLMESİ

Samed ÖZDEMİR

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Harita Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Fevzi KARSLI
2021, 137 sayfa

LiDAR (Light Detection and Ranging) teknolojisi ve Fotogrametrik verilerden görüntü eşleme ile üretilen nokta bulutları, yüksek çözünürlüklü Sayısal Yükseklik Modellerinin (SYM) üretiminde kullanılmaktadır. Ancak SYM’lerde, su yüzeylerinde oluşan üçgenleme ve süreksizliklere bağlı olarak ortaya çıkan geometrik düzensizlikler bulunmaktadır. Bu düzensizliklerin hidrolojik olarak düzeltilmesi, manuel olarak çizilen su ayırma çizgilerinin kullanılması durumunda yüksek miktarda zaman ve iş gücü gerektirmektedir. Bu çalışmada, SYM üzerindeki durağan (göl, deniz vb.) ve akarsu su kütlelerinin tespit edilmesi/çıkarılması ve hidrolojik düzeltilmesi için MATLAB ortamında otomatik bir yaklaşım geliştirilmiştir. Bu yaklaşım, dijital hava fotoğraflarından eşleştirme yöntemiyle üretilen (Rize, Malatya ve Edirne) ve LiDAR algılayıcılardan (İstanbul) elde edilen nokta bulutlarının içerdiği geometrik bilgileri kullanmaktadır. Nokta bulutu üzerinden 3B yapı tensörü ile hesaplanan öznitelik haritaları SLIC (Simple Linear Iterative Clustering) süper piksel algoritması kullanılarak bölütlenmiştir. Ardından, üretilen öznitelik haritaları Rastgele Orman (RO) sınıflandırıcısı ile su ve su değil olmak üzere iki sınıf olarak sınıflandırılmıştır. Alt veri setlerine bölünen çalışma alanlarının sınıflandırma doğrulukları için hesaplanan F-Ölçütü (F-Score), Doğruluk (Correctness), Bütünlük (Completeness) ve Kalite (Quality) ölçütlerinin ortalama değerleri sırasıyla; Çalışma Alanı-1 Deniz (Rize) için %85,7, %99,7, %96,7 ve %96,4, Çalışma Alanı-2 (Malatya) için %93,7, %99,6, %95,9 ve %95,5, Çalışma Alanı-3 (Edirne) için %94,9, %97,9, %95,4 ve %93,5, Çalışma Alanı-4 (İstanbul) için %73,6, %95,3, %94,3 ve %90,1 olarak tespit edilmiştir. Sınıflandırma ile tespit edilen su kütlesi sınırlarının Sayısal Arazi Modeli (SAM) ile kesiştirilmesi ile elde edilen su yüzey yükseklikleri kullanılarak 3B bir yüzey oluşturulmuş ve hidrolojik düzeltme işlemi gerçekleştirilmiştir.

Anahtar Kelimeler: Hidrolojik Düzeltme, Nokta Bulutu, Rastgele Orman, Sayısal Arazi Modeli, Su Kütlesi Çıkarımı, Sınıflandırma, Sayısal Yükseklik Modeli.



PhD. Thesis

SUMMARY

AUTOMATIC EXTRACTION AND HYDRO-FLATTENING OF WATER BODIES IN
DIGITAL SURFACE AND TERRAIN MODELS

Samed ÖZDEMİR

Karadeniz Technical University
Graduate School of Natural and Applied Sciences
Geomatics Engineering Department
Supervisor: Prof. Dr. Fevzi KARSLI
2021, 137 pages

Point clouds obtained from LiDAR (Light Detection and Ranging) and photogrammetric sensors allow the creation of a high-resolution Digital Elevation Models (DEM). DEM's directly generated from the point clouds, contains geometric irregularities that occur due to triangulation artifacts or inaccurate elevation information on water surfaces. The smooth representation of the water bodies on the DEM can be achieved with the hydro-flattening process performed using break lines drawn by manual methods that require a high amount of time and labor. In this study, an approach has been developed in the MATLAB environment to automatically detect/extract and hydro-flatten standing and stream water bodies on the DEM. The proposed approach uses the geometric information contained in the point clouds which are obtained from the digital aerial photographs (Rize, Malatya and Edirne) with dense matching and LiDAR sensors (Istanbul). The feature maps were generated with the 3D structure tensor over the point cloud and segmented using the SLIC (Simple Linear Iterative Clustering) algorithm. Then, the generated feature maps were classified into two classes, water and non-water, by the Random Forest classifier, and hydro-flattening operation was carried out over the detected water bodies on the DEM. F-Score, Correctness, Completeness and Quality metrics were used in the accuracy analysis step. The average values of the accuracy metrics calculated for each of the study areas which were divided into sub-data sets; 85,7%, 99,7%, 96,7% and 96,4% for Study Area-1 Sea (Rize), 93,7%, 99,6%, 95,9% and 95,5% for Study Area-2 (Malatya), 94,9%, 97,9%, 95,4% and 93,5% for Study Area-3 (Edirne) and for Study Area-4 (İstanbul), 73,6%, 95,3%, 94,3% and 90,1% were determined respectively. A 3D water surface was created using the water surface elevations obtained by intersecting water body boundaries with the Digital Terrain Model (DTM). Finally, the hydro-flattening operation was carried out by using this surface.

Key Words: Classification, Digital Elevation Model, Digital Terrain Model, Hydro Flattening, Point Cloud, Random Forest, Automatic Water Body Extraction



ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1.	Hidrolojik düzleştirme işlemi; a) öncesi, b) sonrası SAM	2
Şekil 2.	Büyük formatlı dijital hava kamerası; a) Vexcel UltraCam Eagle Mark 3, b) Kamera sabiti ve uçuş yüksekliklerine göre çerçeve boyutları	15
Şekil 3.	RGB ve LiDAR algılayıcı taşıyabilen bir İHA platformu.....	15
Şekil 4.	LiDAR algılayıcıların ölçüm prensibi	16
Şekil 5.	Hibrit algılama sistemleri; a) Leica CityMapper-2, b) RGB, NIR kameralar ve LiDAR konumu	17
Şekil 6.	Ortofoto üretimi; a) resim ve obje koordinatları arasındaki ilişki, b) geriye projeksiyon	18
Şekil 7.	8 farklı yönlü optimizasyon yolu ile en doğru eşleşme	20
Şekil 8.	Nokta eşleme ve epipolar geometri	20
Şekil 9.	PTD algoritması ile nokta bulutunun filtrelenmesi; a) PTD algoritması ile yer ve yer üstü noktaların ayrılması, b) çekirdek noktalardan üretilen TIN, c) TIN yoğunlaştırma.....	23
Şekil 10.	SAM ve YM gösterimi	24
Şekil 11.	LiDAR nokta bulutundan üretilen a) YM, b) SAM.....	25
Şekil 12.	Kd-tree yönteminin görselleştirmesi.	27
Şekil 13.	Öznitelik hesabında kullanılan komşuluk türleri; a) silindirik komşuluk, b) küresel komşuluk, c) en yakın komşuluk	28
Şekil 14.	Akış yönü algoritmaları; a) SFD algoritmasının akış yönü, b) MFD algoritmasının akış yönleri	37
Şekil 15.	Rastgele Orman sınıflandırma algoritmasının akış grafiği.....	42
Şekil 16.	Doğruluk analizi terimleri görsel ifadesi	44
Şekil 17.	Su kütlelerinin otomatik tespit edilmesi ve hidrolojik düzleştirilmesi işlem adımları.....	48
Şekil 18.	Çalışma Alanı-1 (Rize).....	50
Şekil 19.	Çalışma Alanı-1 Deniz için oluşturulan dört adet alt veri setine ait ortofotolar; a) Deniz-1, b) Deniz-2, c) Deniz-3, d) Deniz-4.....	51
Şekil 20.	Çalışma Alanı-1 Dere için oluşturulan altı adet alt veri setine ait ortofotolar; a) Dere-1, b) Dere-2, c) Dere-3, d) Dere-4, e) Dere-5, f) Dere-6	52
Şekil 21.	Çalışma Alanı-2 (Malatya)	53
Şekil 22.	Çalışma Alanı-2 için oluşturulan yedi adet alt veri setine ait ortofotolar; a) Malatya-1, b) Malatya-2, c) Malatya-3, d) Malatya-4, e) Malatya-5, f) Malatya-6, g) Malatya-7	55



Şekil 23. Çalışma Alanı-3 (Edirne).....	56
Şekil 24. Çalışma Alanı-3 için oluşturulan iki adet alt veri setine ait ortofotolar; a) Edirne-1, b) Edirne-2.....	57
Şekil 25. Çalışma Alanı-4'e (İstanbul) ait Worldview uydu görüntüsü	58
Şekil 26. Çalışma Alanı-1'e ait örnek bir bölgede filtreleme işlemi sonucunda bulunan yer üstü noktalar (kırmızı renkli).....	59
Şekil 27. PCfill fonksiyonu ile nokta bulutlarında filtreleme sonucu oluşan boşlukların doldurma işlemi; a) öncesi, b) sonrası	60
Şekil 28. Çalışma Alanı-2 için hesaplanan öznitelik haritaları.....	65
Şekil 29. PCgrid fonksiyonu ile nokta bulutunun gridlere bölünmesi.....	66
Şekil 30. Çalışma Alanı-1 Deniz için bulunan Relief-F tabanlı öznitelik seçimi.....	67
Şekil 31. Çalışma Alanı-1 Dere için bulunan Relief-F tabanlı öznitelik seçimi	68
Şekil 32. Çalışma Alanı-2 için bulunan Relief-F tabanlı öznitelik seçimi	69
Şekil 33. Çalışma Alanı-3 için bulunan Relief-F tabanlı öznitelik seçimi sonuçları.....	70
Şekil 34. Çalışma Alanı-4 için bulunan Relief-F tabanlı öznitelik seçimi sonuçları.....	70
Şekil 35. Çalışma Alanı-2 akış toplanma alanları (beyaz piksel: en yoğun akış toplanma alanı)	72
Şekil 36. Çalışma Alanı-2 ortofoto ve raster öznitelik haritalarının birleştirilmesi.....	73
Şekil 37. Çalışma Alanı-1'de SLIC segmentlerinin görünümü; a) ortofoto, b) SLIC süper pikselleri.....	74
Şekil 38. Çalışma Alanı-1 Deniz eğitim veri seti; a) ortofoto, b) 3 bantlı öznitelik görüntüsü	76
Şekil 39. Çalışma Alanı-1 Dere eğitim veri seti; a) ortofoto, b) 3 bantlı öznitelik görüntüsü	77
Şekil 40. Çalışma Alanı-2 eğitim veri seti; a) ortofoto, b) 3 bantlı öznitelik görüntüsü	78
Şekil 41. Çalışma Alanı-3 eğitim veri seti; a) ortofoto, b) 3 bantlı öznitelik görüntüsü	79
Şekil 42. Çalışma Alanı-2 su kütlesi sınırları; a) sınıflandırma sonucu elde edilen ikili görüntü, b) su kütlesi sınırlarının SAM üzerinde gösterimi.....	80
Şekil 43. Su yüzey yüksekliği histogramı.....	81
Şekil 44. Su kütlesi sınırlarından oluşturulan yüzeyin SAM üzerinde gösterimi.....	82
Şekil 45. Hidrolojik düzleştirilmiş SAM	82
Şekil 46. Akarsu akış hattının tespit edilmesi; a) sınıflandırma sonucunda elde edilen ikili görüntü, b) bu görüntüden üretilen iskelet	83
Şekil 47. Akarsu kütlesinin iskeletinden oluşturulan profil ve kesit noktaları	84
Şekil 48. En kesit genişliklerinin otomatik belirlenmesi	85



Şekil 49. Akarsu için profil ve en kesitlerin oluşturulması; a) profil hattı ve en kesitler, b) en kesit yükseklikleri.....	86
Şekil 50. En kesit noktalarından oluşturulan su yüzeyi.....	87
Şekil 51. Hidrolojik olarak düzleştirilmiş akarsu kütlesi.....	88
Şekil 52. Çalışma Alanı-1 Deniz sınıflandırma sonucu elde edilen su kütlesi sınırları.....	90
Şekil 53. Çalışma Alanı-1 Dere sınıflandırma sonucu elde edilen su kütlesi sınırları	91
Şekil 54. Çalışma Alanı-2 sınıflandırma sonucu elde edilen su kütlesi sınırları	92
Şekil 55. Çalışma Alanı-3 sınıflandırma sonucu elde edilen su kütlesi sınırları	93
Şekil 56. Çalışma Alanı-4 sınıflandırma sonucu elde edilen su kütlesi sınırları	95
Şekil 57. Çalışma Alanı-1 Deniz için düzeltilmiş su kütlesi sınırları.....	97
Şekil 58. Çalışma Alanı-1 Dere için düzeltilmiş su kütlesi sınırları.....	98
Şekil 59. Çalışma Alanı-2 düzeltilmiş su kütlesi sınırları	100
Şekil 60. Çalışma Alanı-3 düzeltilmiş su kütlesi sınırları	101
Şekil 61. Çalışma Alanı-4 düzeltilmiş su kütlesi sınırları	102
Şekil 62. Hidrolojik düzeltme işlemi öncesi ve sonrasında su yüzey yükseklikleri	104
Şekil 63. Hidrolojik düzleştirilmiş SAM; a) Deniz-1, b) Deniz-2.....	105
Şekil 64. Hidrolojik düzleştirilmiş SAM; a) Deniz-3, b) Deniz-4.....	106
Şekil 65. Hidrolojik düzleştirilmiş SAM; a) Dere-1, b) Dere-2	107
Şekil 66. Hidrolojik düzleştirilmiş SAM; a) Dere-3, b) Dere-4	107
Şekil 67. Hidrolojik düzleştirilmiş SAM; a) Dere-5, b) Dere-6	108
Şekil 68. Hidrolojik düzleştirilmiş SAM; a) Malatya-1, b) Malatya-2.....	109
Şekil 69. Hidrolojik düzleştirilmiş SAM; a) Malatya-3, b) Malatya-4.....	109
Şekil 70. Hidrolojik düzleştirilmiş SAM; a) Malatya-5, b) Malatya-6.....	110
Şekil 71. Hidrolojik düzleştirilmiş SAM; Malatya-7	110
Şekil 72. Hidrolojik düzleştirilmiş SAM; Çalışma Alanı-3.....	111
Şekil 73. Hidrolojik düzleştirilmiş SAM; Çalışma Alanı-4.....	112
Şekil 74. Çalışma Alanı-1 için oluşturulan su ayırma çizgileri	113
Şekil 75. Çalışma Alanı-2 için oluşturulan su ayırma çizgileri	113
Şekil 76. Çalışma Alanı-2 örneğinde su kütlelerinde karşılaşılan boşluklar ve yükseklik hataları.....	116
Şekil 77. Filtreleme işlemi sonucunda tepelerde ortaya çıkan yüzey hataları; a) YM, b) SAM	117
Şekil 78. Çalışma Alanı-1 Deniz veri setinde karşılaşılan sınıflandırma hataları	119
Şekil 79. Çalışma Alanı-2 veri setinde karşılaşılan sınıflandırma hataları.....	119
Şekil 80. Çalışma Alanı-4 veri setinde karşılaşılan sınıflandırma hataları.....	120



Şekil 81. Çalışma Alanı-1 Dere veri setinde karşılaşılan sınıflandırma hataları	121
Şekil 82. Çalışma Alanı-2’de karşılaşılan kubbe etkisi	122
Şekil 83. Hidrolojik düzeltirme işleminde akarsu kütlelerinde karşılaşılan hatalar.....	124
Şekil 84. İki akarsu kolunun birleştiği alanda karşılaşılan enterpolasyon hatası.....	125



TABLolar DİZİNİ

Sayfa No

Tablo 1. Sınıflandırma sonucu doğruluk analizlerinin literatürde bulunan çalışma sonuçları ile kıyaslanması.....	12
Tablo 2. Fotoğraflardan 3B nokta bulutu üretiminde kullanılan yazılımlar ve nokta eşleme algoritmaları	22
Tablo 3. Vexcel UltraCam Eagle kamerası Pankromatik bandı teknik özellikleri	49
Tablo 4. Vexcel UltraCam Eagle kamerası MultiSpektral bandı teknik özellikleri	49
Tablo 5. Çalışma Alanı-1 Deniz nokta bulutu istatistikleri	51
Tablo 6. Çalışma Alanı-1 Dere için üretilen alt veri setlerinin istatistikleri.....	52
Tablo 7. Çalışma Alanı-2 nokta bulutu istatistikleri.....	54
Tablo 8. Çalışma Alanı-3 için oluşturulan alt veri setlerine ait bilgiler.....	57
Tablo 9. Çalışma alanlarında üretilen ürünlerin genel istatistikleri.....	59
Tablo 10. Çalışma Alanı-3 komşuluk boyutu seçim parametreleri	63
Tablo 11. Tüm çalışma alanları için hesaplanan komşuluk boyutları	63
Tablo 12. Çalışma Alanı-1 Deniz sınıflandırma doğruluk analizi sonuçları	90
Tablo 13. Çalışma Alanı-1 Dere veri setinin doğruluk analizi sonuçları	92
Tablo 14. Çalışma Alanı-2 veri setinin doğruluk analizi sonuçları	93
Tablo 15. Çalışma Alanı-3 veri setinin doğruluk analizi sonuçları	94
Tablo 16. Çalışma Alanı-4 veri setinin doğruluk analizi sonuçları	95
Tablo 17. Çalışma Alanı-1 Deniz için düzeltilmiş sınırların doğruluk analizi sonuçları	97
Tablo 18. Çalışma Alanı-1 Dere için düzeltilmiş sınırların doğruluk analizi sonuçları	99
Tablo 19. Çalışma Alanı-2 için düzeltilmiş sınırların doğruluk analizi sonuçları.....	100
Tablo 20. Çalışma Alanı-3 için düzeltilmiş sınırların doğruluk analizi sonuçları.....	101
Tablo 21. Çalışma Alanı-4 için düzeltilmiş sınırların doğruluk analizi sonuçları.....	102



KISALTMALAR DİZİNİ

AOP	: Noktaların Açısı (Angle of Points)
ASPRS	: Amerikan Fotogrametri ve Uzaktan Algılama Topluluğu (American Society of Photogrammetry and Remote Sensing)
CBS	: Coğrafi Bilgi Sistemleri
CIE	: Uluslararası Aydınlatma Komisyonu (International Commission on Illumination)
GMM	: Gauss Bileşim Modeli (Gaussian Mixture Models)
GPS	: Küresel Konumlandırma Sistemi (Global Positioning System)
HGM	: Harita Genel Müdürlüğü
INS	: Ataletsel Seyrüsefer Sistemi (Inertial Navigation System)
İHA	: İnsansız Hava Aracı
LiDAR	: Işık Tespiti ve Ölçümü (Light Detection and Ranging)
LTİ	: LiDAR'dan Görüntü (LiDAR to Image)
MFD	: Çoklu Akış Yönü (Multiple Flow Direction)
MLC	: Maksimum Benzerlik Sınıflandırma (Maximum Likelihood Classification)
MS	: Multispektral
NDVI	: Normalleştirilmiş Fark Bitki İndeksi (Normalized Difference Vegetation Index)
NDWI	: Normalleştirilmiş Fark Su İndeksi (Normalized Difference Water Index)
NHD	: Ulusal Hidrografi Veri Seti (National Hydrography Dataset)
NIR	: Yakın Kızılötesi (Near Infra Red)
PCA	: Asal Bileşen Analizi (Principal Component Analysis)
PDF	: Olasılık Yoğunluğu Fonksiyonu (Probability Density Function)
PFHs	: Nokta Öznitelik Histogramları (Point Feature Histograms)
PTD	: Aşamalı TIN Yoğunlaştırma (Progressive TIN Densification)
RADAR	: Radio Detection and Ranging
RANSAC	: Rastgele Örneklem Konsensüsü (Random Sample Consensus)
RO	: Rastgele Orman (Random Forest)
RTY	: Relief Tabanlı Yöntem
SAM	: Sayısal Arazi Modeli
SFD	: Tek Akış Yönü (Single Flow Direction)
SfM	: Hareket ile Nesne Oluşturma (Structure From Motion)



SGM	: Yarı Global Eşleme (Semi Global Matching)
SLIC	: Basit Lineer İteratif Kümeleme (Simple Linear Iterative Clustering)
SLIER	: Tarama Çizgisi Yoğunluk Yükseklik Oranı (Scan Line Intensity Elevation Ratio)
SSI	: Spektral Şekil İndeksi (Spectral Shape Index)
SVM	: Destek Vektör Makineleri (Support Vector Machines)
SYM	: Sayısal Yükseklik Modeli
TIN	: Düzensiz Üçgen Ağı (Triangulated Irregular Network)
TIR	: Termal Kızılötesi (Thermal Infra Red)
TKGM	: Tapu ve Kadastro Genel Müdürlüğü
YM	: Sayısal Yüzey Modeli
YÖA	: Yer Örneklem Aralığı
YSA	: Yapay Sinir Ağları



1. GENEL BİLGİLER


1.1. Giriş

Son yıllarda, Uzaktan Algılama ve Fotogrametrik veri toplama yöntemleri ile elde edilen yüksek çözünürlüklü arazi verilerinin yaygınlaşması ile yer yüzeyinin özniteliklerinin daha iyi bir şekilde karakterize edilmesinin önü açılmıştır (Zheng vd., 2019). Bu veri toplama yöntemleri arasında Light Detection and Ranging (LiDAR) teknolojisi yer yüzeyine dair sağladığı yüksek çözünürlüklü, akıllı, hassas ve yoğun noktasal bilgiler ile öne çıkmaktadır. Bunun yanı sıra, son yıllarda bir bilgisayarla görme yöntemi olarak gelişim gösteren Hareket ile Nesne Oluşturma (SfM) ve diğer görüntü eşleştirme yöntemleri hava ve kara platformlarından elde edilen fotoğraflardan üretilen yüksek çözünürlüklü nokta bulutlarına olan erişimin artmasına olanak sağlamıştır (Leberl vd., 2010; Javernick vd., 2014). Nokta bulutlarından elde edilen ham ve işlenmiş bilgiler, sadece haritacılık alanında değil aynı zamanda jeomorfoloji (Javernick vd., 2014; Cook, 2017; Kasvi vd., 2019; Langat vd., 2019), hidroloji (Lewis vd., 2018; Liu vd., 2020), taşkın izleme (Saksena, 2015; Horkaew ve Puttinaovararat, 2017; Rogers, 2017) ve doğal kaynak yönetimi (Şikola vd., 2019; Chawla vd., 2020) alanlarında yaygın olarak kullanılmaktadır (Zheng vd., 2019).

Geleneksel olarak, topoğrafik Sayısal Yükseklik Modeli (SYM) üretiminde fotogrametrik hava kameralarından elde edilen görüntüler kullanılarak gerçekleştirilen stereo değerlendirme işleminde manuel olarak çizilen su ayırma çizgileri kullanılmaktadır. Çizilen su ayırma çizgileri sayesinde su yüzeyleri düz ve sürekli bir yapıda temsil edilebilmektedir (Heideman, 2012). Günümüzde yoğun bir biçimde kullanılan LiDAR ve görüntü eşleme ile üretilen nokta bulutları, yüksek çözünürlüklü SYM oluşturulmasına olanak sağlamaktadır. Ancak kullanılan algılayıcının teknik özelliklerine bağlı olarak su yüzeylerinde oluşan boşluklar ve hatalı su yüzeyi yüksekliklerinden kaynaklanan geometrik düzensizlikler özellikle çıplak/yalın arazi yüzeyinin oluşturulmasında hassasiyet ve doğruluğun azalmasına neden olmaktadır (Parrot ve Ramírez Núñez, 2016). Söz konusu geometrik düzensizlikler (Şekil 1a), su kütlelerinin olduğu alanlarda LiDAR veya fotogrametrik nokta bulutu kullanılarak üretilen yüzey modellerinin klasik topoğrafik



haritalardaki gibi düzgün bir gösterim sağlanamamasına neden olmaktadır (Parrot ve Ram3rez N3ñez, 2016; Sangireddy vd., 2016; Deshpande ve Yilmaz, 2017). Bu sebeple, nokta bulutlarında su k3tlelerinin olduėu b3lgelerde karřılařılan geometrik d3zensizlikleri gidermek amacıyla veri 3zerine su ayırma izgileri eklenerek hidrolojik d3zleřtirilmiř Sayısal Arazi Modeli (SAM) veya D3zensiz 3gen Aėı (TIN) y3zeyler oluřturulur (řekil 1b). Hidrolojik d3zleřtirme iřleminin amacı, LiDAR veya fotogrametrik y3ntemler ile 3retilen nokta bulutlarından oluřturulan SAM'daki su y3zeylerinin geleneksel y3ntemlerle 3retilen SAM'daki gibi d3zg3n g3steriminin gerekleřtirilmesidir (Heideman, 2012). Bu sayede oluřturulan SAM'dan 3retilen eřy3kselti eėrileri, topoėrafik haritalardaki eřy3kselti eėrileri ile uyumlu olmaktadır (Parrot ve Ram3rez N3ñez, 2016; Deshpande ve Yilmaz, 2017; Zheng vd., 2019). Su ayırma izgileri ve kıyı izgilerinin tespit edilmesinde manuel y3ntemler kullanılması 3zellikle ok sayıda dere, g3l, akarsu vb. su k3tlesi bulunması durumunda pahalı ve zaman alıcı olmakla birlikte y3ksek miktarda iř g3c3 gerektirmektedir (Toscano vd., 2014).



řekil 1. Hidrolojik d3zleřtirme iřlemi; a) 3ncesi, b) sonrası SAM

Bu tez alıřmasında SAM, Sayısal Y3zey Modeli (YM) 3zerindeki duraėan (g3l, deniz vb.) ve akarsu su k3tlelerinin otomatik olarak tespit edilmesi/ıkarılması ve



hidrolojik olarak düzleştirilmesi amacıyla dijital hava fotoğraflarından eşleştirme yöntemiyle üretilen ve LiDAR algılayıcılardan elde edilen nokta bulutlarının içerdiği geometrik bilgileri girdi verisi olarak kullanan bir yaklaşım geliştirilmiştir. Geliştirilen yaklaşımın otomatize edilmesi, farklı tipte ve özellikte veri setlerine uygulanabilmesi amacıyla MATLAB ortamında derlenen kod ile ayrıca bir yazılım geliştirilmiştir. Geliştirilen yaklaşımın uygulanmasında Harita Genel Müdürlüğü (HGM) tarafından sağlanan hava fotoğraflarından görüntü eşleştirme yöntemlerinden SfM yöntemini kullanan Agisoft PhotoScan yazılımı ile nokta bulutları üretilmiştir. Ardından LAStools yazılımında gerçekleştirilen filtreleme işlemi ile yer ve yer üstü noktalar ayrıştırılmıştır. Nokta bulutlarının yerel komşuluklarındaki değişimleri ifade eden Eğrisellik (Change of Curvature), Düzlemsellik (Planarity), Çizgisellik (Linearity), Eşyönlülük (Anisotropy), Omnivaryans (Omnivariance), Saçılım (Scattering), Özdeğerler Toplamı (EigSum), birinci özdeğere göre eğriselliğin değişimi (CC1), ikinci özdeğere göre eğriselliğin değişimi (CC2) ve X, Y ve Z yönlerindeki yüzey normalleri (Normal X, Normal Y ve Normal Z) adlı geometrik öznitelikler 3B yapı tensörü'nden faydalanarak MATLAB ortamında yazılan kod ile çıkartılmıştır. Bunlara ek olarak yerel komşulukta alan yoğunluğu (Surface Density), hacim yoğunluğu (Volume Density), komşuluktaki yükseklik farkı (ZRange), merkez noktanın komşuluktaki yükseklik sırası (ZRank), komşuluğun standart sapması (StSap) ve komşuluğun X, Y ve Z yönlerindeki varyansı (Varyans X, Varyans Y ve Varyans Z) da yazılan kod ile hesaplanmıştır. Hesaplanan geometrik öznitelikler, nokta bulutlarındaki “renk” (LiDAR nokta bulutunda renk bilgisi yerine yoğunluk bilgisi kullanılmıştır) ve akarsular için hesaplanan “akış toplanma alanları” ile birleştirilerek raster formatta öznitelik haritaları üretilmiştir. Sınıflandırma öncesinde hangi özniteliklerin sınıflandırma başarımına olumlu etkisinin olduğunun araştırılması amacıyla filtre tabanlı öznitelik seçim yöntemi olan Relief-F kullanılarak öznitelik haritalarından düşük katkıya sahip öznitelikler çıkartılmıştır. Relief-F sonrasında oluşturulan yeni öznitelik haritalarının Basit Lineer İteratif Kümeleme (SLIC) algoritması ile süper piksel segmentasyonu yapılmıştır. Her bir süper piksel segmentinin ortalama öznitelik değerleri hesaplanarak Rastgele Orman (RO) sınıflandırıcısı ile iki sınıf (su ve su değil) olarak sınıflandırılarak su kütlelerinin tespiti gerçekleştirilmiştir. Tespit edilen su kütlelerine hidrolojik düzleştirme işlemi uygulanmıştır. Hidrolojik düzleştirme işleminin ilk aşaması olan su kütlesi sınırlarının tespiti sınıflandırma işlemi sonucunda elde edilmiştir. İkinci aşamada su kütlelerine ait su yüzey yüksekliklerinin tespit edilmesi gerekmektedir. Deniz ve göl gibi



durağan su kütlelerinin yüzey yükseklikleri, su kütlesi sınırlarındaki yükseklik değerlerinin histogramı oluşturularak Olasılık Yoğunluğu Fonksiyonu (PDF) yöntemi ile en sık tekrarlanan yükseklik değeri olarak tespit edilmiştir. Üçüncü aşamada, sınırları ve yüzey yüksekliği bulunan su kütlelerine SAM üzerinde yeni yükseklik değerlerinin yazılması ve düzeltilmiş su kütlesi sınırlarının üretilmesi gerçekleştirilmiştir. Tespit edilen su kütlesi sınırları morfolojik genişleme operasyonundan geçirilerek su-kara sınırlarındaki olası düzensizlikler giderilmiş ve oluşan yeni sınırlar içine SAM'dan elde edilen su yüzey yükseklikleri yazılarak su kütesine ait bir yüzey oluşturulmuştur. Bu yüzey SAM ile kesiştirilmiş ve kesişim sınırları düzeltilmiş su kütlesi sınırları olarak kaydedilmiştir. Bu sınırlar içinde kalan SAM piksellerine, hesaplanan su yüzey yükseklikleri yazılarak üçüncü aşama tamamlanmıştır. Son aşamada, su-kara geçişlerindeki olası düzensizliklerin ortadan kaldırılması amacıyla, SAM'da düzeltilmiş su kütlesi sınırları boyunca bir yumuşatma filtresi uygulanarak hidrolojik düzeltme işlemi tamamlanmıştır. Akarsu kütlelerinin yüksekliklerinin belirlenmesinde ise su kütesinin en yüksek noktasından başlayarak akış aşağı yönde olacak şekilde bir profil oluşturulmuş ve üzerinden belirli aralıklarla en kesitler alınarak her bir kesitin yüksekliği PDF yöntemi ile tespit edilmiştir. Kesit genişlikleri akarsu yatağının sınırlarındaki değişime bağlı olarak otomatik olarak tespit edilmiştir. Elde edilen kesit konumları ve yükseklikleri ile enterpolasyon yapılarak akarsu yatağının 3B modeli oluşturulmuş ve ardından bu model SAM ile kesiştirilerek hidrolojik düzeltme işlemi gerçekleştirilmiştir. Bu tez çalışmasında geliştirilen yaklaşım ile farklı algılayıcılardan elde edilen nokta bulutlarındaki durağan ve akış halindeki su kütlelerini karakterize eden geometrik öznitelikler belirlenmiş ve su kütlelerinin tespitinde son kullanıcı tarafından kolaylıkla uygulanabilir bir model haline getirilmiştir. Tez kapsamında geliştirilen yaklaşım ile su kütlelerinin tespitinde ve hem durağan hem de akış halindeki su kütlelerinin hidrolojik düzeltme işleminde başarılı sonuçlar elde edilmiştir.

1.1.1. Çalışmanın Motivasyonu

Ülkemizde, SAM ve YM gibi yükseklik bilgisi içeren ürünlerin üretiminde yaygın olarak başta HGM ve Tapu ve Kadastro Genel Müdürlüğü (TKGM) olmak üzere ilgili diğer kurumların envanterinde bulunan dijital hava kameralarından elde edilen fotoğraflar kullanılmaktadır. Bu bağlamda, günümüzde, bilgisayarla görme alanındaki ilerlemelere paralel olarak fotogrametrik olarak üretilmiş hava fotoğrafları değerlendirilerek yüksek



çözünürlüklü nokta bulutları SfM yöntemleri ile üretilmektedir. Böylelikle SAM üretiminde, yüksek miktarda iş gücüne ihtiyaç duyan klasik fotogrametrideki manuel yükseklik eğrilerinin çiziminin yerini SfM yöntemleri ile üretilen nokta bulutlarından otomatik olarak oluşturulan yükseklik eğrileri almaya başlamıştır. Ancak fotogrametrik nokta bulutları ile üretilen SAM içerisinde su kütlesi bulunması durumunda, SfM yöntemi su yüzeyinde eşleştirme yapacak yeteri doğrulukta noktalar bulamamaktadır. Buna bağlı olarak oluşan boşluk ya da aykırı noktalar yüzünden su kütlelerinin gösteriminde istenen kartografik doğruluk elde edilememektedir. Nokta bulutlarından üretilen SYM'de kartografik olarak doğru gösterimin sağlanabilmesi ve hatalı yüzey oluşumunun önüne geçilebilmesi için su ayırma çizgilerinin manuel olarak çizilmesi gerekmekte ancak bu işlem çok zaman alıcı ve maliyetli olmaktadır. Gelişen bilgisayar teknolojisinin beraberinde getirdiği yüksek işlem gücü potansiyeli ile birlikte iş gücünün daha faydalı kullanımına olanak sağlayacak ve hem zamansal hem de ekonomik maliyeti azaltacak olan otomatik hidrolojik düzeltme işlemi bir gereksinim haline gelmiştir. Bu bağlamda, geliştirilen yaklaşım ile nokta bulutlarından üretilen öznetelik haritalarının sınıflandırılması sonucunda elde edilen su kütlesi sınırları kullanılarak otomatize bir şekilde hidrolojik düzeltme işlemi gerçekleştirilmiştir. Hem LiDAR teknolojisi hem de fotogrametrik görüntü eşleme ile üretilen nokta bulutları üzerinde uygulanan yaklaşım ile farklı topoğrafik ve çevre koşullarına sahip su kütlelerinin tespitinde başarılı sonuçlar elde edilmiştir. MATLAB ortamında geliştirilen yazılım kullanılarak, sınıflandırma sonucu tespit edilen su kütlelerinin hidrolojik düzeltme işlemi otomatik olarak gerçekleştirilmiştir. Hidrolojik düzeltme işleminin otomatize edilmesi sayesinde, su ayırma çizgilerinin manuel olarak çizilmesine duyulan ihtiyaç ortadan kaldırılmış olacaktır.

1.1.2. Literatür Taraması

Literatürde, su kütlelerinin tespitine yönelik çalışmalarda kullanılan nokta bulutu ve raster veri türleri yaygın olarak üç ayrı şekilde elde edilmektedir. Birincisi, hava platformlarına entegre LiDAR algılayıcı sistemler ile elde edilen nokta bulutu olurken (Acharjee vd., 2017), bir diğeri uydu platformlarından aktif ve pasif algılayıcılar ile elde edilen raster verilerdir (Horkaew ve Puttinaovarat, 2017). Üçüncüsü ise İnsansız Hava Aracı (İHA) ve uçak platformlarına entegre edilen algılayıcı sistemler ile elde edilen raster ve nokta bulutu verileridir. Son yıllarda, İHA platformlarının taşıma kapasitelerinin



artmasına ve bu platformlarla uyumlu LiDAR ve Radio Detection and Ranging (RADAR) gibi aktif algılayıcıların gelişmesine bağlı olarak çok sensörlü veri üretimi gerçekleştirilmekte ve su kütlelerinin tespitine yönelik çalışmalarda sıklıkla kullanılmaktadır (Tymków vd., 2019; Bandini vd., 2020).

Smeeckaert vd., (2013) yaptıkları çalışmada LiDAR verilerini kullanarak farklı büyüklükteki dokuz test alanında kıyı şeridini Destek Vektör Makineleri (SVM) sınıflandırıcısı ile belirlemişlerdir. LiDAR verilerinden ürettikleri SAM ile LiDAR noktalarının yükseklik, yerel nokta yoğunluğu ve yerel şekil parametrelerini birleştirmişlerdir. SVM sınıflandırıcısını eğitmek için kıyı şeritlerinden elde ettikleri örnekleri kara ve su olmak üzere iki sınıfa ayırmışlardır. Yapılan çalışmanın genel doğruluğu %97 ile %85 aralığında değişmektedir. Sınıflandırma sonucu ortaya çıkan hatalar su alanları için uçuş hattının merkezinde bulunan noktalardan, kara için ise asfalt gibi yüzeylere düşük geliş açısına sahip lazer ışınının oluşturduğu boşluklardan kaynaklandığı belirtilmiştir. Ayrıca sulak alanlarda da uygulanan yöntemin başarısının su derinliği ve ışın geliş açısına bağlı olarak azaldığı belirtilmiştir.

Toscano vd., (2014) LiDAR yükseklik ve yoğunluk verilerinden her bir piksele düşen noktaların medyan bilgilerini alarak 2 m yer örnekleme aralığında oluşturuldukları raster görüntüleri kullanarak su ayırma çizgilerini otomatik olarak belirlemişlerdir. Hidrolojik düzleştirme işlemi konusunda yaptıkları çalışmada iki farklı yöntem üzerine çalışmışlardır. Birinci yöntemde, yükseklik bilgilerini içeren raster verinin histogram analizini yaparak pik değerlerini bulmuş ve bu değerlere karşılık gelen olası su kütlelerini tespit ederek bunların çevreleri ile olan morfolojik ilişkileri ile olası yanlış tespitlerini gidermeye çalışmışlardır. İkinci yöntemde, çalışma alanındaki küçük su kütlelerinin ilk yöntemde tespit edilememesi durumu için de yoğunluk değerlerinden faydalanmışlardır. Yüzde 20'lik dilimin altında kalan yoğunluk değerleri seçilerek yükseklik değerleri kontrol edilmiş ve her iki yöntem ile tespit edilen tüm su kütlelerini birleştirmişlerdir. Tespit edilen su kütlelerinin sınırlarını su ayırma çizgileri olarak kaydetmişlerdir. Elde edilen sonuçları manuel olarak çizilen sınırlar ile karşılaştırıldıklarında büyük oranda örtüşme yakaladıklarını belirtmişlerdir.

Canaz vd., (2015) yaptıkları çalışmada üç farklı test alanında durağan su kütlelerinin sınırlarının çıkartılmasında LiDAR verisini kullanmışlardır. Su kütlelerinin düzlemsel yapıda olduğu varsayımından faydalanan Rastgele Örneklem Konsensüsü (RANSAC) algoritması ile çalışma alanındaki düzlemler belirlenmiştir. Ardından su kütlesine ait



sınırların belirlenebilmesi için Angle of Points (AOP) ve LiDAR to Image (LTI) algoritmalarından faydalanmışlardır. Burada AOP algoritması ile su kütlesinin merkez noktasından mesafe ve açı bilgileri kullanılarak su kütlesinin sınırlarını oluşturan noktalar tespit edilmiştir. LTI yönteminde ise su kütlesine ait noktalar raster formatına dönüştürüldükten sonra morfolojik işlemler uygulanarak sınırları tespit edilmiştir. Her ne kadar AOP algoritması kompleks geometriye sahip göl sınırlarının tespit edilmesinde istenen başarıyı sağlayamamışsa da LTI algoritmasının bu boşluğu doldurarak istenen doğruluğu sağladığı hava fotoğrafları ile yaptıkları doğruluk analizinde ortaya konulmuştur. Yapılaşmanın olmadığı dağlık bölgelerde RANSAC algoritması ile düzlemlerin tespit edilmesinde başarılı sonuçlar elde edilmişse de bu yöntem ile kentsel ve büyük ölçekli çalışma alanlarında başarılı sonuçlar elde edilmesi güç olacaktır.

Broersen vd., (2017) çalışmalarında farklı kanal genişliği (1-5 m) ve toprak türüne (kil, bataklık ve kum) sahip üç test alanında yaptıkları çalışmada 2B ve 3B olarak kanal iskeletlerini doğrudan LiDAR nokta bulutundan otomatik olarak çıkartmışlardır. 2B iskelet çıkartma yönteminde lazer ışınının su yüzeyinden yansımaması sonucunda oluşan boşluklardan faydalanmışlardır. 3B yöntemde ise yüzey eğriliğini dikkate alarak iskelet çıkartma işlemi gerçekleştirmişlerdir. Ek olarak her iki yöntemle elde edilen sonuçları birleştirerek ayrı bir kanal iskeleti de oluşturmuşlardır. Çalışma sonucunda 2B iskelet oluşturma işleminin üzeri bitki örtüsü ile örtülmemiş ve nispeten geniş kanallarda başarılı olduğu ancak aksi durumda doğruluğun düştüğü belirtilmiştir. Bu yöntem ayrıca kanallardaki yüzey eğriliğinin düşük olmasından etkilenmemektedir. 3B yöntem ise 2B yöntemin yararlandığı su boşluklarını kullanmadan bitki örtüsünün çok yoğun olmadığı kanallarda başarılı sonuçlar üretmiştir. Ancak kanallardaki su yüksekliğinin fazla olmasından dolayı yüzey eğriliğinin düştüğü durumlarda doğruluğun da düştüğü belirtilmiştir. Her iki yöntemin birleştirilmesi ile sonuçlarda her ne kadar iyileşmeler gerçekleşse de bu iyileşmeler her iki yöntemin de zayıf kaldığı alanlarda çok küçük oranda olmaktadır.

Deshpande ve Yilmaz, (2017) Single Photon LiDAR nokta bulutlarından bir dere ve bir göl içeren iki ayrı çalışma alanında yarı otomatik bir yöntemle hidrolojik olarak düzleştirilmiş SAM üretimini gerçekleştirmiştir. Çalışmada su kütlesinin sınırlarını tespit edebilmek için öncelikle nokta bulutundaki yer üstü objeleri grid tabanlı olarak filtrelemişler ve LiDAR'ın su yüzeylerinden yansımanın düşük olması nedeniyle ölçemediği noktaların oluşturduğu boşlukları doldurarak bir SAM üretmişlerdir. Daha



sonra Ulusal Hidrografi Veri Seti (NHD) akış çizgisi kullanılarak bu çizgi boyunca belirli aralıklarla kesitler alınmış ve bu kesitler içerisinde kalan en düşük yükseklik su yüzeyinin yüksekliği olarak kabul edilerek oluşturulan yüzey ile SAM kesişiminden derenin kıyı şeridini oluşturmuşlardır. Kıyı şeridi içinde kalan SAM'a, kesitlerden elde edilen yükseklik değerlerini enterpole ederek yazmışlardır. Göl kıyı şeridinin oluşturulmasından, dere kıyı şeridinin çıkartılmasına benzer bir yaklaşım uygulamışlardır. Yaklaşık göl sınırlarından elde edilen su yükseklikleri ile üretilen yüzey, çalışma alanının SAM ile kesiştirilmesi sayesinde kıyı şeridini bulmuş ve hidrolojik olarak düzleştirmişlerdir. Çalışma sonucunda, LiDAR nokta bulutunun yetersiz kalacağı büyük miktarda bitki örtüsü içeren bölgelerde manuel olarak kontrol ve düzeltme işlemlerinin gerekli olabileceğini belirtmişlerdir.

Yousefi vd., (2018) Asal Bileşen Analizi (PCA) ile iyileştirilmiş K-means yöntemini kullanarak Malezya'nın Kuala Terengganu, Kuzeydoğu Almanya'da Kuzey Denizi ve Doğu Avrupa'da Azak Denizi olmak üzere üç adet çalışma alanında QuickBird uydu görüntülerinden su kütlelerini bölütlemişlerdir. İlk aşamada RGB renk uzayındaki görüntüler HSV renk uzayına dönüştürülerek bu bantlar arasındaki korelasyon azaltılmıştır. Daha sonra PCA yöntemi ile öznetelik seçimi yapılarak elde edilen sonuçlar K-means yöntemi ile sınıflandırma işlemine girdi olarak verilmiştir. Önerilen yöntem ile yapılan bölütleme işleminde elde edilen doğruluk değerlendirmesi sonuçları yaklaşık olarak %92 ile %97 arasında değişmektedir. Çalışmada önerilen yöntemin ilerleyen aşamalarda farklı sınıflandırma algoritmaları kullanılarak iyileştirilebileceği vurgulanmıştır.

Roelens vd., (2018) yaklaşık 10 hektar alana sahip geniş bir çayırılık alan ve yaklaşık 150 hektar alana sahip şehir yerleşim alanlarındaki drenaj kanallarının çıkartılması amacıyla yaptıkları çalışmada yakın kızılötesi dalga boyunda çalışan LiDAR (10 cm yer örnekleme aralığında) ve hava fotoğraflarından yararlanmışlardır. Hava fotoğraflarından elde edilen ortofotodaki renk bilgileri LiDAR nokta bulutuna geri yansıtılmak sureti ile kullanılmıştır. Drenaj kanallarına ait doğrulama verileri jeodezik yöntem ile toplanmıştır. LiDAR nokta bulutunun yansıma değerleri kalibre edildikten sonra nokta bulutunun geometrik özellikleri Weinmann vd., (2017) tarafından tanımlanan doğrusallık, düzlemsellik, saçılım, omnivaryans, eşyönsüzlük, eigenentropy, özdeğerler toplamı ve eğriselliğin değişimi parametreleri ile hesaplanmış ve bunlara ek olarak Normalleştirilmiş Fark Su İndeksi (NDWI), Normalleştirilmiş Fark Bitki İndeksi (NDVI) ve Spektral Şekil İndeksi (SSI) radyometrik özellikleri hesaplanarak RO sınıflandırıcısı ile iki sınıf (drenaj kanalı ve drenaj kanalı değil) olarak sınıflandırmışlardır. Sınıflandırma sonuçlarında



çayırılık alanda kappa değeri 0,77, şehir yerleşim alanlarında ise kappa değeri 0,73 olarak bulunmuştur. Çalışmada en büyük katkının hesaplanan geometrik özellikler ile elde edildiği vurgulanmıştır. Bunun yanı sıra LiDAR yansımaya değerlerinin sınıflandırmaya dahil edilmesi durumunda daha da iyi sonuçlar elde edildiği belirtilmiştir.

Tymków vd., (2019) insansız hava aracına entegre edilen RGB kamera (Nikon D800), termal kızılötesi kamera (Optris PI Lightweight 450) ve LiDAR (Velodyne HDL-32E) ile elde edilen veriler ile dört adet çeşitli genişlik ve yapıdaki dere yatağı ve bir adet göl içeren çalışma alanlarında su kütlelerinin sınırlarını tespit etmişlerdir. Yer kontrol noktaları ile referanslandırılan çalışma alanlarında farklı yüksekliklerden yapılan uçuşlarda, RGB kamera için yer örnekleme aralığı 8-10 mm arasında değişirken, termal kızılötesi kamera için bu değer 125-250 mm arasında değişim göstermektedir. Çalışma alanlarında elde edilen LiDAR nokta bulutunda bulunan nokta sayıları da 50-95 milyon nokta ($540-860 \text{ nokta/m}^2$) arasında değişmektedir. Elde edilen RGB ve Termal Kızılötesi (TIR) görüntülerden ortofoto görüntüler üretilirken LiDAR nokta bulutları ile SAM üretimi gerçekleştirmişlerdir. Denetimli sınıflandırma, eşikleme ve görüntü dönüşümleri kullanılarak sonuç verilerden su sınırları tespit etmişlerdir. RGB ve TIR verileri ile tüm çalışma alanları için doğruluk ve kappa katsayısının 0,80 üzerinde olduğu tespit edilmiştir. RGB ve LiDAR ile tüm çalışma alanları için elde edilen kappa katsayısı ise 0,60 ile 0,80 arasında değişmektedir. Su sınırlarının belirlenmesinde özellikle su yüzeyinin içinde ve çevresinde yetişen bitki örtüsü ile kaplanmasının en büyük problem olduğunu ve bu problemin çözümü için LiDAR algılayıcıların penetrasyon yeteneğinin faydalı olduğunu vurgulamışlardır.

Shaker vd., (2019) Kanada'nın Ontario şehrinde, kıyı ve akarsu ortamlarında multispektral LiDAR (Teledyne Optech Titan) verileri kullanılarak akarsu ve göl su kütlelerini içeren dört çalışma alanında otomatik olarak su ve kara sınıflarının tespit edilmesi konusunda bir çalışma gerçekleştirmişlerdir. Düşük irtifada ($<500 \text{ m}$) gerçekleştirilen uçuşlardan elde edilen nokta bulutlarının nokta yoğunluklarının $10,2-23,2 \text{ nokta/m}^2$ olduğu belirtilmiştir. Nokta bulutlarındaki su kütleleri, Gauss Bileşim Modeli (GMM) ve Tarama Çizgisi Yoğunluk Yükseklik Oranı (SLIER) ile elde edilen eğitim verilerinin yanı sıra yüksekliğin varyansı, yoğunluğun varyansı ve üç adet bant oranından da faydalanılarak Maksimum Benzerlik Sınıflandırma (MLC) ile yapılan sınıflandırma sonucunda elde edilen genel doğruluk değerleri GMM için %80 iken SLIER yaklaşımı için genel doğruluk değeri %96'ya kadar yükseldiği belirtilmiştir. Çalışma sonucunda geri



dönüş sayısı, yüksekliğin varyansı ve yoğunluğun varyansının her zaman sınıflandırmanın sonucunu olumlu olarak etkilemediği vurgulanmıştır. Multispektral LiDAR bantlarının su kütlelerinin tespit edilmesinde doğruluğun artmasını sağladığı belirtilmiştir.

Zheng vd., (2019) hidrolojik olarak düzeltilmiş SAM oluşturulması için raster tabanlı olarak dere yataklarının otomatik çıkarımını gerçekleştirmişlerdir. Çalışmalarında açık kaynak kodlu Geonet yazılımını kullanmışlardır. Dere yataklarının belirlenmesinde kullandıkları iş akışı temel olarak üç aşamadan oluşmaktadır: SAM'ın Gauss filtresi ile filtrelenmesi, eğrilik ve birikim parametreleri ile dere yatağının iskeletinin oluşturulması ve son olarak da dere ağının belirlenmesi için kullanılan en düşük maliyetli yol analizi (least cost path). Bu işlemlerde öncül veri olarak orta çözünürlüklü dere ağları kullanılmıştır. Üç farklı çalışma alanında (doğal, tarımsal ve şehir) uygulanan yöntem ile elde edilen sonuçlar hâlihazırda bulunan vektör veriler ile kontrol edilerek doğruluk %91 olarak belirlenmiştir. Ancak bu yöntemin başarılı olabilmesi için kullanılan öncül verinin daha yüksek çözünürlükte olması gerektiği vurgulanmıştır.

Song vd., (2020) ResNet-FPN tabanlı Mask R-CNN derin öğrenme yöntemi ile Worldview-3 ve GaoFen-2 uydularından elde edilen multispektral görüntüleri kullanarak su kütlelerini otomatik olarak tespit etmişlerdir. Tongzhou New Town bölgesinde yaptıkları çalışmada, 1,24 m yer örnekleme aralığına sahip Worldview-3 multispektral bantları 0,3 m çözünürlüğündeki pankromatik bant ile birleştirilerek 0,3 m çözünürlüğünde gerçek renkli görüntüler elde edilmiştir. Aynı işlem GaoFen-2 uydusunun 3,2 m yer örnekleme aralığındaki multispektral bantlarına da uygulanarak 0,8 m gerçek renkli görüntüler elde etmişlerdir. Bu görüntülerden elde edilen 500×500 m boyutlarındaki alt kümeler kullanılarak derin öğrenme modelinin eğitimi göl, büyük dere, küçük dere ve çeltik tarlası sınıfları ile gerçekleştirmişlerdir. Çalışma sonucunda eğitilen derin öğrenme modeli ile su kütleleri ortalama olarak %85 doğruluk ile tespit edilmiştir. Çapraz doğrulama amacıyla oluşturulan dört farklı eğitim modelinde eğitim ve test verisinin aynı görüntüden olmasının, sonuçları olumsuz etkilediğini vurgulamışlardır.

Chen vd., (2020) APEX ve AVIRIS-NG algılayıcılarından elde edilen yüksek çözünürlüklü hiperspektral görüntülerden spektral kütüphaneleri kullanarak kentsel alanlardaki su kütlelerinin çıkartılması konusunda çalışmışlardır. Çalışmada su kütlelerinin tespit edilmesinde geleneksel NDWI gibi su indekslerinin yerine ASTER ve ECOSTRESS spektral kütüphanelerinden derlenen dalga boyu aralıkları kullanmışlardır. Üç farklı bölgede seçilen çalışma alanlarında yakın kızılötesi ve kısa dalga kızılötesi bantlardan



faydalanarak geliřtirdikleri yöntem ile su kütlelerinin tespitinde %80'e varan doğruluklara ulaşmışlardır. Önerilen yöntemin su kütlesinin yüzeyinin bitki örtüsü ile kaplanması durumunda başarısız olduğunu belirtmişlerdir.

Literatür incelemesi sonucunda su kütlelerinin tespit edilmesinde kullanılan yaklaşımlar, nokta bulutu tabanlı ve raster tabanlı olmak üzere kategorize edilebilir. Nokta bulutu tabanlı yaklaşımlar genel olarak nokta bulutunun elde edildiğı LiDAR sisteminin kullandığı dalga boyunun su ile olan etkileşimi sonucu ortaya çıkan boşluklardan faydalanmaktadır. Su penetrasyon yeteneklerinden dolayı batimetrik ve hidrolojik çalışmalarda yaygın olarak faydalanılan yeşil dalga boyundaki lazer ışınlarını kullanan LiDAR sistemleri için RANSAC ve benzeri algoritmalar ile düzlem tespitine yönelik yaklaşımlar geliştirilmiştir. Nokta bulutlarından su kütlesi tespitine yönelik bu yaklaşımlar, farklı topoğrafik koşullar ve algılayıcı sistemler kullanılması durumunda başarısız olacaktır. Raster tabanlı olarak su kütlelerinin tespitinde ise yaygın olarak multispektral (MS) ve hiperspektral uydu görüntüleri kullanılan sınıflandırma yaklaşımları benimsenmiştir. Özellikle hiperspektral görüntüler ele alındığında, bu görüntülerin mekânsal çözünürlüklerinin düşük olması kullanım alanını büyük ölçekli çalışma alanlarındaki büyük su kütlelerinin tespiti ile kısıtlamaktadır. Bu çalışmada, ülkemizde topoğrafik haritaların üretiminde yaygın olarak kullanılan dijital hava fotoğraflarından su kütlelerinin tespitine ve hidrolojik düzleştirilmesine yönelik bir yaklaşım geliştirilmiştir. Geliştirilen yaklaşım ile farklı topoğrafik, bitki örtüsü ve yapılaşma özelliklerine sahip çalışma alanlarında fotogrametrik teknikle elde edilmiş görüntülerden ve LiDAR teknolojisi ile üretilen nokta bulutlarından otomatik olarak tespit edilen su kütleleri üzerinde hidrolojik düzleştirme işlemi gerçekleştirilmiştir. Literatürde görülen diğer çalışmalardan farklı olarak su kütlelerinin tespitinde LiDAR nokta bulutunda oluşan boşluklardan ya da MS görüntülerden üretilebilecek olan NDVI, NDWI vb. indislerden yararlanılmamıştır. Bunun yerine su kütlelerinin tespitinde, nokta bulutundan 3B yapı tensörü ile üretilen yerel geometrik öznitelikler ve nokta bulutlarında hali hazırda bulunan spektral bilgiler kullanılmıştır. Ayrıca, Relief-F algoritması kullanılarak öznitelik seçim işlemi gerçekleştirilmiş ve bu sayede farklı alanlardaki su kütlelerinin ayırt edilmesinde en etkili olan öznitelikler tespit edilmiştir. Bunun yanı sıra, öznitelik haritalarında birbirine yakın öznitelik değerlerine sahip olan homojen bölgeler SLIC algoritması ile oluşturulmuş ve sınıflandırma işleminde kullanılmıştır. Bu sayede, sınıflandırma işlemin karşılaşılan hatalı tespitler azaltılırken aynı zamanda sınıflandırma için harcanan süre kısaltılmıştır.



Sınıflandırma sonucunda elde edilen su kütlesi sınırları kullanılarak MATLAB ortamında kodlanan fonksiyonlar ile hidrolojik düzleştirme işlemi gerçekleştirilmiştir. Çalışma alanlarının her biri için hesaplanan F-Ölçütü (F-Score), Doğruluk (Correctness), Bütünlük (Completeness) ve Kalite (Quality) ölçütlerinin ortalama değerleri; Çalışma Alanı-1 için sırasıyla %85,7, %99,7, %96,7 ve %96,4, Çalışma Alanı-2 için sırasıyla %93,7, %99,6, %95,9 ve %95,5, Çalışma Alanı-3 için sırasıyla %94,9, %97,9, %95,4 ve %93,5, Çalışma Alanı-4 için sırasıyla %73,6, %95,3, %94,3 ve %90,1 olarak tespit edilmiştir. Su kütlelerinin tespitine yönelik geliştirilen yaklaşım ile elde edilen doğruluk analizi sonuçlarının literatürdeki güncel yaklaşımlar ile genel doğruluk değerleri üzerinden gerçekleştirilen kıyaslaması Tablo 1’de verilmiştir.

Tablo 1. Sınıflandırma sonucu doğruluk analizlerinin literatürde bulunan çalışma sonuçları ile kıyaslanması

Veri Türü	Yöntem	Yazar	Genel Doğruluk
MS LiDAR nokta bulutu	MLC	Shaker vd., 2019	%99,80
MS uydu görüntüsü	Mask R-CNN Derin Öğrenme	Song vd., 2020	%94,40
RGB, TIR görüntüler ve LiDAR nokta bulutu	MLC	Tymków vd., 2019	%99,80
RGB görüntü ve LiDAR nokta bulutu	RO	Roelens vd., 2018	%89,00
RGB görüntüden üretilen nokta bulutu ve LiDAR nokta bulutu	RO	Önerilen yaklaşım	%99,70

1.1.3. Çalışmanın Amacı

Bu çalışma ile HGM tarafından desteklenen öncelikli araştırma konularından “Sayısal Yüzey Modeli ve Sayısal Arazi Modeli Su Kütlelerinin Otomatik Düzeltilmesi” başlığına katkıda bulunulmuştur.

Nokta bulutu tabanlı öznetelik haritaları sayesinde farklı algılayıcılar ile üretilen nokta bulutlarındaki su kütlelerinin geometrik özellikleri karakterize edilmiş ve bu özellikler sayesinde farklı çevresel ve topoğrafik koşullara sahip alanlardaki su kütlelerinin otomatik olarak tespit edilmesi sağlanmıştır. Bu sayede, geliştirilen yaklaşım su kütlelerinin tespit edilmesinde yaygın biçimde kolaylıkla uygulanabilecektir.



Çalışmada, LiDAR tekniği veya stereo hava fotoğraflarından üretilen SYM'deki su kütlelerinin otomatik olarak düzeltilmesi amaçlanmaktadır. Bu düzeltme işlemi ile SYM'nin topografik açıdan doğru bir şekilde gösterimi sağlanmış ve bu sayede üretilen SAM'dan elde edilen eşyükselti eğrileri klasik topografik haritalar ile aynı doğrulukta elde edilebilir hale getirilmiştir.

Hidrolojik düzleştirme işlemleri MATLAB yazılımında, HGM tarafından sağlanan raster ya da nokta bulutu formatındaki YM veya SAM ile “göl”, “dere” ve “deniz” alanlarının otomatik olarak tespit edilen sınırları kullanılarak gerçekleştirilmiştir.

1.2. Çalışmada Kullanılan Yöntemler

Bu bölümde, yapılan tez çalışması kapsamında kullanılan teknoloji ve yöntemler açıklanmıştır. İlk olarak, havadan ve yerden çekilen fotoğraflardan metrik bilgilerin elde edilmesine yönelik temel modeli içeren Fotogrametri biliminden ve matematik temellerinden bahsedilmiştir. Ardından, fotogrametrik yoğun nokta bulutu üretiminde kullanılan matematik model ve nokta bulutlarının filtrelenmesinde kullanılan algoritma açıklanmıştır. Devamında, SYM kavramı ve bunun alt ürünleri olan SAM ve YM ile ilgili bilgiler verilmiştir. Ardından, nokta bulutlarında her bir noktanın yerel komşuluğundaki geometrik özniteliklerin elde edilmesinde kullanılan 3B yapı tensörü, komşuluk türleri ve komşuluk boyutunun seçimi ile ilgili detaylar açıklanarak sunulmuştur. Yedinci alt başlıkta, sınıflandırma işleminde kullanılacak en etkili özniteliklerin seçilmesinde kullanılan Relief-F yöntemi anlatılmıştır. Sekizinci alt başlıkta, SAM'dan akış yönü ve akış toplanma alanlarının hesaplanmasında kullanılan yöntemler anlatılmıştır. Dokuzuncu alt başlıkta, geometrik öznitelikler, akış toplanma alanları ve renk bilgileri raster formatta birleştirilerek oluşturulan öznitelik haritalarının SLIC algoritması ile süper piksel segmentasyonu açıklanmıştır. Onuncu alt başlıkta, su kütlelerinin tespitinde kullanılan RO sınıflandırıcısı ile öznitelik haritalarının sınıflandırılması ile ilgili bilgiler verilmiştir. Onbirinci alt başlıkta, sınıflandırma doğruluklarının hesaplanmasında kullanılan F-Ölçütü, Doğruluk, Bütünlük ve Kalite ölçütleri tanıtılmıştır. Son olarak, sınıflandırma sonucunda elde edilen su kütleleri kullanılarak gerçekleştirilen hidrolojik düzleştirme işlemi ve bu işlemde kullanılan yöntemler detaylandırılmıştır.




1.2.1. Fotogrametri

Amerikan Fotogrametri ve Uzaktan Algılama Topluluğu'na (ASPRS) göre, “Fotogrametri, elektromanyetik ışıma görüntülerinin ve diğer fenomenlerin fotoğrafik görüntülerini ve modellerini kaydetme, ölçme ve yorumlama süreci yoluyla fiziksel nesneler ve çevre hakkında güvenilir bilgi elde etme bilimi ve teknolojisidir” (Aber vd., 2010). Fotogrametri neredeyse fotoğrafın kendisi kadar eskiye dayanmakta olan bir alandır. Yaklaşık olarak 150 yıl önce Fotogrametri'nin temelleri atıldıktan sonra hızlıca gelişerek analog, optik-mekanik ve analitik yöntemleri geride bırakarak hiçbir optik mekanik donanımına ihtiyaç duymayan ve tamamen dijital görüntülerden bilgisayarla görme yaklaşımlarının uygulandığı bir alan haline gelmiştir. Fotogrametri, öncelikle üç boyutlu nesnelerin ve arazi özelliklerinin iki boyutlu fotoğraflardan hassas ölçümlerini yapmakla ilgilenir. Fotogrametri'nin uygulama alanları arasında, koordinatların ölçülmesi, mesafelerin, yüksekliklerin, alanların ve hacimlerin ölçülmesi, topoğrafik haritaların hazırlanması, sayısal yükseklik modelleri ve ortofotoların oluşturulması yer almaktadır (Baltsavias, 1999; Aber vd., 2010).

Günümüzde Fotogrametri alanında kullanılan algılayıcı sistemlerine bağlı olarak pek çok hava ve kara platformlarından faydalanılmaktadır. Fotogrametri'de kullanılan algılayıcı sistemler, aktif ve pasif algılayıcılar olmak üzere ikiye ayrılabilir. Pasif algılayıcılar, elektromanyetik spektrumun kırmızı, yeşil, mavi ve bazı algılayıcılarda yakın kızılötesi dalga boylarında kayıt yapan, kullanılan algılayıcı sistemin boyutlarına göre; büyük, orta ve küçük formatlı kameralardır. Büyük formatlı kameralar, tek başlarına ağır olmalarının yanı sıra destek ekipmanları (GPS, INS ve kontrol bilgisayarı) ile birleştirildiklerinde ancak çift motorlu uçaklar tarafından taşınabilen ve yüksek odak uzaklıklarından (150-300 mm arasında) dolayı genel olarak 3000 ila 12000 m arasında değişen uçuş yüksekliklerinde, büyük mühendislik projeleri veya bölgesel haritalama amaçlı olarak kullanılır (Şekil 2) (Jacobsen, 2010).





Şekil 2. Büyük formatlı dijital hava kamerası; a) Vexcel UltraCam Eagle Mark 3, b) Kamera sabiti ve uçuş yüksekliklerine göre çerçeve boyutları (URL-1, 2021)


Hafif tek motorlu uçaklar ve İHA platformlarına entegre edilebilen orta formatlı kameralar, daha kısa odak uzaklıklarından dolayı (50-150 mm arası) daha düşük uçuş yüksekliklerinde (800-2000 m) inşaat alanları ve şehir haritalarının oluşturulması gibi uygulamalarda yaygın olarak kullanılırlar (Jacobsen, 2010). Çoğunlukla İHA platformlarına entegre edilen küçük formatlı kameralar, fotoğrafçılar tarafından kullanılan pek çok farklı odak uzaklıklarında değiştirilebilir lenslere sahip kameralardır ve yaygın olarak büyük ölçekli (20-500m uçuş yüksekliği) modelleme ve haritalama işlerinde kullanılırlar. Günümüzde, gelişen teknoloji ve kullanıcı ihtiyaçlarına paralel olarak boyutları küçülen ve yaygınlaşan LiDAR ve RADAR gibi aktif algılayıcılar da İHA platformlarına entegre edilebilmektedir (Şekil 3) (Bandini vd., 2020).



Şekil 3. RGB ve LiDAR algılayıcı taşıyabilen bir İHA platformu (Wallace vd., 2016)




Geçtiğimiz yıllarda, dünya yüzeyinin 3B haritalanmasında sağladığı yüksek doğrulukta yoğun nokta bulutları sayesinde LiDAR teknolojisi fotogrametrik projelerde önemli bir yere sahip olmuştur. LiDAR algılayıcı sistemler temelde, algılayıcıdan gönderilen bir lazer pulsunun objeye çarpıp algılayıcıya geri dönmesi arasındaki zaman farkından faydalanarak algılayıcı ile obje arasındaki mesafenin ölçülmesi prensibine dayanmaktadır. LiDAR ile birlikte taşıyıcı platforma entegre edilen GPS ve INS'den elde edilen konum ve dönüklük parametrelerinden faydalanılarak her bir lazer pulsunun X, Y ve Z koordinatları hesaplanabilmektedir. LiDAR, aynı zamanda dönen her bir lazer pulsunun yoğunluğunu (intensity) ve pulsun yol boyunca etkileşime girerek oluşturduğu çoklu dönüşleri de kaydedebilmektedir (Şekil 4) (Habib, 2017).



Şekil 4. LiDAR algılayıcıların ölçüm prensibi (Habib, 2017)

Günümüzde, LiDAR algılayıcılar ve hava kameralarının entegrasyonu sonucunda ortaya çıkan yeni bir tür olan hibrit algılayıcılar da ticari kullanım için hazır hale gelmiştir. Hibrit algılayıcılara örnek olarak Şekil 5'te gösterilen Leica CityMapper-2, nadirde 2 adet 150 MP kamera (RGBNIR), 4 adet eğik RGB kamera ek olarak LiDAR algılayıcıya sahiptir. Hibrit algılayıcılar, yoğun yapılaşmaya sahip olan kent merkezlerinin haritalanması ve şehir modellerinin oluşturulması için pek çok kolaylık sağlayacaktır (URL-2, 2021).






Şekil 5. Hibrit algılama sistemleri; a) Leica CityMapper-2, b) RGB, NIR kameralar ve LiDAR konumu (URL-2, 2021)

1.2.2. Hava Fotoğraflarından Ortofoto Üretimi

Ortofoto, İHA kullanımının yaygınlaşması ile hava fotoğraflarına erişimin artmasına paralel olarak harita, jeoloji, ziraat, şehir planlama, çevre bilim ve Coğrafi Bilgi Sistemleri (CBS) gibi pek çok disiplin tarafından yaygın olarak kullanılan bir fotogrametrik üründür. Ortofoto üretimi, hava veya kara platformlarından elde edilen fotoğrafların merkezi projeksiyondan ve kameranın optik sisteminden kaynaklanan bozulmalar (distorsiyon), obje uzayındaki yükseklik değişimlerinden kaynaklanan yükseklik (rölyef) hataları giderilmesi ile gerçekleştirilir. Ortofoto üretiminde uygulanan fotogrametrik işlemler sonucunda geometrik olarak doğru ya da düzeltilmiş fotoğraflar elde edilir (Kraus, 2011).





Şekil 6. Ortofoto üretimi; a) resim ve obje koordinatları arasındaki ilişki (Kraus, 2011), b) geriye projeksiyon (Acar, 2018)

Ortofoto üretiminde, kamera koordinat sistemindeki görüntü matrisinin arazi koordinat sistemine dönüştürülmesi gerekmektedir (Şekil 6). Bu dönüşüm için arazi koordinat sistemindeki her bir XY noktasının Z koordinatları SYM üzerinden alınması gerekmektedir. SYM'nin doğruluğu oluşturulacak olan ortofotonun kalitesine doğrudan etki edecektir. Fotogrametrik hava fotoğraflarından ortofoto üretiminin matematik modeli izdüşüm (kolinearite) denklemleri (1) ile ifade edilir. İzdüşüm denklemleri bir görüntü noktasının ortofoto koordinatlarının hesaplanması için kullanılır ve aşağıdaki gibi ifade edilir (Kraus, 2011).

$$\begin{aligned} x &= x_0 - c \frac{r_{11}(X - X_0) + r_{12}(Y - Y_0) + r_{13}(Z - Z_0)}{r_{31}(X - X_0) + r_{32}(Y - Y_0) + r_{33}(Z - Z_0)} \\ y &= y_0 - c \frac{r_{21}(X - X_0) + r_{22}(Y - Y_0) + r_{23}(Z - Z_0)}{r_{31}(X - X_0) + r_{32}(Y - Y_0) + r_{33}(Z - Z_0)} \end{aligned} \quad (1)$$

Burada, x ve y görüntü koordinatlarını, x₀ ve y₀ asal nokta koordinatlarını, c odak uzaklığını, r_{ij} dönüklük matrisini, X₀, Y₀ ve Z₀ izdüşüm merkezinin koordinatlarını, X, Y ve Z hesaplanacak olan obje koordinatlarını temsil etmektedir.



1.2.3. Görüntü Eşleme ile Nokta Bulutu Üretimi


Günümüzde pek çok farklı algılayıcı sistem ve yöntem ile yaygın olarak üretilmekte olan 3B nokta bulutları, bina, ağaç ve enerji nakil hatlarının çıkarımı, şehir içlerindeki yol ve kaldırımların tespit edilmesi, şehir modellerinin oluşturulması ve robotikte semantik segmentasyon gibi pek çok alanda yaygın olarak kullanılmakta olan bir veri türüdür (Weinmann vd., 2015; Akbulut vd., 2018; Acar vd., 2019).

LiDAR algılayıcılar nokta bulutlarını doğrudan üretirken, 2B fotogrametrik görüntülerden nokta bulutu üretilmesi için stereo eşleme algoritmalarına ihtiyaç duyulmaktadır. Günümüzde Yarı Global Eşleme (SGM), fotogrametri alanında yaygın olarak kullanılan stereo eşleme algoritmalarından biridir. SGM algoritmasının temelinde iç ve dış yönelmesi bilinen resim çiftlerinin, epipolar çizgiler yardımı ile piksel tabanlı olarak eşlenik noktalarının bulunması ve bu noktaların 3B koordinatlarının triangulasyon ile hesaplanması temeline dayanmaktadır (Hirschmüller, 2008; Hirschmüller, 2011; Xu vd., 2020). Daha sonra stereo çiftlerin her birinden oluşturulan derinlik haritaları (depth maps) birleştirilerek 3B obje uzayı oluşturulur (Hirschmüller, 2011; Acar vd., 2019). SGM algoritması radyometrik değişimlerden ve seçilen parametrelerden bağımsız olarak nokta eşleme yapabilmektedir (Hirschmüller, 2008). SGM algoritması, Şekil 7’de gösterildiği gibi görüntü boyunca her bir piksel ile buluşan 8 yoldan ilerler ve (2) numaralı maliyet fonksiyonunu kullanarak 1B olarak optimizasyon gerçekleştirir (Hirschmüller, 2011; Acar vd., 2019).

$$E(D) = \sum_p \left(C(p, D_p) + \sum_{q \in N_p} P_1 T[|D_p - D_q| = 1] + \sum_{q \in N_p} P_2 T[|D_p - D_q| > 1] \right) \quad (2)$$


Burada, $E(D)$ derinlik haritası D ’ye bağlı olarak hesaplanan enerjiyi ve $C(p, D_p)$ tüm p pikselleri için D ’ye bağlı olarak eşleştirme maliyetini tanımlamaktadır (Hirschmüller, 2011; Acar vd., 2019). Her bir yol, bir piksele belirli bir miktar eşleşmeme (disparite) ile ulaşmak için gereken maliyeti hesaplar. Her bir piksel ve eşleşmeme için 8 yoldan elde edilen maliyetler toplanır ve en küçük maliyete sahip olan yol tercih edilir (Hirschmüller, 2011; Acar vd., 2019; Xu vd., 2020).





Şekil 7. 8 farklı yönlü optimizasyon yolu ile en doğru eşleşme (Hirschmüller, 2011)

SGM algoritmasında kullanılan epipolar geometri (Şekil 8), stereo resim çiftlerinden eşlenik noktaların bulunması için kullanılan, resim çifti arasındaki içsel projektif geometridir. Stereo resim çifti arasındaki epipolar geometri, esasen, eksen olarak taban çizgisine sahip olan düzlem çizgisi ile görüntü düzlemlerinin kesişiminin geometrisidir (taban çizgisi, kamera merkezlerini birleştiren çizgidir). Obje geometrisinden bağımsızdır ve yalnızca kameraların iç yöneltme parametrelerine ve bağıl pozuna bağlıdır (Hartley ve Zisserman, 2004).



Şekil 8. Nokta eşleme ve epipolar geometri (Hartley ve Zisserman, 2004)

Şekil 8 (a)'da, C ve C' iki kamera merkezi ve düzlemini ifade eder. Kamera merkezleri, 3B uzaydaki X noktası ve bu noktanın her iki görüntüdeki izdüşümleri olan x ve x' noktaları ile birlikte π düzleminindedir. Şekil 8 (b)'de bir görüntü noktası olan x , ilk



kamera merkezi C ve x tarafından tanımlanan 3B uzayda bir ışına geri yansıtılır. Bu ışın, ikinci görüntüde l' ile ifade edilen bir çizgi olarak görüntülenir. X'e yansıyan 3B uzaydaki X noktası bu ışın üzerinde yer almalıdır, bu nedenle ikinci görüntüdeki X'in görüntüsü l' üzerinde olmalıdır (Hartley ve Zisserman, 2004).

Sadece x'in bilindiği varsayımında bulunarak, karşılık gelen x' noktasının nasıl kısıtlandığı sorgulanabilir. Düzlem π , taban çizgisi ve x ile tanımlanan ışın tarafından belirlenir. Şekil 8'den, (bilinmeyen) x' noktasına karşılık gelen ışının π düzleminde bulunduğunu, dolayısıyla x' noktasının, ikinci görüntü düzlemi ile kesişme çizgisi olan l' üzerinde bulunduğu bilinmektedir. Bu l' çizgisi, x'ten geri yansıtılan ışının ikinci görüntüdeki görünümüdür. Bu çizgi, x'e karşılık gelen epipolar çizgidir. Bunun stereo uygunluk algoritması açısından faydası, x'e karşılık gelen nokta için aramanın tüm görüntü düzlemini kapsamaması gerekmediğinden l' çizgisiyle sınırlandırılabilmesidir (Hartley ve Zisserman, 2004).

Bir stereo resim çifti verildiğinde, Şekil 8'den de görüleceği üzere bir görüntüdeki her bir x noktasına, diğer görüntüde karşılık gelen bir epipolar çizgi l' bulunmaktadır. İkinci görüntüdeki x noktasıyla eşleşen herhangi bir x' noktası epipolar çizgi l' üzerinde yer alacaktır. Epipolar çizgi, birinci kamera merkezi C'den geçen x noktasının ışının ikinci görüntüdeki izdüşümü olacaktır. Buradan hareketle, epipolar geometrinin cebirsel tanımı olan temel (fundamental) matris F (5) nolu eşitlik, kamera projeksiyon matrisleri olan P ve P' ise sırasıyla (3) ve (4) nolu formüller yardımı ile hesaplanabilir (Hartley ve Zisserman, 2004).

$$P = K[I \mid 0] \quad (3)$$

$$P' = K'[R \mid t] \quad (4)$$

$$F = [e']_x K' R K^{-1} \quad (5)$$

Burada, K birinci kamera matrisini, K' ikinci kamera matrisini, I birim matrisi, R ikinci kameranın birinci kameraya bağlı olarak dönüklüklerini, t ikinci kameranın öteleme bilgilerini ve e' ikinci kameradaki birinci kameranın epipolar çizgisinin izdüşümünü temsil etmektedir. Böylelikle stereo resim çifti arasındaki eşlenik noktaların her birinin 3B uzaydaki koordinatları hesaplanabilir. Günümüzde, hava ya da kara platformlarından elde edilen görüntülerden Alan Büyütme (Region Growing), Yerel Eşleme (Local Matching) ve



SGM algoritmaları ile nokta bulutu üreten açık kaynak kodlu veya ticari yazılımlardan bazıları aşağıda Tablo 2’de verilmiştir.

Tablo 2. Fotoğraflardan 3B nokta bulutu üretiminde kullanılan yazılımlar ve nokta eşleme algoritmaları (Acar, 2018)

Yazılımın Adı	Kullanım İzni	Algoritma
Agisoft PhotoScan	Ticari	LM
Concept Capture	Ticari	-
Correlator	Ticari	-
Dense Matcher	Ticari	SGM
Erdas Imagine	Ticari	SGM
E-foto	Açık Kaynak Kodlu	-
Keystone	Ticari	SGM
MATLAB	Ticari	LM
MicMac	Açık Kaynak Kodlu	LM
MVE	Açık Kaynak Kodlu	RG
Photo Modeler	Ticari	-
Pix4D	Ticari	LM
Pixel Factory	Ticari	-
PMVS	Açık Kaynak Kodlu	LM
RSG	-	SGM
SocetSet	Ticari	LM
SURE	Ticari	SGM


1.2.4. Nokta Bulutlarının Filtrelenmesi

Günümüzde, nokta bulutlarından zemin ve zemin üstü (bina, ağaç, elektrik direği vs.) noktaların tespit edilerek çıkartılması amacıyla kullanılan pek çok filtreleme yöntemi bulunmaktadır (Parrot ve Ramírez Núñez, 2016; Han vd., 2017). Filtreleme yöntemleri; yüzey tabanlı filtreleme, eğime tabanlı filtreleme, kümeleme ve bölütleme ve minimum blok tabanlı filtreleme olmak üzere dört kategoriye ayrılmaktadırlar. Yüzey tabanlı filtreleme yöntemleri de morfoloji tabanlı filtreleme, iteratif enterpolasyon tabanlı filtreleme ve aşamalı yoğunlaştırma tabanlı filtreleme yöntemleri olarak üçe ayrılır (Dong vd., 2018). Yüzey tabanlı filtreleme algoritmaları arasında, Axelsson (2000) tarafından önerilen aşamalı TIN yoğunlaştırma (PTD) yöntemi, yer noktalarının ve yer olmayan



noktaların ayrılmasındaki başarısı ve etkinliği nedeniyle yaygın olarak kullanılmaktadır (Dong vd., 2018; Acar vd., 2019).

PTD yöntemi, başlangıçta belirlenen çekirdek noktalarından oluşturulan bir TIN'in iteratif olarak sıklaştırılması üzerine kuruludur (Axelsson, 2000; Dong vd., 2018; Ramiya vd., 2019). Çekirdek noktaları, kullanıcı tarafından tanımlanan bir griddeki en düşük yüksekliğe sahip noktalardır (Şekil 9). Grid boyutu, çalışma alanındaki maksimum bina boyutuna göre belirlenir. Tespit edilen çekirdek noktaları ilk TIN'i oluşturmak için kullanılır. Çekirdek noktalarının seçiminden önce nokta bulutundan aykırı noktaların temizlenmesi gerekir. Böylece seçilen çekirdek noktaları arasında aykırı değerler kalmaz.



Şekil 9. PTD algoritması ile nokta bulutunun filtrelenmesi (Axelsson, 2000); a) PTD algoritması ile yer ve yer üstü noktaların ayrılması, b) çekirdek noktalarından üretilen TIN, c) TIN yoğunlaştırma

TIN'in iteratif olarak yoğunlaştırılmasında, her bir iterasyon için yoğunlaştırma parametreleri TIN'e ait olan zemin noktaları kullanılarak hesaplanır. Eğer sınıflandırılmamış bir P noktasının, B_1 , B_2 ve B_3 noktaları ile oluşturulan TIN yüzeyine hem açı (α_1 , α_2 ve α_3) hem de mesafe değerleri hesaplanan yoğunlaştırma parametrelerinin altındaysa, bu nokta TIN'e eklenir (Şekil 9a). Bu işlem, tüm noktalar yer veya yer üstü olmak üzere bir sınıf değeri alana kadar devam eder (Axelsson, 2000).



1.2.5. Sayısal Yükseklik Modelleri


Sayısal Yükseklik Modelleri, 3B dünya yüzeyine ait yükseklik bilgilerini temsil eden grafik bir gösterim biçimidir. SYM, bazen SAM ile eşanlamlı olarak kullanılan, ancak gerçekte hem SAM'ı hem de YM'yi tanımlamak için kullanılan bir şemsiye terimdir. SAM'lar çıplak arazi yüzeyini temsil ederken, YM bitki örtüsünün (ağaçlar vb.) ve insan yapımı detayların (binalar vb.) yüksekliklerini tanımlar (Şekil 10). YM'ler raster formatta bulunabileceği gibi vektör tabanlı TIN yüzeyler olarak da üretilmektedir (Shingare ve Kale, 2013; Hirt, 2015).



Şekil 10. SAM ve YM gösterimi (Pula vd., 2019)

SAM, 2B noktalar üzerinde benzersiz yükseklik değerlerine sahip örneklem noktaları ile sürekli arazi yüzeyinin bir kısmını veya tamamını yaklaşık olarak modeller (Şekil 11). Yükseklikler, arazi noktaları ile bazı referans yüzeyler (örneğin, ortalama deniz seviyesi, jeoid ve elipsoid) veya jeodezik referans arasındaki yaklaşık dikey mesafelerdir. Çoğunlukla raster gridleri olarak düzenlenmiş olan 2B noktalar tipik olarak jeodezik koordinatlar (enlem ve boylam) veya düzlemsel koordinatlar (kuzey ve doğu değerleri) olarak verilir. SAM'lar genellikle her 2B noktaya tek bir benzersiz yükseklik değeri atar, bu nedenle dikey arazi özelliklerini (örneğin uçurumlar) tanımlayamaz. SAM'lar bu nedenle arazinin gerçek 3B modellerinden ziyade 2,5B'dir (Weibel ve Heller, 1991; Hirt, 2015).





Şekil 11. LiDAR nokta bulutundan üretilen a) YM, b) SAM

1.2.6. Nokta Bulutlarından Geometrik Özniteliklerin Çıkartılması

3B sahne analizi ile nokta bulutlarından, yerel komşuluklardaki değişimlerin karakterize edilmesi amacıyla geometrik özelliklerin çıkartılması sağlanır (Pauly vd., 2003). Bu bağlamda, 3B sahne analizi genel olarak üç adımdan oluşmaktadır; (1) her bir noktanın yerel komşuluğunun oluşturulması, (2) her bir noktanın yerel komşuluğundaki noktalara bağlı olarak geometrik özniteliklerinin çıkartılması ve (3) çıkartılan özniteliklere bağlı olarak noktaların sınıflandırılması (Pauly vd., 2003; Weinmann vd., 2015; Blomley vd., 2016). Bu adımlara, çıkartılan özniteliklerden hangilerinin yapılan çalışma için en anlamlı öznitelikler olduğunun belirlenmesi için öznitelik seçimi aşaması da eklenebilir. Ancak, 3B sahnelerin karmaşık yapısı, noktaların yer örnekleme aralığındaki düzensizlikler ve yüksek boyuttaki nokta bulutlarının işlenmesinde gereken yüksek işlem gücü bu tarz çalışmalarda karşılaşılabilecek güçlüklerden bazılarıdır (Weinmann vd., 2015).

Nokta bulutlarından geometrik özniteliklerin çıkartılmasındaki ilk ve en önemli adım uygun komşuluk boyutunun seçilmesidir. Komşuluk boyutunun doğru seçilmemesi durumunda öznitelik haritaları objelerin ayırt edici özelliklerini belirleyemeyecek ve bu da



sınıflandırma aşamasında düşük doğrulukta sonuçlar elde edilmesine neden olacaktır. Burada, raster verilerdeki gibi düzenli bir yapıda olmayan nokta bulutlarında yerel komşulukların nasıl oluşturulması gerektiğinden de bahsedilmelidir. Nokta bulutları genel olarak her bir noktanın X, Y ve Z (bunlara ek olarak fotogrametrik nokta bulutlarında renk bilgisi, LiDAR nokta bulutlarında yoğunluk, kaydedilen atım sayısı, tarama yönü vb. bilgiler de içermektedir) koordinatlarını içeren düzensiz bir liste olarak tanımlanabilir. Böylesi bir veride her bir noktanın yerel komşularının tek tek tespit edilmesi zaman alıcı ve verimsiz bir yaklaşım olacaktır. Bundan dolayı yerel komşulukların oluşturulmasında, mekânsal topolojik ilişkileri oluşturmada hızlı ve efektif bir yöntem olan Kd-tree'den faydalanılmıştır. Kd-tree ile oluşturulan yerel komşuluklar, hem en uygun komşuluk boyutunun tespit edilmesi hem de nokta bulutlarından özniteliklerin çıkartılması adımlarında kullanılmıştır. Nokta bulutlarından geometrik özniteliklerin çıkartılmasında ve en uygun komşuluk seçiminde yerel komşuluktaki 3B uzaydaki değişimleri tanımlayan 3B yapı tensöründen faydalanılmıştır. 3B yapı tensörü, yerel komşuluktaki mekânsal değişimleri ile oluşturulan kovaryans matrisinin özdeğerleri üzerinden tanımlar. Bu özdeğerler kullanılarak yerel komşuluk karakterize edilebilir.


1.2.6.1. Komşu Noktaların Tespit Edilmesi

Fotoğraf gibi düzenli bir yapıda bulunan raster veri yapılarının aksine düzensiz bir yapıda olan nokta bulutu verisi, açık bir geometrik dağılım bilgisine sahip değildir. Bu nedenle, örnek noktalar arasındaki mekânsal topolojik ilişkinin temsil edilmesi ve ardından en yakın komşu noktaların araştırılması gereklidir. Bu bağlamda, nokta bulutlarındaki her bir noktanın mekânsal topolojik ilişkilerinin oluşturulması ve komşuluktaki noktaların elde edilmesi amacıyla Kd-tree yöntemi yaygın olarak kullanılmaktadır. Kd-tree yöntemi, veritabanı aramaları, istatistik ve bilgisayar görüşü için yaygın olarak kullanılan bir yöntemdir. Kd-tree yöntemi Bentley (1975) tarafından geliştirilen bir ikili ağaç yöntemidir. Bu yöntem, belirli bir veri kümesini hiper düzlemlerle birçok alt bölüme bölerek büyük bir veri kümesi içinde hızlı arama yapılmasına olanak sağlar. Şekil 12'de Kd-tree yönteminin çalışma mantığının basit bir gösterimi görülmektedir.

Örnek olarak iki boyutlu dikdörtgen bir düzlemde gerçekleştirilecek sorgulamalar düşünüldüğünde, bu düzlem daha küçük alt dikdörtgenlere hiper düzlemler vasıtası ile ayrılır. Bu işlem kullanıcı tarafından belirlenen derinlik parametresine bağlı olarak



tekrarlanarak ardışık dikdörtgenler oluşturulur. Bu alt dikdörtgenler, bir işaretçi ile gösterilen yaprak düğümler olarak adlandırılır. Belirli bir nokta için, Kd-tree yöntemi, verilen noktaya en yakın yaprak düğümünü belirlemek için işaretçileri kullanarak veri kümesini hızlı bir şekilde arar.



Şekil 12. Kd-tree yönteminin görselleştirmesi (Bentley, 1975).


Şekil 12’de gösterilen 2B düzlemi merkezdeki A nodu solunda B ve sağında C nodu olmak üzere iki alt dikdörtgene bölmüştür. Belirlenen derinlik parametresine bağlı olarak her nod alt nodlara bölünmeye devam eder. Bir noktanın komşuları tespit edilmek istendiğinde Şekil 12’de gösterilen Kd-tree diyagramı takip edilerek aranan komşu noktalara ulaşılabilir. Kd-tree yöntemi, en yakın komşuları belirleyebildiği gibi aynı zamanda bir noktanın verilen arama çapı içerisinde kalan komşu noktalarını da tespit edebilmektedir. Bu çalışmada, uygun komşuluk boyutunun seçilmesi ve nokta bulutlarından öznitelik bilgilerinin çıkartılması aşamalarında yerel komşulukların oluşturulması için Kd-tree yönteminden faydalanılmıştır.

1.2.6.2. Uygun Komşuluk Boyutunun Seçilmesi

Öznitelik haritalarının oluşturulmasında, sınıflar arasındaki ayrımı belirgin hale getirebilmek için seçilen yerel komşuluğun boyutu büyük öneme sahiptir (Pauly vd., 2003; Weinmann vd., 2015; Blomley vd., 2016). Bu bağlamda, yerel komşuluk boyutunun büyük seçilmesi bu komşuluktaki her bir 3B nokta yerel yüzey değişimine daha az etki edeceği için öznitelik haritalarının bir yumuşatma filtresinden geçmiş gibi daha yumuşak ve



pürüzsüz olmasına neden olacaktır (Pauly vd., 2003; Weinmann vd., 2015). Ancak öncelikli olarak komşuluk türlerinden bahsetmek gerekmektedir. Komşuluk türleri, küresel komşuluk, silindirik komşuluk ve en yakın komşuluk olmak üzere üç sınıfa ayrılabilir (Guo vd., 2015; Blomley vd., 2016). Silindirik komşulukta (N_S) ise (Şekil 13a), 3B uzaydaki tüm noktalar 2B bir düzleme indirgendikten sonra bu düzleme iz düşürülmüş bir X noktasına merkezlenen sabit bir yarıçapa sahip daire olarak tanımlanabilir (Filin ve Pfeifer, 2005). Küresel komşuluk (N_K) (Şekil 13b), 3B uzayda bulunan bir X noktasına merkezlenen sabit bir yarıçapa sahip bir küre ile oluşturulur ve bu küre içinde kalan diğer noktalar X noktasının komşuları olarak etiketlenir (Lee ve Schenk, 2002). En yakın komşuluk (N_E) küresel komşuluğa benzetmekle birlikte burada temel parametre 3B uzaydaki bir X noktasının komşuluğundaki nokta sayısıdır ve bu komşulukta noktaların merkez X noktasına verilen miktarda komşu nokta belirlenir (Linsen ve Prautzsch, 2001).



Şekil 13. Öznitelik hesabında kullanılan komşuluk türleri; a) silindirik komşuluk, b) küresel komşuluk, c) en yakın komşuluk (Guo vd., 2015)

Silindirik komşuluk (Şekil 13a), merkezdeki kırmızı noktanın S ile çapı belirlenen silindirin içinde kalan noktalar komşularıdır. Küresel komşuluk (Şekil 13b), S ile çapı verilen kürenin içinde kalan noktalar kırmızı merkez noktanın komşularıdır. En yakın komşuluk (Şekil 13c), turuncu ile gösterilen noktalar merkezdeki kırmızı noktanın en 5 yakın komşusudur (Guo vd., 2015).

Nokta bulutunda komşuluk boyutu seçilirken uygulanabilecek en basit yaklaşım, kullanılan nokta bulutunun karakteristiği hakkında iyi bir bilgiye sahip olunması durumunda deneysel olarak tespit edilen sabit bir komşuluk boyutunun verilmesidir. Ancak böylesi bir yaklaşım çalışma alanına dair öncül bilgiye sahip olmayı gerektirir ve otomasyon sağlanması açısından yetersizdir. Komşuluk boyutunun doğru bir şekilde



belirlenebilmesi için (6) nolu formül ile ifade edilen 3B yapı tensörü S 'den faydalanılabilir (Pauly vd., 2003; Blomley vd., 2016).

$$S = \frac{1}{k+1} \sum_{i=0}^k (X_i - \bar{X}) (X_i - \bar{X})^T \quad (6)$$

Burada, belirli bir 3B nokta $X = X_0$ için en yakın k adet komşusu ile birlikte 3B bir kovaryans matrisi oluşturulur. Geometrik merkez olan $\bar{X}$ aşağıdaki (7) numaralı formül ile ifade edilir ve komşuluk merkezi olan X_0 noktasından biraz daha farklı bir konumda olabilir (Weinmann vd., 2015).

$$\bar{X} = \frac{1}{k+1} \sum_{i=0}^k X_i \quad (7)$$

3B yapı tensörü simetrik pozitif tanımlı bir matrisi temsil ettiği için negatif olmayan ve ortogonal bir sistemde üç adet özdeğeri vardır (Weinmann vd., 2015; Blomley vd., 2016). Burada özvektörler dikkate alındığında beklenen bir değişim olmadığı varsayılması durumunda yapı tensörünün genel durumunda rankı 3 olacaktır. Sonuç olarak, reel sayılar kümesine ait olan λ_1, λ_2 ve λ_3 olmak üzere üç özdeğer ($\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq 0$) ana eksenleri üzerindeki bir 3B elipsoidin sınırlarını temsil etmektedir (Weinmann vd., 2015). Bu sayede, özdeğerlerden faydalanılarak yerel 3B şekil karakterize edilebilir (Weinmann vd., 2015; Blomley vd., 2016).

Komşuluk boyutu seçimi bağlamında bakıldığında, literatürde yapı tensörünün özdeğerlerinden faydalanan üç adet yaklaşım önerilmiştir (Weinmann vd., 2015). İlk olarak, yerel yüzey değişiminin tespiti için yapı tensörünün özdeğerleri kullanılarak (8) nolu formülü ile hesaplanan eğriselliğin değişiminden faydalanılmıştır (Pauly vd., 2003). Burada, başlangıç için seçilen komşuluk boyutu C_λ değişiminde kayda değer bir artış olana kadar iteratif olarak artırılır. C_λ değerindeki ani sıçrayışlar komşuluğun normal yönünde ciddi değişimler olduğunu göstermektedir (Pauly vd., 2003; Weinmann vd., 2015).

$$C_\lambda = \frac{\lambda_3}{\lambda_1 + \lambda_2 + \lambda_3} \quad (8)$$

İkinci olarak, özdeğerlerden 1B, 2B ve 3B boyutsallık öznitelikleri olan doğrusallık L_λ (9) nolu formül, düzlemsellik P_λ (10) nolu formül ve saçılım S_λ (11) nolu formül ile



hesaplanan parametreler kullanılarak uygun komşuluk boyutu seçiminde faydalanılabilir (Demantké vd., 2012).

$$L_{\lambda} = \frac{\lambda_1 - \lambda_2}{\lambda_1} \quad (9)$$

$$P_{\lambda} = \frac{\lambda_2 - \lambda_3}{\lambda_1} \quad (10)$$

$$S_{\lambda} = \frac{\lambda_3}{\lambda_1} \quad (11)$$

Yukarıda verilen parametrelere ek olarak, Shannon (1948) tarafından geliştirilen Shannon entropisi (12) kullanılarak da en uygun komşuluk boyutu seçilebilir. Bunun için, farklı komşuluk boyutlarında (örneğin, en yakın 10 komşudan başlanarak maksimum 100 komşuluğa kadar komşuluk boyutu 1'er artırılır) Shannon entropisi hesaplanır. En düşük Shannon entropi'sine sahip olan komşuluk boyutu istenen ayırt edici özneliklerin oluşturulmasını sağlayacaktır. Shannon entropisi kullanılarak tespit edilen komşuluk boyutu özneliklerin çıkartılmasında en uygun komşuluk boyutu olarak seçilir.

$$E_{\text{dim}} = -L_{\lambda} \ln(L_{\lambda}) - P_{\lambda} \ln(P_{\lambda}) - S_{\lambda} \ln(S_{\lambda}) \quad (12)$$

Üçüncü olarak, özdeğerler 3B komşuluğun düzenlilik ya da düzensizlik durumunu araştırmak için doğrudan kullanılabilir. Bu amaçla, λ_1 , λ_2 ve λ_3 olmak üzere üç özdeğer toplamları ile normalize edilir. Normalize edilmiş özdeğerler $e_i = \lambda_i / \Sigma \lambda$ ($i \in \{1,2,3\}$) ile özentropi E_{λ} ölçütü Shannon entropi'si kullanılarak formül (13)'deki gibi hesaplanır (Weinmann vd., 2015).

$$E_{\lambda} = -e_1 \ln(e_1) - e_2 \ln(e_2) - e_3 \ln(e_3) \quad (13)$$

Özentropi 3B bir komşuluktaki 3B noktaların düzenliliği veya düzensizliğini tespit etmek amacıyla kullanılır. Özentropi'nin minimize edilmesi ile yerel komşuluktaki değişim de minimize edilmiş olur ve böylelikle farklı ölçeklerde hesaplanan özentropi ile en uygun komşuluk boyutu bulunabilir (Weinmann vd., 2015; Blomley vd., 2016). Bu çalışmada en uygun komşuluk boyutunun tespit edilmesinde özentropi tabanlı yaklaşım benimsenerek,



MATLAB ortamında kodlanan nhoodsized fonksiyonu ile en uygun komşuluk boyutu seçimi gerçekleştirilmiştir.

1.2.6.3. Nokta Bulutlarından Özniteliklerin Çıkartılması

Literatürde değişken nokta yoğunluğuna sahip olan nokta bulutlarından ayırt edici özniteliklerin çıkartılmasında pek çok farklı yaklaşım kullanılmıştır. Johnson ve Hebert, (1999), belirlenen bir X noktasının çevresindeki komşuluğun karakterize edilmesi bağlamında en uygun 3B öznitelik tanımlayıcısını oluşturmak amacıyla Spin Images tanımlayıcısını önermiştir. Bu tanımlayıcı, 3B bir X noktasının yüzey normalinde düzlemsel bir görüntü parçasının döndürülerek her bir piksele kaç adet nokta düştüğünü belirleyerek yerel komşuluktaki değişimi incelemektedir. Daha güçlü bir alternatif olarak Osada vd., (2002) rastgele örneklenen geometrik ilişkileri baz alan şekil dağılımları yaklaşımını önermiştir. Bu yaklaşımda 3B bir X noktası etrafında rastgele örneklenen açı ve mesafe gibi geometrik bilgiler kullanılarak yerel komşuluğun karakterize edilmesi sağlanmaktadır (Blomley vd., 2014). Rusu vd., (2008) ve Rusu vd., (2009) çalışmalarında önerilen Nokta Öznitelik Histogramları (PFHs) isimli benzer bir yaklaşımda ise, 3B bir X noktasının en yakın komşularının X noktasının yerel normal vektörüne göre açı ve mesafe değişimleri gibi noktalar arasındaki geometrik ilişkiler bir histogram şeklinde ele alınmaktadır. Farklı olarak, Tombari vd., (2010) tarafından önerilen Signature of Histograms of Orientations (SHOT) tanımlayıcısı, 3B bir X noktaya merkezlenen küresel bir gridin ağırlıklandırılmış yüzey normali histogramını oluşturarak yerel komşuluğa ait öznitelikleri çıkartmaktadır. Buraya kadar olan yöntemler ile elde edilen öznitelik vektörleri tek başına anlamlandırılmaları güç olmaktadır (Weinmann vd., 2015).

Sonuç olarak, 3B sahne analizinde uygulanan pek çok yaklaşım, verilen 3B bir X noktasının yerel komşuluğundaki noktaların 3B koordinat değişimleri ile hesaplanan kovaryans matrisi ile temsil edilen 3B yapı tensöründen faydalanmaktadır. Jutzi vd., (2009) belirli temel geometrik ilişkilerin karakterize edilmesini sağlamak amacıyla 3B yapı tensörünün özdeğerlerinin analitik olarak değerlendirilmesini önermiştir. Ayrıca, bu özdeğerlerden faydalanılarak, günümüzde nokta bulutlarının işlenmesinde yaygın olarak kullanılan ve anlaşılması kolay olan, çizgisel, düzlemsel ve hacimsel yapılar gibi bazı yerel 3B şekil tanımlayıcılarının türetilmesi de mümkün olmaktadır (Pauly vd., 2003; West vd., 2004). Bu özniteliklere eşlik eden, açı istatistiklerinden (Munoz vd., 2009), yükseklik ve



yerel düzlem karakteristiklerinden (Mallet vd., 2011), yerel komşuluğun temel özellikleri ve 2B projeksiyonu (Weinmann vd., 2013), yüzey karakteristikleri tanımlayıcıları, eğim, yükseklik karakteristikleri, düşey profiller ve 2B projeksiyonlar (Guo vd., 2015) gibi elde edilen ek geometrik özellikler de süreçlere sıklıkla dahil edilmektedir (Weinmann vd., 2015). Bu çalışmada nokta bulutlarından özneteliklerin çıkartılmasında MATLAB ortamında kodlanan EFextract fonksiyonu kullanılmıştır.

EFextract fonksiyonu ilk olarak girdi nokta bulutunun Kd-tree ağaç yapısını oluşturur ve ardından nhoudsize fonksiyonu ile belirlenen komşuluk boyutu ve kullanıcı tarafından belirlenen komşuluk türüne bağlı olarak tüm komşu noktalarını tespit eder. Tespit edilen komşu noktaların (X_i, Y_i, Z_i) koordinatlarından, komşuluk merkezi olan noktanın (X_m, Y_m, Z_m) koordinatları çıkartılarak yerel komşuluğun koordinatları hesaplanmış olur. Yerel komşuluk koordinatlarının kovaryans matrisi hesaplandıktan sonra bu matrisin özdeğerleri hesaplanır. Bu bağlamda, yerel 3B şeklin elde edilmesi için, Doğrusallık L_λ (14), Düzlemsellik P_λ (15), Saçılım S_λ (16), Omnivaryans O_λ (17), Eşyönsüzlük (Anisotropy) A_λ (18), Özentropi E_λ (19), Özdeğerler Toplamı Σ_λ (20), Eğrisellik C_λ (21) ve bundan türetilen $CC1_\lambda$ (22) ve $CC2_\lambda$ (23) aşağıdaki formüller kullanılarak hesaplanır.

$$L_\lambda = \frac{e_1 - e_2}{e_1} \quad (14)$$

$$P_\lambda = \frac{e_2 - e_3}{e_1} \quad (15)$$

$$S_\lambda = \frac{e_3}{e_1} \quad (16)$$

$$O_\lambda = \sqrt[3]{e_1 e_2 e_3} \quad (17)$$

$$A_\lambda = \frac{e_1 - e_3}{e_1} \quad (18)$$

$$E_\lambda = -\sum_{i=1}^3 e_i \ln(e_i) \quad (19)$$

$$\Sigma_\lambda = e_1 + e_2 + e_3 \quad (20)$$

$$C_\lambda = \frac{e_3}{e_1 + e_2 + e_3} \quad (21)$$

$$CC1_\lambda = \frac{e_1}{e_1 + e_2 + e_3} \quad (22)$$



$$CC2_{\lambda} = \frac{e_2}{e_1 + e_2 + e_3} \quad (23)$$

Bunlara ek olarak EFextract fonksiyonu, kovaryans matrisinden elde edilen özvektörler ile komşuluğun X, Y ve Z yönlerindeki yüzey normalleri, alan yoğunluğu, hacim nokta yoğunluğu, komşuluktaki yükseklik değişimini gösteren ZRange, merkez noktanın komşuluktaki yükseklik sıralamasını 0 ile 1 arasındaki ölçekte gösteren ZRank, komşuluktaki standart sapma ve komşuluğun X, Y ve Z yönlerindeki varyans parametrelerini hesaplar. Tüm öznitelikler, normalize edilmiş özdeğerler kullanılarak hesaplandığı için 0-1 arasında değerlere sahiptir. Burada tek istisna özdeğerler toplamı özniteliğidir. Çünkü normalize edilmiş değerler ile hesaplanması durumunda hep 1 değerini getirdiği için normalize edilmemiş özdeğerler ile hesaplanmış ve ardından elde edilen sonuç değerlerin tüm veri seti ile uyumlu bir aralıkta olması için 0-1 aralığına ölçeklenmiştir.

1.2.7. Öznitelik Seçimi

Yeterli miktarda bilginin bulunmadığı durumlarla başa çıkabilmek için olabildiğince çok öznitelikten faydalanılması gerekmektedir. Ancak bu özniteliklerden bazıları yapılan çalışma için uygun olurken geri kalan özniteliklerin kullanılması istenen sonuçları vermeyebilir (Guo vd., 2015; Weinmann vd., 2015; Çölkesen ve Kavzoğlu, 2018). Bu bağlamda, veri madenciliği ve ya modelleme işlerinde karşılaşılan en temel güçlük, verideki bir ve ya daha fazla öznitelik arasındaki ilişkinin tanımlanması ve karakterize edilmesidir (Urbanowicz vd., 2018). Pek çok veri setinde, özniteliklerin sadece belirli bir alt kümesi sınıflandırma sonuçlarına gerçekten etki eden faydalı/ilintili özniteliklerdir. Arta kalan faydasız/ilintisiz özniteliklerse yeteri miktarda bilgi içermemekte ve veri boyutunun artmasına sebep olmaktadır (Kira ve Rendell, 1992; Urbanowicz vd., 2018). Öznitelik seçimi bütün sınıflandırma yöntemleri için uygulanması gereken en önemli birinci aşamadır çünkü artık ve ilintisiz özniteliklerin elimine edilmesine ve böylelikle de eğitim süresinin kısaltılmasına ve sınıflandırma sonuçlarının iyileştirilmesine katkı sağlar (Kira ve Rendell, 1992; Kavzoğlu vd., 2015; Weinmann vd., 2015; Urbanowicz vd., 2018; Yousefi vd., 2018).

Günümüze kadar pek çok öznitelik seçim yöntemi literatüre girmiş ve yeni yöntemlerin sürekli olarak geliştirilmeye devam etmekte olması yapılması istenen tüm işler



için evrensel bir en iyinin olmadığını göstermektedir (Urbanowicz vd., 2018). Öznitelik seçimi yöntemleri; Filtre tabanlı yöntemler, Wrapper tabanlı yöntemler ve Embedded yöntemler olmak üzere üç kategoriye ayrılabilir (Durgabai ve Bhushan, 2014; Kavzoğlu vd., 2015; Weinmann vd., 2015; Urbanowicz vd., 2018). Wrapper tabanlı ve Embedded yöntemler bir sınıflandırıcı kullanarak hangi özneliğin daha iyi tahmin yeteneği olduğu ve doğruluğu iyileştirdiğini analiz ettiği için filtre tabanlı yöntemlere göre daha iyi sonuçlar sağlamaktadırlar (Durgabai ve Bhushan, 2014; Kavzoğlu vd., 2015; Weinmann vd., 2015). Bu yöntemler öznelik seçimi yaparken, sınıflandırıcıya sürekli olarak sınıflandırma sonucunu iyileştiren ve en iyi tahmin yeteneğine sahip öznelikleri tek tek ekleyerek (sequential forward selection) ya da tüm özneliklerden sırasıyla en düşük öznelikleri çıkartarak (sequential backward elimination) öznelik çıkartım işlemini gerçekleştirirler (Weinmann vd., 2015). Ancak Wrapper tabanlı ve Embedded yöntemler kullandıkları sınıflandırıcı için en uygun öznelikleri seçmektedir ve bunun yanı sıra yüksek miktarda işlem gücüne de ihtiyaç duymaktadırlar (Durgabai ve Bhushan, 2014; Weinmann vd., 2015). Buna karşın, Filtre tabanlı yöntemler herhangi bir sınıflandırıcıya bağlı olmaksızın ve doğrudan eğitim verisine dayalı bir skor fonksiyonundan faydalanarak öznelik seçimi yapmakta ve böylece her ne kadar diğer yöntemlere göre nispeten daha düşük performans gösterse de uygulamada çok basit ve etkin sonuçlar elde edilmesine olanak sağlamaktadır (Durgabai ve Bhushan, 2014; Weinmann vd., 2015; Çölkesen ve Kavzoğlu, 2018; Urbanowicz vd., 2018;).

Relief, örnek tabanlı öğrenme yöntemlerine benzer bir şekilde öznelik ağırlıklarının belirlenmesi temeline dayanan bir algoritmadır. Relief algoritması, bir eğitim veri setinde, belirlenen bir örneklem aralığı ve uygunluk eşiğine bağlı olarak hedeflenen istatistiki olarak en uygun öznelikleri tespit eder (Kira ve Rendell, 1992). Relief algoritması ve türevleri, öznelik kombinasyonlarını araştırmak yerine en yakın komşuluk kavramından faydalanarak öznelik istatistiklerini hesaplamasından dolayı öznelikler arasındaki ilişkiyi en iyi tanımlayan filtre tabanlı yöntemdir (Kira ve Rendell, 1992; Urbanowicz vd., 2018). Relief tabanlı yöntemlerin (RTY) avantajları (Durgabai ve Bhushan, 2014; Urbanowicz vd., 2018); (1) tek değişkenli etkilerin yanı sıra karşılıklı etkileşimleri de tespit etmekte başarılı, (2) öznelik sayısındaki artışa bağlı olarak lineer bir şekilde ölçeklenebilir, eğitim örneklerinin artması ile karesel olarak ölçeklenebilir, (3) iteratif ve verimlilik yaklaşımları ile çok büyük öznelik uzayları için kolayca ölçeklenebilir, (4) pek



çok farklı veri türü ve uygulama alanı için kullanılabilecek kadar esnek bir yapıda, (5) pek çok farklı türde RTTY uygulamalarının mevcut olması şeklinde ifade edilebilir.

Bu tez kapsamında, ayırt edici özniteliklerin belirlenmesi amacıyla, Kira ve Rendell, (1992) tarafından önerilen Relief algoritmasının bir uzantısı olarak Kononenko vd., (1995) tarafından geliştirilen Relief-F algoritmasından faydalanılmıştır. Relief-F algoritması çok sınıflı, gürültülü ve eksik veri ile başa çıkabilmesi şartlı bağımlı ve bağımsız öznitelikleri ayırt edebilmesindeki yeteneği nedenlerinden dolayı tercih edilmiştir. Relief-F algoritması aynı sınıf komşularına farklı değerler veren öznitelikleri (kestiricileri) cezalandırırken, farklı sınıf komşuları için farklı değerler veren öznitelikleri ödüllendirerek her bir özniteliğin ağırlığını belirler. Başlangıçta Relief-F, tüm özniteliklerin ağırlıklarını W_j sıfıra eşitler. Ardından, rastgele bir gözlem x_r seçerek her bir sınıf için bu gözlemin en yakın komşularını x_q bulur ve aşağıdaki (24) ve (25) numaralı formülleri kullanarak ağırlıklara karar verir (Kononenko vd., 1995).

Eğer x_r ve x_q aynı sınıfta ise;

$$W_j^i = W_j^{i-1} - \frac{\Delta_j(x_r, x_q)}{m} \cdot d_{rq} \quad (24)$$

Eğer x_r ve x_q farklı sınıflarda ise;

$$W_j^i = W_j^{i-1} + \frac{p_{y_q}}{1-p_{y_r}} \cdot \frac{\Delta_j(x_r, x_q)}{m} \cdot d_{rq} \quad (25)$$

Burada, W_j^i i. işlem adımında öznitelik F_j 'nin ağırlığı, p_{y_r} x_r 'nin ait olduğu sınıfın öncül olasılığı, p_{y_q} x_q 'nin ait olduğu sınıfın önsel olasılığı, m iterasyon sayısı, $\Delta_j(x_r, x_q)$ öznitelik F_j 'nin, x_r ve x_q gözlemlerinin farkı ve son olarak d_{rq} (26) numaralı denklem ile ifade edilen mesafe fonksiyonudur.

$$d_{rq} = \frac{\bar{d}_{rq}}{\sum_{l=1}^k \bar{d}_{rl}} \quad (26)$$

1.2.8. Akış Yönü ve Akış Toplanma Alanları

Günümüzde gerçekleştirilen pek çok araştırmada SAM, yüzey akış özelliklerinin belirlenmesinde, hidrolojik modelleme çalışmalarında, mekânsal analiz çalışmalarında ve



işleme dayalı modelleme çalışmalarında yaygın olarak kullanılmaktadır (Poppenga vd., 2010; Schwanghart ve Kuhn, 2010; Rampi vd., 2014; Schwanghart ve Scherler, 2014). SAM, topoğrafya ve topoğrafik değişimleri gösteren, her bir hücresinde yükseklik değerleri barındıran grid yapısındaki coğrafi bir veri türüdür (Brooks, 2003; Schwanghart ve Kuhn, 2010). Her bir SAM hücresinin coğrafi konumu, x-y düzlemindeki projeksiyon bilgilerini içeren bir referanslandırma matrisi tarafından sağlanır. Böylelikle, her bir hücrenin koordinat bilgileri elde edilebilir ve iki hücre arasındaki iki boyutlu Öklid mesafesi (27) hesaplanabilir. Burada i ve j, SAM'daki hücrelerin lineer indekslerini temsil etmektedir (Schwanghart ve Kuhn, 2010).

$$d_{ij} = \sqrt{(X_i - X_j)^2 + (Y_i - Y_j)^2} \quad (27)$$


Hidrolojik süreçler dikkate alındığında, SAM'daki yüksekliklerin tek başlarına kullanılması yerine her bir hücredeki yüksekliklerin, komşu hücreler ile olan ilişkilerinden faydalanılmaktadır (Schwanghart ve Kuhn, 2010). Bu komşuluk ilişkileri kullanılarak üretilen en önemli verilerden bir tanesi, yerel bir temelde bir noktadaki potansiyel enerjinin ölçütü olması itibari ile eğimdir (28). Eğimin hesaplanmasında, bir hücrenin komşuluğundaki tüm hücreler arasındaki eğim hesaplandıktan sonra bu değerler içinden aşağı yönlü olan en büyük eğim değeri bulunarak bir eğim haritası oluşturulur.

$$S_{ij} = \frac{z_i - z_j}{d_{ij}} \quad (28)$$

Eğim haritaları oluşturulduktan sonraki aşamada, suyun arazi üzerindeki akışının modellenmesi için akış yönü haritalarının oluşturulması gerekmektedir. Bu konuda pek çok algoritma önerilmiş olup (Tarboton, 1997; Orlandini vd., 2003; Seibert ve McGlynn, 2007), bunlardan en önemli olan ikisi Tek Akış Yönü (SFD) ve Çoklu Akış Yönü (MFD) algoritmalarıdır (Şekil 14) (Schwanghart ve Kuhn, 2010). D8 olarak da bilinen SFD algoritması akış en büyük eğimden geçmek zorundadır ve bu da özellikle düşük yükseklik değerlerine sahip topoğrafyada gerçekçi olmayan ve tek bir bölgeye yoğunlaşmış akışların oluşmasına neden olur (Nicholas, 2005). SFD algoritmasında karşılaşılan bu problemlerin çözülmesi amacıyla MFD algoritması geliştirilmiştir. MFD algoritması, bir hücreye düşen akışı kendisinden alçakta olan komşu hücrelere paylaştırır ve böylelikle akışın



çatallanmasına veya birleşmesine olanak sağlar (Coulthard vd., 2002; Schwanghart ve Kuhn, 2010).



Şekil 14. Akış yönü algoritmaları; a) SFD algoritmasının akış yönü, b) MFD algoritmasının akış yönleri

Akış toplanma alanları SAM'dan elde edilen en önemli ürünlerden bir tanesidir ve üretilmesi için akış yönü bilgisine ihtiyaç duyulmaktadır. Akış toplanma alanlarının bulunmasında algoritmalar, topolojik ve yerel akış kurallarının uzun mesafelerdeki etkisini tespit etmek durumundadır (Schwanghart ve Kuhn, 2010). Bu algoritmalar, birbirine akış sağlayan tüm SAM hücrelerinin sayısını tespit ederek yukarı yönlü toplam drenaj alanının tespit edilmesini sağlar. Akış yönü bilgisinden faydalanılarak belirli bir hücreden çıkan akış yollarının ve yukarı yönlü toplam drenaj alanının hesaplanması mümkündür (Gallant ve Wilson, 2000; Schwanghart ve Kuhn, 2010). Sabit akış koşullarında bir SAM hücresinde birim zaman ve alandaki akış oranının 1 olduğu durumda her bir hücrede toplanan su miktarı (29) formülüne göre hesaplanır (Schwanghart ve Kuhn, 2010).

$$\frac{dx_i}{dt} = \sum_{j=0}^n f_{ij} - \sum_{j=0}^n f_{ji} = \sum_{j=0}^n m_{ij}w_i - \sum_{j=0}^n m_{ji}w_j \quad (29)$$

Burada, w_i , $i = 1, \dots, n$ 'e kadar olan hücrelerdeki tutulan su miktarını, f_{ij} , i hücresinden j hücresine olan akışı, m_{ij} ise w_i 'de tutulan suyun dağılım oranını temsil eder (Schwanghart ve Kuhn, 2010).

Dışarıdan gelen akış oranı f_{0i} (30) formülüne göre hesaplanır ve her bir zaman adımı için iteratif olarak yinelenerek toplam drenaj alanı hesaplanır.

$$\sum_{j=1}^n w_i - \sum_{j=0}^n m_{ji}w_j = f_{0i} \quad (30)$$



1.2.9. Öznitelik Haritalarının Süper Pikseller ile Bölütlenmesi

Algılayıcı teknolojilerindeki gelişime bağlı olarak küçülen piksel boyutları sayesinde uzaktan algılama ve fotogrametrik görüntülerin içerdiği piksel sayıları artmıştır. Yüksek çözünürlüklü görüntülerin sınıflandırılmasında, geleneksel piksel tabanlı yöntemler her bir pikseli birbirinden bağımsız olarak ele alarak sınıflandırma işlemini gerçekleştirdiğinden dolayı sınıflandırma doğruluğu ve süresi düşünüldüğünde zayıf kalmaktadır (Kavzoğlu vd., 2015; Kavzoğlu ve Tonbul, 2018). Günümüzde, geleneksel piksel tabanlı sınıflandırma yönteminde karşılaşılan bu sorunların giderilmesi amacıyla obje tabanlı sınıflandırma yöntemleri geliştirilmiştir. Obje tabanlı sınıflandırma yöntemleri, görüntü piksellerini bir bölütleme algoritması ile spektral olarak homojen objelere dönüştürdükten sonra oluşan her bir objeyi sınıflandırır (Liu ve Xia, 2010; Kavzoğlu ve Tonbul, 2018). Piksel tabanlı ve obje tabanlı sınıflandırma yöntemleri arasındaki fark, sınıflandırma birimi ve sınıflandırma öznitelikleri olmak üzere iki açıdan ele alınabilir. İlk olarak, sınıflandırma biriminin pikselden görüntü objelerine dönüştürülmesi sınıf içi spektral varyasyonu azaltarak piksel tabanlı yöntemde karşılaşılan tuz ve biber (salt and pepper noise) etkisini ortadan kaldırır (Liu ve Xia, 2010). İkinci olarak, sınıflandırma öznitelikleri düşünüldüğünde objelerin mekânsal, doku ve bağlamsal özelliklerinin de sınıflandırılacak objeye eklenerek sınıflandırma doğruluğunun artırılmasına katkı sağlanabilir (Liu ve Xia, 2010; Kavzoğlu ve Tonbul, 2018).

Bu bağlamda, her ne kadar nokta bulutlarının hesaplanan öznitelikler ile tek tek sınıflandırılması mümkün olsa da benzer öznitelik değerlerine sahip ve aynı zamanda mekânsal olarak birbirlerine yakın konumda bulunan noktaların kümelenmesi ile sınıflandırma işleminde daha başarılı sonuçlar elde edileceği öngörülmüştür. Bunun yanı sıra, eğitilen sınıflandırıcı daha az miktarda veri sınıflandıracağı için zamansal anlamda da kazanımların olması kaçınılmazdır. Bunun için liste formatındaki öznitelik bilgilerinden çok bantlı (her bir öznitelik için bir bant) görüntüler üretilmiş ve SLIC algoritması ile hem öznitelik hem de mekânsal olarak birbirine yakın olan görüntü segmentleri yani süper pikseller üretilmiştir. Her bir süper pikselin ortalama değeri alınarak eğitim ve sınıflandırma aşamalarında kullanılmıştır.



1.2.9.1. SLIC Süper Piksel Algoritması

SLIC süper piksel segmentasyon yöntemi, k-means kümeleme yaklaşımını baz alarak ve yaklaşık süper piksel boyutunu (k) tek parametre olarak kullanarak efektif bir şekilde süper pikseller oluşturan bir algoritmadır. Seçilen k parametresine bağlı olarak görüntü üzerinde S (31) nolu formül ile belirlenen aralıklarla örneklemeler oluşturularak küme merkezleri belirlenir (Achanta vd., 2012).

$$S = \sqrt{N_{\text{piksel}}/k} \quad (31)$$

Burada, N_{piksel} görüntüdeki piksel sayısı, k ise yaklaşık süper piksel boyutudur. Daha sonra küme merkezleri, süper pikselleri kenar ve gürültü içeren bir piksele yerleştirilmesini önlemek amacıyla, 3×3 komşuluktaki en düşük gradyana sahip olan konuma kaydırılır. Arama penceresinin küçültülerek algoritmanın performansını artırmak amacıyla, en yakın küme merkezi ile her bir piksel arasındaki mesafeyi belirleyen mesafe ölçütü D (35) formülü ile hesaplanır (Achanta vd., 2012). D'nin hesaplanması için öncelikli olarak her bir pikselin küme merkezine olan renk uzayındaki ve mekânsal uzaydaki mesafelerinin hesaplanması gerekmektedir. SLIC algoritması bir pikselin rengini temsil etmek için Uluslararası Aydınlatma Komisyonu (CIE) tarafından 1976 yılında tanımlanan CIELAB renk uzayından faydalanmaktadır (Pauli, 1976; Achanta vd., 2012). CIELAB uzayında renkler, L aydınlık siyahtan (0) beyaza (100), a yeşilden (-) kırmızıya (+) ve b maviden (-) sarıya (+) değerleri kullanılarak temsil edilir (Pauli, 1976). Renk uzayında bir pikselin küme merkezine olan mesafesi d_c (32) formülüne göre hesaplanır (Achanta vd., 2012).

$$d_c = \sqrt{(l_j - l_i)^2 + (a_j - a_i)^2 + (b_j - b_i)^2} \quad (32)$$

Burada, l_i , a_i ve b_i küme merkezinin renk bilgilerini, l_j , a_j ve b_j ise sorgulanan pikselin renk bilgilerini temsil etmektedir. Mekânsal olarak bir pikselin küme merkezine olan mesafesi d_s (33) formülü ile hesaplanır.

$$d_s = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2} \quad (33)$$



Burada, x_i ve y_i küme merkezinin sırası ile satır ve sütun numaralarını, x_j ve y_j ise sorgulanan pikselin sırası ile satır ve sütun numaralarını temsil etmektedir. Renk d_c ve mekânsal d_s uzayda hesaplanan mesafelerin etkili bir şekilde kullanılabilmesi ve hesaplama karmaşıklığının azaltılması amacıyla bu iki mesafeyi birleştiren D' ölçütü (34) formülü ile hesaplanır. Ancak bu mesafeler birleştirilirken renk ve mekânsal yakınlık ölçütlerinin, küme içerisindeki maksimum mesafeye bağlı olarak hesaplanan N_c ve N_s ölçütleri ile normalize edilmesi gerekmektedir (Achanta vd., 2012).

$$D' = \sqrt{\left(\frac{d_c}{N_c}\right)^2 + \left(\frac{d_s}{N_s}\right)^2} \quad (34)$$

Belirli bir kümedeki maksimum mekânsal mesafe N_s , S ile belirlenen örneklem aralığına karşılık gelecektir. Ancak söz konusu renk uzayı olduğunda, renk mesafeleri kümeden kümeye büyük farklılıklar gösterdiği için maksimum renk mesafesi N_c 'nin hesaplanmasında güçlüklerle karşılaşmaktadır. Bu sorunun önüne geçilebilmesi amacıyla N_c değerine sabit bir m katsayısı tanımlanarak yeni mesafe ölçütü D (35) formülü ile hesaplanmıştır (Achanta vd., 2012).

$$D = \sqrt{d_c^2 + \left(\frac{d_s}{S}\right)^2 m^2} \quad (35)$$

Yeni mesafe ölçütü D kullanılarak, her bir pikselin en yakınındaki küme merkezi belirlenecektir. Bir süper pikselin yaklaşık olarak kaplayacağı alan $S \times S$ ile belirlenirken, bir süper piksel merkezinin çevresinde en yakın benzer piksellerin aranacağı bölge $2S \times 2S$ olarak tanımlanmıştır. Bütün pikseller bir en yakın küme merkezi ile ilişkilendirildikten sonra uygulanan bir güncelleme adımıyla yeni küme merkezleri, küme içinde bulunan piksellerin hem renk uzayında hem de mekânsal uzaydaki ortalama konumu olarak güncellenir. L2 norm yöntemi kullanılarak güncel ve bir önceki küme merkezleri arasındaki fark hesaplanır ve bu fark belirlenen eşikten küçük oluncaya kadar bu adım tekrarlanır. En son adımda, bağlantılı bileşen analizi kullanılarak ayrı kalan pikseller komşusu olduğu süper piksele atanarak işlem tamamlanır (Achanta vd., 2012).



1.2.10. Özniteliklerin Sınıflandırılması

Günümüzde, uzaktan algılama ve fotogrametrik yöntemler ile elde edilen verilerin sınıflandırılmasında denetimli ve denetimsiz yöntemler olmak üzere pek çok yaklaşım kullanılmaktadır (Acharya vd., 2019). Denetimli sınıflandırıcılar, model tabanlı yöntemlere göre daha sağlam bir yaklaşım olmalarından dolayı yaygın bir şekilde tercih edilmektedirler. Denetimli sınıflandırıcılar, eğitim verileri üzerinden hedef sınıfların karakteristiklerini öğrenebilir ve daha sonra bu bilgileri sınıflandırılmamış verilerin sınıflandırılmasında kullanabilirler. İyi bir sınıflandırıcı, eğitim verilerinde karşılaşılabilen Hughes olayı yani öznitelik sayısının eğitim örneklem sayısından çok daha fazla olduğu durum, özniteliklerin nonlineer olması durumu, eğitim örneklem verilerinde sınıfların yetersiz temsili ve hem eğitim hem de sınıflandırılacak veri setinde gürültü olması durumu gibi zorlukların üstesinden gelebilmelidir. Bunun yanı sıra hızlı bir şekilde işlem yapabilmesi de gerekmektedir (Belgiu ve Drăgut, 2016).

Denetimli sınıflandırıcılar parametrik ve non-parametrik olarak ikiye ayrılmaktadır. MLC yöntemi denetimli parametrik sınıflandırıcı olarak tek tepeli (unimodal) verilerin sınıflandırılmasında çok iyi bir başarı göstermektedir. Ancak, çok tepeli (multimodal) girdi veri setleri söz konusu olduğunda parametrik denetimli sınıflandırıcılar normal dağılımı baz aldıkları için büyük sınırlamalarla karşılaşmaktadır (Kavzoğlu vd., 2015; Belgiu ve Drăgut, 2016). SVM, RO ve Yapay Sinir Ağları (YSA) gibi denetimli non-parametrik sınıflandırıcılar frekans dağılımı ile ilgili hiçbir varsayımda bulunmadıkları için nadiren normal dağılıma sahip olabilen uzaktan algılanmış verilerin sınıflandırılmasında yaygın olarak kullanılmaktadırlar (Belgiu ve Drăgut, 2016; Lary vd., 2016; Acharya vd., 2019).


1.2.10.1. Rastgele Orman Sınıflandırıcısı

Son yıllarda, uzaktan algılanmış verilerin sınıflandırılmasına toplu (ensemble) sınıflandırıcılar yaygın bir şekilde kullanılmaya başlanmıştır. Bu sınıflandırıcılar bir veya daha fazla denetimli sınıflandırıcıya bağlı olarak torbalama (bagging) veya artırma (boosting) yöntemlerini kullanarak eğitim işlemleri gerçekleştirilir. Bagging (bootstrap aggregation) yaklaşımında topluluktaki her bir sınıflandırıcı rastgele bir eğitim alt kümesinde eğitilirken, boosting yaklaşımında tüm eğitim örnekleri kullanılarak iteratif olarak eğitim işlemi gerçekleştirilir (Breiman, 2001; Cutler vd., 2012; Belgiu ve Drăgut,



2016; Kavzoğlu ve Tonbul, 2018). Toplu sınıflandırıcılar içinde güncel olarak en sık kullanılan yöntem olan RO sınıflandırıcısı, sağladığı yüksek doğruluk, kısa eğitim süresi ve eğitim verisinde aşırı öğrenme/uyma oluşturmaması nedeni ile tercih edilmektedir (Cutler vd., 2012; Kavzoğlu ve Tonbul, 2018).

Adından da anlaşılacağı gibi, RO her bir ağacın rastgele değişkenlerin bir koleksiyonuna bağlı olarak oluştuğu ağaç temelli bir topluluktur. RO’da kullanılan ağaçlar, monografideki ikili yinelemeli bölümlere ağaçlarına dayanmaktadır. Bu ağaçlar, tek tek değişkenler üzerinde bir dizi ikili bölüm (“bölmeler”) kullanarak kestirici uzayını böler (Şekil 15). Ağacın “kök” düğümü tüm kestirici uzayını kapsar. Bölünmemiş düğümler, “terminal düğümleri” olarak adlandırılır ve kestirici uzayının son bölümünü oluşturur. Her bir terminal olmayan düğüm, kestirici değişkenlerinden birinin değerine göre biri solda ve diğeri sağda olmak üzere iki alt düğüme ayrılır. Sürekli bir kestirici değişkeni için, bir bölme, bölme noktası ile belirlenir; tahmincinin bölünme noktasından daha küçük olduğu noktalar sola, geri kalanı sağa gider (Breiman, 2001; Cutler vd., 2012).



Şekil 15. Rastgele Orman sınıflandırma algoritmasının akış grafiği



Kategorik bir kestirici değişkeni olan X_i , sonlu bir kategori kümesi olan $S_i = \{s_{i,1}, \dots, s_{i,m}\}$ den değerlerini alır. Bölünme, bu kategorilerin bir alt kümesi olan $S \subset S_i$ kategorileri sola ve geriye kalan kategorileri sağa gönderir. Bir bölme düğümünü iki alt düğüme bölmek için, her bir kestirici değişkeni üzerinde gerçekleştirilebilecek bölümler dikkate alınarak bunlar içinden en iyi bölmeyi sağlayan bölüm düğümü sınıflandırma bağlamında genel olarak Gini indeksi (36) nolu formül ile belirlenir (Breiman, 2001; Cutler vd., 2012).

$$Q = \sum_{k \neq k'}^K \hat{p}_k \hat{p}_{k'} \quad (36)$$

Burada, K sınıf sayısını, k gözlem sayısını ve $\hat{p}_k$ (37) bölüm düğümündeki gözlemlerin sınıf sayısına oranını ifade eder. I kayıp fonksiyonunu temsil etmektedir.

$$\hat{p}_k = \frac{1}{n} \sum_{i=1}^n I(y_i = k) \quad (37)$$


Bir bölme düğümü seçildikten sonra, veriler iki alt düğüme bölünür ve bu düğümlerin her biri, orijinal düğümlerle aynı şekilde işlenir. Bu işlem, belirlenen bir durdurma kriteri karşılanana kadar yinelemeli olarak devam eder. Örneğin, tüm bölünmemiş düğümler belirli bir sayıdan daha az sayıda durum içerdiğinde prosedür durabilir. Durdurma kriteri karşılandığında, bölünmemiş düğümler “terminal düğümleri” olarak adlandırılır. Regresyon problemleri için cevabın ortalaması alınarak veya sınıflandırma problemleri için en sık sınıf hesaplanarak uç düğümlerdeki tüm gözlemler için bir tahmin edilen değer elde edilir. Yeni bir noktada tahmin etmek için, onun kestirici değerleri kümesi, noktayı bir uç düğüme düşene kadar ağaçtan aşağı iletmek için kullanılır ve uç düğüm için tahmin edilen değer, yeni noktanın tahmin değeri olarak kullanılır (Breiman, 2001; Cutler vd., 2012).

1.2.11. Sınıflandırma Doğruluklarının Analizi

Sınıflandırma sonuçlarının doğrulukları, hava fotoğrafları üzerinden sayısallaştırılan veya jeodezik ölçüler ile elde edilen vektör veriler üzerinden gerçekleştirilmiştir. Raster formattaki ikili sınıflandırma haritaları ile aynı özelliklere sahip olacak şekilde üretilen referans haritalar karşılaştırılarak doğruluk analizleri gerçekleştirilmiştir. Piksel bazlı



olarak doğruluk analizi gerçekleştirilirken, gerçek pozitif (TP) hem sınıflandırma haritasında hem de referans haritasında bulunan pikselleri, hatalı negatif (FN) referans haritasında olup sınıflandırma sonucunda bulunamayan pikselleri ve hatalı pozitif (FP) referans haritasında olmayıp sınıflandırma haritasında bulunan pikselleri temsil etmektedir (Şekil 16) (Rutzinger vd., 2009).



Şekil 16. Doğruluk analizi terimleri görsel ifadesi (Rutzinger vd., 2009; Acar, 2018)

Piksel tabanlı doğruluk analizinde, Doğruluk (38), Bütünlük (39) ve Kalite (40) ölçütleri (Rutzinger vd., 2009) hesaplanmıştır.

$$\text{Doğruluk} = \frac{TP}{TP+FP} \quad (38)$$

$$\text{Bütünlük} = \frac{TP}{TP+FN} \quad (39)$$

$$\text{Kalite} = \frac{TP}{TP+FN+FP} \quad (40)$$

Doğruluk analizinde, yukarıda bahsedilen piksel tabanlı ölçütlerin yanı sıra sınır tabanlı F-Ölçütü (41) (Csurka vd., 2013) kullanılarak referans veri ile sınıflandırma sonucunda tespit edilen sınırların uyumu kontrol edilmiştir. F-Ölçütünün hesaplanabilmesi için öncelikle Kesinlik (Precision) ve Duyarlılık (Recall) ölçütlerinin hesaplanması gerekmektedir. Burada B_{gt}^c , görüntüdeki bir z pikseli için c sınıfına ait ikili formattaki referans görüntüsünün sınırlarını temsil etmektedir. Benzer şekilde B_{ps}^c , sınıflandırma sonucunda elde edilen ikili formattaki segmentasyon görüntüsünün sınırlarını



temsil etmektedir. θ mesafe hata toleransı (görüntünün köşegen uzunluğunun %0,75'i olarak seçilmiştir) ve d öklit mesafesini tanımlamaktadır.

$$\begin{aligned}
 Kesinlik &= \frac{1}{|B_{ps}|} \sum_{z \in B_{ps}^c} [d(z, B_{gt}^c) < \theta] \\
 Duyarlilik &= \frac{1}{|B_{gt}|} \sum_{z \in B_{gt}^c} [d(z, B_{ps}^c) < \theta] \\
 F\text{-Ölçütü} &= \frac{2 \times Kesinlik \times Duyarlilik}{Duyarlilik + Kesinlik}
 \end{aligned} \tag{41}$$

1.2.12. Hidrolojik Düzleştirme İşlemi

Hidrolojik düzleştirme işlemi temel olarak su kütlesi sınırlarının tespit edilmesi, su yüzey yüksekliği/yüksekliklerinin tespit edilmesi, su kütlesi yüksekliklerinin düzeltilmesi ve su-kara geçişlerinin yumuşatılması olmak üzere dört adımdan oluşmaktadır. Her ne kadar, durağan ve akarsu kütlelerine uygulanan hidrolojik düzleştirme işlemlerinde su yüzey yüksekliklerinin tespiti ve su yüzey yüksekliklerinin düzeltilmesi aşamalarında farklılıklar olsa da temel işlem adımları aynı kalmaktadır. İlk adım olan su kütlesi sınırları, sınıflandırma işlemi ile durağan ve akarsu kütleleri için elde edilebilmektedir. İkinci adım olan su kütlesi yüksekliklerinin tespit edilmesinde, durağan su kütleleri için sabit bir yükseklik belirlenerek hidrolojik düzleştirme işlemi buna göre yapılırken, akarsu kütleleri için akışın başlangıç noktasından akış aşağı yönlü olarak çizilen profilden belirli aralıklarla en kesitler çıkartılarak her en kesit noktasındaki yükseklik tespit edilmiştir. Su kütlesi sınırları ve su yüzey yükseklikleri kullanılarak su kütlesi 3B bir yüzey olarak elde edilir ve bu yüzey SAM ile kesiştirilerek hidrolojik düzeltme işlemi gerçekleştirilir. Son olarak su-kara geçişlerinde karşılaşılabilecek ani değişimleri önlemek amacıyla bir yumuşatma filtresi uygulanır.

1.2.12.1. Su Kütlesi Yüzey Yüksekliklerinin Belirlenmesi

SfM kullanılarak üretilen fotogrametrik nokta bulutlarında, doku, renk değişimi ve süreksizlik gibi özelliklere sahip olmamakla beraber oluşan doku ve renk bilgilerinin SfM algoritması için yeterli ayırt ediciliği sağlamamasından dolayı su yüzeylerindeki yükseklik bilgileri ya hesaplanamamakta ya da hatalı hesaplanmaktadır. Dahası bu hatalar



filtrelenmek istendiğinde pek çok istatistiki yaklaşım zayıf kalmakta ve istenen sonucu verememektedir. Hidrolojik düzleştirme söz konusu olduğunda ise, su yüzey yüksekliğinin yaklaşık olarak (± 50 cm) bilinmesi yeterlidir (Heideman, 2012). Bu bağlamda, su yüzeyine ait yüksekliklerin tespit edilmesi için en güvenilir kaynağı su-kara sınırları oluşturmaktadır (Legleiter, 2012; Bandini vd., 2020).

Çalışmada, yaklaşık su yüzeyi yüksekliklerini tespit etmek için sınıflandırma sonucunda elde edilen su kütlesi sınırlarından faydalanılmıştır. Deniz ve göl gibi durağan su kütlelerinde sınıflandırma sonucu elde edilen su kütlesi sınırlarındaki yükseklik değerleri SAM üzerinden tespit edilmiştir. Elde edilen yükseklikler içerisinde pek çok farklı değer bulunmaktadır. Bu değerlerden hangisinin gerçek su yüzey yüksekliğine yakın olduğunu tespit etmek için her bir yükseklik değerinin frekansını gösterir bir histogram oluşturulmuştur. Daha sonra, PDF (42) ile yükseklik histogramının tepe noktası yani en sık tekrarlanan yükseklik değeri tespit edilerek hidrolojik düzleştirme işleminde kullanılmıştır.

$$y = f(x | \mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{\frac{-(x-\mu)^2}{2\sigma^2}} \quad (42)$$


Burada, x histogramdaki yükseklik değerlerini, μ tüm yükseklik değerlerinin ortalamasını, σ ise tüm yükseklik değerlerinin standart sapmasını ifade etmektedir.



2. YAPILAN ÇALIŞMALAR

Bu tez çalışmasında, yüksek çözünürlüklü SAM'dan su kütlelerinin otomatik olarak tespit edilebilmesi ve hidrolojik düzeltme işleminin uygulanabilmesi için nokta bulutlarından elde edilen yerel komşulukların değişimlerini ifade eden, Eğrisellik (Change of Curvature), Düzlemsellik (Planarity), Çizgisellik (Linearity), Eşyönsüzlük (Anisotropy), Omnivaryans (Omnivariance), Saçılım (Scattering), Özdeğerler Toplamı (EigSum), birinci özdeğere göre eğriselliğin değişimi (CC1), ikinci özdeğere göre eğriselliğin değişimi (CC2) ve X,Y ve Z yönlerindeki yüzey normalleri (Normal X, Normal Y ve Normal Z) geometrik özniteliklere ek olarak yerel komşulukta alan yoğunluğu, hacim yoğunluğu, komşuluktaki yükseklik farkı (ZRange), merkez noktanın komşuluktaki yükseklik sırası (ZRank), komşuluğun standart sapması (StSap) ve komşuluğun X,Y ve Z yönlerindeki varyansı (Varyans X, Varyans Y ve Varyans Z) öznitelikleri hesaplanmıştır. Elde edilen özniteliklerin her birinden raster formatta çok bantlı görüntüler üretilmiş ve SLIC algoritması ile süper piksel segmentasyonu yapılarak homojen görüntü segmentleri oluşturulmuştur. RO sınıflandırıcısı ile gerçekleştirilen eğitim ve sınıflandırma aşamalarında her bir süper pikselin içerdiği öznitelik bilgilerinin ortalama değerleri kullanılmıştır. Sınıflandırma işleminde öznitelik haritaları, su ve su değil (diğer) olmak üzere iki sınıfa ayrılmıştır. Sınıflandırma sonucunda su kütlesi olarak tespit edilen süper pikseller kullanılarak SAM üzerinde hidrolojik düzeltme işlemi uygulanmıştır. Yapılan çalışma Şekil 17'de gösterildiği üzere dört aşamada ele alınmıştır. Birinci aşamada, çalışma alanına ait hava fotoğraflarının işlenerek nokta bulutu, ortofoto ve SAM üretilmesi yer almaktadır. İkinci aşamada, nokta bulutlarından öznitelik haritalarının oluşturularak öznitelik seçimi ve süper piksel segmentasyonu ile sınıflandırılmaya hazır hale getirilmesi sağlanmıştır. Üçüncü aşamada, üretilen öznitelik haritaları ve vektör veriler kullanılarak su kütlelerinin sınıflandırılması yer almaktadır. Son aşamada ise, elde edilen sınıflandırılmış veriler yardımı ile SAM üzerinde hidrolojik düzeltme işlemi gerçekleştirilmiştir.





Şekil 17. Su kütlelerinin otomatik tespit edilmesi ve hidrolojik düzeltilmesi işlem adımları

2.1. Çalışma Alanları

Çalışma alanları, Harita Genel Müdürlüğü'nün Üniversiteler ile Araştırma Projesi yürütme programı esaslarına dayalı "Sayısal Yüzey Modeli ve Sayısal Arazi Modeli Su Kütlelerinin Otomatik Düzeltilmesi" projesi kapsamında ülkemizin topoğrafik ve bitki örtüsü yapısını en iyi şekilde yansıtan üç farklı coğrafi bölgeden seçilmiştir. Çalışma alanları temel olarak Doğu Karadeniz, İç Anadolu, Trakya bölgelerindeki su kütlelerinin belirgin özelliklerini barındıran sırasıyla Çalışma Alanı-1 (Rize), Çalışma Alanı-2 (Malatya) ve Çalışma Alanı-3 (Edirne) çalışma alanlarından oluşmaktadır. Bunun yanı sıra, Marmara Bölgesinde bulunan Çalışma Alanı-4 (İstanbul), fotogrametrik nokta bulutları için geliştirilen yaklaşımının LiDAR verilerine uygulanabilirliğinin araştırılması amacıyla eklenmiş olup toplamda dört çalışma alanı belirlenmiştir. Çalışma alanlarına ait hava fotoğrafları, iç yöneltme ve dış yöneltme parametrelerine ek olarak su kütlelerinin sınırlarının vektör verileri HGM tarafından sağlanmıştır. Çalışma alanına ait güncel vektör veri bulunmadığı durumlarda üretilen ortofotolar üzerinden manuel olarak su kütlesi sınırları çevrilerek çizilmiştir.



Çalışma alanlarına ait 13080×20010 piksel çözünürlüğündeki 3 bantlı (Kırmızı, Yeşil, Mavi) dijital hava fotoğrafları HGM'nin envanterinde bulunan Vexcel UltraCam Eagle kamerası ile elde edilmiştir. Multi-spektral bantta elde edilen görüntüler (Tablo 4) pankromatik bandın mekânsal çözünürlüğüne (Tablo 3) yükseltilmiştir. Uçuş yükseklikleri, Çalışma Alanı-1 için 7000 m, Çalışma Alanı-2 için yaklaşık 7500 m ve Çalışma Alanı-3 için yaklaşık 4500 m'dir.

Tablo 3. Vexcel UltraCam Eagle kamerası Pankromatik bandı teknik özellikleri

Görüntü Formatı	En	68,016 mm	13080 piksel
	Boy	104,052 mm	20010 piksel
Görüntü Sınırları	-	(34,01-52,02) mm	(34,01-52,02) mm
Piksel Boyutu	-	5,200×5,200 mikron	-
Odak Uzaklığı	c	100,500 mm	± 0,002 mm
Asal Nokta	X_ppa	0,000 mm	± 0,002 mm
	Y_ppa	0,000 mm	± 0,002 mm

Tablo 4. Vexcel UltraCam Eagle kamerası MultiSpektral bandı teknik özellikleri


Görüntü Formatı	En	68,016 mm	4360 piksel
	Boy	104,052 mm	6670 piksel
Görüntü Sınırları	-	(34,01-52,02) mm	(34,01-52,02) mm
Piksel Boyutu	-	15,600×15,600 mikron	-
Odak Uzaklığı	c	100,500 mm	± 0,002 mm
Asal Nokta	X_ppa	0,000 mm	± 0,002 mm
	Y_ppa	0,000 mm	± 0,002 mm

2.1.1. Çalışma Alanı-1 (Rize)

Rize ili Ardeşen ilçesinde seçilen bu çalışma alanı, Karadeniz bölgesinin tipik topoğrafik ve bitki örtüsü özelliklerini barındırmaktadır (Şekil 18). Yüksek ağaçlar ile örtülü dağlık bir yapıya sahip olan çalışma alanının sahil kesimlerinde topoğrafya daha düz bir yapıya geçerken yoğun yerleşim alanları ile karşılaşmaktadır. Çalışma Alanı-1'de deniz ve akarsu olmak üzere iki farklı su kütlesi ile karşılaşmaktadır. Çalışma alanının doğu-batı doğrultusu boyunca uzanan deniz su kütlesi genel olarak homojen bir yapıya sahip olmakla beraber kıyılarında insan yapısı iskele, T mahmuzları ve dolgular haricinde doğal yapı olarak bir adet sahile ve dere ağzına sahiptir. Çalışma alanının güney



yakasından iki kol olarak gelen akarsu su kütlesi kuzeyde denize dökülmeden önce birleşerek insan yapısı köprülerin altından, su arıtma tesisi vb. yapıların yanından akmaktadır. Akarsuyun derinliği yüksek olmamakla beraber dere yatağının içini tamamen doldurmamakta ve dere yatağı içinde alüvyonların oluşturduğu pek çok irili ufaklı adacık bulunmaktadır. Dere yatağının genişliği en dar yerinde yaklaşık olarak 35 m en geniş yerinde ise yaklaşık olarak 160 m'ye kadar ulaşabilmektedir.



Şekil 18. Çalışma Alanı-1 (Rize)

Çalışma Alanı-1'de 7,25 km yükseklikten alımı yapılan %60 ileri %30 yan bindirmeli 10 adet ~0,5 m yer örnekleme aralığına (YÖA) sahip dijital hava fotoğrafı bulunmaktadır. Hava fotoğrafları ve dış yöneltme parametreleri yardımı ile Agisoft PhotoScan yazılımında 83.387.238 adet nokta ve renk bilgilerini (RGB) içeren bir nokta



bulutu üretilmiş ve LAStools yazılımı ile yer ve yer üstü noktalar olmak üzere filtreleme işlemi gerçekleştirilmiştir.

Çalışma Alanı-1, durağan ve akış halindeki su kütlelerine uygulanacak hidrolojik düzleştirme işlemlerinin farklılık göstermesinden dolayı Çalışma Alanı-1 Deniz ve Çalışma Alanı-1 Dere olmak üzere iki parçaya ayrılmıştır. Deniz çalışma alanında, özniteliklerin hesaplanması ve sınıflandırılmasında ihtiyaç duyulan performans beklentilerine bağlı olarak, çalışma alanına ait nokta bulutu ve ortofotodan dört adet alt veri seti oluşturulmuştur (Şekil 19). Çalışma Alanı-1 Deniz’e ait nokta bulutu istatistikleri Tablo 5’te verilmiştir.




Şekil 19. Çalışma Alanı-1 Deniz için oluşturulan dört adet alt veri setine ait ortofotolar; a) Deniz-1, b) Deniz-2, c) Deniz-3, d) Deniz-4

Tablo 5. Çalışma Alanı-1 Deniz nokta bulutu istatistikleri

Çalışma Alanı	Alan (km ²)	Nokta Sayısı
Deniz-1	2,31	1.769.293
Deniz-2	2,18	1.694.940
Deniz-3	1,67	1.376.196
Deniz-4	1,64	1.526.474



Çalışma Alanı-1'e ait ortofoto ve nokta bulutları, akış halindeki su kütlelerinin tespitinde kullanılmak üzere Dere-1, Dere-2, Dere-3, Dere-4, Dere-5 ve Dere-6 olmak üzere altı adet alt veri setine bölünmüştür (Şekil 20). Tablo 6'da Çalışma Alanı-1'den üretilen Dere alt veri setlerine ait nokta bulutu istatistikleri görülmektedir.



Şekil 20. Çalışma Alanı-1 Dere için oluşturulan altı adet alt veri setine ait ortofotolar; a) Dere-1, b) Dere-2, c) Dere-3, d) Dere-4, e) Dere-5, f) Dere-6


Tablo 6. Çalışma Alanı-1 Dere için üretilen alt veri setlerinin istatistikleri

Çalışma Alanı	Alan (km ²)	Nokta Sayısı
Dere-1	1,69	2.095.518
Dere-2	1,46	1.858.059
Dere-3	1,69	2.360.654
Dere-4	1,69	2.500.388
Dere-5	1,69	2.492.878
Dere-6	1,69	2.612.582



2.1.2. Çalışma Alanı-2 (Malatya)

Çalışma Alanı-2, Karakaya baraj gölünün Kale ve Doğanyol ilçeleri arasında kalan kısmından seçilmiştir (Şekil 21). Bu çalışma alanı dağlık bir topoğrafyaya ve seyrek bitki örtüsüne sahiptir. Çalışma alanında insan yapısı olarak seyrek yapılaşma görülmektedir. İlgili çalışma alanının kuzeybatı sınırından başlayarak güneydoğu yönüne doğru uzanarak güney-doğu ve güney-batı yönlerine ayrılan tek bir su kütlesi bulunmaktadır. Bu su kütlesi üzerinde kayda değer bir insan yapısına rastlanmamaktadır. Karakaya baraj gölünün çalışma alanı sınırları içinde kalan kısmı en dar yerinde yaklaşık olarak 360 m ve en geniş yerinde ise yaklaşık olarak 650 m'ye kadar ulaşabilmektedir. Bu çalışma alanı, doğu batı yönünde yaklaşık 15 km, kuzey güney yönünde de yaklaşık 15 km bir genişliğe ve 170 km² alana sahiptir.



Şekil 21. Çalışma Alanı-2 (Malatya)

Çalışma Alanı-2’de, 6,7 km yükseklikten alımı yapılan %60 ileri %30 yan bindirmeli 21 adet ~0,34 m YÖA’ya sahip dijital hava fotoğrafları bulunmaktadır. Orijinal hava fotoğrafları ve dış yöneltme parametreleri kullanılarak Agisoft PhotoScan yazılımında 410.539.623 adet nokta ve renk bilgilerini (RGB) içeren bir nokta bulutu üretilmiş ve PTD




yöntemini kullanan LAAtools yazılımı ile yer ve yer üstü olmak üzere nokta bulutu etiketlenerek filtreleme işlemi gerçekleştirilmiştir.

Çalışma Alanı-2, öznitelik çıkarımı ve sınıflandırma gibi yüksek işlem gücü gerektiren uygulamalar göz önüne alınarak alt veri setlerine bölünmüştür. Özellikle öznitelik çıkarımı işlem adımı kullanılarak nokta sayısı bu işlemin performansını doğrudan etkilemekte ve işlem süresini uzatmaktadır. MATLAB ortamında kodlanan fonksiyonların nokta bulutu boyutuna bağlı olarak karşılaşılabileceği performans kısıtlamalarından kaçınmak amacıyla, Çalışma Alanı-2'nin nokta bulutu ve ortofotoları 7 alt veri setine ayrılmış, bu veri setlerine ait alan ve nokta sayısı bilgileri Tablo 7'de verilmiştir (Şekil 22).

Tablo 7. Çalışma Alanı-2 nokta bulutu istatistikleri

Çalışma Alanı	Alan (km ²)	Nokta Sayısı
Malatya-1	12,65	37.027.041
Malatya-2	8,22	21.858.851
Malatya-3	14,96	38.096.667
Malatya-4	8,22	18.716.331
Malatya-5	14,96	30.984.799
Malatya-6	12,95	25.877.711
Malatya-7	11,59	26.161.750






Şekil 22. Çalışma Alanı-2 için oluşturulan yedi adet alt veri setine ait ortofotolar; a) Malatya-1, b) Malatya-2, c) Malatya-3, d) Malatya-4, e) Malatya-5, f) Malatya-6, g) Malatya-7



2.1.3. Çalışma Alanı-3 (Edirne)

Edirne ili Keşan ilçesi sınırları içerisinde kalan Çalışma Alanı-3 içinde iki adet sulama göleti bulunmaktadır (Şekil 23). Çalışma alanı düz bir topoğrafya ve sık ormanlara sahiptir. Bu göletlerden birincisi yaklaşık olarak 450 m genişliğe ve 550 m uzunluğa sahiptir. İkinci gölet olan Dokuzdere Göleti ise yaklaşık olarak 350 m genişliğe ve 1.300 m uzunluğa sahiptir. Çalışma alanındaki en düşük yükseklik yaklaşık olarak 12 m iken, en büyük yükseklik 184 m olarak tespit edilmiştir.




Şekil 23. Çalışma Alanı-3 (Edirne)

Edirne çalışma alanında, 4,76 km yükseklikten alımı yapılan %70 ileri %30 yan bindirmeli 12 adet ~0,33 m YÖA sahip dijital hava fotoğrafı bulunmaktadır. Hava fotoğrafları ve dış yöneltme parametreleri kullanılarak Agisoft PhotoScan yazılımında 126.277.462 adet nokta ve renk bilgilerini (RGB) içeren bir nokta bulutu üretilmiştir.



Üretilen nokta bulutları “las” formatta dışarı aktarıldıktan sonra, PTD yöntemini kullanan LAStools yazılımı ile filtreleme işlemi gerçekleştirilmiştir.

Edirne çalışma alanına ait ortofoto ve nokta bulutundan Şekil 24’te görüldüğü gibi Edirne-1 ve Edirne-2 olmak üzere iki alt veri seti oluşturulmuştur. Çalışma Alanı-3’te nokta bulutu boyutunun büyük olması ve sınıflandırma aşamasında alt veri setlerinden birinin eğitim işlemlerinde kullanılması amacıyla alt veri setleri oluşturulmuştur. Çalışma Alanı-3’te oluşturulan alt veri setleri ile ilgili nokta bulutu bilgileri Tablo 8’de verilmiştir.



Şekil 24. Çalışma Alanı-3 için oluşturulan iki adet alt veri setine ait ortofotolar; a) Edirne-1, b) Edirne-2

Tablo 8. Çalışma Alanı-3 için oluşturulan alt veri setlerine ait bilgiler

Çalışma Alanı	Alan (km ²)	Nokta Sayısı
Edirne-1	1,91	6.723.755
Edirne-2	2,98	10.130.697

2.1.4. Çalışma Alanı-4 (İstanbul)

Tez çalışmasında önerilen yaklaşımın LiDAR verilerinde de çalışabilirliğinin test edilmesi için seçilen İstanbul ili Haliç bölgesinde bulunan çalışma alanı, hafif eğimli bir topoğrafyaya sahiptir. Haliç çevresinde, su kütlesi sınırlarını etkileyecek bir bitki örtüsü bulunmazken, sahil düzenlemeleri, tersane ve irili ufaklı iskeleler su-kara sınırlarını



oluşturmaktadır. Yoğun yapılaşmanın bulunduğu çalışma alanına ait nokta bulutu, LAStools yazılımı kullanılarak yer ve yer üstü olmak üzere etiketlenerek filtrelenmiştir. Çalışma alanına ait LiDAR verisi 1,5 km² alanda 8.585.192 adet noktaya sahiptir. Çalışma alanında en düşük yükseklik sıfır iken en büyük yükseklik 61 m'dir. İstanbul çalışma alanı, diğer çalışma alanlarına göre daha küçük bir alanı kapsadığı için alt veri setlerine ayrılmamış, bütün bir şekilde işlenmiştir (Şekil 25).



Şekil 25. Çalışma Alanı-4'e (İstanbul) ait Worldview uydu görüntüsü

2.2. Hava Fotoğraflarından Nokta Bulutu Üretimi

Hava fotoğrafları kullanılarak Edirne, Malatya ve Rize bölgelerinden seçilen çalışma alanlarının 3B nokta bulutu ve ortofoto görüntüleri üretilmiştir. Hava fotoğraflarının değerlendirilmesinde yüksek miktarda nokta üretebilme kapasitesinden dolayı Agisoft




PhotoScan yazılımı kullanılmıştır. Çalışma alanlarına ait görüntüler ile iç ve dış yöneltme parametreleri yazılıma yüklendikten sonra en yüksek doğruluk ayarlarında “Sparse Matching” yapılmış ve ardından “Dense Matching” işlemine geçilerek çalışma alanlarının nokta bulutu en yüksek yoğunlukta üretilmiştir. Yazılımda, nokta bulutu üretiminde eşleme algoritmasının özellikle su yüzeylerinde yaptığı eşleme hatalarını en aza indirebilmek için derinlik filtreleme işlemi uygulanmıştır. Yazılımda, nokta bulutlarından 1 m YÖA’ya sahip YM üretilerek tüm çalışma alanlarının 1 m YÖA’ya sahip ortofoto görüntüleri üretilmiştir. Üretilen tüm verilerin istatistiki bilgileri Tablo 9’da verilmiştir.

Tablo 9. Çalışma alanlarında üretilen ürünlerin genel istatistikleri

Çalışma alanı	Ortofoto YÖA	SAM YÖA	Nokta sayısı	Nokta yoğunluğu	Alan
Çalışma Alanı-1	1 m	1 m ve 5 m	83.387.238	1,3 nokta/m ²	74 km ²
Çalışma Alanı-2	1 m	1 m ve 5 m	410.539.623	2,6 nokta/m ²	170 km ²
Çalışma Alanı-3	1 m	1 m ve 5 m	126.277.462	3,8 nokta/m ²	44 km ²
Çalışma Alanı-4	-	1 m ve 5 m	8.585.192	5,7 nokta/m ²	1,5 km ²


Agisoft PhotoScan yazılımı ile üretilen nokta bulutlarının filtreleme işlemi, LAStools yazılımı ile yer ve yer üstü noktalar olmak üzere sınıflandırılarak gerçekleştirilmiştir (Şekil 26). Nokta bulutları filtrelendikten sonra, MATLAB ortamında kodlanan PC2Raster fonksiyonu ile yer noktalarından 1 m ve 5 m örneklem aralıklarında iki adet SAM üretilmiştir.



Şekil 26. Çalışma Alanı-1’e ait örnek bir bölgede filtreleme işlemi sonucunda bulunan yer üstü noktalar (kırmızı renkli)



Filtreleme işleminden sonra nokta bulutlarında yer üstü noktalarının çıkartılmasından kaynaklanan boşluklar oluşmaktadır. Bu durum, özellikle öznitelik bilgileri hesaplanırken noktaların topolojik ilişkilerini doğrudan etkileyeceğinden dolayı, yanlış sonuçlar elde edilmesine neden olacaktır. Bu durumun önüne geçebilmek amacıyla, nokta bulutlarındaki boşluklar MATLAB ortamında kodlanan PCfill fonksiyonu ile doldurulmuştur. PCfill fonksiyonu, yer noktalarını girdi olarak aldıktan sonra, bu noktalardan geçen bir yüzey fonksiyonu oluşturmaktadır. Yüzey oluşturulurken, yer noktaları kullanılarak oluşturulan Delaunay Triangulasyonu'ndan faydalanılarak doğal komşuluk enterpolasyonu gerçekleştirilir. PCfill fonksiyonu ile sonuç yüzey fonksiyonuna yer üstü noktaların X ve Y koordinatları verilerek yeni Z koordinatlarını hesaplanır. Ardından yalın arazi nokta bulutu ve yeni yükseklikleri hesaplanmış olan yer üstü nokta bulutlarını birleştirerek yeni bir nokta bulutu oluşturulur (Şekil 27). İlerleyen işlem adımlarında, komşuluk seçimi ve öznitelik bilgilerinin hesaplanmasında PCfill ile üretilen doldurulmuş nokta bulutları kullanılmıştır.



Şekil 27. PCfill fonksiyonu ile nokta bulutlarında filtreleme sonucu oluşan boşlukların doldurma işlemi; a) öncesi, b) sonrası

PC2Raster fonksiyonu girdi olarak nokta bulutu verisini alır ve kullanıcı tarafından belirlenen YÖA bilgisi ile SAM oluşturur. Girdi nokta bulutu verisini temsil edecek



$v=f(x,y,z)$ formunda bir matematiksel yüzey Delaunay Triangulasyonu’ndan faydalanılarak doğal komşuluk enterpolasyonu ile oluşturulur. Daha sonra kullanıcı tarafından belirlenen YÖA parametresi ile nokta bulutu sınırları içinde bir 2B grid (X ve Y koordinatları) oluşturularak, her bir grid noktasına oluşturulan matematiksel yüzey temsiliinde karşılık gelen yükseklik değerleri (Z) hesaplanır. Ardından elde edilen yükseklik değerleri oluşturulan 2B grid ile boyutları (satır ve sütun) tanımlanan bir SAM’a yazılır. Oluşturulan SAM’ın sol üst köşesine karşılık gelen X ve Y koordinat bilgileri ve YÖA parametresinden bir referanslandırma matrisi de oluşturularak SAM “geotiff” formatında kaydedilerek işlem tamamlanır.

Çalışma Alanı-4 veri seti LiDAR nokta bulutu ve bu bölgeye ait vektör verileri içermektedir. LiDAR nokta bulutunun işleme adımlarından en önemlisi olan filtreleme adımı PTD yöntemi ile gerçekleştirilmiştir. Bu yazılım ile yer ve yer üstü olmak üzere nokta bulutu iki sınıfa ayrılmış ve ardından fotogrametrik nokta bulutu işleme adımı olduğu gibi PCFill fonksiyonu ile filtreleme sonucunda oluşan boşluklar yer üstü noktalar ile doldurulmuştur. LiDAR nokta bulutundan SAM üretimi için yine MATLAB ortamında kodlanan PC2Raster fonksiyonu kullanılmış ve çalışma alanının 1 m YÖA ile SAM üretilmiştir.

2.3. Nokta Bulutlarından Öznitelik Haritalarının Üretilmesi

Günümüzde pek çok farklı algılayıcı sistem ve yöntem ile yaygın olarak üretilmekte olan 3B nokta bulutlarının otomatik olarak analiz edilmesi, fotogrametri, uzaktan algılama, bilgisayarla görme ve robotik alanlarında büyük öneme sahiptir. Nokta bulutları, bina ve ağaç çıkarımı, enerji nakil hatlarının çıkarımı, şehir içlerindeki yol ve kaldırımların tespit edilmesi, şehir modellerinin oluşturulması ve robotikte semantik segmentasyon gibi pek çok alanda yaygın olarak kullanılmakta olan bir veri türüdür (Weinmann vd., 2015).

Büyük ölçekte su kütlelerinin tespit edilmesinde düşünüldüğünde, su kütlelerinin fiziksel ve kimyasal özelliklerindeki farklılıklar ve çevresindeki ortamla olan etkileşimine bağlı olarak bu alanlardan elde edilen görüntülerin renk ve doku karakteristiklerinde farklılıklar ile karşılaşılacaktır (Song vd., 2020). Bu bağlamda su kütlelerinin sınıflandırılmasında spektral bilgiler tek başına yeterli olmayacaktır. Nokta bulutlarından yükseklik bilgisi ile birlikte elde edilen geometrik özelliklerin kara ve su sınıflarının belirlenmesinde güçlü bir etmen olmakla birlikte LiDAR nokta bulutlarındaki komşuluk



bilgilerinin de bu sınıflandırma işlemi için faydalı olacaktır (Shaker vd., 2019). Buna bağlı olarak, fotogrametrik görüntülerden üretilen nokta bulutlarından yerel komşuluklardaki geometrik öznitelikler 3B yapı tensöründen faydalanılarak oluşturulmuştur.

2.3.1. En Uygun Komşuluk Boyutu Seçimi

En uygun komşuluk boyutunun seçimi üretilecek olan öznitelik haritalarının kalitesini doğrudan etkileyecektir (Pauly vd., 2003; Guo vd., 2015; Weinmann vd., 2015). Öznitelik haritalarının oluşturulmasında, sınıflar arasındaki ayrımı belirgin hale getirebilmek için seçilen yerel komşuluğun boyutu büyük öneme sahiptir. Buna bağlı olarak, yerel komşuluk boyutunun büyük seçilmesi bu komşuluktaki her bir 3B nokta yerel yüzey değişimine daha az etki edeceği için öznitelik haritalarının bir yumuşatma filtresinden geçmiş gibi daha yumuşak ve pürüzsüz olmasına böylece ince detayların kaybolmasına neden olacaktır (Pauly vd., 2003; Weinmann vd., 2015).

Bu çalışmada Weinmann vd., (2015) tarafından önerilen özentropi tabanlı en uygun komşuluk boyutu seçim yöntemi küresel komşuluk ile kullanılmıştır. En uygun komşuluk boyutunun belirlenmesi amacıyla MATLAB ortamında nhoudsize fonksiyonu kodlanmıştır. En uygun komşuluk boyutunun hesaplanabilmesi için noktalar arasındaki komşuluk ilişkilerini hızlı ve etkin bir biçimde tespit edecek bir uzay bölütleme algoritmasına ihtiyaç vardır. Bu yüzden nhoudsize fonksiyonunda, düzensiz bir yapıda bulunan 3B nokta bulutlarında bir noktanın komşuluğunun oluşturulması ve komşu noktaların hızlı bir şekilde tespit edilmesi için, günümüzde yaygın olarak kullanılan Kd-tree yöntemi (Bentley, 1975) tercih edilmiştir. Genel olarak Kd-tree yöntemi, K-boyutlu çok katmanlı veriden elde edilen nokta kümelerini kompakt hiyerarşik bir veri yapısı olarak temsil eder. Böylece komşu noktaların verimli bir biçimde tespit edilmesine olanak sağlar. Kd-tree yöntemi ile bir noktanın belirli sayıdaki en yakın komşuları belirlenebileceği gibi bu nokta merkez alınarak mesafe bazlı olarak da komşu noktalar belirlenebilir. Nhoudsize fonksiyonu ile Kd-tree yöntemini kullanarak, $k=[5;10;15;25;35;50;60;75;90;100;120]$ olmak üzere önceden tanımlanan en yakın komşuluk boyutlarının her biri için özentropi değerleri hesaplanır ve özentropiyi minimize eden komşuluk boyutunu en uygun komşuluk boyutu olarak seçilir. Ayrıca, burada kullanılan en yakın komşuluk değerlerinin ortalama çapları da hesaplanarak küresel ya da silindirik komşuluk tercih edilmesi durumunda kullanılabilir hale getirilmesi sağlanmıştır. Örnek olarak Tablo 10'da Çalışma Alanı-3 için hesaplanan



komşuluk boyutu parametreleri görülmektedir. Burada, ortalama entropi değerini sıfıra en yakın hale getiren 35 en yakın komşu ya da 3,39 m komşuluk boyutu olarak seçilmiştir.

Tablo 10. Çalışma Alanı-3 komşuluk boyutu seçim parametreleri

Komşu sayısı	Ortalama entropi	Std Sap entropi	Ort komşuluk çapı (m)	Std Sap k çap
5	0,50	0,39	1,10	0,39
10	0,62	0,50	1,71	0,50
15	0,63	0,57	2,16	0,57
25	0,46	0,73	2,87	0,73
35	0,13	0,78	3,39	0,78
50	-0,58	0,91	4,11	0,91
60	-1,16	0,96	4,49	0,96
75	-2,17	1,06	5,06	1,06
90	-3,30	1,13	5,55	1,13
100	-4,13	1,17	5,86	1,17
120	-5,91	1,27	6,46	1,27

Farklı çalışma alanlarında silindirik, küresel ve en yakın komşuluk türleri ile öznitelik haritaları üretilmiş ve sonuçları karşılaştırılmıştır. Bu komşuluk türlerinden küresel komşuluğun uygulama yapılan çalışma alanları için en tutarlı sonuçları ürettiği deneysel olarak tespit edilmiştir. Buna bağlı olarak tez çalışmasında, nokta bulutlarından özniteliklerin çıkartılmasında küresel komşuluğun kullanılmasına karar verilmiştir. Özniteliklerin hesaplanmasında, tüm çalışma alanları için hesaplanan en uygun komşuluk boyutları Tablo 11’de gösterilmiştir.

Tablo 11. Tüm çalışma alanları için hesaplanan komşuluk boyutları


Çalışma alanı	Komşuluk çapı (m)	Komşuluk Türü
Çalışma Alanı-1 Deniz	3,6	Küresel
Çalışma Alanı-1 Dere	3,6	Küresel
Çalışma Alanı-2	3,3	Küresel
Çalışma Alanı-3	3,4	Küresel
Çalışma Alanı-4	1,0	Küresel



2.3.2. Özniteliklerin Hesaplanması

Yapılan çalışma kapsamında, nokta bulutlarından yerel komşuluktaki 3B değişimlerin tespit edilebilmesi için 20 adet öznitelik MATLAB ortamında kodlanan EFextract fonksiyonu ile hesaplanmıştır. EFextract fonksiyonu ile nhoodsized fonksiyonundan gelen komşuluk bilgileri ve kullanıcının tercih ettiği komşuluk türüne bağlı olarak tüm nokta bulutunun öznitelikleri hesaplanır. Çalışma alanlarının her birine ait alt veri setleri EFextract fonksiyonu ile tek tek işlenerek öznitelik bilgileri üretilmiştir. EFextract fonksiyonundan elde edilen öznitelik bilgileri, süper piksel bölütlemesi ve sınıflandırma aşamasında kolaylık sağlaması amacıyla MATLAB ortamında kodlanan pft2rft fonksiyonu ile raster formatına dönüştürülmüştür. Pft2rft fonksiyonu ile nokta bulutunun sol alt ve sağ üst (X, Y) koordinat çiftlerine bağlı olarak oluşturulan sınırları içerisinde, nokta bulutundaki her bir noktaya karşılık gelen öznitelik bilgilerini, kullanıcı tarafından belirlenen bir YÖA parametresine göre oluşturulan referanslandırılmış raster gridine yazılmıştır. Bu işlem her bir öznitelik için tekrarlanarak çok katmanlı bir görüntü oluşturulmuştur. Bu fonksiyonda kullanıcı tarafından değiştirilebilen bir yumuşatma parametresi de eklenerek raster veri üretiminde, nokta bulutunun doğası gereği oluşabilecek küçük boşluklar doldurulabilmektedir. Üretilen raster verinin her bir katmanı bir öznitelik haritasını temsil etmektedir. Ayrıca, pft2rft fonksiyonuna eklenen GPU işleme yeteneği sayesinde, büyük miktarda nokta bulutlarından öznitelik haritalarının üretilmesinde CPU ile işlemeye göre dört kata kadar performans artışı sağlanmıştır. Şekil 28’de Çalışma Alanı-2’den seçilen örnek bir alan için hesaplanan 20 adet öznitelik haritası gösterilmiştir.






Şekil 28. Çalışma Alanı-2 için hesaplanan öznitelik haritaları

Çalışma alanlarının yüksek miktarda nokta içermesinden dolayı, bir çalışma alanının tamamının özniteliklerinin EExtract fonksiyonu ile üretilmesi zaman açısından maliyetli olmakla birlikte çoğu zaman bu işlemin gerçekleştirilmesinde bilgisayar kaynakları yetersiz kalmaktadır. Bu sorunların üstesinden gelebilmek amacıyla nokta bulutunu Şekil 29’da gösterildiği biçimde düzenli gridlere bölen PCgrid fonksiyonu yazılmıştır. PCgrid fonksiyonu ile girdi nokta bulutunu kullanıcı tarafından tanımlanan boyutlara göre gridlere bölünür. Bu gridler oluşturulurken, özniteliklerin hesaplanmasında grid kenarlarındaki ani kesilmeden kaynaklanan hatalı değerlerin önüne geçebilmek için bir



tampon bölge (buffer) de oluşturulmaktadır. Tampon bölgenin boyutu, kullanıcı tarafından belirlenebileceği gibi aynı zamanda komşuluk boyutuna bağlı bir şekilde otomatik olarak da belirlenebilir. Tez kapsamında kullanılan tampon bölge boyutu, otomatik olarak belirlenen komşuluk boyutuna eşit olacak şekilde belirlenmiştir. Elde edilen gridlerdeki nokta bulutları, çok çekirdekli işlemciye sahip bir bilgisayar tarafından, eşanlı işleme (parallel processing) kullanılarak tüm nokta bulutunun öznitelikleri EExtract fonksiyonu ile hesaplanmıştır.




Şekil 29. PCgrid fonksiyonu ile nokta bulutunun gridlere bölünmesi

2.3.3. Öznitelik Seçimi

Öznitelik üretim aşamasında üretilen 20 adet öznitelikten hangilerinin sınıflandırma işleminde en yüksek ayırt ediciliğe sahip olduğunun tespit edilmesi ve sınıflandırma doğruluğuna katkısı olmayan veya olumsuz katkıda bulunan özniteliklerin tespit edilmesi amacıyla öznitelik seçim işlemi gerçekleştirilmiştir. Tez kapsamında öznitelik seçimi için,




(Kira ve Rendell, 1992) tarafından önerilen filtre tabanlı Relief algoritması üzerine (Kononenko vd., 1995) tarafından kurulan Relief-F algoritmasından faydalanılmıştır. Relief-F algoritması çok sınıflı, gürültülü ve eksik veri ile başa çıkabilmesi koşullu bağımlı ve bağımsız öznitelikleri ayırt edebilmesindeki yeteneğinden dolayı tercih edilmiştir. Relief-F algoritması aynı sınıf komşularına farklı değerler veren öznitelikleri (kestiricileri) cezalandırırken, farklı sınıf komşuları için farklı değerler veren öznitelikleri ödüllendirerek her bir özneliğin ağırlığını belirler (Kononenko vd., 1995). Relief-F ile ağırlıkları tespit edilen özniteliklerden en yüksek ağırlık değerine sahip olan ilk 10 öznitelik seçilerek öznitelik haritalarının oluşturulmasında kullanılmıştır. Böylelikle hem sınıflandırma işleminde daha az fakat daha yüksek öneme sahip öznitelik kullanılırken sınıflandırma performansı da hem zamansal açıdan hem de doğruluk açısından iyileşme sağlanmıştır. Bunların yanı sıra, oluşturulan öznitelik haritalarının kullanacak olduğu depolama alanında da azalma olmuştur. Öznitelik seçimi işleminde Çalışma Alanı-1 (Şekil 30-31), Çalışma Alanı-2 (Şekil 32), Çalışma Alanı-3 (Şekil 33) ve Çalışma Alanı-4'ün (Şekil 34) her birinden seçilen alt görüntülere iki sınıflı (su ve su değil) referans veriler ile Relief-F algoritması uygulanarak elde edilen öznitelik ağırlıkları aşağıdaki şekillerde verilmiştir.



Şekil 30. Çalışma Alanı-1 Deniz için bulunan Relief-F tabanlı öznitelik seçimi




Çalışma Alanı-1 Deniz için Şekil 30'da gösterilen en yüksek ağırlığa sahip özniteliklerden sırasıyla düzlemsellik, çizgisellik, CC2, CC1, eşyönsüzlük, özdeğerler toplamı, omnivaryans, eğrisellik, Zrange ve standart sapma öznitelikleri sınıflandırma işleminde kullanılmak üzere seçilmiştir. Çalışma alanında özellikle kara sınırları içinde lokal komşuluklardaki düzlemsellik özniteliği en yüksek ağırlığa sahiptir. Su ve kara sınır geçişlerinde oluşan çizgisel özellikleri belirleyen çizgisellik özniteliği, su kütesindeki boşlukları belirgin hale getiren CC1, CC2, eşyönsüzlük ve özdeğerler toplamı öznitelikleri ve su kara geçişlerindeki ani yön değişimlerini belirgin hale getiren omnivaryans özniteliği seçilen diğer özniteliklere göre daha yüksek ağırlıklara sahiptirler. Eğrisellik, komşuluktaki yükseklik değişimini gösteren ZRange ve standart sapma öznitelikleri diğer özniteliklere göre görece daha düşük ağırlıklara sahiptirler.



Şekil 31. Çalışma Alanı-1 Dere için bulunan Relief-F tabanlı öznitelik seçimi

Çalışma Alanı-1 Dere için 20 adet öznitelik ve akış toplanma alanlarından Şekil 31'de gösterilen en yüksek ağırlığa sahip sırasıyla Normal Z, akış toplanma, düzlemsellik, CC2, özdeğerler toplamı, Zrange, standart sapma, Varyans Z, omnivaryans ve çizgisellik öznitelikleri sınıflandırma işleminde kullanılmak üzere seçilmiştir. Çalışma alanındaki akarsu yatağının çevresindeki topoğrafyaya göre görece düz olmasından dolayı Normal Z parametresi en yüksek ağırlığı almıştır. Ardından, akarsu yatağının akış hattını vurgulayan akış toplanma özniteliği gelmektedir. Yine akarsu yatağının görece düz bir yapıda olmasından dolayı düzlemsellik özniteliği üçüncü sırada bulunmaktadır. Diğer öznitelikler akarsu yatağındaki ve sınırlarındaki küçük değişimleri göstermesi nedeniyle seçilmişlerdir.






Şekil 32. Çalışma Alanı-2 için bulunan Relief-F tabanlı öznitelik seçimi


Relief-F algoritması ile Çalışma Alanı-2 için hesaplanan 20 adet öznitelik ve akış toplanma alanları için hesaplanan ağırlıklar Şekil 32’de gösterilmiştir. Relief-F algoritmasının en yüksek ağırlık değeri tespit ettiği çizgisellik, omnivaryans, CC1, eşyönsüzlük, akış toplanma alanları, CC2, Normal Z, saçılım, düzlemsellik ve eğrisellik öznitelikleri sınıflandırma işleminde kullanılmak üzere seçilmiştir. Bu özniteliklerden, kara ve su geçişlerindeki ani yön değişimini belirgin hale getiren omnivaryans, saçılım ve eğrisellik öznitelikleri göze çarpmaktadır. Çizgisellik özniteliği, su kara sınırları boyunca çizgisel özellikleri su ayırma çizgisini belirgin hale getirmesinden dolayı Relief-F algoritması tarafından seçildiği görülmektedir. CC1, CC2 ve eşyönsüzlük öznitelikleri ise su yüzeyinde oluşan boşlukları belirgin hale getirmesi ve nokta yoğunluğu yüksek olan kara sınırlarını öne çıkarması nedeniyle algoritma tarafından seçildiği görülmektedir. Normal Z, yerel komşulukta oluşturulan yüzeyin normal vektörünün Z eksenindeki bileşenidir. Bundan dolayı özellikle kara sınırlarının belirlenmesinde etkili olduğu için seçilmiştir.





Şekil 33. Çalışma Alanı-3 için bulunan Relief-F tabanlı öznitelik seçimi sonuçları

Çalışma Alanı-3'te sırası ile CC2, düzlemsellik, özdeğerler toplamı, çizgisellik, eşyönsüzlük, CC1, Normal X, omnivaryans, standart sapma ve Zrange öznitelikleri en yüksek ağırlıklara sahiptir (Şekil 33). Relief-F algoritmasının en yüksek ağırlık tespit ettiği bu öznitelikler sınıflandırma aşamasında kullanılmak üzere seçilmiştir. CC2, düzlemsellik ve özdeğerler toplamı öznitelikleri çalışma alanındaki göllerin yüzeylerinde bulunan boşluklara bağlı olarak diğer özniteliklere karşı görece daha yüksek ağırlıklara sahiptir.



Şekil 34. Çalışma Alanı-4 için bulunan Relief-F tabanlı öznitelik seçimi sonuçları

Çalışma Alanı-4 için Relief-F ile belirlenen öznitelik ağırlıkları Şekil 34'te gösterilmiştir. En yüksek ağırlığa sahip özniteliklerden sırasıyla Zrange, standart sapma,




omnivaryans, çizgisellik, Varyans Z, özdeğerler toplamı, düzlemsellik, CC1, eşyönsüzlük ve CC2 öznitelikleri sınıflandırma işleminde kullanılmak üzere seçilmiştir. Zrange, standart sapma ve Varyans Z öznitelikleri LiDAR nokta bulutunda özellikle su kütlelerinin yerel komşuluklarındaki Z değerinin etkisini göstermektedir. Özdeğerler toplamı özniteliği su kütlelerinde oluşan boşlukları belirgin hale getirirken omnivaryans, çizgisellik ve düzlemsellik öznitelikleri su kütlesi ve çevresindeki en belirgin geometrik özellikleri ortaya çıkarmaktadır.

Relief-F ile ağırlıkları belirlenen özniteliklerin kaç tanesinin sınıflandırma aşamasında faydalı olacağını tespit etmek amacıyla bir dizi deneysel sınıflandırma işlemi gerçekleştirilmiştir. Farklı çalışma alanlarında en yüksek ağırlığa sahip özniteliklerden, sırası ile 1'den 20 katmana kadar seçilen öznitelik haritalarında yapılan deneysel çalışmalarda en iyi sınıflandırma başarımının 10 öznitelikte elde edildiği tespit edilmiştir. Relief-F yöntemi ile ağırlıkları tespit edilen özniteliklerden en yüksek ağırlığa sahip olan ilk 10 öznitelik, 1m YÖA'lı raster formata dönüştürülerek ortofoto ile birleştirilmiştir. Çalışma Alanı-4'te renk bilgisi bulunmadığı için renk bilgisi yerine LiDAR nokta bulutundaki her bir lazer pulsunun geri dönüşünde taşıdığı enerji miktarını ifade eden yoğunluk (intensity) bilgilerinden üretilen görüntü, raster formata dönüştürülen öznitelik haritaları ile birleştirilerek sınıflandırma işlemine hazırlanmıştır.

2.3.4. Akış Toplanma Alanlarının Belirlenmesi

Akarsu kütlelerinin tespit edilmesinde ek veri olarak kullanılan akış toplanma alanlarının belirlenmesinde Schwanghart ve Kuhn (2010) tarafından MATLAB ortamında geliştirilen TopoToolbox'tan faydalanılmıştır. Ayrıca buradan elde edilen veriler, çalışma alanlarının su ayırma çizgilerinin otomatik olarak tespit edilmesinde de kullanılmıştır. Akış toplanma alanlarının oluşturulmasında, yer üstü objeler filtrelenerek oluşturulan fotogrametrik görüntülerden üretilen nokta bulutundan akış haritalarının üretilmesi için üretilen 10 m örnekleme aralığındaki SAM kullanılmıştır. Akış toplanma alanlarının oluşturulması için, öncelikle SAM üzerindeki akış yönlerinin tespit edilmesi gerekmektedir. SAM akış yönlerinin tespit edilmesinde, bir SAM pikselinin etrafındaki 3x3 komşuluktaki eğim değerleri dikkate alınarak merkez pikselin komşu piksellerden hangilerine akış oluşturacağı tespit edilmesinde sıklıkla kullanılan MFD algoritmasından faydalanılmıştır (Quinn vd., 1991) (Şekil 35).






Şekil 35. Çalışma Alanı-2 akış toplanma alanları (beyaz piksel: en yoğun akış toplanma alanı)

2.3.5. Ortofoto ve Öznitelik Haritalarının Birleştirilmesi

Nokta bulutları kullanılarak üretilen özniteliklerin daha hızlı ve efektif bir şekilde işlenebilmesi için raster formata dönüştürülmesi gerekmektedir. Relief-F algoritması ile elde edilen en yüksek ağırlığa sahip ilk 10 öznitelikler her bir çalışma alanı için belirlenmiş ve bu özniteliklerden 1 m örnekleme aralıklı raster veriler pft2rft fonksiyonu kullanılarak üretilmiştir. Raster öznitelik haritaları, nokta bulutundaki koordinat bilgilerinden faydalanarak referanslandırılmıştır. Daha sonra, oluşturulan öznitelik haritaları çalışma alanına ait 1 m yer örnekleme aralıklı ortofotolar ile birleştirilerek sınıflandırma için hazır hale getirilmiştir. Çalışma Alanı-4'te LiDAR nokta bulutu kullanılması ve çalışma alanına ait ortofoto görüntülerin olmamasından dolayı bu adımda renk bilgisi yerine LiDAR nokta bulutunun yoğunluk (intensity) bilgisi öznitelik bilgileri ile birleştirilmiştir. Ortofoto ve öznitelik haritalarının birleşimi Çalışma Alanı-2 örneğinde Şekil 36'da gösterilmektedir.





Şekil 36. Çalışma Alanı-2 ortofoto ve raster öznitelik haritalarının birleştirilmesi


2.4. Öznitelik Haritalarının Sınıflandırılması

Toplu sınıflandırıcılar içinde güncel olarak en sık kullanılan yöntem olan RO denetimli sınıflandırıcısı, sağladığı yüksek doğruluk, kısa eğitim süresi ve eğitim verisinde aşırı öğrenme/uyma (overfitting) oluşturmaması nedeni ile bu çalışmada tercih edilmiştir. RO sınıflandırıcısının eğitilebilmesi için her bir çalışma alanından, oluşturulan 13 bantlı öznitelik haritalarından (Çalışma Alanı-4 için 11 bantlı) çalışma alanının özelliklerini temsil eden bir alt veri seti seçilmiş ve bu veriler üzerinde eğitim işlemi gerçekleştirilmiştir. Verilerin sınıflandırılmasında piksel tabanlı ve obje tabanlı olmak üzere iki yaklaşım kullanılmaktadır. Piksel tabanlı sınıflandırma yöntemi her bir pikseli birbirinden bağımsız olarak ele alarak sınıflandırma işlemini gerçekleştirirken, obje tabanlı sınıflandırma yöntemi görüntü piksellerini bir segmentasyon algoritması ile spektral olarak homojen objelere dönüştürdükten sonra oluşan her bir objeyi sınıflandırır (Liu ve Xia, 2010; Kavzoğlu ve Tonbul, 2018). Bu bağlamda obje tabanlı sınıflandırma yöntemi piksel tabanlı sınıflandırma yöntemine göre sağladığı avantajlardan dolayı tercih edilmektedir. Bu çalışmada obje tabanlı sınıflandırma yaklaşımı benimsenerek birbirleri ile benzer özelliklere sahip piksel kümeleri (süper piksel) oluşturmak için SLIC algoritmasından faydalanılmıştır. SLIC algoritması normal bir obje tabanlı sınıflandırma için gereken doku bilgilerini üretmemektedir. Ancak yapılan çalışmada yerel komşuluklarla ilgili pek çok öznitelik hesaplandığı için bu adıma gerek olmadığı varsayılarak işlemler gerçekleştirilmiştir.



2.4.1. SLIC Süper Pikselleri

Geleneksel piksel bazlı görüntü işleme yöntemleri tek bir piksele ait spektral ve istatistiki bilgiyi çıkartıp kullanırken objeler arasındaki ilişkiyi dikkate almamakta, bundan dolayı da yüksek çözünürlüklü görüntülerin sağlamış olduğu avantajlardan faydalanamamaktadır (Kavzoğlu ve Tonbul, 2018; Song vd., 2020). Bir piksel ve komşuluğundaki diğer pikseller arasındaki spektral veya öznitelik korelasyonunun dikkate alınması, yapılacak sınıflandırma işleminin sonuçlarına hem işlem süresi hem de sınıflandırma doğruluğu anlamında olumlu katkılarda bulunacaktır. Bu bağlamda sınıflandırma başarımının iyileştirilmesi ve karmaşıklığının azaltılması amacıyla RGB ve öznitelik bilgilerini içeren görüntülerdeki piksellerden anlamlı obje segmentlerinin oluşturulmasında SLIC algoritmasından faydalanılmıştır. SLIC algoritması, süper piksel görüntülerini oluştururken sadece süper piksel boyutu parametresi kullanmaktadır. Bu çalışmada, süper piksel boyutu olarak 20 piksel seçilmiştir. Ancak, SLIC algoritması, süper piksel boyutunu komşuluktaki renk ve mesafe bilgilerine göre artırıp azaltabilmektedir. Rize ili örneğinde SLIC algoritması ile üretilen süper piksel sınırları Şekil 37’de kırmızı çizgiler ile gösterilmiştir.



Şekil 37. Çalışma Alanı-1’de SLIC segmentlerinin görünümü; a) ortofoto, b) SLIC süper pikselleri



2.4.2. Öznitelik Haritalarının Rastgele Orman ile Sınıflandırılması

RO sınıflandırıcısı, tahminleri gerçekleştirmek için Classification and Regression Trees (CART) yönteminden faydalanan bir toplu sınıflandırıcıdır. Karar ağaçları, eğitim veri setinden değişim yöntemi (bagging) ile rastgele seçilen örneklemeler kullanılarak oluşturulur. Karar ağaçlarının bu şekilde oluşturulması, bazı örneklerin birden fazla kez seçilirken bazılarının da hiç seçilmemesine neden olabilir. Seçilen örneklerin üçte ikisi (in-bag örnekler) karar ağaçlarının eğitilmesi için kullanılırken geriye kalan üçte birlik kısım RO modelinin başarımını test etmek amacıyla dahili bir çapraz doğrulama yöntemi olarak kullanılır. Bu hata tahmin yöntemine out of bag (OOB) hatası denir. Her bir karar ağacı birbirinden bağımsız olarak ve ağaçlardaki alt dallar budanmadan ve bütün ağaç ayırım nodları kullanıcı tarafından belirlenen öznitelik miktarı parametresine göre belirlenerek oluşturulur. Kullanıcı tarafından belirlenen ağaç adedince bir orman oluşturularak, varyansı yüksek ve yanlılığı düşük ağaçlar oluşturulur (Breiman, 2001). Sınıflandırmanın en son kararı, tüm ağaçlardan elde edilen olasılıkların aritmetik ortalaması alınarak hesaplanır. Yeni bir etiketlenmemiş verinin sınıflarının belirlenmesinde RF içindeki her bir karar ağacı bir sınıf için oy kullanır ve en çok oya sahip olan sınıf karar sınıfı olarak belirlenir (Belgiu ve Drăgut, 2016).

Tez çalışması kapsamında, eğitim ve sınıflandırma işlemlerinde su ve su değil olmak üzere iki sınıf kullanılarak sınıflandırma modelleri üretilmiştir. Tüm çalışma alanlarında RO sınıflandırıcısı, bagging yöntemi ile 500 adet karar ağacı üzerinde eğitilmiştir. Çalışma Alanı-4 dışındaki tüm çalışma alanlarında eğitim işlemi, çalışma alanının üç bantlı (RGB) ortofoto görüntüsü ve Relief-F ile hesaplanan en yüksek ağırlıklara sahip 10 öznitelik haritası birleştirilmesi ile oluşturulan 13 bantlı görüntüde gerçekleştirilmiştir. Çalışma Alanı-4'e ait bir ortofoto bulunmadığı için öznitelik haritaları LiDAR nokta bulutundan elde edilen yoğunluk (intensity) verisi ile birleştirilerek 11 bantlı bir görüntü oluşturulmuştur. Her bir çalışma alanı için kullanılan öznitelik bilgilerinin ve su kütlelerinin morfolojik özelliklerine bağlı olarak ayrı bir model üretilmiştir.

Çalışma Alanı-1 Deniz veri setinde, RGB ortofoto ve Relief-F ile hesaplanan en yüksek ağırlıklara sahip 10 öznitelik haritası birleştirilerek oluşturulan 13 bantlı görüntüde (R, G, B, Düzlemsellik, Çizgisellik, CC2, CC1, Eşyönsüzlük, Özdeğerler Toplamı, Omnivaryans, Eğrisellik, Zrange ve Standart Sapma) RO sınıflandırıcısının eğitim işlemi gerçekleştirilmiştir (Şekil 38). Eğitim işleminde, 13 bantlı eğitim görüntüsü SLIC süper



piksel algoritması ile bölütlenmiş ve oluşan süper piksel bölütlerinin her bir öznitelik bandı için ortalama değerleri hesaplanmıştır. Eğitim verileri %90 eğitim ve %10 test olmak üzere ayrılmış ve sınıflandırıcı %90 eğitim verisi üzerinde eğitilmiştir. Oluşturulan RO modeli, Çalışma Alanı-1 Deniz alt veri setlerinin sınıflandırılmasında kullanılmak üzere kaydedilmiştir.




Şekil 38. Çalışma Alanı-1 Deniz eğitim veri seti; a) ortofoto, b) 3 bantlı öznitelik görüntüsü

Çalışma Alanı-1 Dere için RO sınıflandırıcısının eğitim işleminde, Şekil 39’da gösterilen alt veri setinde eğitilmiştir. Bu veri seti, RGB ortofoto ve 10 adet en yüksek ağırlığa sahip öznitelik haritalarının birleştirilmesi ile üretilmiş ve 13 banda (R, G, B, Normal Z, Akış Toplanma, Düzlemsellik, CC2, Özdeğerler Toplamı, ZRange, Standart Sapma, Varyans Z, Omnivaryans ve Çizgisellik) sahiptir. SLIC süper piksel algoritması ile eğitim verisi bölütlenerek, tüm bantlarda her bir süper pikselin ortalama değerleri hesaplanmıştır. Eğitim verisi, %70 eğitim ve %30 test olmak üzere iki parçaya ayrılmıştır. Eğitim verileri kullanılarak RO sınıflandırıcısının eğitim işlemi gerçekleştirilmiştir.




Oluşturulan RO modeli, Çalışma Alanı-1 Dere alt veri setlerinin sınıflandırılmasında kullanılmak üzere kaydedilmiştir.



řekil 39. Çalışma Alanı-1 Dere eğitim veri seti; a) ortofoto, b) 3 bantlı öznitelik görüntüsü

RO modelinin üretilmesi için eğitim veri seti olarak Çalışma Alanı-2’de Malatya-1 alt veri setinde RGB ortofoto ve Relief-F filtre tabanlı öznitelik seçim yöntemi ile hesaplanan en yüksek ağırlıklara sahip 10 öznitelik haritasının birleştirilmesi sonucunda elde edilen 13 bantlı görüntü (R, G, B, Çizgisellik, Omnivaryans, CC1, Eşyönsüzlük, Akış Toplanma, CC2, Normal Z, Saçılım, Düzlemsellik ve Eğrisellik) üzerinde eğitilmiştir (řekil 40). Eğitim işlemine başlamadan önce, SLIC süper piksel algoritması ile 13 bantlı eğitim görüntüsü bölütlenmiştir. Bölütleme sonucu elde edilen tüm süper piksellerin her bir öznitelik bandı için ortalama değerleri hesaplanmış ve ardından %90 eğitim ve %10 test olmak üzere ayrıldıktan sonra eğitim verileri RO sınıflandırıcısına girdi olarak verilmiştir. Oluşturulan RO modeli, Malatya çalışma alanındaki alt veri setlerinin sınıflandırılmasında kullanılmak üzere kaydedilmiştir.






Şekil 40. Çalışma Alanı-2 eğitim veri seti; a) ortofoto, b) 3 bantlı öznitelik görüntüsü

Çalışma Alanı-3'te eğitim işlemi Edirne-1 (Şekil 41) alt veri setinde gerçekleştirilmiştir. RGB ortofoto ve Relief-F filtre tabanlı öznitelik seçim yöntemi ile hesaplanan en yüksek ağırlıklara sahip 10 öznitelik haritası birleştirilmesi sonucunda elde edilen 13 bantlı görüntüde (R, G, B, CC2, Düzlemsellik, Özdeğerler Toplamı, Çizgisellik, Eşyönsüzlük, CC1, Normal X, Omnivaryans, Standart Sapma ve Zrange) eğitilmiştir. Eğitim işlemine başlamadan önce, SLIC süper piksel algoritması ile 13 bantlı eğitim görüntüsü bölütlenmiştir. Bölütleme sonucu elde edilen tüm süper piksellerin her bir öznitelik bandı için ortalama değerleri hesaplanmış ve ardından %90 eğitim ve %10 test olmak üzere ayrıldıktan sonra eğitim verileri RO sınıflandırıcısına girdi olarak verilmiştir. Oluşturulan RO modeli, Edirne çalışma alanındaki alt veri setlerinin sınıflandırılmasında kullanılmak üzere kaydedilmiştir.





Şekil 41. Çalışma Alanı-3 eğitim veri seti; a) ortofoto, b) 3 bantlı öznitelik görüntüsü

Çalışma Alanı-4 küçük olması nedeniyle alt veri setlerine bölünememiştir. Bundan dolayı RO sınıflandırıcısının eğitiminde çalışma alanı %50 eğitim ve %50 test olmak üzere ayrılmıştır. Eğitim veri setinin küçük olması nedeni ile RO modeli 500, 1000 ve 2000 ağaç kullanılarak eğitilmiş ve ağaç sayısının sonuç üzerindeki etkileri araştırılmıştır. Oluşturulan RO modeli sınıflandırma işleminde kullanılmak üzere kaydedilmiştir.

2.5. Hidrolojik Düzleştirme


Hidrolojik düzleştirme işlemi için, akarsu ve durağan su kütleleri için iki ayrı yaklaşım uygulanmıştır. Bu yaklaşımlar temelde aynı mantığı kullanarak hidrolojik düzleştirme işlemini gerçekleştiriyor olsa da durağan su kütleleri ve akarsu kütlelerinde su yüzeyi yüksekliklerinin tespit edilmesi ve su yüzeylerinin oluşturulmasında farklılaşmaktadırlar.

2.5.1. Durağan Su Kütlelerinin Hidrolojik Düzleştirilmesi

Göl ve deniz gibi durağan su kütlelerinin hidrolojik olarak düzleştirilmesinde, sınıflandırma sonucunda elde edilen ikili (binary) görüntülerden faydalanılmıştır. Bu



görüntüler, morfolojik operasyonlar uygulanarak su kütlesi ile kara sınırları arasında oluşan düzensizlikler ve bazı aykırı küçük pikseller yok edilerek düzgünleştirilmiştir. Fotogrametrik görüntülerden eşleştirme yöntemi ile üretilen nokta bulutlarından su yüzeyine dair net bir yükseklik bilgisi elde edilmesi su yüzeylerinde karşılaşılabilecek aykırı yükseklik değerlerinden dolayı sağlıklı olmayacaktır (Legleiter, 2012; Bandini vd., 2020). Ancak, su kütlesi kıyılarında bu aykırılıklara rastlanmamaktadır. Buna bağlı olarak yüzey yüksekliğinin doğrudan su kütlesi üzerinden alınamayacağı durumlar için su kütesinin kıyı şeridinden alınmasına karar verilmiştir. Su yüzey yükseklik bilgisinin güvenilir bir şekilde alınabileceği su kütlesi ile karanın kesişim sınırları tespit edilmiştir (Şekil 42).




Şekil 42. Çalışma Alanı-2 su kütlesi sınırları; a) sınıflandırma sonucu elde edilen ikili görüntü, b) su kütlesi sınırlarının SAM üzerinde gösterimi

Bu işlem için gerekli yükseklik bilgileri göl gibi kapalı ya da iki kıyısı bulunan su kütleleri için tüm kıyı hattından, deniz gibi tek kıyı çizgisi olan su kütlelerinden de sadece bu tek kıyı hattından alınmıştır. Elde edilen yükseklik bilgileri yardımı ile kıyı hattındaki yükseklik değişimlerini tespit edebilmek için bir histogram oluşturulmuş ve daha sonra bu




histogramdan su yüzeyine ait yükseklik bilgisi PDF istatistiki yaklaşımı kullanılarak tespit edilmiştir. PDF yöntemi, yükseklik histogramına bir normal dağılım eğrisi uydurarak histogramın tepe noktasını bulmayı amaçlamaktadır. Böylelikle kıyı hattı boyunca en sık tekrarlanan yükseklik tespit edilmiş olur (Şekil 43).



Şekil 43. Su yüzey yüksekliği histogramı


RO sınıflandırma sonucunda su kütlesi olarak tespit edilen ikili görüntü sınırlarının su kütlesi sınırları ile tam eşleşmemesi ihtimaline karşılık 1 m genişliğinde bir tampon bölge oluşturulmuş ve ardından oluşan yeni sınırlar içine tespit edilen su yüzey yükseklik bilgisi yazılarak sabit yüksekliğe sahip bir yüzey oluşturulmuştur. Şekil 44’te kırmızı renk ile gösterilen yüzeyin içinde görülen mavi alanlar SfM algoritmasının hesapladığı hatalı yükseklik bilgilerinden kaynaklanmaktadır. Bu alanlar, hidrolojik düzeltme işleminde ardıl işleme ile kolayca yok edilebilmektedir.





Şekil 44. Su kütlesi sınırlarından oluşturulan yüzeyin SAM üzerinde gösterimi

Kıyı hattından elde edilen yükseklik bilgisi kullanılarak oluşturulan su yüzeyi ile SAM kesiştirilerek su ayırma çizgisi tespit edilmiş ve bu çizginin su kütlesi tarafındaki yükseklik bilgileri ile SAM'daki yükseklik bilgileri güncellenmiştir. Su ayırma çizgisi boyunca 3×3 boyutlarında bir yumuşatma filtresi geçirilerek oluşabilecek geometrik hataların önüne geçilmiştir. Böylelikle durağan su kütleleri için hidrolojik düzeltme işlemi gerçekleştirilmiştir (Şekil 45).




Şekil 45. Hidrolojik düzeltilmiş SAM



2.5.2. Akarsu Kütlelerinin Hidrolojik Düzleştirmesi

Akarsu kütlelerinin hidrolojik düzleştirilmesinde durağan su kütlelerindeki işleme benzer bir yaklaşım uygulanmıştır. Ancak akarsu kütleleri, iki kıyı şeridi arasında eğim aşağı yönde aktığından dolayı hidrolojik düzleştirme işleminde bazı ek adımların uygulanması gerekmektedir. Bunun için öncelikle sınıflandırma sonucunda elde edilen ikili raster formattaki su kütlesi sınırlarından akarsuyun ana aksını belirleyen bir iskelet morfolojik operasyonlar yardımı ile oluşturulmuştur. Çalışma Alanı-1 Dere’de örnek bir alan için üretilen sınıflandırma haritası ve bu haritadan üretilen iskelet Şekil 46’da gösterilmiştir.




Şekil 46. Akarsu akış hattının tespit edilmesi; a) sınıflandırma sonucunda elde edilen ikili görüntü, b) bu görüntüden üretilen iskelet

Oluşturulan iskelet üzerinden, MATLAB ortamında yazılan findprofilepts fonksiyonu kullanılarak, iskeletin profili oluşturulmuş ve en kesit noktaları tespit edilmiştir. Bu fonksiyona, morfolojik operasyonlar ile üretilen iskelet, SAM, referanslandırma matrisi ve kullanıcı tarafından belirlenen profil uzunluğu girdi olarak




verilmektedir. Bu girdileri kullanarak findprofilepts fonksiyonu ile öncelikle iskeletin başlangıç ve bitiş noktaları tespit edilir. Ardından bu noktalara karşılık gelen SAM noktalarının yükseklikleri alınarak, en yüksek değere sahip olan piksel akarsu başlangıcı, en düşük yükseklik değerine sahip olan pikseli de akarsuyun bitişi olarak belirlenir. Böylelikle akarsuyun akış yönü tespit edilmiş olur. Akarsu kütlelerinin birden fazla başlangıç noktası olması durumunda, tüm başlangıç ve bitiş noktaları tespit edildikten sonra, bu noktaların kesişim noktası iskelet üzerinde belirlenir ve kesişim noktası olarak işaretlenir. Tüm başlangıç ve bitiş noktaları arasındaki iskeletin uzunluğu jeodezik mesafe yöntemi ile kullanılan raster görüntünün ölçeği dikkate alınarak hesaplanır. Profil uzunluğu parametresine bağlı olarak, iskelet boyunca akarsuyun başlangıç noktasından bitiş noktasına kadar belirlenen aralıklarla kesit noktaları oluşturulur. Bu çalışmada profil uzunluğu parametresi 100 m olarak seçilmiştir. Çalışma Alanı-1 Dere için oluşturulan profil ve kesit noktaları Şekil 47’de gösterilmiştir.



Şekil 47. Akarsu kütlelerinin iskeletinden oluşturulan profil ve kesit noktaları



Oluşturulan profil noktalarından en kesitlerin oluşturulması ve kesitlerdeki yüksekliklerin tespit edilmesi amacıyla MATLAB ortamında csectPP fonksiyonu yazılmıştır. Bu fonksiyon girdi olarak, findprofilepts fonksiyonu sonucunda oluşan profil bilgilerini, SAM, referanslandırma matrisi ve kesit genişliği parametrelerini kullanmaktadır. Kesit genişliği parametresi otomatik olarak belirlenebilir. Bunun için, başlangıçta oluşturulan iskelet görüntüsündeki her bir pikselden, ikili sınıflandırma görüntüsündeki tüm piksellere jeodezik mesafe hesaplanır. Hesaplanan mesafelerin ortalaması alınarak ve üzerine standart sapma değeri eklendikten sonra iki ile çarpılarak bulunan değer kesit genişliği olarak atanır. Çalışma Alanı-1 Dere'de örnek bir alan için hesaplanan kesit genişlikleri Şekil 48'de gösterilmiştir.




Şekil 48. En kesit genişliklerinin otomatik belirlenmesi

Ardından, akarsu yatağındaki yükseklik değişimlerini tespit etmek amacıyla, kesit genişliği parametresi kullanılarak csectPP fonksiyonu ile kesit noktalarından akış yönüne dik olacak şekilde en kesitler alınmıştır. Ancak akarsu yatağı, akış yönü boyunca bazı yerlerde yaklaşık 30 m genişliğe kadar daralırken bazı yerlerde 100 m ve üzerinde genişliğe ulaşmaktadır. Bundan dolayı sabit bir kesit genişlik parametresi ile hidrolojik düzleştirme işlemi yapmak mümkün olmayacaktır. Bu sorunu gidermek amacıyla, csectPP fonksiyonuna adaptif kesit genişliği bulma yeteneği kazandırılmıştır. Adaptif kesit




genişliği, fonksiyona verilen genişlik parametresini kullanarak kesit içerisinde en sık tekrarlanan yüksekliği su yüzey yüksekliği olarak kabul eder. Ardından, eğer verilen kesit genişliği içerisinde kesitin her iki yakasında da su yüzey yüksekliği ile kesişim var ise bu kesişim sınırları kesitin toplam genişliğinin %30'undan daha az değilse kesit genişliği olarak tespit edilir. Tespit edilen genişlik, kesit genişliği parametresinin %30'undan az ise bu kesitin genişliği kesit genişlik parametresinin %30'u olarak tespit edilir. Eğer kesitin bir veya iki yakasında da kesişim yok ise kesit genişliğinin iki katı bir genişlikte kesişim aranır. Bu durumda da kesişim yok ise bu noktalar atlanarak, diğer noktaların kesitleri bulunmaya devam edilir. En kesitlerin her birinden elde edilen yükseklik değerlerinin histogramı oluşturularak, durağan su kütlelerinde uygulanan PDF yöntemi uygulanmış ve elde edilen yükseklik bilgileri akarsu yüzeyinin oluşturulması amacıyla kesit noktalarına yazılmıştır. Kesit noktalarının akarsu üzerinde köprü vb. yapılara rastlaması durumu göz önüne alınarak, kesit noktalarının yükseklikleri kendisinden bir önceki kesit noktasının yüksekliği ile karşılaştırılmış ve bir önceki kesitten daha büyük yükseklik değerine sahip olması durumunda yükseklik değeri bir önceki kesitin yükseklik değerine eşitlenmiştir. Çalışma Alanı-1 Dere için profil hattı kullanılarak üretilen en kesit noktaları numaralandırılmış ve her bir en kesitin yüksekliği Şekil 49'da gösterilmiştir.



Şekil 49. Akarsu için profil ve en kesitlerin oluşturulması; a) profil hattı ve en kesitler, b) en kesit yükseklikleri




Kesit noktalarındaki yükseklik bilgisi ve en kesit genişliği bilgileri kullanılarak, akış yönü boyunca düzgün bir şekilde azalan ve genişliği csectPP fonksiyonu ile tespit edilen kesit genişliklerinde bir yüzey, lineer enterpolasyon kullanılarak oluşturulmuştur. Şekil 50’de Çalışma Alanı-1 Dere için hidrolojik düzleştirme işleminde kullanılmak üzere en kesit yükseklikleri kullanılarak üretilen yüzey gösterilmektedir.



Şekil 50. En kesit noktalarından oluşturulan su yüzeyi

Hidorojik düzleştirme işlemini gerçekleştirmek amacıyla, akarsu yüzeyi ve SAM kesiştirilerek iki yüzey arasındaki sınır tespit edilmiş ve bu sınırlar arasında kalan alana akarsu yüzeyinden elde edilen yükseklik değerleri yazılmıştır. Son olarak, tespit edilen sınırlar boyunca 3×3 boyutunda bir yumuşatma filtresi uygulanarak, su-kara geçişlerindeki olası düzensizliklerin önüne geçilmesi sağlanmıştır (Şekil 51).





Şekil 51. Hidrolojik olarak düzleştirilmiş akarsu kütlesi



3. BULGULAR

Çalışmanın bu bölümünde, öznitelik haritaları üzerinden gerçekleştirilen sınıflandırma işlemi sonucunda tespit edilen su kütlesi sınırları ve doğrulukları, su kütlesi sınırlarından üretilen yüzey modelinin SAM ile kesiştirilmesi sonucunda elde edilen sınırlar ve düzeltilmiş sınırlar ile gerçekleştirilen hidrolojik düzeltme işlemi sonucunda elde edilen hidrolojik olarak düzeltilmiş SAM üretim aşamaları gösterilmiştir. Ayrıca çalışmada kullanılan doğruluk ölçütleri ile tespit edilen su kütlelerinin referans veriler ile karşılaştırılması sonucunda elde edilen doğruluk analizi sonuçları da paylaşılmıştır.

3.1. Sınıflandırma Sonucunda Tespit Edilen Su Sınırları ve Doğruluk Analizi

Bu çalışmada, RO sınıflandırıcısı ile sınıflandırılan ortofoto ve öznitelik haritalarının birleştirilmesi ile elde edilen çok bantlı görüntülerden otomatik olarak tespit edilen su sınırlarının doğruluk analizinde F-Ölçütü, Doğruluk, Bütünlük ve Kalite ölçütlerinden faydalanılmıştır. Doğruluk analizinde kullanılmak üzere su kütlelerine ait vektörel verisi bulunmayan çalışma alanları için ortofotolar üzerinden manuel sayısallaştırma yapılarak su kütlelerinin vektör verileri üretilmiştir. Bu veriler kullanılarak üretilen ikili referans görüntüler MATLAB ortamında yazılan piksel tabanlı doğruluk analizi fonksiyonuna verilerek doğruluk ölçütleri hesaplanmıştır. İkili formattaki sınıflandırma görüntüleri vektör formata dönüştürülmüştür. Üretilen ikili formattaki sınıflandırma ve referans görüntülerinin her biri için referanslandırma matrisi de üretilmiştir. Böylelikle, tüm ürünler belirli bir referans sisteminde koordinatlı olarak kaydedilmiş ve işlenmiştir.

Çalışma Alanı-1 Deniz’de sınıflandırma sonucu tespit edilen ikili formattaki sınıflandırma görüntülerinden MATLAB ortamında uygulanan basit morfolojik operasyonlar ile küçük sınıflandırma hataları temizlenmiştir. Genel olarak kara sınırları içerisinde karşılaşılan 500 pikselden küçük sınıflandırma hataları ikili sınıflandırma görüntülerinden silinmek suretiyle temizlenmiştir. Gerçekleştirilen temizleme işleminin tespit edilen su kütlesi sınırlarına herhangi bir etkisi bulunmamaktadır. Morfolojik operasyonlardan sonra elde edilen Çalışma Alanı-1 Deniz’e ait su kütlesi sınırları Şekil 52’de gösterilmiştir.





Şekil 52. Çalışma Alanı-1 Deniz sınıflandırma sonucu elde edilen su kütlesi sınırları

Çalışma Alanı-1 Deniz’de sınıflandırma sonucunda elde edilen su kütlelerinin morfolojik işlemlerden geçirildikten sonra gerçekleştirilen doğruluk analizi sonuçları Tablo 12’de verilmiştir. Doğruluk analizi sonuçları incelendiğinde, en yüksek F-Ölçütü değeri Deniz-4’te elde edilirken en düşük değeri Deniz-2’de elde edilmiştir. Su kütlelerinin hangi doğrulukta tespit edildiğini gösteren Doğruluk ölçütü tüm alt veri setlerinde %99 üzerinde bulunmuştur. Hatalı sınıflandırmaların doğruluğa olan etkisini gösteren Bütünlük ve Kalite ölçütleri Deniz-2 ve Deniz-3 alt veri setlerinde diğer alt veri setlerine oranla düşük çıkmıştır. Çalışma Alanı-1 Deniz için ortalama doğruluk analizi sonuçlarına bakıldığında, F-Ölçütü 0,8570, Doğruluk 0,9970, Bütünlük 0,9670 ve Kalite 0,9641 olarak hesaplanmıştır.

Tablo 12. Çalışma Alanı-1 Deniz sınıflandırma doğruluk analizi sonuçları

Çalışma Alanı	F-Ölçütü	Doğruluk	Bütünlük	Kalite
Deniz-1	0,9231	0,9969	0,9812	0,9783
Deniz-2	0,7034	0,9997	0,9461	0,9459
Deniz-3	0,8471	0,9957	0,9595	0,9556
Deniz-4	0,9543	0,9955	0,9810	0,9767

Akış halindeki su kütlelerinin belirlenmesi amacıyla Çalışma Alanı-1 Dere veri setinde gerçekleştirilen sınıflandırma işlemi sonucunda tespit edilen su kütleleri morfolojik operasyonlardan geçirildikten sonra elde edilen sınırlar Şekil 53’te gösterilmiştir.



Sınıflandırma sonucu elde edilen ikili görüntülerde, sırasıyla 500 pikselden küçük alanlar silinmiş ardından da küçük boşluklar morfolojik operasyonlar ile doldurulmuştur.



Şekil 53. Çalışma Alanı-1 Dere sınıflandırma sonucu elde edilen su kütlesi sınırları

Çalışma Alanı-1 Dere veri setinde morfolojik operasyonlar sonucunda elde edilen su kütlesi sınırları kullanılarak gerçekleştirilen doğruluk analizi sonuçları Tablo 13'te verilmiştir. Tüm alt veri setleri için hesaplanan ortalama değerler; F-Ölçütü 0,7658, Doğruluk 0,7894, Bütünlük 0,5674 ve Kalite 0,4937'dir. En düşük doğruluk analizi sonuçları Dere-1 alt veri setinde elde edilmiştir. Bu duruma, eğitim verisinin Dere-1 alt veri setini kapsamamasının yanı sıra, bu alanda hesaplanan akış toplanma alanlarının özellikle dere yatağının bir tarafına yığılması neden olmuştur. F-Ölçütü'ne göre Dere-4, 5 ve 6 alt veri setlerinde 0,85 üzerinde değerler elde edilmiştir. Doğruluk ölçütü tüm veri setleri için 0,73 üzerinde değerlere sahiptir.



Tablo 13. Çalışma Alanı-1 Dere veri setinin doğruluk analizi sonuçları

Çalışma Alanı	F-Ölçütü	Doğruluk	Bütünlük	Kalite
Dere-1	0,5551	0,7462	0,3275	0,2947
Dere-2	0,7348	0,7314	0,4942	0,4183
Dere-3	0,7065	0,8112	0,5686	0,5022
Dere-4	0,8593	0,8269	0,6754	0,5917
Dere-5	0,8575	0,8261	0,6334	0,5589
Dere-6	0,8813	0,7943	0,7052	0,5963

Çalışma Alanı-2’de bulunan baraj gölünün sınıflandırma sonucu tespit edilen sınırları Şekil 54’de gösterilmiştir. Çalışma Alanı-2’nin alt veri setleri Malatya-5, Malatya-6 ve Malatya-7’de karşılaşılan 750 pikselden küçük sınıflandırma hataları morfolojik operasyonlar ile giderilmiştir. Su kütlesi sınırları içerisinde oluşan küçük boşluklar morfolojik operasyonlar ile doldurularak sonuç su kütlesi sınırları elde edilmiştir.



Şekil 54. Çalışma Alanı-2 sınıflandırma sonucu elde edilen su kütlesi sınırları

Tablo 14’te Çalışma Alanı-2’de tespit edilen su kütlelerine ait doğruluk analizi sonuçları verilmiştir. Bu çalışma alanında, RO modelinin eğitildiği Malatya-1 alt veri seti



en yüksek doğruluk değerlerine sahiptir. Eğitim işleminin gerçekleştirildiği Malatya-1 veri seti hariç tutularak doğruluk analizi sonuçlarına bakıldığında bu çalışma alanındaki su kütlelerinin başarılı bir şekilde tespit edildiği sonucuna ulaşılabılır. Çalışma Alanı-2’de doğruluk analizi ölçütlerinin ortalama değerleri; F-Ölçütü 0,9368, Doğruluk 0,9957, Bütünlük 0,9588 ve Kalite 0,9549 olmaktadır. Şekil 54’ten de görülebileceği üzere, Malatya-5 ve Malatya-6 alt veri setlerine su kütlesi sınırlarında karşılaşılan görece düşük sınıflandırma performansının etkileri, düşük F-Ölçütü değerlerinde görülmektedir.

Tablo 14. Çalışma Alanı-2 veri setinin doğruluk analizi sonuçları

Çalışma Alanı	F-Ölçütü	Doğruluk	Bütünlük	Kalite
Malatya-1	0,9999	0,9931	0,9891	0,9824
Malatya-2	0,9988	0,9968	0,9813	0,9782
Malatya-3	0,9677	0,9966	0,9534	0,9503
Malatya-4	0,9833	0,9973	0,9720	0,9695
Malatya-5	0,8782	0,9947	0,9207	0,9162
Malatya-6	0,7653	0,9939	0,9358	0,9305
Malatya-7	0,9647	0,9977	0,9594	0,9573

Çalışma Alanı-3 veri setinde, bulunan iki adet sulama göletine ait sınırlar Şekil 55’te görülmektedir. Bu çalışma alanında, su kütlesi sınırları içerisinde sınıflandırma işlemi sonucunda oluşan toplamda 25 adet 50 ile 100 piksel arasındaki küçük boşluklar morfolojik operasyonlar ile temizlenmiştir. Su kütlesi sınırlarında süreksizliklere neden olan küçük boşluklara müdahalede bulunulmamıştır. Su kütlesi dışında hatalı tespitlere rastlanmadığı için ek morfolojik operasyon uygulanmamıştır.



Şekil 55. Çalışma Alanı-3 sınıflandırma sonucu elde edilen su kütlesi sınırları




Çalışma Alanı-3'te sınıflandırma sonuçlarının referans vektör veriler ile karşılaştırılması sonucu elde edilen doğruluk analizi sonuçları Tablo 15'te verilmiştir. Her iki veri setinde elde edilen tüm doğruluk ölçütleri 0,90 üzerindeki değerlere sahiptir. Tüm alt veri setlerinden elde edilen ortalama doğruluk analizi sonuçları, F-Ölçütü 0,9490, Doğruluk 0,9790, Bütünlük 0,9537 ve Kalite 0,9349 olarak hesaplanmıştır. Şekil 55'te gösterilen sınırlar incelendiğinde, Edirne-1 alt veri setinde elde edilen görece düşük doğruluk ölçütü değerlerinin su kütlesi sınırlarında karşılaşılan sınıflandırma hatalarından kaynaklandığı görülmektedir.

Tablo 15. Çalışma Alanı-3 veri setinin doğruluk analizi sonuçları

Çalışma Alanı	F-Ölçütü	Doğruluk	Bütünlük	Kalite
Edirne-1	0,9194	0,9732	0,9276	0,9046
Edirne-2	0,9785	0,9847	0,9798	0,9651

Geliştirilen yaklaşımın LiDAR verilerine uygulanabilirliğinin araştırılması için seçilen Çalışma Alanı-4'te 500 ağaç kullanılarak eğitilen RO modeli ile elde edilen su kütlesi sınırları Şekil 58'de gösterilmiştir. Bu çalışma alanında kısıtlı miktarda veri bulunması ve olası aşırı öğrenme durumunun önüne geçilebilmesi amacı ile çalışma alanının %50'si eğitim veri seti olarak kullanılmıştır. Sınıflandırma işleminde ise çalışma alanının tamamına ait veri seti kullanılmıştır. Bu veri setinde belirlenen alan parametresi altında kalan sınıflandırma sonuçları morfolojik operasyonlar ile temizlenmiştir.





Şekil 56. Çalışma Alanı-4 sınıflandırma sonucu elde edilen su kütlesi sınırları

Kısıtlı miktardaki veride eğitim yapılmasından kaynaklanabilecek yetersiz öğrenme durumunun önüne geçebilmek amacı ile eğitim işlemi 500, 1000 ve 2000 ağaç üzerinde gerçekleştirilmiş ve sonuçları karşılaştırılmıştır. Sınıflandırma sonucunda elde edilen su kütlesi sınırlarının doğruluk analizi sonuçları Tablo 16’da verilmiştir. Bu çalışma alanında 0,89 ve üzerinde elde edilen Doğruluk, Bütünlük ve Kalite ölçütleri geliştirilen yaklaşımın LiDAR verilerine de başarılı bir şekilde uygulanabileceğini göstermektedir. Çalışma alanında kullanılan kısıtlı verilerin sonuçlara olumsuz etkileri özellikle F-Ölçütü değerlerinde görülebilmektedir.

Tablo 16. Çalışma Alanı-4 veri setinin doğruluk analizi sonuçları

Çalışma Alanı	F-Ölçütü	Doğruluk	Bütünlük	Kalite
Çalışma Alanı-4 (500 ağaç)	0,7362	0,9525	0,9431	0,9007
Çalışma Alanı-4 (1000 ağaç)	0,6878	0,9478	0,9451	0,8984
Çalışma Alanı-4 (2000 ağaç)	0,7016	0,9309	0,9526	0,8896



Sınıflandırma sonucunda tespit edilen su kütlesi sınırlarının arazideki su kütlesi sınırları ile yüksek bir örtüşme gösteremediği hesaplanan F-Ölçütü değerlerinden görülebilmektedir. Doğruluk, Bütünlük ve Kalite ölçütlerine göre daha düşük değerlere sahip olmuştur. Özellikle F-Ölçütü'nün belirgin hale getirdiği diğer bir sorun; kısıtlı eğitim verisine sahip bu çalışma alanında ağaç sayısındaki artışa paralel olarak sınıflandırma doğruluğunda bir iyileşme sağlanamamasıdır. Bu durum diğer doğruluk ölçütlerinde de görüldüğü üzere sadece küçük iyileşmeler göstermiştir.

3.2. Hidrolojik Düzleştirme İçin Su Kütlesi Sınırlarının Tespit Edilmesi

Sınıflandırma sonucunda elde edilen su kütleleri incelendiğinde, su kütlesi sınırlarında RO sınıflandırıcısının doğru bir şekilde tespit edemediği bazı bölgeler görülmektedir. Tespit edilen sınırlar bazı yerlerde su kütlesinin içinde bulunurken nadiren de olsa kara sınırlarını ihlal edebilmektedir. Bu sorunun üstesinden gelmek amacıyla, sınıflandırma işlemi sonucunda tespit edilen su kütlesi sınırlarındaki yükseklik bilgilerinden faydalanılarak su kütlesi için yüzey yüksekliği hesaplanmıştır. Sınıflandırma sonucunda tespit edilen ikili görüntü, tespit edilen sınırların büyütülerek olası eksik tespitlerin önüne geçmek amacıyla morfolojik genleşme operasyonundan geçirilmiştir. Oluşan yeni görüntüde, her bir “true” piksele tespit edilen su yüzey yüksekliklerinin yazılması ile yeni bir yüzey oluşturulmuştur. Oluşturulan yeni yüzey, uygulanan genleşme operasyonundan dolayı daha geniş bir alanı kapsamakta ve böylece kara sınırları ile örtüşmesi sağlanmıştır. Daha sonra, oluşturulan yeni yüzey SAM ile kesiştirilerek sınıflandırma işleminde eksik kalan sınırlar düzeltilmiş ve yeni su kütlesi sınırları tespit edilmiştir.

Çalışma Alanı-1 Deniz veri setinde sınır düzeltme işlemi sonucunda elde edilen yeni su kütlesi sınırları Şekil 57’de gösterilmiştir. Gerçekleştirilen işlem sonucunda, Deniz-1 veri setinde arazi sınırları ile örtüşme oranının, SAM’da T mahmuzları etrafında elde edilen yükseklik değerlerindeki yükseklik değişimlerinden dolayı daha düşük olduğu gözlenmiştir. Buna ek olarak, Deniz-1 alt veri setinde su kütlesi sınırlarının sahil hattı boyunca yer yer kara sınırları ile örtüşmesinde sorunlar olduğu görülmüştür. Deniz-2, Deniz-3 ve Deniz-4 alt veri setlerinde tespit edilen su kütlesi sınırları arazideki sınırlar ile daha yüksek bir örtüşmeye sahip olmuştur. Ancak, Deniz-4 alt veri setindeki iskelenin



doğu sınırlarında tespit edilen su kütlesi sınırları yatay ekseninde vektörel verilere göre yer yer yaklaşık olarak ± 4 m farklılık göstermektedir.



Şekil 57. Çalışma Alanı-1 Deniz için düzeltilmiş su kütlesi sınırları


Çalışma Alanı-1 Deniz veri setinde oluşturulan yeni sınırlar ile gerçekleştirilen doğruluk analizi işleminin sonuçları ve sınıflandırmadan elde edilen doğruluk sonuçlarına göre elde edilen değişimler Tablo 17’de gösterilmiştir. Sonuçlar incelendiğinde su kütlesi sınırlarında Deniz-2 ve Deniz-3 alt veri setlerinin F-Ölçütü değerlerinde sınıflandırma işlemi sonucunda elde edilen doğruluk değerlerine göre sırasıyla %28,12 ve %13,45 oranında belirgin bir artış olduğu görülmektedir. Doğruluk ölçütünde elde edilen artışlar %1’in altında kalırken Deniz-2 alt veri setinde %-1,31 oranında azalma görülmüştür. Bütünlük ve Kalite ölçütünde Deniz-1 alt veri seti hariç diğer alt veri setlerinde artış kaydedilmiştir.

Tablo 17. Çalışma Alanı-1 Deniz için düzeltilmiş sınırların doğruluk analizi sonuçları

	F-Ölçütü		Doğruluk		Bütünlük		Kalite	
Deniz-1	0,9576	%3,45	0,9996	%0,27	0,9758	%-0,54	0,9754	%-0,29
Deniz-2	0,9846	%28,12	0,9866	%-1,31	0,9973	%5,12	0,9839	%3,8
Deniz-3	0,9816	%13,45	0,9983	%0,26	0,9867	%2,72	0,9850	%2,94
Deniz-4	0,9598	%0,55	0,9970	%0,15	0,9810	%0	0,9781	%0,14



Sınır düzeltme işlemi uygulanan Çalışma Alanı-2 için elde edilen yeni su kütlesi sınırları Şekil 58’de gösterilmiştir. Gerçekleştirilen işlem sonucunda, alt veri setlerinde tespit edilen su kütlesi sınırlarının ortofotoda görülen dere kıyı hattı ile örtüştüğü görülmektedir. Dere-1 (Şekil 58a), Dere-2 (Şekil 58b) ve Dere-3 (Şekil 58c) alt veri setlerinde görülen köprülerin düzeltme işleminde kesiklik oluşturmadığı gözlenmiştir. Dere-5 (Şekil 58e) ve Dere-6 (Şekil 58f) alt veri setlerinde belirli bölgelerde SAM’daki yükseklik değerlerine bağlı olarak su kütlesi sınırlarında küçük düzensizlikler ile karşılaşmıştır.



Şekil 58. Çalışma Alanı-1 Dere için düzeltilmiş su kütlesi sınırları

Çalışma Alanı-1 Dere veri setinde oluşturulan yeni sınırlar ile gerçekleştirilen doğruluk analizi işleminin sonuçları Tablo 18’de gösterilmiştir. Sonuçlar incelendiğinde su kütlesi sınırları, SAM’da karşılaşılan aykırı yükseklik değerlerine bağlı olarak oluşan birkaç düzensizlik haricinde akarsu yatağının iki yakasındaki su ayırma çizgileri net bir



şekilde çıkartılmıştır. Doğruluk analizine bakıldığında, elde edilen değerler sınırları net bir şekilde belirlenmiş olmasına rağmen düşük kalmaktadır. Bunun nedeni, akarsu kütlesinin sınıflandırma için hazırlanan referans verisinde sadece akış oluşturan su kütlesinin sınırları bulunurken dere yatağının sınırları bulunmamaktadır. Buna bağlı olarak doğruluk analizi sonuçlarında Bütünlük ve Kalite ölçütleri dışındaki ölçütler daha düşük değerlere sahip olmaktadır.

Tablo 18. Çalışma Alanı-1 Dere için düzeltilmiş sınırların doğruluk analizi sonuçları

	F-Ölçütü		Doğruluk		Bütünlük		Kalite	
Dere-1	0,5175	%-3,76	0,5904	%-15,58	0,9619	%63,44	0,5769	%28,22
Dere-2	0,4000	%-33,48	0,4040	%-32,74	0,9898	%49,56	0,4023	%-1,6
Dere-3	0,6260	%-8,05	0,6487	%-16,25	0,9876	%41,9	0,6434	%14,12
Dere-4	0,6193	%-24	0,6117	%-21,52	0,9805	%30,51	0,6044	%1,27
Dere-5	0,7676	%-8,99	0,6259	%-20,02	0,9551	%32,17	0,6080	%4,91
Dere-6	0,6932	%-18,81	0,6206	%-17,37	0,9584	%25,32	0,6043	%0,8

Gerçekleştirilen düzeltme işlemi sonucunda Çalışma Alanı-2’de elde edilen yeni su kütlesi sınırları Şekil 59’da gösterilmiştir. Gerçekleştirilen düzeltme işlemi ile elde edilen yeni su kütlesi sınırları ortofoto üzerinde görülen sınırlar ile çok yüksek örtüşme oranına sahiptir. Uygulanan işlem özellikle Malatya-6 ve Malatya-7 alt veri setlerinde karşılaşılan eksik su kütlesi sınırlarını başarılı bir şekilde tamamlamıştır. Çalışma Alanı-2’nin açık bir topoğrafyaya sahip olması ve buna bağlı olarak fotogrametrik yöntemle üretilen nokta bulutunda özellikle su kütlesi sınırlarındaki yükseklik değerlerindeki tutarlılık bu başarıya ulaşılmasına yardımcı olmuştur.





Şekil 59. Çalışma Alanı-2 düzeltilmiş su kütlesi sınırları

Çalışma Alanı-2’de gerçekleştirilen doğruluk analizinin sonuçları ve sınıflandırma sonuçlarına göre kıyaslaması Tablo 19’da gösterilmiştir. Sonuçlar incelendiğinde sınıflandırma işlemi sonucunda elde edilen doğruluk değerlerine göre özellikle Malatya-5 ve Malatya-6 alt veri setlerinin F-Ölçütü değerlerinde sırasıyla %12,09 ve %23,47 oranında belirgin bir artış olduğu göze çarpmaktadır. Malatya-3, Malatya-4 ve Malatya-7 alt veri setlerinde F-Ölçütü sırası ile %3,23, %1,67 ve %2,67 oranında artış göstermiştir. Bütünlük ve Kalite ölçütlerinde artışlar en yüksek %7’ye kadar ulaşmaktadır. Tüm alt veri setlerinde Doğruluk ölçütünde %2,64 ve daha az olmak üzere azalma tespit edilmiştir.

Tablo 19. Çalışma Alanı-2 için düzeltilmiş sınırların doğruluk analizi sonuçları

	F-Ölçütü		Doğruluk		Bütünlük		Kalite	
Malatya-1	1,0000	%0,01	0,9802	%-1,29	0,9999	%1,08	0,9801	%-0,23
Malatya-2	1,0000	%0,12	0,9844	%-1,24	0,9996	%1,83	0,9840	%0,58
Malatya-3	1,0000	%3,23	0,9862	%-1,04	0,9984	%4,5	0,9846	%3,43
Malatya-4	1,0000	%1,67	0,9868	%-1,05	0,9992	%2,72	0,9861	%1,66
Malatya-5	0,9991	%12,09	0,9880	%-0,67	0,9979	%7,72	0,9859	%6,97
Malatya-6	1,0000	%23,47	0,9793	%-1,46	0,9995	%6,37	0,9789	%4,84
Malatya-7	0,9914	%2,67	0,9713	%-2,64	0,9968	%3,74	0,9683	%1,1



Çalışma Alanı-3 veri setinde, sınır düzeltme işlemi sonucunda elde edilen yeni su kütlesi sınırları Şekil 60'ta gösterilmiştir. Gerçekleştirilen işlem sonucunda, Edirne-1 ve Edirne 2 alt veri setlerinde tespit edilen su kütlesi sınırları, sınıflandırma sonucu elde edilen sınırlara göre iyileşme sağlanmıştır. Ancak, yoğun bitki örtüsü nedeni ile fotogrametrik yöntemle üretilen nokta bulutunda su kütlesi çevresinde elde edilen yükseklik hataları, uygulanan yöntemin belirli bölgelerde yetersiz kalmasına neden olmuştur.



Şekil 60. Çalışma Alanı-3 düzeltilmiş su kütlesi sınırları

Çalışma Alanı-3'te yeni oluşturulan sınırlar ile gerçekleştirilen doğruluk analizi işleminin sonuçları Tablo 20'de gösterilmiştir. Sonuçlar incelendiğinde su kütlesi sınırlarında Bütünlük ölçütüne göre Edirne-1 ve Edirne-2 için sırasıyla %5,12 ve %1,52 olmak üzere sınıflandırma işlemi sonucunda elde edilen doğruluk değerlerine göre bir miktar artış olduğu göze çarpmaktadır. Bunun yanı sıra Doğruluk, F-Ölçütü ve Kalite ölçütlerine göre görece yüksek oranda azalma görülmüştür.

Tablo 20. Çalışma Alanı-3 için düzeltilmiş sınırların doğruluk analizi sonuçları

	F-Ölçütü		Doğruluk		Bütünlük		Kalite	
Edirne-1	0,9001	%-1,93	0,9061	-6,71	0,9788	%5,12	0,8887	%-1,59
Edirne-2	0,9837	%0,52	0,9538	-3,09	0,9950	%1,52	0,9493	%-1,58

Çalışma Alanı-4 veri setinde gerçekleştirilen sınır düzeltme işlemi sonucunda elde edilen yeni su kütlesi sınırları Şekil 61'de gösterilmiştir. Kırmızı renk ile gösterilen



hidrolojik düzleştirme sınırlarının uydu görüntüsünün kenarlarında oluşturduğu boşluklar, LiDAR verisinin kapsadığı alanın tam bir dikdörtgen olmamasından kaynaklanmaktadır.



Şekil 61. Çalışma Alanı-4 düzeltilmiş su kütlesi sınırları

Çalışma Alanı-4'te gerçekleştirilen sınır düzeltme işlemi sonrasında elde edilen doğruluk değerleri ve bu değerlerin 500 ağaç üzerinde uygulanan RO sınıflandırma sonucu elde edilen doğruluk değerleri Tablo 21'de gösterilmiştir. Sınır düzeltme sonucu elde edilen yeni sınırlar, sınıflandırma ile tespit edilen sınırlara göre özellikle F-Ölçütü değerlerinde ciddi iyileşme göstermiştir. F-Ölçütü değerlerindeki bu iyileşme özellikle su sınırlarının arazi gerçeği ile örtüşmesi ile açıklanabilir.

Tablo 21. Çalışma Alanı-4 için düzeltilmiş sınırların doğruluk analizi sonuçları


	F-Ölçütü		Doğruluk		Bütünlük		Kalite	
Çalışma Alanı-4	0,9753	%23,91	0,9772	%1,97	0,9973	%5,42	0,9746	%7,39



3.3. Hidrolojik Düzleştirilmiş SAM

SAM üzerinden, bir önceki adımda elde edilen düzeltilmiş su kütlesi sınırları kullanılarak, hidrolojik düzeltme işlemi uygulanacak pikseller tespit edilmiştir. Bu piksellere, su kütlesini çevreleyen kıyı şeridinden PDF yöntemi ile tespit edilen su yüzey yükseklikleri yazılarak hidrolojik düzeltme işlemi gerçekleştirilmiştir. Tespit edilen su kütlesi sınırlarından karaya geçişlerde oluşabilecek ani yükseklik değişimlerinin giderilmesi amacıyla su kütlesi sınırları boyunca 5×5 boyutlarında bir yumuşatma filtresi uygulanmıştır. Çalışma Alanı-2’de, hidrolojik düzeltme işlemi öncesi ve sonrasındaki su kütlelerinin yüzey yükseklikleri, 1 m YÖA SAM’dan alınan en kesitler Şekil 62’de gösterilmiştir. Şekil 62’de, kesitlerin Y eksenini yükseklik bilgisini, X eksenini de kesit genişliğini göstermektedir. Şekil 62a ve Şekil 62c hidrolojik düzeltme işlemi öncesindeki su kütlelerini, Şekil 62b ve Şekil 62d hidrolojik düzeltme sonrasındaki su kütlelerini göstermektedir.






Şekil 62. Hidrolojik düzleştirme işlemi öncesi ve sonrasında su yüzey yükseklikleri

Çalışma Alanı-1 Deniz’de durağan su kütlelerine uygulanan hidrolojik düzleştirme sonucunda elde edilen SAM Şekil 63-64’te gösterilmiştir. Ayrıca SAM üzerinde kırmızı renklerle 10 m aralıklı eş yükselti eğrileri gösterilmiştir. Her bir eş yükselti eğrisinin yüksekliği siyah renk ile belirtilmiştir. Hidrolojik düzleştirme işlemi ile üretilen SAM, su-




kara sınırlarında karşılaşılan birkaç noktadaki aykırılık haricinde başarılı bir şekilde oluşturulmuştur.



Şekil 63. Hidrolojik düzeltilmiş SAM; a) Deniz-1, b) Deniz-2







Şekil 64. Hidrolojik düzeltilmiş SAM; a) Deniz-3, b) Deniz-4

Çalışma Alanı-1 Dere’de akarsu kütlelerine uygulanan hidrolojik düzeltme sonucunda elde edilen SAM Şekil 65-67’de gösterilmiştir. Ayrıca, SAM üzerinde kırmızı renkler ile en düşük yüksekliğin 20 m yukarısına kadar 2 m aralıklı ve daha yüksek konumlarda 20 m aralıklı eş yükselti eğrileri gösterilmiştir. Ayrıca suyun akış hattı yeşil renk ile vurgulanarak görseller anlaşılır hale getirilmeye çalışılmıştır. Her bir eş yükselti eğrisinin yüksekliği siyah renk ile belirtilmiştir.






Şekil 65. Hidrolojik düzeltilmiş SAM; a) Dere-1, b) Dere-2



Şekil 66. Hidrolojik düzeltilmiş SAM; a) Dere-3, b) Dere-4







Şekil 67. Hidrolojik düzleştirilmiş SAM; a) Dere-5, b) Dere-6

Çalışma Alanı-2’de durağan su kütlelerine uygulanan hidrolojik düzeltirme sonucunda elde edilen SAM’lar Şekil 68-71’de gösterilmiştir. Mavi renk SAM üzerindeki en düşük yüksekliği temsil ederken sarı renk SAM üzerindeki en büyük yüksekliği temsil etmektedir. Bu renklerin karşılık geldiği yükseklik değerleri her bir şeklin sağ tarafında bulunan renk çubuğu üzerinden tespit edilebilir. Ayrıca SAM üzerinde kırmızı renklerle 50 m aralıklı eş yükselti eğrileri de gösterilmiştir. Her bir eş yükselti eğrisinin yüksekliği siyah renk ile belirtilmiştir. Çalışma Alanı-2’de, su kütlesi sınırlarının tespitinde elde edilen başarılı sonuçlar hidrolojik düzeltirme işleminin de kusursuz bir şekilde gerçekleştirilmesine olanak sağlamıştır.






Şekil 68. Hidrolojik düzleştirilmiş SAM; a) Malatya-1, b) Malatya-2




Şekil 69. Hidrolojik düzleştirilmiş SAM; a) Malatya-3, b) Malatya-4






Şekil 70. Hidrolojik düzeltilmiş SAM; a) Malatya-5, b) Malatya-6



Şekil 71. Hidrolojik düzeltilmiş SAM; Malatya-7




Çalışma Alanı-3'te durağan su kütlelerine uygulanan hidrolojik düzeltirme sonucunda elde edilen SAM Şekil 72'de gösterilmiştir. Ayrıca SAM üzerinde kırmızı renkler ile 5 m aralıklı eş yükselti eğrileri gösterilmiştir. Her bir eş yükselti eğrisinin yüksekliği siyah renk ile belirtilmiştir.



Şekil 72. Hidrolojik düzeltilmiş SAM; Çalışma Alanı-3

Çalışma Alanı-4'te LiDAR nokta bulutundan elde edilen SAM'daki su kütlelerinin hidrolojik olarak düzeltilmesi sonucunda elde edilen yeni SAM Şekil 73'te gösterilmiştir.






Şekil 73. Hidrolojik düzleştirilmiş SAM; Çalışma Alanı-4


3.4. Su Ayırma Çizgilerinin Oluşturulması

Belirli zamanlar haricinde su akışı bulunmayan derelere kuru dere denir. Mevsimsel olarak yağış veya kar kütlelerinin erimesi sonucunda oluşan su akışını daha büyük su kütlelerine taşıyan doğal drenaj kanallarındırlar. Kuru dereler, topoğrafik haritalarda su ayırma çizgisi ile gösterilirler. Tez çalışmasında, su ayırma çizgilerinin otomatik olarak tespit edilebilmesi için, MATLAB ortamında Schwanghart ve Kuhn (2010) tarafından geliştirilen TopoToolbox modülünden faydalanılmıştır. Su ayırma çizgilerinin hesaplanabilmesi için, öncelikle SAM'dan her bir pikselin komşuluğundaki hangi piksele akış taşıdığını gösteren akış yönü haritası MFD akış yönü algoritması kullanılarak oluşturulmuştur. Ardından, akış yönü haritaları kullanılarak her bir SAM pikselinde toplanan su miktarını belirleyen akış toplanma haritası oluşturulmuştur. Akış toplanma haritası üzerinde gerçekleştirilen eşikleme işlemi yardımı ile su ayırma çizgileri oluşturulmuştur. İkili formatta oluşturulan su ayırma çizgileri, MATLAB ortamında yazılan bir kod ile vektör formata dönüştürülmüştür. Çalışma Alanı-1 ve Çalışma Alanı-2 üzerinde gerçekleştirilen işlemler sonucunda elde edilen su ayırma çizgileri Şekil 74-75'te gösterilmiştir.





Şekil 74. Çalışma Alanı-1 için oluşturulan su ayırma çizgileri



Şekil 75. Çalışma Alanı-2 için oluşturulan su ayırma çizgileri



4. TARTIŞMA

Ülkemizde, başta HGM ve TKGM olmak üzere ilgili diğer kurumların envanterinde bulunan sayısal hava kameralarından elde edilen fotoğraflar, SAM ve YM üretiminde yaygın olarak kullanılmaktadır. Geçmişte yükseklik modellerinin üretiminde manuel iş gücüne dayalı olarak fotogrametrik kıymetlendirme işlemi yaygın olarak kullanılmaktaydı. Tecrübeli bir operatör tarafından gerçekleştirilen kıymetlendirme işleminde arazide bulunan tüm detaylar ve su ayırma çizgileri manuel olarak çizilmektedir. Günümüzde bilgisayar teknolojisinin gelişimine paralel olarak bilgisayarla görme alanında yaşanan ilerlemeler sayesinde arazi yüzeyine ait detaylı yükseklik bilgisi manuel işlem adımlarına ihtiyaç duyulmadan SfM yöntemleri ile elde edilebilmektedir. SfM yöntemleri üretilen nokta bulutları, pek çok açık kaynaklı ve ticari yazılımda bulunan nokta bulutu filtreleme algoritmaları kullanılarak yer üstü noktalar filtrelendikten sonra yalın yer yüzeyi noktaları kullanılarak SAM üretimi gerçekleştirilebilir. Ancak, çalışma alanında su kütlesi bulunması durumunda, nokta bulutlarından SAM üretiminde istenen kartografik doğruluğun elde edilebilmesi için hidrolojik düzeltme işlemi uygulanması gerekmektedir. Manuel olarak su ayırma çizgilerinin çizilmesini gerektiren bu işlem zaman alıcı olmakla beraber iş gücü kullanımını ve veri üretim maliyetini artırmaktadır.

HGM tarafından desteklenen öncelikli araştırma konularından “Sayısal Yüzey Modeli ve Sayısal Arazi Modeli Su Kütlelerinin Otomatik Düzeltilmesi” başlığına katkıda bulunmak üzere tez kapsamında geliştirilen yaklaşım ile hem LiDAR teknolojisi hem de fotogrametrik görüntülerden eşleştirme ile üretilen nokta bulutlarındaki su kütlelerinin otomatik olarak tespit edilerek hidrolojik düzeltme işlemi gerçekleştirilmiştir. Özellikle, ülkemizde HGM ve TKGM kurumlarının SYM ürünlerinin üretiminde yaygın olarak hava kameralarının kullandığı göz önünde bulundurulduğunda geliştirilen yaklaşımın kurumların kaynaklarını daha etkin bir biçimde kullanmasına olanak sağlayacağı görülebilir. Nokta bulutlarından üretilen öznitelik haritaları sayesinde farklı algılayıcılar ile üretilen nokta bulutlarındaki su kütlelerinin geometrik özellikleri karakterize edilmiş ve bu özellikler sayesinde farklı çevresel ve topoğrafik koşullara sahip alanlardaki su kütlelerinin otomatik olarak tespit edilerek MATLAB ortamında geliştirilen hidrolojik düzeltme yazılımı ile otomatize bir şekilde hidrolojik düzeltme işlemi gerçekleştirilmiştir.



Geliştirilen yaklaşım ile hidrolojik düzleştirme işleminde manuel olarak su kütlelerinin çizilmesine duyulan ihtiyaç ortadan kaldırılmış olacaktır.


Tez çalışmasında geliştirilen yaklaşım ile farklı topoğrafik, bitki örtüsü ve yapılaşma özelliklerine sahip çalışma alanlarında fotogrametrik görüntülerden eşleştirme ve LiDAR teknolojisi ile üretilen nokta bulutlarından otomatik olarak tespit edilen su kütleleri üzerinde hidrolojik düzleştirme işlemi gerçekleştirilmiştir. MATLAB ortamında geliştirilen yaklaşım ile su kütlelerinin tespitinde literatürde yaygın olarak kullanılan nokta bulutundaki boşluklar veya MS görüntülerden üretilebilecek olan NDVI, NDWI vb. indislerden yararlanılmamıştır. Bugüne kadar ortaya konan yaklaşımlardan farklı olarak, nokta bulutundan 3B yapı tensörü ile üretilen yerel geometrik öznitelikler kullanılarak su kütlelerini tanımlayan geometrik bilgilerden faydalanılmış ve kolay bir şekilde genelleştirilerek pek çok farklı çalışma alanında uygulanabilecek bir yaklaşım geliştirilmiştir. Bunların yanı sıra, uygulanan filtre tabanlı öznitelik seçim yöntemi Relief-F ile su kütlelerinin tespit edilmesinde en yüksek katkıya sahip olan öznitelikler bulunmuştur. Durağan ve akış halindeki su kütlelerinin hidrolojik düzleştirme işlemi için MATLAB ortamında yazılan kodlar sayesinde pek çok farklı disiplin ve kurumdan gelen araştırmacı ve operatörler kolay bir şekilde kendi veri setlerine bu yaklaşımı uygulayabileceklerdir.

Tez çalışması kapsamında gerçekleştirilen, hava fotoğraflarından fotogrametrik yöntemle nokta bulutlarının oluşturulması, nokta bulutlarından öznitelik çıkarımı ve haritalarının oluşturulması, sınıflandırma ve hidrolojik düzleştirme işlemlerinde bazı zorluk ve hatalar ile karşılaşmıştır. Bu bölümde, karşılaşılan zorluklar ve hatalar açıklanmış ve bunların aşılması için uygulanan işlem adımları anlatılmıştır.

Tez çalışmasında karşılaşılan işlem adımlarına göre öncelikli sorunlardan bazıları hava fotoğraflarından nokta bulutu üretim işlemi ve bunun ardından gelen nokta bulutu filtreleme işlemleridir. Fotogrametrik yöntemlerle veya LiDAR ile üretilen nokta bulutlarında su kütleleri, su yüzeyinin yansıma karakteristiğine ve kullanılan sensörün algılama yaptığı elektromanyetik spektrumun dalga boyuna bağlı olarak doğru bir şekilde tespit edilememektedir. LiDAR nokta bulutlarındaki bu sorunla daha çok kızılötesi dalga boyunda lazer ışını kullanan algılayıcı sistemlerde karşılaşılmaktadır. Söz konusu fotogrametrik nokta bulutları olduğunda ise algılayıcının karakteristiğinden bağımsız olarak SfM algoritmalarından kaynaklanan hatalar ile de karşılaşılmaktadır. Bu hatalar, su kütlelerinin yüzeyinin renk ve doku durumuna bağlı olarak, SfM algoritmasının eşlenik



nokta bulamaması ya da eşlenen noktaların yüksekliğini doğru olarak belirleyememesinden kaynaklı olarak su yüzeylerinde boşlukların oluşması ya da su yüzey yüksekliklerinin hatalı olarak hesaplanmasına neden olur (Şekil 76). Söz konusu hataların, su kütlesi ile kara kesişim sınırlarındaki etkisi daha az olurken, su kütlesinin merkezine doğru gidildikçe artmaktadır. Su kütlelerinde karşılaşılan hatalı yüksekliklerin düzeltilmesi amacıyla aykırı nokta ayıklama algoritmaları denenerek bu hata ortadan kaldırılmaya çalışılmıştır. Ancak uygulanan algoritmalar oluşan hatalı yüksekliklerin belirgin bir istatistiki özelliği olmamasından dolayı bu işlemde başarılı sonuçlar elde edilememesine neden olmuştur. Bu da üretilen model ve sınıflandırma doğruluklarının, kullanılan verideki bu hatalar ile sınırlandırılmasına sebep olmuştur.




Şekil 76. Çalışma Alanı-2 örneğinde su kütlelerinde karşılaşılan boşluklar ve yükseklik hataları

Nokta bulutlarının filtrelenmesi işleminde, yüksek bitki örtüsüyle kaplı tepelerde fotogrametrik nokta bulutunun bitki örtüsü penetrasyonu olmamasından kaynaklanan hatalar ile karşılaşılmıştır. Bu hatalar ile yoğun bitki örtüsüne sahip olan Çalışma Alanı-1 ve Çalışma Alanı-3 veri setlerinde belirgin olarak görülebilmektedir. Filtreleme algoritması yer üstü olarak tespit ettiği noktaları ayrıştırdıktan sonra arda kalan fotogrametrik nokta bulutunda yer yüzeyini temsil edecek noktalar bulunmaması bu duruma neden olmaktadır. Bu hataları içeren filtrelenmiş nokta bulutu, öznitelik haritalarının üretiminde kullanılmakta ve tepe bölgelerinde filtreleme işlemi sonrası gerçek arazi yüzeyi oluşturulamadığı için arazi gerçeğini yansıtmayan öznitelikler hesaplanmasına neden olmaktadır. Sınıflandırma işleminde bu durumun gözle görülür etkileri bulunmamıştır.



Sadece Çalışma Alanı-1 Dere veri setinde filtreleme işlemi sonucu arazi yüzeyinin iyi modellenemediği bölgelerde hesaplanan akış toplanma alanlarında küçük sınıflandırma hatalarına olduğu belirlenmiştir. Bu hatalar ardıl işlemede uygulanan morfolojik işlemler sayesinde kolaylıkla temizlenebilmiştir. Farklı filtreleme yaklaşımları da kullanılsa bu durumun devam ettiği gözlenmiştir. Bu sorun, kullanılan fotogrametrik yaklaşımın doğasından dolayı ortaya çıktığı için herhangi bir düzeltme işlemi uygulanmamıştır. Fotogrametrik yöntem ile üretilen nokta bulutlarında karşılaşılan filtreleme hataları Çalışma Alanı-1 Dere veri setindeki bir örnek ile Şekil 77’de kırmızı kutular içine alınarak gösterilmiştir.



Şekil 77. Filtreleme işlemi sonucunda tepelerde ortaya çıkan yüzey hataları; a) YM, b) SAM

Çalışmada karşılaşılan diğer bir sorun da nokta bulutlarından öznitelik haritalarının üretilmesinde veri yoğunluğundan kaynaklı olarak veri işlemede ortaya çıkmaktadır. Nokta bulutlarından özniteliklerin çıkartılmasında faydalanan Kd-tree yöntemi tüm noktaları mekânsal olarak alt gruplara ayırarak komşu noktaları tespit etmektedir. İşlenen nokta bulutunda bulunan nokta sayısına ve komşuluk boyutuna bağlı olarak bu işlem zaman alıcı olmakta hatta yüksek yoğunluklu nokta bulutlarında bellek yetersizliğine bağlı olarak zaman zaman gerçekleştirilememektedir. Bu sorunla karşılaşmamak amacıyla tüm çalışma alanlarından alt veri setleri üretilmişse de yeterli olmamıştır. Bu sorunun çözümü olarak, işlenen çalışma alanının nokta bulutu 500×500 m boyutlarında alt parçalara bölünmüş ve



her bir parça eşanlı işlenerek daha sonra birleştirilmiştir. Bu sayede, küçük veri setlerinde daha kısa sürede öznitelik çıkarımı gerçekleştirilirken büyük veri setlerinde de öznitelik çıkarımındaki performans sorunları giderilmiştir. Burada veri işlemede harcanan süre vurgulanması gereken önemli bir husustur. Tüm çalışma alanlarının işlendiği i5-9300H işlemci 16 GB belleğe sahip bilgisayarda nokta bulutlarından öznitelik çıkarımı ~30 milyon nokta içeren bir nokta bulutu için yaklaşık olarak 1,5 saat sürmektedir. Pek çok alt veri setinden oluşan çalışma alanları için bu işlem süresi eğitim, sınıflandırma ve hidrolojik düzleştirme işlemleri de eklendiğinde zamansal açıdan maliyetli olmaktadır.

Sınıflandırma işleminde, özellikle durağan su kütlelerinin tespit edilmesinde başarılı sonuçlar elde edilmişse de bazı bölgelerde su ve kara sınıflarının doğru bir şekilde tespit edilemediği görülmüştür. Fotogrametrik görüntülerden üretilen nokta bulutlarından durağan su kütlelerinin sınıflandırılmasında karşılaşılan hatalar özellikle su kütlesi sınırlarında gözlenmiştir. Bunun temel nedenlerinden bir tanesi kara sınırlarından su kütlesi sınırlarına doğru geçişlerde oluşan geometrinin hesaplanan öznitelikler üzerindeki etkisidir. Bu bölgelerde, fotogrametrik görüntülerden üretilen nokta bulutunda su kütlesi yüzeyinde karşılaşılan yüksek miktardaki saçılımın hemen ardından karaya geçişte karşılaşılan düzgün arazi yüzeyi geometrisi hesaplanan özniteliklerde yüksek miktarda değişime neden olmaktadır. Bunlara ek olarak, öznitelik haritaları ile birleştirilen ortofoto görüntülerde su kütlesinde ışığın geliş açısına bağlı olarak oluşan parlamalar da sınıflandırma sonuçlarına olumsuz anlamda etki etmektedir. Şekil 78-80’de sırasıyla Çalışma Alanı-1 Deniz, Çalışma Alanı-2 ve Çalışma Alanı-4 veri setlerinde hatalı sonuçların elde edildiği bölgeler gösterilmiştir. Burada kırmızı renkli çizgiler referans su kütlesi sınırlarını ve yeşil renkli çizgiler de sınıflandırma sonucunda tespit edilen su kütlesi sınırlarını göstermektedir.





Şekil 78. Çalışma Alanı-1 Deniz veri setinde karşılaşılan sınıflandırma hataları



Şekil 79. Çalışma Alanı-2 veri setinde karşılaşılan sınıflandırma hataları



İstanbul çalışma alanında, Şekil 80’de gösterilen hatalar uydu görüntüsünde görülmemesine rağmen LiDAR verisinde görülebilen bu bölgeye demirlemiş olan gemilerin yoğunluk ve öznitelik değerlerinin su kütlesinden farklı olmasından kaynaklanmaktadır.




Şekil 80. Çalışma Alanı-4 veri setinde karşılaşılan sınıflandırma hataları

Çalışma Alanı-1 Dere veri setinde akarsu kütlelerinin sınıflandırılmasında elde edilen doğruluk değerleri her ne kadar hidrolojik düzleştirme işleminin gerçekleştirilmesi için bir sorun teşkil etmese de istenen seviyeye ulaştırılamamıştır (Şekil 81). Bu sorunun temel nedeni, geniş akarsu yatağının büyük bölümünün neredeyse kuru olması ve akarsu yatağının içinden akmakta olan suyun çok küçük bir alandan sığ bir şekilde akmasına bağlı olarak yeterli miktarda ayırt edici özellik içermemesinden kaynaklanmaktadır. Söz konusu çalışma alanına ait farklı zamanlarda çekilmiş hava fotoğrafları olmamasından dolayı mevcut veri kullanılmıştır. Ayrıca, Rize bölgesinin sarp topoğrafyası ve yer yer akarsu kenarlarındaki ağaçların gölgelerinden dolayı akarsu yatağının belirli bölgelerinde üretilen nokta bulutu topoğrafyayı düzgün bir şekilde temsil edememektedir. Bu bölgelerde, su kütlelerinin sınıflandırılmasında ayırt edici öznitelikler çıkartılamamıştır. Diğer bir sorun da su kütlesi sınırlarının manuel olarak çiziminde ortaya çıkmıştır. HGM tarafından sağlanan referans vektör veri, yıllar içinde sürekli farklı akış koşulları altında bulunan akarsu yatağındaki değişimlerden dolayı, hava fotoğraflarının alım anındaki sınırları ile uyumlu değildir. Bu nedenle, su kütlesi sınırlarının manuel olarak sayısallaştırılması gerekmiştir. Manuel sayısallaştırma işleminde, su yüzeyindeki yansımaların kara sınırları ile karışması ve gölgede kalan su kütlesi sınırlarının net bir şekilde tespit edilememesinden



su-kara ayrımının oluşturulmasında zorluklarla karşılaşmıştır. Tüm bu etmenlerin bir araya gelmesi sonucunda akarsu kütlelerinin sınıflandırılması güç bir hale gelmiştir.




Şekil 81. Çalışma Alanı-1 Dere veri setinde karşılaşılan sınıflandırma hataları

Hidrolojik düzeltirme işleminde karşılaşılan en büyük güçlüklerden birisi su kütlelerindeki su yüzey yüksekliklerinin tespit edilmesidir. Daha önce de belirtildiği üzere fotogrametrik nokta bulutlarındaki su yüzey yükseklikleri, yansıma ve doku değişimlerine bağlı olarak doğru bir şekilde tespit edilememektedir. Buna bağlı olarak su kütlelerinin yüksekliklerinin tespit edilmesinde, doğrudan sınıflandırma sonucu elde edilen ikili görüntü sınırları içinde kalan yükseklikler yerine su ile kara sınırları arasındaki sınırın belirlenerek buradan tespit edilen yüksekliklerin kullanılması daha doğru bir işlem adımı olarak düşünülmüştür. Ancak bu durumda da sınıflandırma sonucu oluşan su kütlesi sınırlarındaki hatalara bağlı olarak su yüzeyi yüksekliklerinin doğru tespit edilmesi zorlaşmıştır. Uygulanan PDF yöntemi bu sıkıntıların aşılmasında yardımcı olsa da bu işlem mükemmel olmaktan uzaktır ve zaman zaman birbirine komşu konumdaki çalışma alanlarında ± 1 m kadar yükseklik farklarının olduğu tespit edilmiştir. Yanlış tespit edilen



su kütlesi yüksekliklerinin ardıl işlemler ile düzeltilmesi kolay bir işlem olsa da ek kontrol ve düzeltme işlem adımlarının eklenmesi ile iş akışının zamansal olarak uzamasına neden olmaktadır.

Çalışmada hidrolojik düzleştirme işleminde su yüzey yüksekliklerinin tespit edilmesi aşamasında karşılaşılan diğer bir hata da kubbe etkisidir (dome effect) (Wackrow ve Chandler, 2008; Nesbit ve Hugenholtz, 2019; Mazzoleni vd., 2020). Kubbe etkisi ile yer kontrol noktaları kullanılmadığı, kameradan sadece nadirde görüntü alındığı ve uçuş çizgilerinin birbirine paralel olduğu durumda karşılaşılmaktadır. Bu durumda, SfM algoritması sistematik hataları yayarak üretilen nokta bulutunun özellikle orta ve kenar bölgelerinde bu hataları biriktirir. Bunun sonucunda, bu bölgelerdeki noktaların yüksekliği olduğundan daha az veya daha yüksek olarak hesaplanır. Bu hata, yerel komşulukları etkileyecek kadar dramatik bir etkiye sahip olamamakla beraber sınıflandırma aşamasında da herhangi bir olumsuz etkisi tespit edilmemiştir. Ancak, hidrolojik düzleştirme bağlamında bakıldığında kubbe etkisi, sabit yükseklik değerine sahip olması gereken su kütlesinin yükseklik değerlerinin ± 5 m aralığında değişmesinden dolayı su yüzey yüksekliklerinin hatalı olarak tespit edilmesine neden olmaktadır. Kubbe etkisinin en belirgin olduğu veri seti Çalışma Alanı-2 veri setidir. Bu etki özellikle Çalışma Alanı-2 veri setinin kuzey sınırından başlayarak su kütlesinin iki kola ayrıldığı bölgeye kadar SAM yüksekliklerinde kendisini göstermektedir. Çalışma Alanı-2 veri seti 7 alt bölgeye ayrıldığı için bu etki sonuçlar ürünlerde belirgin bir bozulmaya neden olmamıştır. Çalışma Alanı-2 veri setinde karşılaşılan kubbe etkisi, su kütlesi sınırlarını içeren referans vektör veriye karşılık gelen SAM yükseklik değerleri ile Şekil 82’de gösterilmiştir.




Şekil 82. Çalışma Alanı-2’de karşılaşılan kubbe etkisi



Akarsu kütelleri söz konusu olduğunda, hidrolojik düzleştirme işleminde karşılaşılan en büyük problem sürekli değişen akarsu yatağı genişliğidir. Bu durumun sonuç ürünlerine olan etkisini ortadan kaldırmak amacıyla cSectPP fonksiyonuna adaptif olarak kesit genişliğini tespit edebilme yeteneği kazandırılmıştır. findprofilepts fonksiyonundan elde edilen kesit noktalarından, cSectPP fonksiyonu ile akış doğrultusuna dik en kesitler oluşturulmaktadır. Elde edilen her bir kesit için bir başlangıç yükseklik değeri tespit edilir. Ardından bu yükseklik değerinin, akarsu yatağının her iki kenarında kesişimi kesit üzerinden aranır. Kesişim bulunduğu durumda, başlangıç yükseklik değerinin akarsuyun kıyı şeridini kestiği noktaların koordinatları tespit edilerek kaydedilir. Kesişim bulunamazsa arama genişliği artırılarak işlem tekrar edilir. Bu sayede belirlenen kesit noktalarındaki genişlikler doğru bir şekilde tespit edilebilmektedir. Fakat burada iki kesit arasındaki mesafenin iyi bir şekilde tespit edilmesi sonuç ürünün doğruluğu açısından büyük öneme sahiptir. findprofilepts ile kesit noktalarının tespit edilmesinde kesit aralıklarının doğru bir şekilde belirlenmesi gerekmektedir. İki kesit arasındaki mesafenin çok uzun seçilmesi bu aralıktaki akarsu yatağı genişliğinin gösterdiği değişime bağlı olarak hidrolojik düzleştirme sınırlarının doğru bir şekilde tespit edilmesinde sorunlara neden olacaktır. Aşırı derecede sık seçilen kesit aralıkları çalışma alanının büyüklüğüne bağlı olarak uzun işleme sürelerine ve bazı ekstrem durumlarda su kütlesi sınırlarında tutarsızlıklara neden olacaktır. Buna bağlı olarak, Çalışma Alanı-1 Dere veri setinde 100 m kesit aralıklarında hidrolojik düzleştirme sınırlarının gerçek dere sınırları ile kesişmemesinden kaynaklanan hatalar kırmızı renkteki kutular ile vurgulanarak Şekil 83'te gösterilmiştir.






Şekil 83. Hidrolojik düzeltirme işleminde akarsu kütlelerinde karşılaşılan hatalar

Akarsu kütlelerinde karşılaşılan diğer bir sorun da yan kol olması durumunda meydana gelen kesişim noktalarında ortaya çıkmıştır. Uygulanan hidrolojik düzeltirme yaklaşımı, her bir akarsu kolunu ayrı ayrı değerlendirerek bu kollardan elde edilen akarsu kütlesi sınırlarını birleştirdikten sonra su kütlelerine ait yüzeyi kesit noktalarından elde edilen yükseklikleri kullanarak doğal komşuluk enterpolasyonu sonucunda tespit etmektedir. Ancak uygulanan enterpolasyon işlemi iki akarsu kolunun kesiştiği alanlarda su yüzey yüksekliklerinde $\pm 0,15$ m aralığında değişen hatalara neden olmaktadır. Enterpolasyon sonucu oluşan yüzeydeki yükseklik değişimleri Şekil 84’te gösterilmiştir.





Şekil 84. İki akarsu kolunun birleştiği alanda karşılaşılan enterpolasyon hatası



5. SONUÇ VE ÖNERİLER

Tez çalışması kapsamında, LiDAR ve fotogrametrik nokta bulutlarından 3B yapı tensöründen faydalanılarak öznitelik haritaları üretilmiş ve sınıflandırma aşamasında etkili öznitelikler Relief-F algoritması ile tespit edilmiştir. SAM üzerinden hesaplanan akış toplanma alanları da akarsular için öznitelik haritalarına dahil edilmiş ve hesaplanan tüm öznitelikler çalışma alanlarının ortofotoları ile birleştirilerek çok bantlı öznitelik haritaları üretilmiştir. Üretilen öznitelik haritalarının SLIC süper piksel segmentasyonu yapıldıktan sonra bu segmentler RO sınıflandırıcısı ile sınıflandırılarak SAM üzerindeki su kütleleri otomatik olarak tespit edilmiştir. Tespit edilen su kütlelerinin hidrolojik düzeltme işlemi MATLAB ortamında yazılan betik ve fonksiyonlar ile sağlanmıştır. Her bir çalışma alanının hidrolojik olarak düzeltilmiş SAM'ları üretilmiştir. Önerilen yaklaşım ile su kütlelerinin otomatik olarak tespit edilmesinde ve hidrolojik düzeltme işleminde başarılı sonuçlar elde edilmiştir. Geliştirilen yaklaşım ile su kütlelerinin tespitinde literatürde yaygın olarak kullanılan nokta bulutundaki boşluklar veya MS görüntülerden üretilebilecek olan NDVI, NDWI vb. indislerden yararlanılmamıştır. Bunun yerine, nokta bulutundan 3B yapı tensörü ile üretilen yerel geometrik öznitelikler kullanılarak su kütlelerini tanımlayan geometrik bilgilerden faydalanılmıştır. Ayrıca, uygulanan filtre tabanlı öznitelik seçim yöntemi Relief-F ile su kütlelerinin tespit edilmesinde en yüksek katkıya sahip olan öznitelikler bulunmuştur. Bu sayede, pek çok algılayıcıdan farklı ölçeklerde elde edilen nokta bulutlarından su kütlelerinin tespitine yönelik genelleştirilebilir bir yaklaşım geliştirilmiştir.

Çalışmada, fotogrametrik nokta bulutlarının üretiminde, HGM tarafından sağlanan hava fotoğrafları ve dış yöneltme parametreleri kullanılmıştır. Uygulanan filtreleme işlemi sonucu sadece yalın yer yüzeyi noktaları kalan nokta bulutlarında oluşan boşluklar doldurulduktan sonra 3B yapı tensörü yardımı ile her bir noktanın belirlenen yerel komşuluğundaki öznitelik bilgileri hesaplanarak öznitelik haritaları oluşturulmuştur. Filtre tabanlı öznitelik seçim yöntemi olan Relief-F yöntemi kullanılarak sınıflandırma işleminde en yüksek ağırlığa sahip 10 adet öznitelik seçilmiş ve hava fotoğraflarının Kırmızı, Yeşil ve Mavi spektral bantları ile birleştirilerek sınıflandırma işlemi için hazırlanmıştır. RO sınıflandırıcısı her bir çalışma alanı için 500 ağaç kullanılarak eğitilmiş ve oluşan model yardımı ile çalışma alanının alt veri kümelerinde sınıflandırma işlemi gerçekleştirilmiştir.



Ardından hatalı sınıflandırmalar morfolojik operasyonlar yardımı ile temizlenmiştir. Sınıflandırma işlemi ile tespit edilen su kütlesi sınırlarının doğruluk analizi F-Ölçütü, Doğruluk, Bütünlük ve Kalite ölçütleri ile hesaplanmıştır. Elde edilen doğruluk analizi sonuçlarının ortalama değerleri, Çalışma Alanı-1 Deniz için F-Ölçütü: %85,7, Doğruluk: %99,7, Bütünlük: %96,7 ve Kalite: %96,4, Çalışma Alanı-1 Dere için F-Ölçütü: %76,6, Doğruluk: %78,9, Bütünlük: %56,7 ve Kalite: %49,4, Çalışma Alanı-2 için F-Ölçütü: %93,7, Doğruluk: %99,6, Bütünlük: %95,9 ve Kalite: %95,5, Çalışma Alanı-3 için F-Ölçütü: %94,9, Doğruluk: %97,9, Bütünlük: %95,4 ve Kalite: %93,5, Çalışma Alanı-4 için sırasıyla F-Ölçütü: %73,6, Doğruluk: %95,3, Bütünlük: %94,3 ve Kalite: %90,1 olarak bulunmuştur. Sınıflandırma sonucunda elde edilen su kütlesi sınırlarından faydalanılarak su yüzey yüksekliği tespit edilmiş ve hidrolojik düzleştirme işleminde kullanılmıştır. Nokta bulutlarından üretilen SAM üzerindeki su kütlesi sınırları içerisinde elde edilen su yüzey yüksekliği bilgisi kullanılarak hidrolojik düzleştirme işlemi gerçekleştirilmiştir.

Tez çalışmasında uygulanan yaklaşım ile özellikle durağan su kütlelerinin tespitinde başarılı sonuçlar elde edilmiştir. Önerilen yöntem ile akarsu kütlelerinin tespitinde, akarsu yatağının çoğunluğunun alüvyon ile kaplı olması ve su derinliğinin düşük olmasına bağlı olarak beklenen geometrik özellikleri taşınamaması, fotoğraf çekim anında gölgede kalan alanlardan kaynaklı nokta bulutunda oluşan boşluklar ve referans veriden kaynaklanan belirsiz su kütlesi sınırları nedeniyle elde edilen sonuçlar durağan su kütleleri kadar başarılı olmamaktadır. Yine de elde edilen sonuçlar hidrolojik düzleştirme işleminin gerçekleştirilmesi için yeterli olmuştur.

Önerilen yaklaşım ile elde edilen sonuçlar umut vericidir. Gelecekte, öznitelik haritalarının üretiminde kullanılan algoritma optimize edilerek daha hızlı sonuçların elde edilmesi amaçlanmaktadır. Bu sayede geliştirilen yaklaşım, yüksek performans gereksinimleri olmaksızın çok büyük çalışma alanları için de uygulanabilir hale gelecektir. Bunun yanı sıra, LiDAR nokta bulutlarında da başarısını kanıtlayan bu yaklaşım fotogrametrik ve LiDAR algılayıcılardan elde edilen nokta bulutlarında hidrolojik düzleştirmesinde kolaylıkla kullanılabilecektir. Ayrıca hidrolojik düzleştirme algoritmasına eklenecek ek işlem adımları ile ilerleyen zamanlarda karşılaşılabilecek istisnai durumların da önüne geçilmesi amaçlanmaktadır.

Gelecekte, hibrit algılayıcı sistemlerin yaygınlaşması ile sıkı bir şekilde birbirleri ile referanslandırılmış LiDAR ve hava fotoğraflarının kullanılması sayesinde fotogrametrik nokta bulutlarının, uçuş planlaması, fotoğraf çekim açısı, gölge ve bitki örtüsü kaynaklı



eksikliklerinin giderilmesi sağlanacaktır. Böylece daha yüksek doğruluklu yükseklik verilerinin pasif algılayıcıdan gelen renk bilgileri ile zenginleştirilmesi sonucunda su kütlelerinin otomatik olarak tespit edilmesinde çok daha başarılı sonuçlar elde edilmesine olanak sağlayacaktır. Bunun yanı sıra hem öznitelik haritalarının üretim sürecini hızlandırmak hem de daha iyi bir sınıflandırma sonucu elde edebilmek için günümüzde makine öğrenme algoritmaları içerisinde popüler bir yöntem olan derin öğrenme yöntemleri uygulanarak su kütlelerinin otomatik olarak tespit edilmesi çok daha kolay bir işlem haline getirilebilecektir. Böylelikle, tez kapsamında geliştirilen yaklaşım ile yüksek doğrulukta sınıflandırılmış olan verilere uygulanacak olan hidrolojik düzeltme işlemi daha efektif hale gelerek daha iyi sonuçların elde edilmesine imkân sağlayacaktır.



6. KAYNAKLAR

- Aber, J. S., Marzolf, I. ve Ries, J., 2010. Small-Format Aerial Photography: Principles, Techniques and Geoscience Applications, First Edition, Elsevier, Amsterdam.
- Acar, H., 2018. Bina Çatı Noktalarının Yüksek Çözünürlüklü Görüntülerden Üretilen 3B Nokta Bulutu Verileri ile Otomatik Tespit Edilmesi ve Gerçek Ortofoto Üretimi, Doktora Tezi, K.T.Ü., Fen Bilimleri Enstitüsü, Trabzon.
- Acar, H., Karsli, F., Öztürk, M. ve Dihkan, M., 2019. Automatic Detection of Building Roofs from Point Clouds Produced by the Dense Image Matching Technique, International Journal of Remote Sensing, 40,1, 138-155.
- Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P. ve Süsstrunk, S., 2012. SLIC Superpixels Compared to State-of-the-Art Superpixel Methods, IEEE Transactions on Pattern Analysis and Machine Intelligence, 34,11, 2274-2282.
- Acharjee, P. P., Devarajan, V. ve McCormick, C., 2017. A Prototype Automated Toolbox for a Largescale Waterbody Detection Algorithm using Liner Airborne LiDAR, ASPRS 2017 Annual Conference, Mart, Baltimore, Maryland, Bildiriler Kitabı, 2-5.
- Acharya, T. D., Subedi, A. ve Lee, D. H., 2019. Evaluation of Machine Learning Algorithms for Surface Water Extraction in a Landsat 8 Scene Of Nepal, Sensors, 19,12, 2769.
- Akbulut, Z., Özdemir, S., Acar, H. ve Karsli, F., 2018. Automatic Building Extraction from Image and LiDAR Data with Active Contour Segmentation, Journal of the Indian Society of Remote Sensing, 46,12, 2057-2068.
- Axelsson, P., 2000. DEM Generation from Laser Scanner Data Using adaptive TIN Models, International Archives of Photogrammetry and Remote Sensing, 33, 110-117.
- Baltsavias, E. P., 1999. A Comparison Between Photogrammetry and Laser Scanning, ISPRS Journal of Photogrammetry and Remote Sensing, 54,2-3, 83-94.
- Bandini, F., Sunding, T. P., Linde, J., Smith, O., Jensen, I. K., Köppl, C. J., Butts, M. ve 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.
- Belgiu, M. ve Drăguț, L., 2016. Random Forest in Remote Sensing: A Review Of Applications and Future Directions, ISPRS Journal of Photogrammetry and Remote Sensing, 114, 24-31.
- Bentley, J. L., 1975. Multidimensional Binary Search Trees Used for Associative Searching, Communications of the ACM, 18,9, 509-517.



- Blomley, R., Jutzi, B. ve Weinmann, M., 2016. Classification of Airborne Laser Scanning Data Using Geometric Multi-Scale Features and Different Neighbourhood Types, ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences, III-3, 169-176.
- Blomley, R., Weinmann, M., Leitloff, J. ve Jutzi, B., 2014. Shape Distribution Features for Point Cloud Analysis; A Geometric Histogram Approach on Multiple Scales, ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences, II-3, 9-16.
- Breiman, L., 2001. Random forests. Machine Learning, 45,1, 5-32.
- Broersen, T., Peters, R. ve Ledoux, H., 2017. Automatic Identification of Watercourses in Flat and Engineered Landscapes by Computing the Skeleton of a LiDAR Point Cloud, Computers and Geosciences, 106, 171-180.
- Brooks, S. M., 2003. Slopes and Slope Processes: Research Over the Past Decade, Progress in Physical Geography, 27,1, 130-144.
- Canaz, S., Karsli, F., Guneroglu, A. ve Dihkan, M., 2015. Automatic Boundary Extraction of Inland Water Bodies Using LiDAR Data, Ocean and Coastal Management, 118, 158-166.
- Chawla, I., Karthikeyan, L. ve Mishra, A. K., 2020. A Review of Remote Sensing Applications for Water Security: Quantity, Quality, and Extremes. Journal of Hydrology, 585, 124826.
- Chen, F., Chen, X., Van de Voorde, T., Roberts, D., Jiang, H. ve Xu, W., 2020. Open Water Detection in Urban Environments Using High Spatial Resolution Remote Sensing Imagery, Remote Sensing of Environment, 242, 111706.
- Çölkesen, I. ve Kavzoğlu, T., 2018. Selection of Optimal Object Features in Object-Based Image Analysis Using Filter-Based Algorithms. Journal of the Indian Society of Remote Sensing, 46,8, 1233-1242.
- Cook, K. L., 2017. An Evaluation of the Effectiveness of Low-Cost UAVs and Structure from Motion for Geomorphic Change Detection, Geomorphology, 278, 195-208.
- Coulthard, T. J., Macklin, M. G. ve Kirkby, M. J., 2002. A Cellular Model of Holocene Upland River Basin and Alluvial Fan Evolution, Earth Surface Processes and Landforms, 27,3, 269-288.
- Csurka, G., Larlus, D., Perronnin, F. ve Meylan, F., 2013. What is a Good Evaluation Measure for Semantic Segmentation?, British Machine Vision Conference, Eylül, Bristol, İngiltere, Bildiriler Kitabı, 32.1-32.11.
- Cutler, A., Cutler, D. R. ve Stevens, J. R., 2012. Random Forests, Ensemble Machine Learning, First Edition, 157-175, Springer, Boston.



- Demantké, J., Mallet, C., David, N. ve Vallet, B., 2011. Dimensionality Based Scale Selection in 3D LiDAR Point Clouds. ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 3812, 97-102.
- Deshpande, S. S. ve Yilmaz, A., 2017. A Semi-Automated Method to Create a LiDAR-Based Hydro-Flattened DEM. International Journal of Remote Sensing, 38,5, 1365-1387.
- Dong, Y., Cui, X., Zhang, L. ve Ai, H., 2018. An Improved Progressive TIN Densification Filtering Method Considering the Density and Standard Variance of Point Clouds, ISPRS International Journal of Geo-Information, 7,10, 409.
- Durgabai, R. P. L. ve Bhushan, Y. R., 2014. Feature Selection Using ReliefF Algorithm. International Journal of Advanced Research in Computer and Communication Engineering, 3,10, 8215-8218.
- Filin, S. ve Pfeifer, N., 2005. Neighborhood Systems for Airborne Laser Data. Photogrammetric Engineering & Remote Sensing, 71,6, 743-755.
- Gallant, J. C. ve Wilson, J. P., 2000. Primary Topographic Attributes, Terrain Analysis-Principles and Application, First Edition, 51-86, John Wiley & Sons, New York.
- Guo, B., Huang, X., Zhang, F. ve Sohn, G., 2015. Classification of Airborne Laser Scanning Data Using JointBoost. ISPRS Journal of Photogrammetry and Remote Sensing, 100, 71-83.
- Habib, M. A., 2017. Virtual Surveyor based Object Extraction from Airborne LiDAR Data. Doktora Tezi, The University of Texas at Arlington.
- Han, X. F., Jin, J. S., Wang, M. J., Jiang, W., Gao, L. ve Xiao, L., 2017. A Review of Algorithms for Filtering the 3D Point Cloud, Signal Processing: Image Communication, 57, 103-112.
- Hartley, R. ve Zisserman, A., 2004. Multiple View Geometry in Computer Vision, Second Edition, Cambridge University Press, Cambridge.
- Heidemann, H. K., 2012. Lidar Base Specification Version 1.0, First Edition, 1-101, USGS, Reston.
- Hirschmüller, H., 2008. Stereo Processing by SemiGlobal Matching and Mutual Information. IEEE Transactions on Pattern Analysis and Machine Intelligence, 30,2, 328-341.
- Hirschmüller, H., 2011. Semi-Global Matching-Motivation, Developments and Applications, Photogrammetric Week 11, Eylül, Stuttgart, Almanya, Bildiriler Kitabı, 173-184.
- Hirt, C., 2015. Encyclopedia of Geodesy; Digital Terrain Models, First Edition, Springer, Cham.



- Horkaew, P. ve Puttinaovarat, S., 2017. Entropy-Based Fusion of Water Indices and DSM Derivatives for Automatic Water Surfaces Extraction and Flood Monitoring, ISPRS International Journal of Geo-Information, 6,10, 301.
- Jacobsen, K., 2010. Development of Digital Aerial Cameras, International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 1W17, 38.
- Javernick, L., Brasington, J. ve Caruso, B., 2014. Modeling the Topography of Shallow Braided Rivers Using Structure-from-Motion Photogrammetry. Geomorphology, 213, 166-182.
- Johnson, A. E. ve Hebert, M., 1999. Using Spin Images for Efficient Object Recognition in Cluttered 3D Scenes, IEEE Transactions on Pattern Analysis and Machine Intelligence, 21,5, 433-449.
- Jutzi, B. ve Gross, H., 2009. Nearest neighbour classification on laser point clouds to gain object structures from buildings, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 38, 4-7.
- Kasvi, E. Salmela, J., Lotsari, E., Kumpula, T. ve Lane, S. N., 2019. Comparison of Remote Sensing Based Approaches for Mapping Bathymetry of Shallow, Clear Water Rivers. Geomorphology, 333, 180-197.
- Kavzoğlu, T. ve 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.
- Kavzoğlu, T., Çölkesen, İ. ve Yomralıoğlu, T., 2015. Object-Based Classification with Rotation Forest Ensemble Learning Algorithm Using Very-High-Resolution WorldView-2 Image, Remote Sensing Letters, 6,11, 834-843.
- Kira, K. ve Rendell, L. A., 1992. The Feature Selection Problem: Traditional Methods and a New Algorithm, AAAI, 2, 129-134.
- Kononenko, I., Šimec, E. ve Robnik-Šikonja, M., 1997, Overcoming the Myopia of Inductive Learning Algorithms with ReliefF, Applied Intelligence, 7,1, 39-55.
- Kraus, K., 2011. Photogrammetry: Geometry from Images and Laser Scans, Second Edition, Walter de Gruyter.
- Langat, P. K., Kumar, L. ve Koech, R., 2019. Monitoring River Channel Dynamics Using Remote Sensing and GIS Techniques, Geomorphology, 325, 92-102.
- Lary, D. J., Alavi, A. H., Gandomi, A. H. ve Walker, A. L., 2016. Machine Learning in Geosciences and Remote Sensing, Geoscience Frontiers, 7,1, 3-10.
- Leberl, F., Irschara, A., Pock, T., Meixner, P., Gruber, M., Scholz, S. ve Wiechert, A., 2010. Point clouds, Photogrammetric Engineering & Remote Sensing, 76,10, 1123-1134.



- Lee, I. ve Schenk, T., 2002. Perceptual Organization of 3D Surface Points, International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences, 34,3/A, 193-198.
- 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.
- Lewis, Q. W., Lindroth, E. M. ve Rhoads, B. L., 2018. Integrating Unmanned Aerial Systems and LSPIV for Rapid, Cost-Effective Stream Gauging, Journal of Hydrology, 560, 230-246.
- Linsen, L. ve Prautzsch, H., 2001. Local versus Global Triangulations, EUROGRAPHICS, Eylül, Manchester, İngiltere, Bildiriler Kitabı, 257-263.
- Liu, D. ve Xia, F., 2010. Assessing Object-Based Classification: Advantages and Limitations, Remote Sensing Letters, 1,4, 187-194.
- Liu, K., Song, C., Ke, L., Jiang, L. ve Ma, R., 2020. Automatic Watershed Delineation in the Tibetan Endorheic Basin: A Lake-Oriented Approach Based on Digital Elevation Models, Geomorphology, 358, 107127.
- Mallet, C., Bretar, F., Roux, M., Soergel, U. ve Heipke, C., 2011. Relevance Assessment of Full-Waveform LiDAR Data for Urban Area Classification, ISPRS Journal of Photogrammetry and Remote Sensing, 66,6, S71-S84.
- Mazzoleni, M., Paron, P., Reali, A., Juizo, D., Manane, J. ve Brandimarte, L., 2020. Testing UAV-Derived Topography for Hydraulic Modelling in a Tropical Environment, Natural Hazards, 103, 139-163.
- Munoz, D., Bagnell, J. A., Vandapel, N. ve Hebert, M., 2009. Contextual Classification with Functional Max-Margin Markov Networks, IEEE Conference on Computer Vision and Pattern Recognition, Haziran, Miami FL, ABD, Bildiriler Kitabı, 975-982.
- Nesbit, P. R. ve Hugenholtz, C. H., 2019. Enhancing UAV-SFM 3D Model Accuracy in High-Relief Landscapes by Incorporating Oblique Images, Remote Sensing, 11,3, 239.
- Nicholas, A. P., 2005. Cellular Modelling in Fluvial Geomorphology, Earth Surface Processes and Landforms: The Journal of the British Geomorphological Research Group, 30,5, 645-649.
- Orlandini, S., Moretti, G., Franchini, M., Aldighieri, B. ve Testa, B., 2003. Path-Based Methods for the Determination of Nondispersive Drainage Directions in Grid-Based Digital Elevation Models, Water Resources Research, 39,6, 1144-1151.
- Osada, R., Funkhouser, T., Chazelle, B. ve Dobkin, D., 2002. Shape Distributions. ACM Transactions on Graphics (TOG), 21,4, 807-832.



- Parrot, J. F. ve Ramírez Núñez, C., 2016. LiDAR DTM: Artifacts, and Correction for River Altitudes. Investigaciones Geográficas, 90, 28-39.
- Pauli, H., 1976. Proposed Extension of the CIE Recommendation on “Uniform Color Spaces, Color Difference Equations, and Metric Color Terms”. JOSA, 66,8, 866-867.
- Pauly, M., Keiser, R. ve Gross, M., 2003. Multi-Scale Feature Extraction on Point-Sampled Surfaces, Computer Graphics Forum, 22,3, 281-289.
- Poppenga, S. K., Worstell, B. B., Stoker, J. M. ve Greenlee, S. K., 2010. Using Selective Drainage Methods to Extract Continuous Surface Flow from 1-Meter LiDAR-Derived Digital Elevation Data, U. S. Geological Survey, 5059, 1-12.
- Pula, R. A., Concepcion II, R., Ilagan, L. ve Tobias, R. R., 2019. Classification of Landcover from Combined LiDAR and Orthophotos Using Support Vector Machine, IEEE 11th HNICEM, Kasım, Baguio City, Filipinler. Bildiriler Kitabı, 1-5.
- Quinn, P. F. B. J., Beven, K., Chevallier, P. ve Planchon, O., 1991. The Prediction of Hillslope Flow Paths for Distributed Hydrological Modelling Using Digital Terrain Models, Hydrological Processes, 5,1, 59-79.
- Ramiya, A. M., Nidamanuri, R. R. ve Krishnan, R., 2019. Individual Tree Detection from Airborne Laser Scanning Data Based on Supervoxels and Local Convexity, Remote Sensing Applications: Society and Environment, 15, 100242.
- Rampi, L. P., Knight, J. F. ve Lenhart, C. F., 2014. Comparison of Flow Direction Algorithms in the Application of the CTI for Mapping Wetlands in Minnesota, Wetlands, 34,3, 513-525.
- Roelens, J., Höfle, B., Dondeyne, S., Van Orshoven, J. ve Diels, J., 2018. Drainage Ditch Extraction from Airborne LiDAR Point Clouds, ISPRS Journal of Photogrammetry and Remote Sensing, 146, 409-420.
- Rogers, M., 2017. Can Structure from Motion Determine the Efficacy of River re-Meandering as a Natural Flood Management Measure?, Doktora Tezi, University of Cambridge.
- Rusu, R. B., Marton, Z. C., Blodow, N. ve Beetz, M., 2008. Persistent Point Feature Histograms for 3D Point Clouds, IAS-10, Haziran, Baden, Almanya, Bildiriler Kitabı, 119-128.
- Rusu, R. B., Blodow, N. ve Beetz, M., 2009. Fast Point Feature Histograms (FPFH) for 3D Registration, IEEE International Conference on Robotics and Automation, Mayıs, Kobe, Japonya, Bildiriler Kitabı, 3212-3217.
- Rutzinger, M., Rottensteiner, F. ve 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.



- Saksena, S., 2015. Investigating the Role of DEM Resolution and Accuracy on Flood Inundation Mapping, World Environmental and Water Resources Congress, Mayıs, Austin TX, ABD, Bildiriler Kitabı, 2236-2243.
- Sangireddy, H., Stark, C. P., Kladzyk, A. ve Passalacqua, P., 2016. GeoNet: An Open Source Software for the Automatic and Objective Extraction of Channel Heads, Channel Network, and Channel Morphology from High Resolution Topography Data, Environmental Modelling & Software, 83, 58-73.
- Schwanghart, W. ve Scherler, D., 2014. TopoToolbox 2 MATLAB-Based Software for Topographic Analysis and Modeling in Earth Surface Sciences, Earth Surface Dynamics, 2,1, 1-7.
- Schwanghart, W. ve Kuhn, N. J., 2010. TopoToolbox: A Set of Matlab Functions for Topographic Analysis, Environmental Modelling & Software, 25,6, 770-781.
- Seibert, J. ve McGlynn, B. L., 2007. A New Triangular Multiple Flow Direction Algorithm for Computing Upslope Areas from Gridded Digital Elevation Models, Water Resources Research, 43,4, 1-8.
- Shaker, A., Yan, W. Y. ve 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, 94-108.
- Shingare, P. P. ve Kale, S. S., 2013. Review on Digital Elevation Model, International Journal of Modern Engineering Research, 3,4, 2412-2418.
- Šíkola, M., Chajma, P., Anděl, P., Solský, M. ve Vojar, J., 2019. Finding Water: Reliability of Remote-Sensing Methods in Searching for Water Bodies within Diverse Landscapes, Ecohydrology & Hydrobiology, 19,3, 383-392.
- Smeeckaert, J., Mallet, C., David, N., Chehata, N. ve Ferraz, A., 2013. Large-Scale Classification of Water Areas Using Airborne Topographic Lidar Data, Remote Sensing of Environment, 138, 134-148.
- Song, S., Liu, J., Liu, Y., Feng, G., Han, H., Yao, Y. ve 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.
- Tarboton, D. G., 1997. A New Method for the Determination of Flow Directions and Upslope Areas in Grid Digital Elevation Models. Water Resources Research, 33,2, 309-319.
- Tombari, F., Salti, S. ve Di Stefano, L. 2010. Unique Signatures of Histograms for Local Surface Description, European Conference on Computer Vision, Eylül, Heraklion, Girit, Bildiriler Kitabı, 356-369.
- Toscano, G., Gopalam, U. ve Devarajan, V., 2014. Auto Hydro Break Line Generation Using LiDAR Elevation and Intensity Data, ASPRS 2014 Annual Conference, Mart, Louisville KY, ABD, Bildiriler Kitabı, 1-12.



- Tymków, P., Józków, G., Walicka, A., Karpina, M. ve Borkowski, A., 2019. Identification of Water Body Extent Based on Remote Sensing Data Collected with Unmanned Aerial Vehicle, Water, 11,2, 338.
- Urbanowicz, R. J., Meeker, M., La Cava, W., Olson, R. S. ve Moore, J. H., 2018. Relief-Based Feature Selection: Introduction and Review, Journal of Biomedical Informatics, 85, 189-203.
- URL-1. <https://www.vexcel-imaging.com/ultracam-eagle/>. 5 Ocak 2021
- URL-2. <https://leica-geosystems.com/products/airborne-systems/leica-citymapper-2>. 5 Ocak 2021
- Wackrow, R. ve Chandler, J. H., 2008. A Convergent Image Configuration for DEM Extraction that Minimises the Systematic Effects Caused by an Inaccurate Lens Model, The Photogrammetric Record, 23,121, 6-18.
- Wallace, L., Lucieer, A., Malenovský, Z., Turner, D. ve Vopěnka, P., 2016. Assessment of Forest Structure Using Two UAV Techniques: A Comparison of Airborne Laser Scanning and Structure from Motion (SfM) Point Clouds, Forests, 7,3, 62.
- Weibel, R. ve Heller M., 1991. Geographical Information Systems; Principles and Applications, First Edition, 269-297, Longman, London.
- Weinmann, M., Jutzi, B., Hinz, S. ve Mallet, C., 2015. Semantic Point Cloud Interpretation Based on Optimal Neighborhoods, Relevant Features and Efficient Classifiers, ISPRS Journal of Photogrammetry and Remote Sensing, 105, 286-304.
- Weinmann, M., Jutzi, B. ve Mallet, C., 2013. Feature Relevance Assessment for the Semantic Interpretation of 3D Point Cloud Data, ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Kasım, Antalya, Bildiriler Kitabı II: 313-318.
- Weinmann, M., Jutzi, B., Mallet, C. ve Weinmann, M., 2017. Geometric Features and Their Relevance for 3d Point Cloud Classification, ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences, Haziran, Hannover, Almanya, Bildiriler Kitabı, 157-164.
- West, K. F., Webb, B. N., Lersch, J. R., Pothier, S., Triscari, J. M. ve Iverson, A. E., 2004. Context-Driven Automated Target Detection in 3D Data, Automatic Target Recognition XIV, Eylül, Orlando FL, ABD, Bildiriler Kitabı, 133-143.
- Xu, Y., Ye, Z., Huang, R., Hoegner, L. ve Stilla, U., 2020. Robust Segmentation and Localization of Structural Planes from Photogrammetric Point Clouds in Construction Sites, Automation in Construction, 117, 103206.
- Yousefi, P., Jalab, H. A., Ibrahim, R. W., Noor, N. F. M., Ayub, M. N. ve Gani, A., 2018. Water-Body Segmentation in Satellite Imagery Applying Modified Kernel Kmeans, Malaysian Journal of Computer Science, 31,2, 143-154.



Zheng, X., Godbout, L., Zheng, J., McCormick, C. ve Passalacqua, P., 2019. An Automatic and Objective Approach to Hydro-Flatten High Resolution Topographic Data, Environmental Modelling & Software, 116, 72-86.



ÖZGEÇMİŞ

İlk ve orta öğretimini Kocaeli’nde tamamladı. Lisans öğrenimine 2005 yılında KTÜ Gümüşhane Mühendislik Fakültesi’nde Harita Mühendisliği bölümünde başladı. Lisans mezuniyetinin ardından Mersin/Anamur 22-a kadastro yenileme çalışması ve Kocaeli Belediyesi Park ve Bahçeler Müdürlüğü olmak üzere özel ve devlet sektöründe Harita Mühendisliği mesleğini icra etti. Gümüşhane Üniversitesi’nde Harita Mühendisliği bölümünde araştırma görevlisi olarak başladı ve aynı yıl burada yüksek lisans öğrenimine başladı. Yüksek lisans çalışmasından sonra aynı yıl KTÜ FBE Harita Mühendisliği Anabilim Dalı’nda Prof. Dr. Fevzi KARSLI danışmanlığında doktora çalışmasına başladı.

