

**UYDU GÖRÜNTÜLERİNİN KONTROLSÜZ SINIFLANDIRILMASINDA
OPTİMİZASYON TABANLI YENİ BİR YAKLAŞIM**

DİLEK KÜÇÜK MATCI

DOKTORA TEZİ

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri

Anabilim Dalı

Danışman: Doç. Dr. Uğur AVDAN

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

ARALIK 2019

JÜRİ VE ENSTİTÜ ONAYI

Dilek Küçük Matcı'nın "Uydu Görüntülerinin Kontrolsüz Sınıflandırmasında Optimizasyon Tabanlı Yeni Bir Yaklaşım" başlıklı tezi tarihinde aşağıdaki jüri tarafından değerlendirilerek "Eskişehir Teknik Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim dalında Doktora tezi olarak kabul edilmiştir.

<u>Jüri Üyeleri</u>	<u>Unvanı Adı Soyadı</u>	<u>İmza</u>
Üye (Tez Danışmanı) :	Doç. Dr. Uğur AVDAN	
Üye :	Prof. Dr. Taşkın KAVZOĞLU	
Üye :	Doç. Dr. Tuğba SARAÇ	
Üye :	Dr. Öğr. Üyesi Hakan UYGUÇGİL	
Üye :	Dr. Öğr. Üyesi Emrah PEKKAN	

Prof.Dr. Murat TANIŞLI
Lisansüstü Eğitim Enstitüsü Müdürü

ÖZET

UYDU GÖRÜNTÜLERİNİN KONTROLSÜZ SINIFLANDIRILMASINDA OPTİMİZASYON TABANLI YENİ BİR YAKLAŞIM

DİLEK KÜÇÜK MATCI

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı
Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Aralık 2019

Danışman: Doç. Dr. Uğur AVDAN

Kontrolsüz sınıflandırma, uzaktan algılamada görüntülerin analizi amacıyla kullanılan yöntemlerden biridir. Bu yöntem, kontrollü sınıflandırma yöntemlerinin aksine eğitim verisi gerektirmemektedir. Sınıflandırma doğruluğunu doğrudan etkileyen kaliteli ve yeterli eğitim verilerinin toplanması zahmetli ve maliyetli bir süreçtir. Bu süreç kullanıcının çalışılan alanı çok iyi bilmesini ve sınıflandırma yöntemleriyle ilgili uzman olmasını gerektirmektedir. Kontrolsüz sınıflandırma yöntemleri, eğitim verisi gerektirmediği için daha pratik bir yaklaşımdır. Ancak yine de sınıf sayısı, maximum iterasyon sayısı ve sınıflandırma prosedürünün ne zaman sona erdirileceğini belirten eşik değerleri gibi belirli girdilerin kullanıcı tarafından belirlenmesi gerekmektedir. Bunun yanında kontrolsüz sınıflandırma yöntemleri sonuçlarını etiketlemeden oluşturduğundan yine kullanıcı tarafından sonuçların etiketlenmesi gerekmektedir.

Bu çalışmada, kullanıcıya olan bağımlılığı ortadan kaldıran ve yüksek doğruluklu sonuçlar üreten yeni bir kontrolsüz sınıflandırma yöntemi önerilmiştir. Bu yöntem, veri çoğaltma, faydalı veri seçme, bölütleme ve optimizasyon aşamalarından oluşmakta ve otomatik olarak sınıflandırmayı gerçekleştirmektedir. Geliştirilmiş olan bu yöntem, görüntü işleme konusunda uzman olmaksızın, farklı meslek disiplinlerindeki kişilerin de kolaylıkla uygulayabileceği ve başarılı sınıflandırma sonuçları elde edilmesi anlamında literatüre katkı sağlamaktadır. Ayrıca kontrolsüz sınıflandırma yöntemleri tarafından etiketsiz olarak oluşturulan sonuçların etiketlenmesi amacıyla yeni bir yaklaşım önerilmiştir.

Anahtar Kelimeler: Kontrolsüz Sınıflandırma, Optimizasyon, Uzaktan Algılama, Arazi Örtüsü Etiketleme

ABSTRACT

A NEW OPTIMIZATION BASED APPROACH TO THE UNSUPERVISED CLASSIFICATION OF SATELLITE IMAGES

Dilek KÜÇÜK MATCI

Department of Remote Sensing And Geographic Information Systems

Eskisehir Technical University, Institute of Graduate Programs, December 2019

Supervisor: Assoc. Prof. Dr. Uğur Avdan

The classification process is one of the methods used for the analysis of remotely sensed images. The unsupervised classification methods do not require training data as opposed to supervised classification methods. Collecting quality and sufficient training data directly affecting classification accuracy is a laborious and costly process. This process requires the user to be familiar with the area of study and to become an expert in the classification methods. Unsupervised classification methods are more practical since they do not require training data. However, certain inputs need to be specified by the user, such as the number of classes, the maximum number of iterations, and the threshold values that indicate when the classification procedure will be terminated.

In this study, a new unsupervised classification method that eliminates user dependence and produces high accuracy results is proposed. This method consists of data extension, useful data selection, segmentation and optimization stages and performs the classification automatically. This developed method contributes to the literature in terms of achieving successful classification results which can be easily applied by people from different professional disciplines without being an expert in image processing. In addition, a new approach has been proposed to label unlabeled results by unsupervised classification methods.

Key Words: Unsupervised Classification, Optimization, Remote Sensing, Land Cover Labelling

TEŞEKKÜR

Tez sürecim boyunca bilgi ve birikimlerini benimle paylaşan, her konuda ve koşulda desteklerini benden eksik etmeyen, tez sürecimin verimli ve kusursuz bir şekilde ilerlemesini sağlayan tez danışmanım Doç. Dr. Uğur AVDAN' a,

Tez İzleme Komitelerinde tez sürecinin sağlıklı bir şekilde ilerlemesine ve tezimin şekillenmesinde tecrübe ve deneyimleri ile büyük katkılar sunan sayın Prof. Dr. Taşkın KAVZOĞLU' na ve sayın Doç. Dr. Tuğba SARAÇ' a,

Tezimi inceleyip görüş ve önerilerini benimle paylaşan sayın Dr. Öğr. Üyesi Hakan UYGUÇGİL ve sayın Dr. Öğr. Üyesi Emrah PEKKAN'a,

Sabrı ve hoşgörüsüyle beni destekleyen sevgili eşim ve çocuklarıma,

Hayatımın her aşamasında olduğu gibi bu tez sürecinde de benden desteklerini ve sevgilerini esirgemeyen anneme, babama ve kardeşime,

Tez sürecim boyunca desteklerini benden eksik etmeyen değerli çalışma arkadaşlarıma ve tez çalışmalarım boyunca bana destek olan Eskişehir Teknik Üniversitesi Yer ve Uzay Bilimleri Enstitüsü personeline, en içten dileklerimle teşekkür ederim.

Dilek KÜÇÜK MATCI

Aralık 2019

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Anadolu Üniversitesi tarafından kullanılan “bilimsel intihal tespit programıyla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

.....
Dilek KÜÇÜK MATCI

İÇİNDEKİLER

BAŞLIK SAYFASI	i
JÜRİ VE ENSTİTÜ ONAYI.....	ii
ÖZET	iii
ABSTRACT	iv
TEŞEKKÜR	v
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	vi
ŞEKİLLER DİZİNİ	x
TABLolar DİZİNİ.....	xii
KISALTMALAR DİZİNİ	xiii
1. GİRİŞ.....	15
1.1 Problemin Tanımı Ve Çalışmanın Amacı	15
1.2 Literatür Özeti.....	17
2. TEMEL KAVRAMLAR.....	21
2.1 Elektromanyetik Enerji / Elektromanyetik Spektrum	21
2.2 Enerji-Yeryüzü Nesneleri Etkileşimi.....	22
2.3 Spektral İndisler	22
2.4 Görüntü Keskinleştirme	22
2.4.1 IHS Keskinleştirme Tekniği	22
2.5 Doğruluk Analizi	23
2.6 Temel Bileşenler Analizi (PCA)	23
2.7 Python Programlama Dili.....	23
2.8 Görüntü Filtreleri.....	24
2.9 Sınıflandırma Kalite İndisleri	24
3. SINIFLANDIRMA	25
3.1 Piksel Tabanlı Sınıflandırma	25
3.2 Nesne Tabanlı Sınıflandırma	26
3.3 Kontrollü Sınıflandırma	27
3.4 Kontrolsüz Sınıflandırma	28
3.5 Kontrolsüz Sınıflandırma Algoritmaları	30
3.5.1 Hiyerarşik Sınıflandırma	30
3.5.2 K-Means	32

3.5.3	ISODATA	33
3.5.4	Self Organizing Maps (SOM)	34
3.5.5	DBSCAN	35
3.5.6	Canopy	36
3.5.7	M-Tree	37
3.5.8	Learning Vector Quantization (LVQ)	38
3.5.9	Fuzzy C- Means	39
4.	ÇALIŞMADA KULLANILAN VERİLER VE ÇALIŞMA ALANLARI	40
5.	YÖNTEM	45
5.1	Sınıflandırma	45
5.1.1	Veri Havuzunun Genişletilmesi	46
5.1.2	Başlangıç Sınıflarının Oluşturulması	56
5.1.3	Nihai Sınıfların Oluşturulması- Optimizasyon İşlemi	57
5.2	Etiketleme	59
5.2.1	Geliştirilen Etiketleme Algoritması	59
5.2.2	Corine Arazi Örtüsü Sınıfları	61
5.3	Arayüz	65
5.3.1	Sınıflandırma Arayüzü	65
5.3.2	Doğruluk Analizi Arayüzü	68
5.3.3	Etiketleme Sonuç Arayüzü	69
6.	BULGULAR	70
6.1	Sınıflandırma	70
6.1.1	Çalışma Alanı 1: Sinop	70
6.1.2	Çalışma Alanı 2: Hatay	74
6.1.3	Çalışma Alanı 3: Gemlik	80
6.2	Etiketleme	86
6.2.1	Geliştirilen Yöntem	86
6.2.2	Geliştirilen Yöntem ve Corine Verilerinin Birlikte Kullanılması	91
7.	TARTIŞMA	99
7.1	Sınıflandırma Algoritması	99
7.2	Etiketleme	101
8.	SONUÇ VE ÖNERİLER	103

8.1	Sınıflandırma	103
8.2	Etiketleme	104
8.3	Çalışma Sonucundaki Öneriler.....	106
	ÖZGEÇMİŞ.....	122



ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1 Elektromanyetik Spektrum (diyo.net, 2019)	21
Şekil 3.1 Piksel tabanlı sınıflandırmada temel işlem adımları.....	25
Şekil 3.2 Nesne tabanlı sınıflandırmada temel işlem adımları.....	26
Şekil 3.3 Kontrollü Sınıflandırma.....	27
Şekil 3.4 Kontrolsüz Sınıflandırma.....	29
Şekil 3.5 Kontrolsüz Sınıflandırma Yöntemleri (Ma & Chow, 2004).....	29
Şekil 3.6 Ayrıştırıcı hiyerarşik sınıflandırma (Roux, 2015)	31
Şekil 3.7 Birleştirici hiyerarşik sınıflandırma (Kwon, Lee, & Lee, 2018).....	32
Şekil 3.8 K-Means Algoritması (Younus et al., 2015)	33
Şekil 3.9 ISODATA Algoritması (Jang, Kim, & Byun, 2014).....	34
Şekil 3.10 SOM Algoritması (Anifah, Purnomo, Mengko, & Purnama, 2018)	35
Şekil 3.11 DBSCAN Algoritması (El Bahi & Zatni, 2018)	36
Şekil 3.12 Canopy Algoritması (McCallum et al., 2000)	37
Şekil 3.13 LVQ Algoritması (Kohonen et al., 1992).....	38
Şekil 3.14 Fuzzy C-Means Algoritması (Wang, Zhao, Wang, Tang, & Li, 2015)	39
Şekil 4.1 Veri-1: Gemlik Bölgesi	42
Şekil 4.2 Veri-2: Hatay Bölgesi	43
Şekil 4.3 Veri-3: Sinop Bölgesi.....	44
Şekil 5.1 Önerilen Sınıflandırma Algoritması	45
Şekil 5.2 Başlangıç Sınıflarının Oluşturulması	57
Şekil 5.3 Nihai Sınıf Oluşturma Algoritması	58
Şekil 5.4 Geliştirilen Etiketleme Algoritması	60
Şekil 5.5 CORINE arazi sınıfları incelemesi a)Uydu Görüntüsü b) Corine Sınıfları ...	63
Şekil 5.6 Geliştirilen Etiketleme Algoritması	64
Şekil 5.7 Sınıflandırma Modülü.....	66
Şekil 5.8 Önceliklerin Belirlenmesi	67
Şekil 5.9 Doğruluk Analizi Sonuç Ekranı	68
Şekil 5.10 Etiketleme	69
Şekil 6.1 Sinop Bölgesi için Sonuç Haritası a) Uydu görüntüsü b) Önerilen Yöntem ..	70
Şekil 6.2 Sonuç Haritası a) Uydu görüntüsü b) ISODATA	71

Şekil 6.3 Sonuç Haritası a) Uydu görüntüsü b) Fuzzy C-Means.....	72
Şekil 6.4 Sonuç Haritası a) Uydu görüntüsü b) SOM	73
Şekil 6.5 Sonuç Haritası a) Uydu görüntüsü b) Önerilen Yöntem	75
Şekil 6.6 Sonuç Haritası a) Uydu Görüntüsü b) ISODATA.....	76
Şekil 6.7 Sonuç Haritası a) Uydu Görüntüsü b) Fuzzy C Means	78
Şekil 6.8 Sonuç Haritası a) Uydu Görüntüsü b) SOM.....	79
Şekil 6.9 Sonuç Haritası a) Uydu Görüntüsü b) Önerilen Algoritma	81
Şekil 6.10 Sonuç Haritası a) Uydu Görüntüsü b) ISODATA.....	82
Şekil 6.11 Sonuç Haritası a) Uydu Görüntüsü b) Fuzzy C- Means.....	84
Şekil 6.12 Sonuç Haritası a) Uydu Görüntüsü b) SOM	85
Şekil 6.13 Etiketleme Sonucu a) Uydu Görüntüsü b) Etiketleme Sonucu.....	87
Şekil 6.14 Etiketleme Sonucu a) Uydu Görüntüsü b) Etiketleme Sonucu.....	88
Şekil 6.15 Etiketleme Sonucu a) Uydu Görüntüsü b) Etiketleme Sonucu.....	90
Şekil 6.16 Sinop Bölgesi a) Uydu Görüntüsü b) Corine Sınıfları.....	91
Şekil 6.17 Etiketleme Sonucu a) Uydu Görüntüsü b) Etiketleme Sonucu.....	92
Şekil 6.18 Gemlik Bölgesi a) Uydu Görüntüsü b) Corine Sınıfları	94
Şekil 6.19 Etiketleme Sonucu a) Uydu Görüntüsü b) Etiketleme Sonucu.....	95
Şekil 6.20 Hatay Bölgesi a) Uydu Görüntüsü b) Corine Sınıfları.....	96
Şekil 6.21 Hatay Bölgesi a) Uydu Görüntüsü b) Etiketleme Sonucu	97
Şekil 7.1 Gemlik Bölgesindeki Toprak Alanlar	100

TABLÖLAR DİZİNİ

Sayfa

Tablo 4.1 <i>Sentinel-2 uyduları görüntü kalitesi seviyeleri (ESA, 2018)</i>	40
Tablo 4.2. <i>Sentinel-2 uydusuna ait bant ve özellikleri (ESA, 2018)</i>	40
Tablo 5.1. <i>Spektral indislerden elde edilen eşik değerleri</i>	61
Tablo 5.2 <i>Kural Seti</i>	64
Tablo 6.1 <i>Geliştirilmiş algoritma ile elde edilen doğruluk değerleri</i>	71
Tablo 6.2 <i>ISODATA ile elde edilen ile elde edilen doğruluk değerleri</i>	72
Tablo 6.3. <i>Fuzzy C-Means ile elde edilen ile elde edilen doğruluk değerleri</i>	73
Tablo 6.4 <i>SOM ile elde edilen ile elde edilen doğruluk değerleri</i>	74
Tablo 6.5 <i>Geliştirilen Algoritma ile elde edilen doğruluk değerleri</i>	75
Tablo 6.6 <i>ISODATA ile elde edilen ile elde edilen doğruluk değerleri</i>	77
Tablo 6.7 <i>Fuzzy C-Means ile elde edilen ile elde edilen doğruluk değerleri</i>	78
Tablo 6.8 <i>SOM ile elde edilen ile elde edilen doğruluk değerleri</i>	80
Tablo 6.9 <i>Geliştirilen Algoritma için doğruluk analizi sonuçları</i>	81
Tablo 6.10 <i>ISODATA için doğruluk analizi sonuçları</i>	83
Tablo 6.11 <i>Fuzzy C- Means için doğruluk analizi sonuçları</i>	84
Tablo 6.12 <i>SOM için doğruluk analizi sonuçları</i>	86
Tablo 6.13 <i>Geliştirilen Yöntem için doğruluk analizi sonuçları</i>	87
Tablo 6.14. <i>Geliştirilen Yöntem için doğruluk analizi sonuçları</i>	89
Tablo 6.15 <i>Hatay Bölgesi Hata Matrisi</i>	90
Tablo 6.16 <i>Corine Sınıflarına uygulanan doğruluk analizi sonuçları</i>	92
Tablo 6.17 <i>Sinop Bölgesi Hata Matrisi</i>	93
Tablo 6.18 <i>Corine Sınıflarına uygulanan doğruluk analizi sonuçları</i>	94
Tablo 6.19 <i>Gemlik Bölgesi Hata Matrisi</i>	96
Tablo 6.20 <i>Corine Sınıflarına uygulanan doğruluk analizi sonuçları</i>	97
Tablo 6.21 <i>Hatay Bölgesi Etiketleme Doğruluk Analizi</i>	98
Tablo 8.1. <i>Sınıflandırma İşlem Sonuçları</i>	104
Tablo 8.2 <i>Etiketleme Sonuçları</i>	105

KISALTMALAR DİZİNİ

AWEI	: Otomatik Su Çekme İndisi
BAEI	: Yerleşim Alanı Çıkarımı İndisi
BAI	: Yanmış Alan İndisi
BI	: Parlaklık İndisi
BRBA	: Yerleşim Alanı için Bant Oranı
BSS	: Kümeler Arası Kareler Toplamı
CH	: Calinski Harabasz İndisi
CI_re	: Chlorophyll Index Red-edge
DBSCAN	: Density-based spatial clustering of applications with noise
DBSI	: Kuru Çıplak-Toprak İndisi
DVI	: Fark Vejetasyon İndisi
EGI	: Aşırı Yeşillik İndisi
ESA	: European Space Agency
EVI2:	: İki bantlı Gelişmiş Bitki Örtüsü İndisi
GCL	: Yeşil Klorofil İndisi
GEMI	: Küresel Çevresel İzleme İndisi
GLI	: Yeşil Yaprak İndisi
GVI	: Yeşil Bitki İndisi
IHS	: Intensity, Hue, Saturation
IRECI	: Ters Red Edge Klorofil İndisi
ISODATA	: Iterative Self Organizing Data Analyses Technique
LVQ	: Learning vector quantization
MNDWI	: Değiştirilmiş Normalize Edilmiş Fark Su Endeksi
MSS	: Multispectral Scanner System
NBR	: Normalize Edilmiş Yanma Oranı
NBR2	: Normalize Yanma Oranı 2
NBUI	: Yeni Yerleşim İndisi
NDBI	: Normalleştirilmiş Fark Kentsel Alan İndisi
NDMI	: Normalize Edilmiş Fark Nem İndisi
NDSI	: Normalize Edilmiş Fark Kar İndisi
NDTI	: Normalleştirilmiş Fark Toprak İşleme İndisi

NDVI	: Normalize Edilmiş Fark Bitki İndisi
NDVI _{re}	: Kırmızı Kenar Temelli Normalize Edilmiş Fark Bitki Örtüsü İndisi
NDWI	: Normalize Edilmiş Fark Su İndisi
NIR	: Near Infrared
OSAVI	: Optimize Edilmiş Toprak Ayarlı Bitki İndisi
PCA	: Principal Component Analysis
PSRI	: Bitki Yaşlanma Yansıtma İndisi
RE_NDVI	: Red Edge Normalize Edilmiş Fark Bitki İndisi
REI	: Yol Çıkarma İndisi
SATVI	: Toprak Ayarlı Toplam Bitki Örtüsü İndisi
SAVI	: Toprak Ayarlı Vejetasyon İndisi
SBI	: Toprak Parlaklık İndisi
SI	: Silhouette Index
SIPI	: Yapı Duyarsız Pigment İndisi
SOM	: Self Organizing Maps
TM	: Thematic Mapper
TVI	: Dönüştürülmüş Bitki Örtüsü İndisi
UTM	: Universal Transverse Mercator
WRI	: Su Oranı İndisi
WSS	: Kümeler İçi Kareler Toplamı
YVI	: Sarı Bitkisel İndisi
Nm	: Nano Metre

1. GİRİŞ

Uydu teknolojilerinin gelişmesiyle beraber uzaktan algılama sistemlerinin sağladığı veriler günden güne artmaktadır. Uzaktan algılama teknolojileri, fiziksel bağlantıya sahip olmaksızın dünyamız hakkında çok büyük veri setleri sağlar; bu da dünya hakkında hızlı ve güvenilir bir şekilde bilgi edinmeyi mümkün kılar (Jensen, 2009). Uzaktan algılamanın sağladığı bu veriler, kentsel gelişim ve değişim (Lu & Weng, 2007; Martinuzzi, Gould, & Gonzalez, 2007), yasadışı yapıların tespiti (Ioannidis, Psaltis, & Potsiou, 2009) arazi örtüsü haritalaması (Ashourloo et al., 2019), nesne tespiti (Li, Zhang, Huang, & Yuille, 2018), ormanların ve doğal yapıların belirlenmesi (Comert, Avdan, & Gorum, 2018; Çömert, Matci Küçük, & Avdan, 2019), yangın şiddeti (Warner, Skowronski, & Gallagher, 2017), afet bilgi sistemleri (Poser & Dransch, 2010), kentsel bilgi sistemleri (Jensen & Cowen, 1999) gibi birçok uygulama alanında kullanılabilir. Günümüzde yaklaşık 30 cm den 1000 m ye kadar konumsal çözünürlükte görüntü sağlayan uydu sistemleri bulunmaktadır. Bu sistemler multi spektral, hiper spektral, mikrodalga, termal gibi pek çok farklı spektral çözünürlükte veri sağlayabilmektedir. Elde edilen bu yüksek nitelikli verilerin doğru bir şekilde analiz edilerek kullanılması büyük önem taşımaktadır. Bu nedenle kullanılan analiz yöntemlerinin yüksek doğruluklu sonuçlar sağlaması gerekmektedir. Ayrıca elde edilen bu çok geniş bilgi havuzu pek çok farklı disipline güncel, ekonomik ve hızlı bir veri kaynağı olabilmektedir.

1.1 Problemin Tanımı ve Çalışmanın Amacı

Uydu görüntülerinin sınıflandırılması, uzaktan algılanmış verilerin analizi için en çok kullanılan yöntemlerden bir tanesidir. Bu yöntemlerden biri olan kontrolsüz sınıflandırma yaklaşımı, çalışılan alanla ilgili ön bilgi gerektirmemesi, eğitim verisi olmadan çalışması gibi özelliklerinden dolayı kontrollü sınıflandırma yöntemlerine göre daha kullanışlı bir yaklaşımdır. Ancak bu yaklaşım da sonuç üretebilmek için eğitim verisi gerektirmese de sınıf sayısı, öğrenme oranı, iterasyon sayısı gibi farklı parametreler gerektirmektedir. Bunun yanında, kontrolsüz sınıflandırma yönteminin sağladığı sonuçların doğruluk oranları eğitim verisi kullanılmadığından kontrollü sınıflandırmaya göre genellikle daha düşüktür.

Sınıflandırma sonucunda spektral sınıflar otomatik olarak etiketlenmez. Kullanıcı bu nedenle sınıflandırmanın ardından sınıfları yorumlamak ve etiketlemek durumunda kalır (Jensen & Lulla, 1987). Sınıflandırma sonrasında her zaman anlamlı kümeler oluşmadığından yorumlama ve etiketleme kolay olmayabilir. Dolayısıyla çok zaman gerektirebilir (Enderle & Weih Jr, 2005). Bunun yanında kümeler istenilen bilgi sınıflarına karşılık gelemeyebilir (Ozesmi & Bauer, 2002).

Bu çalışmada, kontrolsüz sınıflandırma yöntemlerinde tespit edilen bu problemlere çözüm olması anlamında aşağıda verilen amaçlar belirlenmiştir:

1. Bu çalışmanın amaçlarından ilki, uydu görüntülerinin otomatik olarak sınıflandırılmasını sağlayan bir yaklaşım geliştirmektir. Bu yaklaşım, görüntüdeki spektral bantlar yardımıyla yeni katmanlar üretilmesini, tüm katmanlarda sınıflar oluşturmayı ve oluşturulan bu sınıfların optimize edilmesini içermektedir. Önerilen yöntem, piksellerin yansıma değerlerinin yanında, spektral indisleri, görüntü filtrelerini ve temel bileşenler analizi (PCA: Principal Components Analysis) yöntemi ile oluşturulan yeni katmanlardaki faydalı verileri göz önünde bulunduran özgün bir çalışmadır.

Mevcut kontrolsüz sınıflandırma yöntemleriyle elde edilen sonuçların genellikle düşük olması nedeniyle geliştirilen yaklaşımla uzaktan algılama ile elde edilmiş verilerin sağlıklı bir şekilde kullanıma hazırlanması ve sonuçların yüksek doğruluklu olarak elde edilmesi çok önemlidir.

Bunun yanında son kullanıcıların sürece olan müdahalesini azaltılması sayesinde yazılım ya da görüntü işleme alanları dışında planlama, afet önleme çalışmaları yapanlar, çevre düzenleme, güvenlik gibi alanlarda uzmanlaşmış son kullanıcıların verileri kolaylıkla işleyerek kullanıma almaları konusunda büyük avantaj sağlayacaktır.

2. Bu tez çalışmasının bir diğer amacı da kontrolsüz sınıflandırma yöntemleriyle elde edilen arazi kullanım sınıflarının otomatik etiketlenmesidir. Kontrolsüz sınıflandırma yöntemleri eğitim verisi olmadan sınıflandırma işlemini gerçekleştirdiği için ürettiği sonuçlarda sınıf etiketleri bulunmamaktadır. Elde edilen bu sonuçların faydalı verilere dönüştürülebilmesi için kullanıcı tarafından yorumlanması gerekmektedir. Bu çalışmada kullanıcıya olan bağımlılığın kaldırılabilmesi için otomatik etiketleme yaklaşımı geliştirilmesi hedeflenmiştir.

1.2 Literatür Özeti

Kontrolsüz sınıflandırma yöntemleri, eğitim verisi gerektirmemesinden dolayı kontrollü sınıflandırmaya göre daha kolaydır. Ancak uzaktan algılanmış görüntülerde bulunan verinin büyüklüğü ve karmaşıklığından dolayı literatürde bulunan kontrolsüz sınıflandırma yöntemlerinden birçoğunun kullanımı efektif olmamaktadır. Uzaktan algılama alanında en sık kullanılan kontrolsüz sınıflandırma yöntemlerinden ikisi K-Means ve ISODATA'dır. Bu yöntemler uzaktan algılama alanında kullanılan yazılımlarda bulunmasından dolayı sıkça kullanılmış olmasına rağmen bir takım kısıtlamalara sahiptir. Bunlardan biri sınıf sayısının tahminidir. Ayrıca kullanıcı, işlemin sürebilmesi için başlangıç merkezleri, yineleme sayısı, kümelerin bölünme veya birleştirilme kuralları gibi çeşitli parametreleri belirlemek zorundadır (Gonçalves, Costa, & Netto, 2011).

Örneğin Duda ve arkadaşları (2002) çalışmalarında kontrolsüz sınıflandırma yöntemlerinin veriler hakkında çok az bilgi bulunduğunda, kontrollü sınıflarına ön bilgi sağlamak amacıyla başarılı sonuçlar sağladığını belirtmişlerdir. Bu doğrultuda K-means, Extended K-Means, Agglomerative hierarchical, Fuzzy K-means ve Fuzzy Maximum Likelihood yöntemlerini karşılaştırmışlardır. Sonuçta doğruluk oranının kullanıcı tarafından belirlenen sınıf sayısına bağlı olduğunu belirtmişlerdir (Duda & Canty, 2002).

Zeraatpisheg ve arkadaşları (2019) orta İran' a ait toprak haritasını güncellemek amacıyla K-Means ve Fuzzy C-Means kontrolsüz sınıflandırma yöntemleri ile DSMART kontrollü sınıflandırma yöntemini kullanmışlardır. Çalışma sonucunda DSMART ve Fuzzy C-Means yöntemlerinin daha yüksek doğruluklu sonuçlar sağladığını belirtmişlerdir. Ancak kontrolsüz sınıflandırma yöntemleri ile sınıflandırılmış verilerin etiketlendirilmesi, toprak sınıfları ve harita açıklamalarının oluşturulmasının uzmanlık bilgisi gerektirdiğini belirtmişlerdir (Zeraatpisheh, Ayoubi, Brungard, & Finke, 2019).

Yang ve arkadaşları çalışmalarında 1973 ve 1998 yılları arasındaki Landsat MSS ve TM görüntülerini kullanarak Atlanta' daki zamansal değişimi belirlemeyi amaçlamışlardır (Xiaojun Yang & Lo, 2002). Bu çalışmada spektral kümeleri tanımlayabilmek için ISODATA kullanılmıştır. Yazarlar bu çalışmada, ISODATA yönteminin performansının parametrelere çok bağımlı olduğunu ve bu parametrelerden en önemlisinin sınıf sayısı olduğunu belirtmişlerdir. Bu sayı çok küçük olduğunda, nispeten geniş kümeler oluşacağını ve bu sonuçların yeterince doğru olmayabileceğini, bu sayı çok büyük

olduğunda ise, ortaya çıkan kümelerin etiketlenmesi için gereken zamanın önemli ölçüde artacağını saptamışlardır.

Thapa ve Murayama (2009), çalışmalarında kentsel alanların haritalanması için kontrolsüz sınıflandırma (ISODATA), kontrollü sınıflandırma, bulanık kontrollü sınıflandırma ve GIS post-processing yöntemlerini karşılaştırmışlardır. Çalışmada en yüksek doğruluk oranı GIS post-processing ile elde etmişlerdir. Bu çalışmada kontrolsüz sınıflandırma ile en düşük doğruluk elde edilmiştir. Kontrolsüz sınıflandırma yöntemi için eğitim verisi kullanılsa da veri kümesindeki spektral sınıfların tam sayısı bilinmediğinden, gerçek sınıflardan çok daha fazla küme seçildiği, bu kümelerin, uzman bilgisi ve zemin referans verileri kullanılarak dikkatlice değerlendirildiği belirtilmiştir. Ayrıca, benzer arazi örtüsü tipleri otomatik olarak birleştirildiğinden, bu birleştirilmiş kümelerin, gerçek arazi kullanım sınıflarına ait olup olmadıklarını belirlemek için tekrar değerlendirildiği ve son olarak, tematik bir kentsel arazi kullanımı ve arazi örtüsü haritası oluşturmak için bir ekstra etiketleme işlemi gerçekleştirildiği eklenmiştir (Thapa & Murayama, 2009).

Uzaktan algılama alanında kullanılan bir diğer yöntem SOM dur. Gonçalves ve arkadaşları (2011), SOM' un uzaktan algılama görüntülerinde kümeleme için etkili bir araç olarak düşünülse de, ağın çıkış alanı boyunca küme sınırlarının saptanması kritik bir işlem olduğunu belirtmişlerdir (Gonçalves et al., 2011). Ayrıca Ji (2000), SOM' un performansının ağ boyutu ve öğrenme oranının seçimi gibi bir dizi faktörden etkilendiğini belirtmiştir (Ji, 2000).

Thomson (1998), çalışmasında kıyı ve nehirlerin uzaktan algılanmış görüntülerini kontrollü ve kontrolsüz yöntemlerle sınıflandırmıştır. Çalışmanın sonucunda kontrolsüz kümeleme yöntemlerinin iki avantajını belirtmiştir. Bunlardan ilki kullanıcıdan çok az girdi veri almasıdır. Diğer de saha çalışması, saha çalışmasını yönlendirmeye yardımcı olan sınıflandırmaları yorumlamak için gerekli olanla sınırlı olmasıdır. Ancak kontrolsüz sınıflandırma yaklaşımında oluşturulan spektral sınıfların anlamlı arazi örtüsü kategorilerine atanmasının zor olduğunu belirtmişlerdir (Thomson, 1998).

DBSCAN, literatürde uzaktan algılanmış görüntülerin kontrolsüz sınıflandırılması için kullanılan bir diğer yöntemdir. Karmaşık ve büyük mekânsal verilerin sınıflandırılmasında kullanılmıştır. Ancak, Khan ve arkadaşları (2014), DBSCAN' de algoritmayı yürütmek için gerekli parametre değerlerinin kullanıcı tarafından belirlenme

gerekliliđi, deđiřen yođunluklara sahip veri k melerinden anlamlı k melere karar vermede problemlerin olması ve belirli hesaplama karmařıklıđına neden olması gibi problemleri olduđu belirtmiřlerdir (Khan, Rehman, Aziz, Fong, & Sarasvady, 2014).

Kontrols z g r nt  sınıflandırmada kullanılan bir diđer yaklařım ise optimizasyondur. Chen ve arkadařları (2012)  alıřmalarında k meleme analizi iřlemine ger ekleřtirebilmek i in par acık s r  optimizasyonu y ntemini kullanmıřlardır (C.-Y. Chen & Ye, 2012). Bu yaklařım sayesinde geleneksel y ntemlerin bařlangı  merkezleri se me ařamasında karřılařtıđı yerel en uygun   z mde sıkıřma problemini ařmıřlardır. Ancak  nerilen bu y ntem yine de algoritmanın  alıřması i in kullanıcı tarafından belirlenen parametrelere ihtiya  duymaktadır.

Optimizasyon y ntemleri yardımıyla k meleme iřlemine ger ekleřtiren bir diđer  alıřmada bal arısı eřleřme optimizasyonu kullanılmıřtır (Fathian, Amiri, & Maroosi, 2007). Bu y ntemle K-means y nteminin yerel optimaya yakınlařma problemini ařmıřlardır. Elde ettikleri sonu ların performansını deđerlendirmek i in karınca kolonisi, genetik algoritma, tavlama benzetimi ve tabu araması gibi diđer sezgisel algoritmalarla karřılařtırılmıřtır.  n hesaplama deneyimi, bulunan   z m n kalitesi, ortalama fonksiyon deđerlendirme sayısı ve gereken iřlem s resi a ısından bařarılı sonu lar elde etmiřlerdir. Ancak bu y ntem iřlemin bařında kullanıcıdan aldıđı sınıf sayısı gibi parametrelere bađımlıdır ve elde edilen k melerin etiketlenmesi ile ilgili bir sonu   nermemektedir.

Chan ve arkadařları (2004),  alıřmalarında k meleme analizinde karřılařılan problemlerden biri olan  zelliklerin ađırlıklandırılması problemini   zmek i in optimizasyon temelli bir algoritma geliřtirmiřtir (Chan, Ching, Ng, & Huang, 2004). Bu algoritma ile hangi k me i in hangi  zelliklerin kullanılması gerektiđi belirlenmeye  alıřılmıřtır. Bu y ntem iřlem bařlangıcında sınıf sayısı, iterasyon sayısı gibi parametrelerle kullanıcıya bađımlılık problemini   zemiyor olsa da belirli veri setleri  zerinde yapılan testler sonucunda diđer y ntemlere g re daha verimli sonu lar elde edilmesini sađlamıřtır.

G r nt  sınıflandırma iřleminde kullanılan optimizasyon yaklařımlarından biri de  ok ama lı optimizasyondur. Bu y ntem kullanılırken, tanımlanan kriterler k meleme mekanizmasından farklıdır. K meleme mekanizmasında genel olarak k me ge erlilik  l  t indisleri objektif fonksiyon olarak form le edilir. Bu perspektifte, objektif fonksiyonlar genellikle sınıflandırıcının hata oranına veya  eřitlilik  l  m ne bađlıdır.

Bunun yanında, genel sapmayı en aza indirmek (verilerin küme içi yayılımını en aza indirmek), bağlantıyı en üst düzeye çıkarmak (kümeler arası bağlantı), özellik sayısını en aza indirmek veya sınıflandırıcının hata oranını en aza indirmek gibi çok amaçlı hedeflere sahiptir (Chin-Wei & Rajeswari, 2010).

Cococcioni ve arkadaşları(2007) sınıflandırıcıların doğruluğu ve karmaşıklığı arasındaki dengelerle Pareto-optimal çözüm kümesinin oluşturulması için evrimsel üç amaçlı optimizasyon algoritmasını uygulamıştır (Cococcioni, Ducange, Lazzerini, & Marcelloni, 2007). Bu algoritma verideki karmaşıklığı azaltarak gerekli bilginin çıkarılmasında başarılı sonuçlar vermişse de sınıf sayısı parametresini kullanıcıdan almaktadır.


Bandyopadhyay ve arkadaşları (Bandyopadhyay, Maulik, & Mukhopadhyay, 2007) çalışmalarında küme geçerlik indislerinin (XB: toplam varyasyon oranı, Jm: küresel küme varyansı) eşzamanlı olarak optimize edildiği bulanık kümeleme problemini çözmek için çok amaçlı bir optimizasyon algoritması kullanmışlardır. Bu algoritma gerçek uydu görüntüleri üzerinde genetik algoritma ve Fuzzy C-Means yöntemlerine göre başarılı sonuçlar vermiş olsa da girdi parametreleri için kullanıcı desteği gerektirmektedir.

2. TEMEL KAVRAMLAR

Uzaktan algılama, fiziksel bir temas olmaksızın, doğal veya yapay nesnelerle ilgili bilgi edinme ve değerlendirme bilimi olarak tanımlanmaktadır. 1800'lü yıllarda fotoğrafın icadı ile başladığı kabul edilen uzaktan algılama, 1957 yılında SPUTNIK-1, 1972 yılında LANDSAT uydusunun fırlatılması ile devam etmiş ve gelişerek günümüze dek uzanmıştır. İlk olarak askeri amaçlarla kullanılan uzaktan algılama verileri günümüzde birçok farklı uygulama alanında kullanılabilmektedir (Campbell & Wynne, 2011). Bu alanlardan bazıları dünya üzerinde gerçekleşen olumlu ve olumsuz değişikliklerin izlenmesi, olumsuz değişiklikler için risk belirleme, hasar tespit ve önlem amaçlı yapılan çalışmalar için ekonomik, doğru ve güncel veriler sağlamak olarak sayılabilir (Féret & Asner, 2014).

2.1 Elektromanyetik Enerji / Elektromanyetik Spektrum

Atomlardan "elektromanyetik dalga" veya parçacık şeklinde yayılan enerjiye "elektromanyetik enerji" adı verilir. Elektromanyetik enerji türlerinin dalga boyu ve frekansa göre dağılımına elektromanyetik spektrum adı verilir. Tüm elektromanyetik dalgaları bir arada gösteren elektromanyetik spektrum 10^{-10} μm dalga boyundan 10^{10} μm dalga boyuna kadar yayılan enerji ortamını gösterir (Manickavasagan & Jayasuriya, 2014).



Şekil 2.1 Elektromanyetik Spektrum (diyot.net, 2019)

2.2 Enerji-Yeryüzü Nesneleri Etkileşimi

Yeryüzündeki nesnelerin elektromanyetik radyasyon ile etkileşimini bilmek uzaktan algılanmış verilerin yorumlanabilmesi açısından önemlidir. Yeryüzüne ulaşan elektromanyetik enerjinin cisimlerle üç farklı etkileşimi söz konusudur. Bunlar geçirilme, yutulma ve yansıtım olarak sayılabilir. Yeryüzüne gelen enerjinin yeryüzü nesneleri ile ne tür bir etkileşime gireceği enerjinin dalga boyu aralığına, nesnenin yapısına ve ortam şartlarına bağlı olarak değişir (Lillesand, Kiefer, & Chipman, 2014). Uzaktan algılamada nesnelerin farklı şartlar altındaki davranışının grafiksel gösterimi spektral imza olarak adlandırılır.

2.3 Spektral İndisler

Spektral indisler, ilgilenilen nesnelerin varlığını/miktarını gösteren iki veya daha fazla dalga boyundan gelen spektral yansıma değeri kombinasyonudur. Uzaktan algılanmış görüntülerde kentsel alan, toprak, bitki örtüsü sulak alan gibi pek çok farklı arazi örtüsü ya da nesnenin ayırt edilebilmesi için birçok farklı spektral indis geliştirilmiştir (Huete, 1988; Jiang, Huete, Didan, & Miura, 2008; Waqar, Mirza, Mumtaz, & Hussain, 2012; Zha, Gao, & Ni, 2003).

2.4 Görüntü Keskinleştirme

Görüntü keskinleştirme, spektral çözünürlüğü yüksek ve mekânsal çözünürlüğü düşük çok bantlı bir görüntünün çözünürlüğünün, spektral çözünürlüğü düşük ama mekânsal çözünürlüğü yüksek bir görüntü kullanılarak artırılması işlemidir. Böylece hem spektral çözünürlüğü, hem de mekânsal çözünürlüğü yüksek bir görüntü elde edilir (Schavemaker, Reinders, Gerbrands, & Backer, 2000). Literatürde Intensity-Hue-Saturation tekniği (IHS) (Tu, Su, Shyu, & Huang, 2001), PCA tabanlı keskinleştirme (Shah, Younan, & King, 2008), Brovey (Eshtehardi, Ebadi, Valadan, & Mohammadzadeh, 2007) gibi farklı keskinleştirme yöntemleri kullanılmaktadır. Bu çalışmada kullanılan yöntemler IHS yöntemi ile keskinleştirilmiştir.

2.4.1 IHS Keskinleştirme Tekniği

IHS tekniği, renkli bir görüntüyü RGB alanından IHS renk alanına dönüştürür. Burada I (yoğunluk) bandı yüksek çözünürlüklü görüntü ile değiştirilir. Görüntüleri

kaynaştırmadan önce, multispektral ve yüksek çözünürlüklü görüntünün histogramları eşleştirilir. Son adımda da IHS görüntüsüne ters dönüşüm işlemi uygulanır ve yüksek çözünürlüklü RGB görüntü elde edilir (Pohl & Van Genderen, 1998).

2.5 Doğruluk Analizi

Uzaktan algılanmış verilerin, farklı alanlarda kullanılabilmesi için işlenmesi ve yorumlanması gerekmektedir. Bu amaçla uygulanan işlemlerin sağladığı verilerin doğruluğunun test edilmesi amacıyla doğruluk analizleri gerçekleştirilmektedir. Bu doğrultuda kullanılan yöntemlerde biri hata matrisidir. Hata matrisi, referans bölgelerden gelen bilgileri, haritadaki bilgilerle karşılaştırır. Matriste sütunlar genellikle, doğru kabul edilir ve referans verileri olarak adlandırılır. Satırlar genellikle harita etiketlerini veya uzaktan algılanan görüntüden oluşturulan sınıflandırılmış verileri ifade etmek için kullanılır (Congalton & Green, 2002).

2.6 Temel Bileşenler Analizi (PCA)

PCA, bir veri kümesinin aralarında korelasyon bulunmayan veriler ile temsil edilen bir yapıya dönüştürülmesidir. Bu doğrultuda, birbirine ortogonal yeni bir koordinat sistemi tanımlanır ve değişkenler bu yeni koordinat sistemine göre tekrar ifade edilir (Jolliffe, 2011). Bu yöntem uzaktan algılamada hiperspektral verilerin yorumlanması (Q. Du & Fowler, 2007; Q. Du, Zhu, Yang, & Fowler, 2009), multispektral verilerle elde edilen doğruluğun artırılması (S. Yang, Wang, & Jiao, 2012), nesne çıkarımı (Fauvel, Chanussot, & Benediktsson, 2009) gibi konularda kullanılan bir yöntemdir.

2.7 Python Programlama Dili

Bu çalışmada geliştirilen algoritmaların kodlanmasında ve arayüzün geliştirilmesinde Python programlama dili kullanılmıştır. Guido Van Rossum tarafından geliştirilen bu dil 1991 yılında yayınlanmıştır. Python web programlama, yazılım geliştirme, modelleme, sistem betikleri oluşturma gibi pek çok alanda kullanılabilen bir dildir (Rossum, 1995). Python dilinin kullanıcılara sunduğu pek çok avantaj bulunmaktadır:

- Python farklı Windows, Mac, Linux vb. gibi platformlarda çalışabilir.
- Python programlama dili basit bir söz dizimine sahiptir.

- Geliştiricilerin diğer bazı programlama dillerinden daha az satırlı programlar yazmasına izin veren sözdizimine sahiptir.
- Python bir tercüman sistemi üzerinde çalışır, yani kod yazıldığı anda çalıştırılabilir. Bu, çalışma hızının çok hızlı olabileceği anlamına gelir.
- Geniş bir geliştirici topluluğu tarafından desteklenen açık kaynaklı bir projedir.
- Nesne yönelimli bir dildir.
- Çok çeşitli kütüphaneler ve eklenti modüllerine sahiptir.

2.8 Görüntü Filtreleri

Görüntü filtreleme, görüntüde yer alan özelliklerin farklarını artırarak görüntünün yorumlanabilirliğini artırmak amacıyla gerçekleştirilir (Mather & Koch, 2011). Görüntü filtrelemede, girdi verisi, filtre fonksiyonu yardımıyla konvolüsyon uygulanarak işlenir. Konvolüsyon işlemi görüntüdeki tüm pikseller için bir pikselin ve çevresindeki komşu piksellerin uygun başka bir matrisle çarpılması ile gerçekleştirilir (He, Sun, & Tang, 2010). Çalışmada, literatürde sıklıkla kullanılan Gauss düzleştirme filtresi, Sobel, Scharr ve Laplacian filtreleri kullanılmıştır.

2.9 Sınıflandırma Kalite İndisleri

Kalite indisleri, verilerin yapısına en uygun sınıflandırma sonucunun elde edilip edilmediğini kontrol eder. Bu tür bir kontrol, kümeler arası ve küme içi olacak şekilde gerçekleştirilebilir. Kalite indisleri sınıflandırma sonucunun, sınıf içinde yüksek benzerlik ve sınıflar arasında yüksek farklılık hedefine ne kadar iyi ulaşıldığını ölçer (Hämäläinen, Jauhainen, & Kärkkäinen, 2017). Literatürde Silhouette Index (Rousseeuw, 1987), Calinski Harabatz Index (Caliński & Harabasz, 1974), Davies Bouldin (Davies & Bouldin, 1979), Dunn Index (Dunn, 1974) gibi farklı kalite indisleri kullanılmıştır.


3. SINIFLANDIRMA

Önceden belirlenmiş olan kriterler doğrultusunda verilerin gruplar veya kategoriler halinde düzenlenmesi olarak da tanımlayabileceğimiz sınıflandırma kavramı Sokal (1974) tarafından “nesnelerin gruplara göre sıralanması, düzenlenmesi ya da ilişkilerini temel alarak kümelenmesi” olarak tanımlanmıştır (Sokal, 1974). Birçok bilim dalında bir karar verme yöntemi olarak kullanılan sınıflandırma, uydu görüntülerinin sınıflandırılması alanında kullanıldığında çeşitli özellikte tematik haritalar üretilebilmektedir.

Uydu görüntülerinde, farklı nesneler, farklı spektral yansıma değerleri oluşturur. Bu fark, zemin nesnelerinin ayırt edilmesinde avantaj sağlamaktadır. Buradan yola çıkarak görüntü sınıflandırma işleminde, uydu görüntülerinin her bir pikseli spektral özelliklerine göre farklı gruplara ayrılır (Lillesand et al., 2014). Görüntü sınıflandırma işleminde genel olarak piksel tabanlı, obje tabanlı, alt piksel tabanlı ve alan tabanlı sınıflandırma yöntemleri kullanılmaktadır.

3.1 Piksel Tabanlı Sınıflandırma

Piksel tabanlı sınıflandırmada, görüntü pikselleri, içerdikleri spektral bilgi ile analiz edilir (Campbell & Wynne, 2011). Piksel, bir görüntünün temel birimidir. Teorik olarak, piksel tabanlı sınıflandırmada, iyi tanımlanmış ve iyi ayrılmış sınıf tanımları kullanılır (Goldblatt, You, Hanson, & Khandelwal, 2016).




Şekil 3.1 Piksel tabanlı sınıflandırmada temel işlem adımları

Ancak bu durum gerçek verilerde her zaman geçerli olmaz. Örneğin arazi örtüsü çalışmalarında, bazı sınıflar (su, bina, vs.) sabit sınıf kurallarına sahip olabilir. Ancak ayrıntılarda problemler ortaya çıkmaktadır. Örneğin bitki örtüsü karakteristiği yıl içinde değişim göstermektedir ve bu durum zaman boyutuna girmeden bölgenin tanımlanmasında problem yaratabilmektedir. Piksel tabanlı yaklaşımlarda karşılaşılan bir başka problem de karışık piksel sorunudur. Özellikle düşük mekânsal çözünürlüklü uydu görüntülerinde bir piksel birkaç bahçe ya da tarlayı kapsayabilmektedir. Bu durumda birden fazla arazi örtüsünden yansıyan değerlerin tek bir piksel içerisinde ayırt edilmesi problem oluşturmaktadır (Ge, Chen, Stein, Li, & Hu, 2016). Piksel tabanlı sınıflandırma literatürde kontrollü ve kontrolsüz olarak kullanılmaktadır.

3.2 Nesne Tabanlı Sınıflandırma

Nesne tabanlı sınıflandırma, sınıflandırma için hem spektral hem de mekânsal bilgileri kullanır. Bu yaklaşım, piksellerin spektral özelliklerine, şekillerine, dokularına ve komşu pikseller ile olan mekânsal ilişkilerine göre sınıflandırılmasını sağlar. Nesne tabanlı sınıflandırma iki aşamalı bir işlemdir. Öncelikle pikseller spektral özelliklerine, boyut, şekil ve doku özellikleri ile komşu piksellerinin özelliklerine göre gruplandırılır. Ardından her bir grup kullanıcı tarafından belirlenen özelliklere ve ölçütlere göre bir sınıfa atanarak sınıflandırılır (Park, Harada, & Kwak, 2016).




Şekil 3.2 Nesne tabanlı sınıflandırmada temel işlem adımları

Bu yöntem bir kontrollü sınıflandırma yöntemidir. İşlemin her aşamasında kullanıcı tarafından belirlenen parametreler kullanılır. Örneğin sürecin ilk aşaması olan piksellerin gruplandırılması işleminde kullanılan nesne boyutu, şekli, heterojenite ölçeği gibi parametreler kullanıcıdan alınan ön bilgilerdendir. Benzer şekilde yöntemin ikinci aşaması olan oluşturulan nesnelerin sınıflandırılması işleminde de kullanıcıdan alınan kurallar belirleyici olmaktadır.

3.3 Kontrollü Sınıflandırma

Kontrollü sınıflandırma yaklaşımında, önceden tanımlanmış olan eğitim verileri kullanılarak diğer veriler sınıflandırılmaktadır. Kullanıcı, her bir sınıfla ilişkilendirilmesi gereken özellikleri belirler. Bilgisayar algoritması daha sonra tüm veriyi sınıflandırmak için bu eğitim bilgilerini kullanır (Richards, 2013).

Uzaktan algılanmış görüntülerin kontrollü sınıflandırılmasında sonuçta elde edilecek arazi örtüsü sınıfları kullanıcı tarafından belirlenir. Bu sınıflara ait eğitim verisi kullanılan algoritmaya tanımlanır.



Şekil 3.3 Kontrollü Sınıflandırma


Kullanılan sınıflandırma algoritması hazırlanan eğitim verisini kullanarak görüntüdeki her bir pikselin hangi sınıfa dâhil olduğunu belirler (Richards & Richards, 1999). Kontrollü sınıflandırmada eğitim verisinin hazırlanması aşaması yoğun ön bilgi ve

zaman gerektirir. Sınıflandırma çalıştırıldıktan sonra sonuç, bilgi sınıflarına (veya arazi örtü tiplerine) karşılık gelen tematik bir harita şeklinde olmaktadır.

Kontrollü sınıflandırma yaklaşımında, elde edilen sonuçların doğruluğunu etkileyen bir takım faktörler bulunmaktadır. Bunlardan en önemlisi eğitim verisinin kalitesidir. Yüksek doğrulukla sonuçlar elde edebilmek için çalışılan bölgede bulunan sınıfları en iyi temsil eden eğitim verisinin hazırlanması gerekmektedir. Bu da kullanıcının bölgeyi iyi tanımasını gerektirmektedir. Bunun yanında hazırlanılan eğitim verisinin büyüklüğü de sonuca etki eden faktörlerden biridir. Literatürde eğitim verisinin büyüklüğü ile ilgili farklı yaklaşımlar vardır. Bunlardan biri her sınıf başına en az [30* spektral bantların sayısı] olması gerektiğidir (Pal & Mather, 2006). Bir diğeri, her kategori için birden farklı alandan toplanmış en az 100 piksel olması gerektiği (Campbell & Wynne, 2011) ya da sınıf başına en az 75 örnek ile başlayıp ardından örneklem büyüklüğü planlamasını iyileştirilmesi olarak sayılabilir (Beleites, Neugebauer, Bocklitz, Krafft, & Popp, 2013).


3.4 KontROLSÜZ Sınıflandırma

KontROLSÜZ sınıflandırma yaklaşımı, görüntüdeki piksellerin spektral değerlerinin analizine ve sahip oldukları değerlere göre gruplara ayrılmasına dayanmaktadır (J. G. Liu & Mason, 2013). Bu yöntem genellikle, bölgenin genel yapısı hakkında yeterli bilgiye sahip olunmadığı durumlarda kullanılır. Bu yaklaşımda benzer özellikleri taşıyan pikseller algoritma tarafından sınıflara atanır ve gerektiğinde aynı sınıf türleri ile birleştirilir. İşlem sonunda oluşturulan sınıflar kullanıcı tarafından etiketlenir (Lillesand et al., 2014). KontROLSÜZ sınıflandırma algoritmaları oldukça hızlı çalışır ve kullanımı daha kolaydır (Langley, Cheshire, & Humes, 2001). Bu yaklaşımda eğitim aşamasının ortadan kaldırılması, hem zaman açısından hem de çalışılan alan ile ilgili ön bilgi gerektirmemesi açısından avantaj sağlar (Ozesmi & Bauer, 2002). Kullanıcıya olan bağımlılığı oldukça azdır. Oluşturulan sınıflar tamamen spektral bilgilere dayanmaktadır. Görüntü işleme ve istatistiksel yazılım paketlerinde yaygın olarak bulunur (Al-Doski, Mansorl, & Shafri, 2013).



Şekil 3.4 Kontrolsüz Sınıflandırma

Kontrolsüz sınıflandırma algoritmaları literatürde farklı şekilde gruplanmaktadır. Bunlardan biri Ma ve Chow (2004)'ün çalışmasında verilmiştir. Buna göre hiyerarşik olup olmamasına göre temelde ikiye ayrılmaktadır (Şekil 3.5). Birch (Zhang, Ramakrishnan, & Livny, 1996), Cure (Guha, Rastogi, & Shim, 1998), Chamelon (Karypis, Han, & Kumar, 1999) ve Rock (Guha, Rastogi, & Shim, 2000) gibi algoritmalar hiyerarşik algoritmalarlardır. K-means (Hartigan & Wong, 1979; MacQueen, 1967), Fuzzy C-Means (J. C. Bezdek, Ehrlich, & Full, 1984; R.-j. Liu, Zhang, & Liu, 2008), ISODATA (Ball & Hall, 1965; Venkateswarlu & Raju, 1992), DB-Scan (Birant & Kut, 2007; Sander, Ester, Kriegel, & Xu, 1998) gibi algoritmalarda hiyerarşik olmayan algoritmalar.




Şekil 3.5 Kontrolsüz Sınıflandırma Yöntemleri (Ma & Chow, 2004)

3.5 Kontrolsüz Sınıflandırma Algoritmaları

Eğitim verisi gerektirmeyen, temel olarak görüntü üzerindeki piksel değerleri üzerinden işlemleri gerçekleştiren kontrolsüz sınıflandırma yaklaşımı üzerinde çok çalışılan bir konudur. Bu bölümde literatürde sıklıkla kullanılan kontrolsüz sınıflandırma algoritmaları verilmiştir.


3.5.1 Hiyerarşik Sınıflandırma

Hiyerarşik sınıflandırma diğer pek çok sınıflandırma yönteminden farklı olarak küme sayısının önceden belirlenmesini gerektirmez. Bu yöntem, birleştirici (yığışımsal) ve ayrıştırıcı (bölücü) hiyerarşik sınıflandırma yöntemleri olmak üzere iki türe sahiptir. Birleştirici hiyerarşik sınıflandırma yaklaşımında veri kümesindeki her bir eleman ayrı bir sınıf olarak kabul edilir. Oluşturulan bu sınıflar her iterasyonda belirli kurallar doğrultusunda birleştirilir. Ayrıştırıcı sınıflandırmada ise veri kümesindeki tüm elemanların tek bir sınıfı oluşturduğu kabul edilir. Bu sınıf her aşamada belirli kurallar doğrultusunda alt sınıflara ayrılır (Şekil 3.6). İşlem sonunda dendrogram adı verilen ve tüm nesnelerin ilişkilerini gösteren bir ağaç yapısı oluşur (Johnson, 1967).




Şekil 3.6 Ayırıştırıcı hiyerarşik sınıflandırma (Roux, 2015)

Birleştirici tekniklerde, başlangıçta her bir gözlem ayrı bir sınıf olarak varsayılır. Sonraki adımda en yakın iki sınıf (gözlem) birleştirilir, sınıf sayısı bir azaltılır ve en son aşamada gözlemler tek bir sınıf olarak birleştirilerek işleme son verilir (Şekil 3.7). Sınıfları birleştirmede sıkça kullanılan teknikler tek bağlantı (sling), ortalama bağlantı, tam bağlantı (clink) ve ward tekniğidir (Murtagh & Contreras, 2017).



3.5.2 K-Means

K-Means metodu, 1967 yılında J. Mac Queen tarafından önerilmiştir (MacQueen, 1967). Çalışma mekanizmasına göre k adet küme merkezi rassal olarak seçildikten sonra, diğer piksellerin, kümelerin merkezine olan uzaklıkları dikkate alınarak, kendilerine en yakın kümelerle dâhil edilmesi prosedürü olan K-Means pek çok çalışmada kullanılmıştır (T.-W. Chen, Chen, & Chien, 2008; Huang, Ma, Lu, Rao, & Hou, 2016; Isa, Salamah, & Ngah, 2009; Ng, Ong, Foong, Goh, & Nowinski, 2006; Tatiraju & Mehta, 2008).




Şekil 3.8 K-Means Algoritması (Younus et al., 2015)

3.5.3 ISODATA

K-Means algoritmasının geliştirilmiş versiyonu olan ISODATA (Iterative Self Organizing Data Analyses Technique) yönteminde (Ball & Hall, 1965; Tou & Gonzalez, 1974) pikseller ile her bir küme ortalaması arasındaki spektral uzaklık hesaplanmaktadır. Pikseller en yakın kümeye atanmaktadır. Bu algorithmada kullanıcı tarafından belirlenen eşik değer ve parametreler doğrultusunda kümeler birleştirilir, silinir ya da bölünür. ISODATA literatürde taşkın hasarı belirleme (Islam & Sado, 2000), arazi örtüsü


haritalama (Calvo, Ciraolo, & Loggia, 2003; Engdahl & Hyypä, 2003), yangın şiddeti belirleme (Epting & Verbyla, 2005) gibi pek çok alanda kullanılmıştır.



Şekil 3.9 ISODATA Algoritması (Jang, Kim, & Byun, 2014)

3.5.4 Self Organizing Maps (SOM)

SOM yöntemi, yapay sinir ağlarının özel bir biçimidir. Yapay sinir ağlarında bulunan eğitim aşaması bu algorithmada denetimsiz olarak kullanılmaktadır. Bu yaklaşımda sistem kendini rekabetçi öğrenme yaklaşımı ile (competitive learning) eğitmektedir. Kohonen (1982) tarafından geliştirilen bu ağlar tek katmanlıdır. Bu katman giriş ve çıkış nöronlarından oluşur (Kohonen, 1982). Her bir nöron bir ağırlık vektörüne bağlıdır. Çıkış nöronlarının her biri bir kümeyi temsil eder (Villmann, Merényi, & Hammer, 2003).




Şekil 3.10 SOM Algoritması (Anifah, Purnomo, Mengko, & Purnama, 2018)

SOM literatürde görüntü işleme (Goncalves, Netto, Costa, & Zullo Junior, 2008; Ji, 2000; Villmann et al., 2003), yağış tahminleri (Hong, Chiang, Liu, Hsu, & Sorooshian, 2006; Sorooshian et al., 2000), rüzgâr sirkülasyonu (Cassano, Lynch, Cassano, & Koslow, 2006; Fayos & Fayos, 2007) ve sismik yorumlama (Coléou, Poupon, & Azbel, 2003) gibi pek çok çalışmada kullanılmıştır.

3.5.5 DBSCAN

Bir diğer kontrolsüz sınıflandırma yöntemi olan Density-based spatial clustering of applications with noise (DBSCAN), büyük hacimli veri tabanlarında, başarılı sonuçlar üreten yoğunluk tabanlı bir yöntemdir (Sander et al., 1998). Kümelerin dışında kalan elemanlar gürültü olarak kabul edilir. DBSCAN, veri kümesindeki her bir elemanın ϵ -komşuluğunu kontrol ederek sınıfları arar.

Eğer bir elemanın ϵ (eps) komşuluğunda bulunan eleman sayısı en küçük nokta sayısına (minpts) eşitse veya fazla nokta içeriyorsa p çekirdek olarak kabul edilir. Bu çekirdeği içerecek şekilde oluşturulan kümeleri genişletmek amacıyla doğrudan *yoğunluk ulaşılabilir nesneler* araştırılır (Han, Pei, & Kamber, 2011). Veri tabanı, uzaysal bakış açısı ile ele aldığı için yoğunlukla uzamsal verilerin analizinde kullanılmaktadır (Ester, Kriegel, Sander, Wimmer, & Xu, 1998).




Şekil 3.11 DBSCAN Algoritması (El Bahi & Zatni, 2018)

3.5.6 Canopy

Canopy, McCallum ve arkadaşları (2000) tarafından önerilen, basit, hızlı ve doğru sonuçlar üreten bir algoritmadır. Canopy algoritması, verileri iki eşik değeri belirleyerek sınıflandırmaya başlar (T_1 ve T_2 , $T_1 > T_2$). İlk olarak, verilerden rastgele bir nokta küme merkezi olarak seçilir. Daha sonra ikinci nokta alınır ve merkez noktadan uzaklık (d) hesaplanır (McCallum, Nigam, & Ungar, 2000). Mesafe eşik değerden küçükse, alınan nokta kümeye kabul edilir. Böylece, algoritmanın tüm tekrarları tamamlandığında,

kümelerin merkez noktaları ve bu kümelere ait elemanlar belirlenir (Dai, Yu, & Jiang, 2016).




Şekil 3.12 Canopy Algoritması (McCallum et al., 2000)

3.5.7 M-Tree

M-Tree algoritması, nesneleri göreceli mesafelerine göre kümelere ayırır ve bu nesneleri metrik alanın sınırlandırılmış bölgelerine karşılık gelen sabit boyutlu düğümlerde saklar (Ciaccia, Patella, & Zezula, 1997). M-Tree ağaçlarında yaprak olmayan düğümler, yaprak düğümleri, yönlendirme nesneleri gibi bazı yapılar bulunur. Algoritma ilk önce yeni nesnenin ait olduğu bir yaprak düğümünü bulmakla başlar. Yaprak düğümü dolu değilse, sadece yaprak düğümüne eklenir. Yaprak düğümü doluysa, yaprak düğümü ayrılır. Bölümleme işlemi ağacın köküne ulaşırsa, yaprak düğümünden iki yönlendirme nesnesi seçilerek orijinal yaprak düğümündeki tüm nesneleri içeren iki yeni düğüm oluşturulur ve yeni kökte saklanır (Mihaescu & Burdescu, 2012).

3.5.8 Learning Vector Quantization (LVQ)


Kohonen (Kohonen, Kangas, Laaksonen, & Torkkola, 1992) tarafından geliştirilen LVQ (Öğrenme Vektör Kantitasyon) algoritmasının temel fikri, bir veri kümesinde doğal kümeler bulmaktır. Bu algoritmada, her veri vektörü, d boyutlu bir veri alanındaki bir nokta ile ilişkilidir. Amaç, aynı sınıftaki vektörlerin veri alanında bir grup oluşturmaktır. Bir özellik vektörünü sınıflandırmak için, tüm ortalama vektörlere Öklid mesafesi ölçülür. LVQ algoritması, denetlenen veya denetlenmeyen, dinamik veya statik algoritmalar gibi farklı türlere sahiptir.



Şekil 3.13 LVQ Algoritması (Kohonen et al., 1992)

3.5.9 Fuzzy C- Means

Dunn (1973) tarafından önerilen ve Bezdek (1981) tarafından geliştirilen Fuzzy C-Means, bir veri kümesi içerisinde bulunan elemanın, iki veya daha fazla kümeye üye olabilirliliği mantığı üzerinde çalışır. Bir verinin üyelik değerleri toplamı bir olmalıdır. Bu algorithmada kullanıcı tarafından küme sayısı, bulanıklık katsayısı, i iterasyon sayısı, işlem sonlanma kriteri belirlenir. (J. Bezdek, Trivedi, Ehrlich, & Full, 1981; Dunn, 1973). Bu yöntemin akışı Şekil 3.14’ te verilmiştir.



Şekil 3.14 Fuzzy C-Means Algoritması (Wang, Zhao, Wang, Tang, & Li, 2015)

4. ÇALIŞMADA KULLANILAN VERİLER VE ÇALIŞMA ALANLARI

Bu çalışmada geliştirilmiş olan yöntemin test edilmesi amacıyla Sentinel 2 görüntüleri tercih edilmiştir. Sentinel 2 görüntülerinin tercih edilmesindeki sebep ücretsiz olarak elde edilebilen bu yüksek-orta çözünürlüklü görüntülerin literatürde pek çok çalışmada yaygın olarak kullanılmasıdır.

Sentinel-2 programı, European Space Agency (ESA) tarafından Copernicus programı kapsamında 23 Haziran 2015 yılında fırlatılmıştır. Bu sistem, multispektral yüksek çözünürlüklü algılayıcıya sahip aynı yörüngeye yerleştirilmiş, birbirine 180 °'lik kademeli iki polar yörüngeli uydudan oluşmaktadır. Dünya'nın yüzey değişikliklerinin izlenmesini desteklemektedir (ESA, 2018).

Sentinel-2 uydu görüntüleri kullanıcılara farklı kalite seviyelerinde sunulmaktadır. Mart 2018 tarihinde Level-2A seviyesi kullanıcılara açılmıştır. Level-2A seviyesi görüntüleri Level-1C seviyesi görüntülerine atmosferik düzeltme uygulanarak üretilmektedir. Her iki kalite seviyesindeki görüntüler için de UTM/WGS84 projeksiyonuna göre geometrik düzeltmeleri yapılmaktadır (ESA, 2018).

Tablo 4.1 Sentinel-2 uyduları görüntü kalitesi seviyeleri (ESA, 2018)

Görüntü Kalitesi	Özellikler	Veri Hacmi
Level 1C	Üst Atmosferik Düzeltme (TOA)- Geometrik Düzeltme	~ 600 MB (her 100×100 km ²)
Level 2A	Alt Atmosferik Düzeltme (BOA)- Geometrik Düzeltme	~800 MB (her 100×100 km ²)

Sentinel-2 uydusu mekânsal çözünürlükleri 10, 20 ve 60 metre arasında olan 13 spektral banda sahiptir. Ayrıca kırmızı aralığında üç bant içermektedir. Bu özelliğe sahip ilk sivil uydudur (Drusch et al., 2012).


Tablo 4.2. Sentinel-2 uydusuna ait bant ve özellikleri (ESA, 2018)

Bant	Dalga Boyu Aralığı (nm)	Çözünürlük (m)
Bant 1	433-453	60
Bant2	458-523	10
Bant3	543-578	10
Bant4	650-680	10
Bant5	698-713	20
Bant6	733-748	20
Bant7	773-793	20

Bant8	785-900	10
Bant8A	855-875	20
Bant9	935-945	60
Bant10	1360-1390	60
Bant11	1565-1655	20
Bant12	2100-2280	20

Çalışma kapsamında geliştirilen algoritmayı test etmek amacıyla Sentinel 2 uydusuna ait level-2A görüntüleri kullanılmıştır. Bunun yanında Sentinel 2 uydusuna ait tüm bantları kullanabilmek amacıyla 20 ve 60 metrelik bantlar 10 m mekânsal çözünürlük elde edebilmek amacıyla IHS yöntemiyle keskinleştirilmiştir.


Çalışmada kullanılan görüntüler Türkiye’de farklı coğrafi bölgelere ait görüntülerdir. Bu bölgeler farklı iklimlere, topografik özelliklere, kentsel dağılımlara sahip olmaları nedeniyle tercih edilmiştir. Bu görüntülerden ilki Gemlik Bölgesine aittir (Şekil 4.1).



Şekil 4.1 Veri-1: Gemlik Bölgesi

Gemlik 19.13 derece doğu meridyeni ile 40.12 derece kuzey enlemi üzerinde bulunmaktadır. Gemlik'in üç tarafı dağlarla kuşatılmıştır. Batısında Marmara Denizi bulunmaktadır. Gemlik İlçesi'nde genellikle Akdeniz iklimi hüküm sürmektedir. Bununla birlikte Karadeniz iklimine geçiş sahası manzarası gösterir (Gemlik_Belediyesi, 2019). Bölgede bulunan bitki örtüsü maki, orman ve zeytinliklerden oluşmaktadır (URL, 2019). Bu çalışma alanı Türkiye'de Marmara bölgesine ait iklim özelliklerini ve bitki örtüsünü temsil etmesi, yüksek yoğunluklu orman ve kentsel alanlar içermesi açısından tercih edilmiştir.


Çalışma alanlarından ikincisi Hatay bölgesine aittir (Şekil 4.2). Hatay Türkiye'nin güneyinde, İskenderun körfezinde kıyılarında yer alır. Bölgenin bitki örtüsü ve maki türlerinden oluşmaktadır.



Şekil 4.2 Veri-2: Hatay Bölgesi

Hatay il sınırları içerisinde yazları sıcak ve kurak, kışları ise ılık ve yağışlı karakteristik Akdeniz iklimi görülmektedir. Hatay, toprak türleri bakımından kırmızı-kahverengi Akdeniz toprakları, kırmızı Akdeniz toprakları, kahverengi orman toprakları, kolüvyal topraklar ile alüvyal topraklar içerir (Hatay_Valiliği, 2019). Bu çalışma alanı, geliştirilmiş olan algoritmanın Akdeniz bitki örtüsü, farklı toprak çeşitleri ve yoğun kentsel alanların tespit edilmesi konusundaki başarısını belirlemek amacıyla kullanılmıştır.

Son çalışma alanı Türkiye'nin kuzeyinde bulunan Sinop bölgesi'ne aittir (Şekil 4.3). Sinop, Karadeniz kıyı şeridinde bulunan Boztepe Burnunda yer alır. 41 derece 12 dakika ve 42 derece 06 dakika kuzey enlemleri ile 34 derece 14 dakika ve 35 derece 26 dakika doğu boylamları arasında yer almaktadır (Sinop_Valiliği, 2019).



Şekil 4.3 Veri-3: *Sinop Bölgesi*


Sinop ilindeki bitki örtüsü, çok çeşitli ağaç türlerinden oluşmuştur. Bunlar meşe, defne, karaağaç, çınar, fındık, kızılcık, kayın, gürgen, karaçam ve sarıçam olarak sayılabilir. Sıcak ve ılıman iklimin hâkim olduğu Sinop oldukça fazla yağış alan bir ildir (Sinop_Valiliği, 2019). Bu bölge ülkenin en kuzeyinde bulunması, Karadeniz iklim özelliklerini ve bitki örtüsünü temsil etmesi nedeniyle tercih edilmiştir.

5. YÖNTEM

Bu bölümde çalışmada belirlenen amaçlar doğrultusunda geliştirilen sınıflandırma ve etiketleme yaklaşımları yer almaktadır.

5.1 Sınıflandırma

Bu çalışmada geliştirilmiş olan sınıflandırma yaklaşımını gösteren bir iş akışı oluşturulmuştur. Bu iş akışı Şekil 5.1’de verilmiştir.



Şekil 5.1 Önerilen Sınıflandırma Algoritması

Çalışmada geliştirilen yöntemde girdi olarak katmanlardan oluşan spektral bant birleşimi kullanılmaktadır. Bu bant birleşimi sadece kırmızı, yeşil ve mavi bantlardan oluşabileceği gibi daha çok katmandan oluşan bant birleşimleri de bu yöntemle sınıflandırılabilir.

5.1.1 Veri Havuzunun Genişletilmesi

Tasarlanan akışa göre görüntü okunduktan sonra yeni veri katmanları oluşturulmaktadır. Bu doğrultuda spektral indisler, PCA ve görüntü filtreleri olmak üzere üç farklı işlem gerçekleştirilmektedir. Yeni katmanlar geliştirilen yazılım yardımıyla otomatik olarak oluşturulmakta ve arayüzde görsel olarak kullanıcıya sunulmaktadır.

5.1.1.1 Spektral indisler

Bu çalışmada veri havuzunun genişletilmesi için kullanılan yöntemlerden ilki görüntüde bulunan spektral bantlar kullanılarak spektral indislerin hesaplanmasıdır. Bu çalışmada görüntüde bulunan bantların niteliğine göre değişmekle beraber yaklaşık 50 spektral indis hesaplanmaktadır. Çalışma kapsamında kullanılan spektral indisler aşağıda verilmiştir:

Chlorophyll Index Red-edge (CI_re): Gitelson ve arkadaşları (2003) tarafından önerilen CI_re indisi yansıma değerleri ve klorofil arasındaki ilişkiyi araştırmak amacıyla önerilmiştir (A. A. Gitelson, Gritz, & Merzlyak, 2003).

$$CI_{RE} = \frac{NIR}{KIRMIZI KENAR 1} \quad (5.1)$$

Plant Senescence Reflectance Index (PSRI): Merzlyak ve arkadaşları (1999) çalışmalarında hem yaprak yaşlanmasının hem de meyve olgunlaşmasının, pigment bileşimine bağlı olarak 670 ve 500 nm (R678 – R500) yakınındaki yansıma değerlerini etkilediğini belirtmiştir. Buradan yola çıkarak bitkilerin yaşlanma/olgunlaşma süreçlerinin başlangıcı, aşaması, nispi oranları ve kinetiğini tahmin etmek için kullanılabilen PSRI indisini önermişlerdir (Merzlyak, Gitelson, Chivkunova, & Rakitin, 1999). Bu çalışmadan yola çıkarak Sentinel-2 bantlarında kullanılmak üzere aşağıdaki formülден yararlanılmıştır:

$$PSRI = \frac{KIRMIZI - MAVİ}{KIRMIZI KENAR 2} \quad (5.2)$$

Transformed Vegetation Index (TVI): Deering ve arkadaşları (1975) tarafından önerilen TVI, negatif değerleri ortadan kaldırmayı ve NDVI histogramlarını normal dağılıma dönüştürmeyi amaçlamaktadır (Deering, 1975).

$$TVI = 100 * \sqrt{\left(\frac{NIR - KIRMIZI}{NIR + KIRMIZI}\right) + 0.5} \quad (5.3)$$

Brightness Index (BI): Escadafal (1989) tarafından önerilen indis, toprağın spektral özelliklerini ortaya çıkarmak amacıyla kullanılmaktadır (Escadafal, 1989).

$$BI = \frac{\sqrt{KIRMIZI * KIRMIZI + YEŞİL * YEŞİL}}{2} \quad (5.4)$$

Normalized Burn Ratio (NBR): NBR, yanmış alanları tanımlamak için kullanılır. Bu indis, elektromanyetik spektrumun yakın kızılötesi (NIR) ve kısa dalga kızılötesi (SWIR) bölümlerini kullanır (García & Caselles, 1991). NBR indisi aşağıda verilen formül ile hesaplanır:

$$NBR = \frac{NIR - SWIR}{NIR + SWIR} \quad (5.5)$$

NBR indisi başlangıçta Landsat TM ve ETM + bantları 4 ve 7 ile kullanılmak üzere geliştirilmiştir, ancak 760 - 900 nm arasında bir NIR bandı ve 2080 - 2350 nm arasında bir SWIR bandı bulunan herhangi bir multispektral sensörle çalışacaktır.

Normalized Burn Ratio 2 (NBR2): NBR 2 indisi SWIR değerleri arasında hesaplanan bir indistir (García & Caselles, 1991). Bu indis yanmış alanların belirlenmesi amacıyla önerilmiştir. Aşağıda verilen formül ile hesaplanır:

$$NBR2 = \frac{SWIR1 - SWIR2}{SWIR1 + SWIR2} \quad (5.6)$$

Soil-adjusted Vegetation Index (SAVI): SAVI, bitki örtüsü az olduğunda toprak parlaklığının etkisini düzeltmek için Normalleştirilmiş Farklı Bitki Örtüsü İndisinin modifikasyonu olarak geliştirilmiştir (Huete, 1988). SAVI indisi aşağıda verilen formül ile hesaplanır (Sinergise, 2017).

$$SAVI = 1.5 * \frac{NIR - KIRMIZI}{NIR + KIRMIZI + 0.5} \quad (5.7)$$

Normalized Difference Moisture Index (NDMI): NDMI, NIR ve SWIR1 bant ile elde edilir. Bu indis genel olarak çalışmalarda bitki biyokütle, su stresi belirleme, değişim analizi gibi amaçlarla kullanılmıştır (Hardisky, Klemas, & Smart, 1983; Wilson & Sader, 2002). NDMI, aşağıda verilen formül ile hesaplanmaktadır:

$$NDMI = \frac{NIR - SWIR1}{NIR + SWIR1} \quad (5.8)$$

Enhanced vegetation index (EVI2): Mavi bantının içerdiği gürültü probleminden kurtulmak amacıyla, Mavi bant yansımaları gerektirmeyen iki bantlı bir EVI (EVI2) geliştirilmiştir (Jiang et al., 2008). Bu indis farklı bitki örtülerini ayırt etmek amacıyla kullanılmaktadır.

$$EVI 2 = 2.5 * \frac{NIR - KIRMIZI}{NIR + 2.4 * KIRMIZI + 1} \quad (5.9)$$

Optimized Soil Adjusted Vegetation Index (OSAVI): Rondaux ve arkadaşları (1996), X değerinin 0,16'ya ayarlandığı optimize edilmiş bir SAVI değerinin tarımsal yüzeylerdeki uygulamasının başarılı sonuçlar verdiğini belirtmiştir (Rondeaux, Steven, & Baret, 1996). OSAVI, toprak yansımalarının optimize edildiği indislerden biridir. Bu indis aşağıda verilen formül ile hesaplanmaktadır:

$$OSAVI = (1 + 0.16) * \frac{NIR - KIRMIZI}{NIR + KIRMIZI + 0.16} \quad (5.10)$$

Difference Vegetation Index (DVI): Bitki örtüsüne duyarlı, toprak ve bitki örtüsünü ayırt eden bir indistir. Bu indis, kırmızı ve fotografik kızılötesi parlaklık ile yeşil ve kahverengi bitki örtüsü arasındaki yansımalar farklılıklarını kullanır (Tucker, 1980). Aşağıda verilen formül ile hesaplanır:

$$DVI = NIR - KIRMIZI \quad (5.11)$$

Green Leaf Index (GLI): GLI, canlı bitkileri topraktan ve cansız maddelerden ayırabilen bir algoritmadır. GLI değerleri -1 ile +1 arasında değişir. Negatif değerler toprak ve yaşam dışı özellikleri temsil ederken, pozitif değerler yeşil yaprakları ve gövdeleri temsil eder (Louhaichi, Borman, & Johnson, 2001). Bu indis aşağıda verilen formül ile hesaplanır:

$$GLI = \frac{((2 * YEŞİL) - KIRMIZI - MAVİ)}{((2 * YEŞİL) + KIRMIZI + MAVİ)} \quad (5.12)$$

Normalized Difference Snow Index (NDSI): NDSI, görünür (yeşil) ve kısa dalga kıızılötesi (SWIR) arasındaki yansıma farkının göreceli büyüklüğünün bir ölçüsüdür. Bu indis genellikle kar haritalama için kullanılmaktadır. Kar, sadece elektromanyetik spektrumun görünür kısımlarında çok fazla yansıtıcı olmakla kalmaz, aynı zamanda NIR'de veya spektrumun kısa dalga kıızılötesi kısmında da yüksek derecede emicidir, ancak en fazla bulut yansıması spektrumun aynı bölümlerinde yüksek kalmaya devam eder. Bulutların ve karların çoğunun iyi ayrılmasını sağlar (Salomonson & Appel, 2004). NDSI aşağıda verilen formül ile hesaplanır:

$$NDSI = \frac{YEŞİL - SWIR}{YEŞİL + SWIR} \quad (5.13)$$

Normalized Difference Water Index (NDWI): Gao (1995) tarafından önerilen NDWI indisi bitkilerdeki ve topraktaki nem içeriğini yansıtır (Gao, 1995). Bunun yanında NDWI indisi pek çok farklı uydu için literatürde su kütlesi çıkarımı için sıklıkla kullanılmaktadır (Bhandari, Kumar, & Singh, 2015; Ding, Liu, Huang, Li, & Zou, 2017; Ezzine, Bouziane, Ouazar, & Hasnaoui, 2017; Jovanovic, Garcia, Bugan, Teich, & Rodriguez, 2014; Mao, Feng, Gong, & Yu, 2014; McFeeters, 2013; Qiao et al., 2012; Singh, Setia, Sahoo, Prasad, & Pateriya, 2015; Sun, Zhao, Chen, Gong, & Yang, 2013; Xiucheng Yang, Zhao, Qin, Zhao, & Liang, 2017). Su kütlesi, görünür bölgede bulunan kıızılötesi dalga boylarına kadar güçlü emiciliğe ve düşük yansıtım özelliğine sahiptir (Y.

Du et al., 2016). Bu nedenle indis yeşil ve yakın kızıl ötesi bantları kullanılarak aşağıdaki formülle hesaplanmaktadır:

$$NDWI = \frac{NIR - YEŞİL}{NIR + YEŞİL} \quad (5.14)$$

Band Ratio for Built-up Area (BRBA): Waqar ve arkadaşları (2012) tarafından orta çözünürlüklü görüntülerden yerleşim alanları ve çıplak toprak alanlarının belirlenmesi amacıyla önerilmiştir. Aşağıda verilen formül ile hesaplanır (Waqar et al., 2012):

$$BRBA = \frac{MIR}{KIRMIZI} \quad (5.15)$$

Global Environmental Monitoring Index (GEMI): GEMI, istenmeyen atmosferik etkileri azaltmak için doğrusal olmayan bir yaklaşım izlemektedir. Pinty ve arkadaşları (1992) tarafından önerilen bu indis görünür kırmızı ve NIR etki alanlarını kullanır ve aşağıdaki formülle hesaplanır (Pinty & Verstraete, 1992):

$$ALFA = \frac{2 * (NIR^2 - KIRMIZI^2) + 1.5 * NIR + 0.5 * KIRMIZI}{KIRMIZI + NIR + 0.5} \quad (5.16)$$

$$GEMI = (ALFA * (1 - (0.25 * ALFA))) - \frac{KIRMIZI - 0.125}{1 - KIRMIZI} \quad (5.17)$$

Green Chlorophyll Index (GCL): Bu indis çeşitli bitki türlerindeki klorofil içeriğine duyarlı olarak sonuçlar üretir. Klorofil düzeyi bitkilerin fizyolojik durumunu yansıttığından sağlıklı ve hastalıklı bitkiler ayırt edilebilir. Bu indis aşağıda verilen formül ile hesaplanır (EOS, 2019):

$$GCL = \frac{NIR}{YEŞİL} - 1 \quad (5.18)$$

Burn Area Index (BAI): Landsat TM görüntülerindeki Kırmızı ve NIR bantları ile hesaplanan bu indis yanmış alanları yüksek doğrulukla ayırma gücüne sahiptir (Martín, Gómez, & Chuvieco, 2005). Martin (1998) tarafından önerilen bu indis aşağıda verilen formül ile hesaplanır (Martin, 1998):

$$BAI = \frac{1}{(0.1 - KIRMIZI)^2 + (0.06 - NIR)^2} \quad (5.19)$$

Road Extraction Index (REI): REI, Shahi (2015) ve arkadaşları tarafından WorldView 2 görüntülerinden asfalt yolları çıkarmak üzere önerilmiştir. Bu indis aşağıda verilen formül ile hesaplanmaktadır (Shahi, Shafri, Taherzadeh, Mansor, & Muniandy, 2015):

$$REI = NIR^2 - \frac{MAVI}{NIR^2} + (MAVI * NIR^2) \quad (5.20)$$

Red Edge Normalized Difference Vegetation Index (RE_NDVI): RE_NDVI indisi, geleneksel geniş bant NDVI indisinin bir modifikasyonudur. Bu bitkisel indis, ana yutulma ve yansıtma tepe noktaları yerine red-edge bantları kullanılarak hesaplanır (A. Gitelson & Merzlyak, 1994).

$$RE_NDVI = \frac{NIR - RED_EDGE1}{NIR + RED_EDGE1} \quad (5.21)$$

Inverted Red-Edge Chlorophyll Index (IRECI): Kanopi klorofil içeriğini tahmin etmek amacıyla kullanılan bu indis aşağıda verilen formül ile hesaplanmaktadır (Guyot & Baret, 1988).

$$IRECI = \frac{NIR - KIRMIZI}{\frac{RED_EDGE1}{RED_EDGE2}} \quad (5.22)$$

Built-up Area Extraction Index (BAEI): BAEI, Bouzekri (2015) tarafından Landsat-8 görüntülerinde bulunan yerleşim alanlarını vurgulamak için önerilmiştir (Bouzekri, Lasbet, & Lachehab, 2015).

$$BAEI = \frac{KIRMIZI + L}{YEŞİL + SWIR1} \quad (5.23)$$

Soil-Adjusted Total Vegetation Index (SATVI): SATVI, mevcut olan birkaç bitki örtüsü indisinin bir modifikasyonudur. Marsett ve arkadaşları(2006) hem yeşil hem de kurumuş bitki örtüsünü haritalandırmak için geliştirdiği NDSVI ile SAVI indisini birleştirmişlerdir. SATVI, aşağıda verilen formül ile hesaplanmaktadır (Marsett et al., 2006).

$$SATVI = \left(\frac{SWIR1 - KIRMIZI}{(SWIR1 + KIRMIZI + 0.5)} \right) * 1.5 - \left(\frac{SWIR2}{2} \right) \quad (5.24)$$

Dry Bare-Soil Index (DBSI): Rasul ve arkadaşları tarafından geliştirilen DBSI, çıplak toprakların daha iyi bir ayrılması için kullanılmaktadır. DBSI değerleri - 2 ila +2 arasında olabilir ve daha yüksek sayılar daha fazla toprağı temsil eder. Piksel değerleri 0.26 ve daha yüksek olan bölgeler çıplak toprak olarak tanımlanmış ve daha düşük değerlere sahip alanlar diğer sınıflara ayrılmıştır (Rasul et al., 2018).

$$DBSI = \left(\frac{SWIR1 - YEŞİL}{(SWIR1 + YEŞİL)} \right) - NDVI \quad (5.25)$$

Water Ratio Index (WRI): WRI, aşağıda verilen formül ile hesaplanmaktadır (Shen & Li, 2010). Su ve buz özelliklerini karasal alanlardan düzgün bir şekilde ayırır. Bu indis aşağıda verilen formül ile hesaplanmaktadır.

$$WRI = \left(\frac{YEŞİL + KIRMIZI}{NIR + MIR} \right) \quad (5.26)$$

Automated Water Extraction Index (AWEI): AWEI, gölge ve karanlık yüzeyleri kapsayan alanları ayırmak amacıyla önerilmiştir (Feyisa, Meilby, Fensholt, & Proud, 2014). Bu indis, aşağıda verilen formül ile hesaplanmaktadır.

$$AWEI = 4 * (YEŞİL - MIR) - (0.25 * NIR + 2.75 * SWIR) \quad (5.27)$$

New Built - Up Index (NBUI): NBUI, kentsel alanın geçirimsiz yüzey malzemesi, yeşil bitki örtüsü, çıplak toprak ve su kütlelerinden dört ana heterojen bileşenden oluşan karmaşık bir ekosistem olması anlayışına dayanarak Sinha ve arkadaşları(2016) tarafından geliştirilmiştir. NBUI, kentsel arazi kullanım sınıflarını temsil etmek için Landsat görüntülerinde bulunan tüm dalga boylarını kullanır ve şöyle hesaplanır (Sinha, Verma, & Ayele, 2016):

$$NBUI = \left(\frac{NIR - KIRMIZI}{NIR + SWIR1} \right) - \left(\left(\frac{KIRMIZI - YEŞİL}{KIRMIZI - YEŞİL + 1} \right) + \left(\frac{MAVİ - NIR}{MAVİ + NIR} \right) \right) \quad (5.28)$$

Excess Green Index (EGI): EGI, bitki örtüsünü topraktan ayırmak için elektromanyetik spektrumun yeşil bölümünü kırmızı ve maviye karşı kontrast oluşturması mantığıyla geliştirilmiştir (Woebbecke, Meyer, Von Barga, & Mortensen, 1995).

$$EGI = 2 * YEŞİL - KIRMIZI - NIR \quad (5.29)$$

Structure Insensitive Pigment Index (SIPI): SIPI, değişken gölgelik yapısı ile bitki örtüsünün analizi için iyidir. Bitkilerdeki klorofil oranını tahmin eder. Yüksek SIPI değerleri, genellikle bitkilerde klorofil kaybına neden olan bitki hastalığının bir göstergesidir (Penuelas, Baret, & Filella, 1995). Bu indis, aşağıda verilen formül ile hesaplanmaktadır:

$$SIPI = \left(\frac{NIR - MAVİ}{NIR - KIRMIZI} \right) \quad (5.30)$$

Normalized Difference Tillage Index (NDTI): Yerleşim bölgelerini toprak alanlardan ayırmak amacıyla yapılan çalışmalarda SWIR bant değerlerinin çıplak

arazilerle yerleşim bölgeleri arasında farklılık gösterdiği belirlenmiştir. Bu noktadan yola çıkarak aşağıdan verilen indis önerilmiştir (Van Deventer, Ward, Gowda, & Lyon, 1997):

$$NDTI = \left(\frac{SWIR1 - SWIR2}{SWIR1 + SWIR2} \right) \quad (5.31)$$

Red-Edge-Based Normalized Vegetation Index (NDVIre): Bitki örtüsü belirleme çalışmalarında ilk olarak Hansen ve arkadaşları tarafından hiperspektral verilerde kullanılmıştır (Hansen & Schjoerring, 2003).

$$NDVIre = \left(\frac{KIRMIZI - KIRMIZI_KENAR_1}{KIRMIZI + KIRMIZI_KENAR_1} \right) \quad (5.32)$$

Modified Normalized Difference Water Index (MNDWI): Yerleşim yerleriyle çevrili alanlarda bulunan su bölgesini incelemek amacıyla önerilen indisin formülü aşağıda verilmektedir (Xu, 2006).

$$MNDWI = \left(\frac{YEŞİL - SWIR1}{YEŞİL + SWIR1} \right) \quad (5.33)$$

Normalized Difference Built-Up Index (NDBI): Kentsel alanların otomatik olarak haritalanması amacıyla Zha ve arkadaşları (2003) tarafından önerilmiştir (Zha et al., 2003).

$$NDBI = \left(\frac{SWIR - NIR}{SWIR + NIR} \right) \quad (5.34)$$

Multi Index: Uzaktan algılama çalışmalarında kentsel alanların belirlenmesi konusunda karşılaşılan sorunlardan biride cansız alanların (toprak ve kentsel bölgeler) ayırt edilebilmesidir. Bu noktadan hareketle Osgouei ve arkadaşları tarafından multi 1 ve Multi 2 indisleri önerilmiştir (Ettehad Osgouei, Kaya, Sertel, & Alganci, 2019). Aşağıda bu indislerin formülleri bulunmaktadır:

$$\text{Multi Index 1} = NDBI + NDVIre + MNDWI \quad (\text{Ettehad Osgouei et al., 2019}) \quad (5.35)$$

$$\text{Multi Index 2} = NDTI + NDVIre + MNDWI \quad (\text{Ettehad Osgouei et al., 2019}) \quad (5.36)$$

5.1.1.2 Temel Bileşenler Analizi (PCA)

Yeni veri katmanları oluşturmak için kullanılan bir diğer yöntem PCA yöntemidir. Literatürde bazı bantlar/görüntüler aralarındaki korelasyon azaltılarak elde edilen yeni verilerin belirli sınıfların tanımlanmasını kolaylaştırdığı ortaya konulmuştur (Bhatti & Tripathi, 2014; Deng, Wang, Deng, & Qi, 2008). Bu bilgiden yola çıkarak özellikle benzer spektral özellikler gösteren orman-yeşil tarım alanları, toprak-nadas alanları gibi sınıfları ayırt edebilmek amacıyla Vegetation Red Edge ve NIR bantları arasında çeşitli kombinasyonlar için PCA kullanılmıştır. Bunun yanında kentsel alanlardaki yansımaları daha ayırt edilebilir olan SWIR bantları da bu yöntemle yeni katmanlar oluşturmak amacıyla kullanılmıştır.

Çalışma kapsamında PCA ile üretilen katmanlar:

Multi 1 PCA: Literatürde bulunan Multi indisini oluşturulan NDBI + NDVI_{re} + MNDWI değerlerinin PCA yöntemiyle indirgenmesiyle elde edilmiştir.

Multi 2 PCA: Literatürde bulunan Multi2 indisini oluşturulan NDTI + NDVI_{re} + MNDWI değerlerinin PCA yöntemiyle indirgenmesiyle elde edilmiştir.

Sw1_sw2: SWIR 1 ve SWIR 2 bant değerlerinin PCA ile indirgenmesiyle elde edilmiştir.

Sw1_sw2_MNDWI: SWIR 1 ve SWIR 2 bant değerleri ile MNDWI indisinin PCA ile indirgenmesiyle elde edilmiştir.

NDBI_SAVI_MNDWI: Literatürde bulunan MNDWI, NDBI ve SAVI spektral indislerinin PCA ile indirgenmesiyle elde edilmiştir.

RGI_BR: RGI ve BR spektral indis değerlerinin PCA ile indirgenmesiyle elde edilmiştir.

12_8_4: SWIR 2, NIR ve Kırmızı bant değerlerinin PCA ile indirgenmesiyle elde edilmiştir.

12_11_2: SWIR 1, SWIR 2 ve Mavi bant değerlerinin PCA ile indirgenmesiyle elde edilmiştir.

8_11_4: SWIR 1, Kırmızı ve NIR bant değerlerinin PCA ile indirgenmesiyle elde edilmiştir.

R_G_B: Mavi, Kırmızı ve Yeşil bant değerlerinin PCA ile indirgenmesiyle elde edilmiştir.

8_5: Kırmızı kenar 1 ve NIR bant değerlerinin PCA ile indirgenmesiyle elde edilmiştir.

8_6_4: Kırmızı kenar 1, Kırmızı ve NIR bant değerlerinin PCA ile indirgenmesiyle elde edilmiştir.

Red_Edge_1_2_3_4: Kırmızı kenar bantlarının PCA ile indirgenmesiyle elde edilmiştir.

5_11_6: Kırmızı kenar 1, Kırmızı kenar 2, ve SWIR 1 bant değerlerinin PCA ile indirgenmesiyle elde edilmiştir.

8_4_3: NIR, Kırmızı ve Yeşil bant değerlerinin PCA ile indirgenmesiyle elde edilmiştir.

GVI_YVI: GVI ve YVI spektral indis değerlerinin PCA ile indirgenmesiyle elde edilmiştir.

5.1.1.3 Görüntü Filtreleri

Veri havuzunun genişletilmesi için kullanılan son yöntem ise görüntü filtreleme operasyonlarıdır. Çalışmada, literatürde sıklıkla kullanılan Gauss düzleştirme filtresi, Sobel, Scharr ve Laplacian filtreleri kullanılarak aşağıdaki katmanlar oluşturulmuştur:

R_g_b_Scharr: Kırmızı, yeşil ve mavi bantlarının PCA ile indirgenmesi ile elde edilen katmanın Scharr filtresi ile düzenlenmesi ile oluşturulmuştur.

Sw1_Sw2_Scharr: SWIR 1 ve SWIR 2 bantlarının PCA ile indirgenmesi ile elde edilen katmanın Scharr filtresi ile düzenlenmesi ile oluşturulmuştur.

Sw1_Sw2_Gaussian: SWIR 1 ve SWIR 2 bantlarının PCA ile indirgenmesi ile elde edilen katmanın Gauss filtresi ile düzenlenmesi ile oluşturulmuştur.


BRBA_Sobel: BRBA indisinin hesaplanmasıyla elde edilen katmanın Sobel filtresi ile düzenlenmesi ile oluşturulmuştur.

Veg_1_2_3_4_Gaussian: Red Edge 1, Red Edge 2, Red Edge 3 ve Red Edge 4 bantlarının PCA ile indirgenmesi ile elde edilen katmanın Gauss filtresi ile düzenlenmesi ile oluşturulmuştur.

DBSI_Gaussian: DBSI indisinin hesaplanmasıyla elde edilen katmanın Sobel filtresi ile düzenlenmesi ile oluşturulmuştur.

5.1.2 Başlangıç Sınıflarının Oluşturulması

Başlangıç sınıflarının oluşturulması için geliştirilmiş olan algoritma Şekil 5.2’de verilmiştir.




Şekil 5.2 Başlangıç Sınıflarının Oluşturulması

Algoritmanın bu aşamasında tüm katmanlarda bulunan veri setleri için histogram oluşturulmuştur. Karl Pearson (Pearson, 1895) tarafından tanımlanan histogramlar, bir veri kümesinin frekans dağılımını gösteren grafiklerdir. Hesaplanan histogramlar ile belirlenen yoğunluklardan yola çıkılarak kümeler oluşturulur. Her katman böylece kendi içinde sınıflandırıldıktan sonra belirlenen önceliklerine göre katmanlarda aynı sınıflarda olan pikseller tek bir sınıfta toplanır.

5.1.3 Nihai Sınıfların Oluşturulması- Optimizasyon İşlemi

Nihai sınıfların oluşturulması için geliştirilmiş olan algoritma Şekil 5.3'te verilmiştir. Görüntüde bulunan her katman için başlangıç çözümü elde edildikten sonra genel bir çözüme ulaşılması gerekmektedir. Bu aşamada dikkat edilmesi gereken noktalardan biri genel sınıfları belirlerken katmanların etkisini belirlemektir. Nesnelerin farklı dalga boylarındaki spektral yansımaları değiştiği için farklı katmanların içerdiği bilgiler diğerlerine göre daha ayırt edici olabilmektedir.



Şekil 5.3 Nihai Sınıf Oluşturma Algoritması

Bu algoritmanın ilk adımı, oluşturulmuş olan başlangıç çözümünün genel kalite indisinin hesaplanmasıdır. Bu amaçla Silhouette index (SI) hesaplanmaktadır. SI, her pikselin kendi kümesine uygunluğunu inceler (Rousseeuw, 1987). $a(i)$; i . pikselin kendi kümesindeki tüm piksellere olan ortalama uzaklıklarını ve $b(i)$ i . birimin diğer kümelerdeki tüm noktalara olan ortalama uzaklıkların minimumunu gösterirken, i . birim için SI aşağıda verilmiş olan formül ile hesaplanmaktadır.

$$SI(i) = \min \frac{1}{|C_k|} \sum_{j \in C_k} d(i, j) \quad (5.38)$$

Oluşturulmuş olan bu çözümde bulunan tüm sınıflar ikili gruplar şeklinde eşlenir. Bu grupların benzerliklerini bulabilmek amacıyla her grup için Calinski Harabasz indisi (CH) hesaplanır. CH, kümeler arası kareler toplamının(BSS) kümeler içi kareler toplamına(WSS) oranlaması ile hesaplanır.

$$CH(k) = \frac{BSS(k)/(k - 1)}{WSS(k)/(n - k)} \quad (5.39)$$

Burada k küme sayısını, BSS kümeler arası kareler toplamını, WSS kümeler içi kareler toplamını ifade etmektedir. $d(i, j)$ pikseller arası uzaklık olmak üzere BSS ve WSS 5.40 ve 5.41 numaralı formüllerle hesaplanmaktadır.

$$WSS(k) = 1/2 \sum_{i=1}^k \sum_{j \in C_i} d(i, j) \quad (5.40)$$

$$BSS(k) = 1/2 \sum_{i=1}^k \sum_{i \in C_i, i \notin C_i} d(i, j) \quad (5.41)$$


CH, literatürde en uygun küme sayısını belirlemek amacıyla kullanılan bir indistir (Caliński & Harabasz, 1974). Bu çalışmada CH indisini birleştirilecek olan sınıfların belirlenmesi amacıyla kullanılmıştır. CH indisi maksimum değerine ulaştığında en iyi sonuca ulaşıldığı kabul edilir. Bu bilgiden yola çıkarak CH indisi en küçük olan ikili grup birleştirilmektedir. Bu süreç birleştirilecek ikili grupların hepsi için tekrarlanır. Algoritmanın en son adımında ise hesaplanmış olan genel kalite indisi en uygun olan çözüm sınıflandırma sonucu olarak kabul edilir.

5.2 Etiketleme

Kontrollü sınıflandırma yöntemlerinin sonuçları kullanıcının belirlediği veriler doğrultusunda etiketli sonuçlar oluşturmaya karşın, kontrolsüz sınıflandırma yöntemleri verileri spektral benzerlik ve farklılıklardan yola çıkarak etiketsiz gruplara ayırır. Bu özellik kontrolsüz sınıflandırma yöntemlerinin dezavantajlarından biridir. Bu problemin çözümü amacıyla bir etiketleme yaklaşımı önerilmiştir.

5.2.1 Geliştirilen Etiketleme Algoritması

Mevcut kontrolsüz sınıflandırma yöntemlerinde, sınıflandırma sonuçları etiketleri olmadan oluşturulmaktadır. Bu durum sonuçların kullanıcılar tarafından yorumlanmasını gerektirdiğinden kullanıcıya olan bağımlılığı arttırmaktadır. Literatür incelendiğinde sınıflandırılmış verilerin etiketlenmesi amacıyla kullanılan bir yöntem bulunamamıştır. Bu dezavantajın azaltılması amacıyla bir etiketleme yaklaşımı önerilmiştir. Çalışma kapsamında başlangıç olarak ‘toprak’, ‘yeşil tarım alanı’, ‘orman’, ‘kentsel alanlar’ ve ‘ekilmemiş tarım alanları’ nın etiketlenmesi hedeflenmiştir. Önerilen yöntemin akışı Şekil 5.4’te verilmiştir.



Şekil 5.4 Geliştirilen Etiketleme Algoritması

Geliştirilen algoritma ile daha önce sınıflandırılmış olan veriler için etiketler üretilebilmektedir. Bu amaçla ilk olarak sınıflara atanan piksellere ait ham bant değerleri, spektral indis ve diğer yöntemlerle oluşturulan verilerin minimum ve maksimum değerleri belirlenir. Bu değerler, daha önce belirlenmiş olan eşik değerler doğrultusunda analiz edilir. Bu eşik değerlere uygun olan etiketlerin hepsi o sınıfa kaydedilir. Tüm katmanlar incelendikten sonra bir sınıfa kaydedilmiş olan etiket o sınıfa atanır. Eğer bir sınıfa birden fazla etiket kaydedildiyse en çok tekrarlanan etiket sonuç haritası için ilgili sınıfa atanır. Ancak kaydedilen tüm etiketler tekrarlanma oranına göre olasılık bilgisiyle kullanıcıya sunulur.

Çalışmada etiketleme algoritmasının test edilmesi amacıyla Sentinel 2 görüntülerinin kullanılmasına karar verilmiştir. Bu doğrultuda algorithmada bulunan eşik değerlerin belirlenebilmesi amacıyla Karadeniz ve Akdeniz Bölgelerine ait Sentinel 2 görüntüleri analiz edilmiştir. Bu doğrultuda çalışmada kullanılan sınıfların tüm

mevsimlerde gösterdiği değişimleri belirleyebilmek için Ocak, Nisan, Haziran, Eylül ve Kasım aylarına ait görüntüler elde edilmiştir. Bu görüntülerin mekânsal çözünürlüğü IHS keskinleştirme yöntemi ile 10 m'ye yükselmiştir. Elde edilen görüntülerde bulunan bantlarla Wetness Index, SAWI, REM, SATVI, OSAVI, NRAVI, NDWI, NDVI, NDSI, NBR, MSBI, GVI, , EGI, , BI, AWEI spektral indisleri hesaplanmıştır. Analiz sonucunda, belirlenen sınıflara ait bölgelerde bu indislerin değerlerinin mevsimsel olarak nasıl değiştiği belirlenmiştir. Bu değerler Ek 1'de verilmiştir. Benzer bir çalışma Akdeniz bölgesine ait Sentinel 2 görüntüleri üzerinde gerçekleştirilmiştir. Elde edilen sonuçlar Ek 2'de verilmiştir. Her iki bölgeden elde edilen değerler incelenerek algoritmada kullanılmak üzere arazi sınıflarına ait eşik değerleri belirlenmiştir. Bu değerler tablo 5.1'de verilmiştir.

Tablo 5.1. Spektral indislerden elde edilen eşik değerleri


ORMAN	YEŞİL TARIM ALANI	NADAS	TOPRAK	KENT	SU	SPEKTRAL İNDİS
-7000<AWEI<0		AWEI<-9000			AWEI>0	AWEI
		BI>0				BI
				MAVI>1300		MAVI
EGI<-2000					EGI>0	EGI
				YEŞİL >2000		YEŞİL
				GVI<-3000		GVI
MSBI<0						MSBI
				NBR<0		NBR
					NDSI>0	NDSI
NDVI>0.3					NDVI<0	NDVI
					NDWI>0	NDWI
				NRAVI<0		NRAVI
0.5<OSAVI<1				0<OSAVI<0.4	OSAVI<0	OSAVI
				SATVI<-1000		SATVI
0.9<REM		REM<0.5				REM
		0.1<SAWI>0.5				SAWI
		<-1500				WETNESS

5.2.2 Corine Arazi Örtüsü Sınıfları

Sınıflandırılmış verilerin etiketlenilmesi amacıyla bu çalışmada geliştirilen ikinci yaklaşım, spektral yansıma değerleri çok yakın olan arazi sınıflarının belirlenmesinde Corine verilerini kullanmaktır. Corine projesi arazi envanterinin belirlenmesi, arazi örtüsü değişimlerinin takip edilmesi ve bu sayede çevreye duyarlı kararlar alınabilmesi amacıyla 1985 yılında Avrupa Birliğince başlatılmıştır. Ülkemizde Corine Projesi çalışmaları 2001


yılında başlamıştır. Şu anda Avrupa Çevre ajansı veri tabanına eklenmiş olan 1990, 2000, 2006, 2012 ve 2018 yıllarına ait arazi örtüsü haritaları bulunmaktadır (Orman_Bakanlığı, 2015). Bu çalışmada 2018 yılına ait arazi örtüsü sınıfları kullanılmıştır.

Corine verileri, tüm Türkiye'yi kapsayan arazi sınıflarını içeren, mekânsal çözünürlüğü 100 m olan verilerdir. Bu veriler genel olarak etiketleme için kullanılabilir olmasına rağmen yüksek çözünürlüklü verilerle çalışılırken yeterince hassas sonuçlar sağlamamaktadır. Örneğin Şekil 5.5'de verilen alan Sinop bölgesine aittir. Bu bölgede bulunan 1 numaralı alan Corine sınıflarında liman bölgesi olarak etiketlenmiştir. Ancak bu alan 10 m çözünürlüklü bir görüntü üzerinden incelendiğinde bu bölgedeki kentsel yapılar ve su ayrılabilir. Aynı şekilde 2, 3 ve 4 numaralı alanlar Corine'de kentsel alan olarak etiketlenmiştir. Ancak alanda bulunan kentsel yapılar, yeşil alanlar ya da toprak bölgeler daha yüksek çözünürlüklü görüntülerde ayırt edilebilmektedir.



Şekil 5.5 CORINE arazi sınıfları incelemesi a)Uydu Görüntüsü b) Corine Sınıfları

Bu nedenle çalışmada Corine arazi örtüsü verilerini bütünüyle almak yerine, sadece geliştirilmiş olan etiketleme yaklaşımında benzer spektral yansımaya sahip sınıfların ayırt etmek amacıyla kullanılmıştır. Bu doğrultuda Şekil 5.6'da verilen prosedür geliştirilmiştir.



Şekil 5.6 Geliştirilen Etiketleme Algoritması

Buna göre sınıflandırılmış veriler, Bölüm 5.2.1’de verilen algoritma doğrultusunda etiketlendikten sonra, ilgili bölgelere karşılık gelen Corine sınıfları ile karşılaştırılmaktadır. Karşılaştırma aşamasında sınıfların nihai etiketlerine karar verilmesi amacıyla Tablo 5.2’de verilen kural seti tanımlanmıştır.

Tablo 5.2 Kural Seti

İlk Etiket	Corine Etiketi	Sınıf Etiketi
Yeşil Tarım Alanı	Tarım Alanı	Yeşil Tarım Alanı
Yeşil Tarım Alanı	Orman	Orman
Orman	Tarım Alanı	Yeşil Tarım Alanı
Nadas	Tarım Alanı	Nadas
Nadas	Kent	Kent
Toprak	Kent	Kent
Kent	Tarım Alanı	Nadas
Kent	Toprak	Toprak
Toprak	Tarım Alanı	Nadas

Belirlenmiş olan bu kural seti ile spektral yansıma değerleri çok yakın olan sınıfların etiketlenmesi için Corine arazi sınıflarından faydalanılması amaçlanmıştır. Tabloda bulunmayan diğer tüm durumlar için bu çalışmada geliştirilmiş olan eşik değer tabanlı etiketlendirme sonuçları geçerli kabul edilmektedir.


5.3 Arayüz

Bu çalışmada geliştirilen algoritmaların son kullanıcılar tarafından kullanımını kolaylaştırmak amacıyla bir arayüz tasarlanmıştır. Geliştirilen algoritmaların kodlanmasında ve arayüzün geliştirilmesinde Python programlama dili kullanılmıştır. Bunun yanında çalışma kapsamında Scikit-learn, NumPy, Gdal/OGR, SciPy ve Tkinter gibi kütüphanelerden faydalanılmıştır.

5.3.1 Sınıflandırma Arayüzü

Çalışma kapsamında geliştirilen sınıflandırma yönteminin kullanımı amacıyla tasarlanmış olan sınıflandırma arayüzünün genel görüntüsü Şekil 5.7’de verilmiştir. Aşağıda arayüzde bulunan alanların açıklamaları verilmiştir:

- 1: Bu yazılım ile gerçekleştirilebilecek işlemlere ait menü
- 2: Programa görüntüyü ekleme alanı,
- 3: Görüntünün ait olduğu uydunun seçildiği alan,
- 4: Sınıflandırılacak olan görüntüde bulunan bantların programa tanımlandığı alan. Bu alanda kullanıcı tarafından programa tanıtılan bant bilgileri etiketleme işleminde kullanılmaktadır.
- 5 ve 6: Geliştirilen algoritma sınıf sayısı ön bilgisi gerektirmeden çalışıyor olsa da eğer kullanıcı sınıf sayısını ya da bir sınıfta bulunması gereken piksel sayısını sınırlamak isterse bunu arayüzde bulunan beş ve altı nolu alanlar ile gerçekleştirebilir.
- 7: Geliştirilen arayüzle görüntüde bulunan bantların ve program tarafından oluşturulan yeni katmanların histogramlarını görüntüleme seçeneği “Show Histograms”, sınıflandırmanın sonucunda etiketlerinde belirlenmesini “Show Labels” alanının işaretlenmesi gerekmektedir. Bu alanın seçilmesi çalışma kapsamında geliştirilen algoritma ile etiketleme gerçekleştirilmektedir.
- 8: Etiketleme işleminde Corine verisinin de kullanıldığı bu çalışmada geliştirilen ikinci yaklaşımla etiketleme gerçekleştirilmektedir.




Şekil 5.7 Sınıflandırma Modülü

9: İşlemlerin durumunu göstermektedir.

10: Kullanıcının görüntü üzerinde bulunan piksellerin değerini görüntüleyebileceği alan

11: Sınıflandırılan görüntü gösterilmektedir.


Bu çalışmada kullanıcı tarafından verilen görüntü bantları kullanılarak veri havuzu genişletilmektedir. Elde edilen bu yeni veri katmanlarında diğer katmanlarda olduğu gibi histogramlar yardımıyla başlangıç sınıfları oluşturulmaktadır. Elde edilen bu sınıflar kullanıcılara Şekil 5.8 de gösterildiği gibi sunulmaktadır. Bu aşama katmanların içerdiği verileri görselleştirerek kullanıcıya sunulmasını sağlamaktadır. Eğer kullanıcının çalıştığı görüntüden sulak alan, kentsel alan vb. gibi öncelikli olarak elde etmek istediği sınıflar bulunuyorsa görselleştirilen katmanlara bu aşamada öncelik verebilmektedir.



Şekil 5.8 Önceliklerin Belirlenmesi

5.3.2 Doğruluk Analizi Arayüzü

Uzaktan algılanmış görüntülerin çeşitli alanlarda kullanılabilmesi için doğru bir şekilde analiz edilmesi gerekmektedir. Bu doğruluğun oranının tespit edilmesi amacıyla farklı yöntemler geliştirilmiştir. Hazırlanmış olan doğruluk analizi arayüzüne literatürde sıklıkla kullanılan yöntemlerden biri olan hata matrisine göre hesaplanan “Genel Doğruluk (Overall Accuracy)” doğruluk ölçütü eklenmiştir. Bu yöntemde analiz edilecek olan görüntü üzerine rassal noktalar üretilir. Görüntü üzerinde bu noktalara karşılık gelen gerçek arazi sınıfları ve sınıflandırma sonucundaki arazi sınıfları karşılaştırılır. Bu doğrultuda hazırlanmış olan doğruluk analizi arayüzü Şekil 5.9 da verilmiştir.




Şekil 5.9 Doğruluk Analizi Sonuç Ekranı

Bu doğrultuda çalışma kapsamında geliştirilen arayüzde kullanıcı şekilde gösterilen bir no’lu alan yardımıyla oluşturulacak olan nokta sayısını tanımlayabilmektedir. Program, belirlenen sayı kadar rassal nokta üretilip görüntü üzerine yerleştirmektedir.

Ayrıca kullanıcının bu noktaları seçip gerçek değerlerini ve sınıflandırma sonucundaki değerlerini tanımlayabilecekleri veri giriş ekranı da bu arayüze eklenmiştir. Şekilde bulunan iki no'lu alan yardımıyla doğruluk analizi gerçekleştirilebilmektedir. Arayüzde bulunan dört ve beş no'lu alanlarda hesaplanan doğruluk oranı, hesaplanan hata matrisi, genel doğruluk oranı ve Kappa Score'u sunulmaktadır. Kullanıcı elde ettiği sonuçları altı no'lu alan yardımıyla kaydedebilmektedir.

5.3.3 Etiketleme Sonuç Arayüzü

Hazırlanmış olan sınıflandırma işlemi ile elde edilen sınıfların etiketlenmesi sonucunda Şekil 5.10'da verilen sonuç haritası hazırlanmaktadır



Şekil 5.10 Etiketleme

Şekilde bulunan birinci alanda, elde edilen sonuç haritası verilmektedir. İkinci alanda sınıflandırma sonucunda elde edilen sınıf sayısı verilmektedir. Üçüncü alanda sonuç haritası için oluşturulan lejant bulunmaktadır. Şekilde işaretlenmiş olan dördüncü bölgede oluşturulan sınıflara atanan etiketleri ve olasılıkları bulunmaktadır. Oluşturulan bu sonuç haritası ve etiketler şekilde bulunan beşinci alanda bulunan kaydetme özelliği ile saklanabilmektedir.

6. BULGULAR


Bu bölümde çalışma dâhilinde geliştirilen sınıflandırma ve etiketlendirme algoritmalarının başarısı farklı çalışma alanlarına ait görüntüler kullanılarak test edilmiştir. Elde edilen sonuç haritaları ve doğruluk analizi sonuçları sınıflandırma ve etiketleme başlıkları altında verilmiştir.

6.1 Sınıflandırma

Sınıflandırma algoritması farklı coğrafi özelliklere sahip olan Sinop, Hatay ve Gemlik bölgelerine ait Sentinel 2 görüntüleri kullanılarak test edilmiştir.

6.1.1 Çalışma Alanı 1: Sinop

Sinop, Türkiye'nin en kuzeyinde bulunmaktadır. Karadeniz iklim özelliklerine ve bitki örtüsüne sahiptir. Bu bölgenin 23/6/2018 tarihli Sentinel 2 uydusuna ait görüntüsünün bantları 10 m çözünürlük elde etmek amacıyla IHS yöntemiyle keskinleştirilmiştir. 10 m çözünürlüklü görüntü geliştirilen algoritma ile sınıflandırılmıştır. Elde edilen sonuç haritası Şekil 6.1'de verilmiştir.



Şekil 6.1 Sinop Bölgesi için Sonuç Haritası a) Uydu görüntüsü b) Önerilen Yöntem

Elde edilen sınıfların doğruluğunu test etmek amacıyla rassal olarak 102 nokta oluşturulmuştur. Bu noktalara karşılık gelen sınıflandırma sonuçları ve gerçek sınıfları belirlendikten sonra Tablo 6.1 de verilen hata matrisi oluşturulmuştur.

Tablo 6.1 Geliştirilmiş algoritma ile elde edilen doğruluk değerleri

	KENT	SU	TOPRAK	Y.ALAN	TOPLAM	ORAN
KENT	23	-	-	1	24	0.96
SU	-	26	-	-	26	1
TOPRAK	2	-	20	4	26	0.77
Y. ALAN	-	-	1	25	26	0.96
TOPLAM	25	26	21	30	102	0.92

Doğruluk analizi sonuçları incelendiğinde, genel doğruluk oranının % 92 olduğu gözlemlenmiştir. Su, yeşil alanlar ve kentsel alanlar yüksek doğrulukla ayrılabilirken toprak alanları %77'lik bir doğruluk elde edilmiştir. Aynı görüntünün ArcGIS yazılımında ISODATA algoritmasıyla 12 sınıf olarak sınıflandırılması ile elde edilmiş sonuç Şekil 6.2'de verilmiştir.




Şekil 6.2 Sonuç Haritası a) Uydu görüntüsü b) ISODATA

Elde edilen bu sonuç için gerçekleştirilen doğruluk analizi sonuçları Tablo 6.2'de verilmiştir.

Tablo 6.2 ISODATA ile elde edilen ile elde edilen doğruluk değerleri

	KENT	SU	TOPRAK	Y.ALAN	TOPLAM	ORAN
KENT	11	-	-	10	21	0.52
SU	-	26	-	-	26	1
TOPRAK	4	-	21	4	29	0.72
Y.ALAN	1	1	2	22	26	0.85
TOPLAM	16	26	16	22	102	0.78

Doğruluk analizi sonuçları incelendiğinde genel doğruluk oranının % 78 olduğu gözlemlenmiştir. Su ve yeşil alanların sınıflandırılmasında %85 ve üstü bir doğruluk elde edilirken diğer sınıfların belirlenmesinde elde edilen doğruluk % 72 yi geçememiştir. Aynı görüntünün KNIME yazılımında Fuzzy C-Means algoritmasıyla 12 sınıf olarak sınıflandırılması ile elde edilmiş sonuç Şekil 6.3'te verilmiştir.




Şekil 6.3 Sonuç Haritası a) Uydu görüntüsü b) Fuzzy C-Means

Elde edilen bu sonuç için gerçekleştirilen doğruluk analizi sonuçları Tablo 6.3'te verilmiştir.

Tablo 6.3. Fuzzy C-Means ile elde edilen ile elde edilen doğruluk değerleri

	KENT	TOPRAK	ORMAN	Y.ALAN	SU	TOPLAM	ORAN
KENT	21	-	-	-	-	21	0.52
TOPRAK	4	21	1	-	-	29	0.72
ORMAN	-	-	-	-	-	0	0
Y.ALAN	5	7	16	-	-	26	0.88
SU	-	-	-	-	26	26	1
TOPLAM	16	23	33	-	26	102	0.77

Doğruluk analizi sonuçları incelendiğinde genel doğruluk oranının % 77 olduğu gözlemlenmiştir. Su ve yeşil alanların sınıflandırılmasında %88 ve üstü bir doğruluk elde edilirken diğer sınıfların belirlenmesinde elde edilen doğruluk % 72'yi geçememiştir. Aynı görüntünün Weka yazılımında SOM algoritmasıyla sınıflandırılması ile elde edilmiş sonuç Şekil 6.4'te verilmiştir.



Şekil 6.4 Sonuç Haritası a) Uydu görüntüsü b) SOM

Elde edilen bu sonuç için gerçekleştirilen doğruluk analizi sonuçları Tablo 6.4'te verilmiştir.

Tablo 6.4 SOM ile elde edilen ile elde edilen doğruluk değerleri

	KENT	TOPRAK	SU	Y.ALAN	TOPLAM	ORAN
KENT	21	-	-	-	21	1
TOPRAK	18	-	-	11	29	0
SU	-	-	26	-	26	1
Y.ALAN	2	-	-	24	24	1
TOPLAM	41	0	26	35	102	0.71

Diğer yöntemlerin aksine SOM algoritması sınıf sayısı parametresini kullanıcıdan almaz. Bunun yerine kullanıcıdan aldığı yükseklik ve öğrenme oranı gibi diğer parametrelerle sınıflandırma yapar. Dolayısıyla sınıf sayısını otomatik olarak hesaplar. Bu özelliğinden dolayı Sinop bölgesine ait görüntünün sınıflandırılması sonucunda üç sınıf elde edilmiştir. Toprak ve nadas alanları hiç belirlenememiş, genel doğruluk oranı ise % 71 olarak elde edilmiştir.

6.1.2 Çalışma Alanı 2: Hatay

Geliştirilen algoritmanın en önemli farklılıklarından biri kullanıcılara çalışma hedefine bağlı olarak orman, tarım, bitki deseni, kentsel alan gibi belirli bir ya da birkaç spektral sınıf üzerine yoğunlaşarak sadece bu sınıflarda hassas ve yüksek doğruluklu sonuçlar elde etme olanağı da sağlamasıdır. Bu doğrultuda ikinci çalışma alanı olarak yoğun kentsel bölgelerin bulunduğu bir alan olan Hatay bölgesi seçilmiştir. Hatay, Türkiye'nin güneyinde bulunan Akdeniz iklimine ve bitki örtüsüne sahiptir. Sentinel 2'ye ait görüntü 10 m mekânsal çözünürlüğe keskinleştirilmiş ve geliştirilen algoritma ile sınıflandırılmıştır. Elde edilen sonuç Şekil 6.5'te verilmiştir.




Şekil 6.5 Sonuç Haritası a) Uydu görüntüsü b) Önerilen Yöntem

Sınıflandırma doğruluğunun test edilmesi amacıyla sınıflandırmanın üretici ve genel doğruluk oranları hesaplanmıştır. Geliştirilen algoritma ile elde edilen sonuçların doğruluk analizi sonuçları Tablo 6.5'te verilmiştir.

Tablo 6.5 Geliştirilen Algoritma ile elde edilen doğruluk değerleri

	KENT	SU	TOPRAK	Y. ALAN	TOPLAM	ORAN
KENT	36	-	4	2	42	0.86
SU	1	8	-	1	10	0.80
TOPRAK	1	-	17	1	19	0.9
Y. ALAN	-	-	4	25	29	0.86
TOPLAM	38	8	25	29	100	0.86

Elde edilen sonuçlar incelendiğinde genel doğruluk oranının %86 olduğu görülmektedir. Bu uygulamada özellikle kentsel bölgelerin yoğun olduğu bir alan seçilmiştir. Bu bölge spektral yansıma değerleri çok yakın olan kentsel alanlar ile toprak alanların iç içe olduğu karmaşık bir yapı içermektedir. Sonuçlar bu anlamda incelendiğinde toprak alanların ve kentsel alanların birbirinden başarıyla ayrılabilirdiği gözlemlenmiştir. Sonuçların literatürde bulunan algoritmalarla karşılaştırılması amacıyla aynı görüntü ISODATA ile sınıflandırılmıştır. Elde edilen sonuç haritası Şekil 6.6’da verilmiştir.




Şekil 6.6 Sonuç Haritası a) Uydu Görüntüsü b) ISODATA

Sınıflandırma doğruluğunun test edilmesi amacıyla bir önceki sonucu değerlendirmek için hazırlanmış olan rassal noktalar kullanılarak “Overall Accuracy” yöntemi uygulanmıştır. Elde edilen sonuç Tablo 6.6’da verilmiştir.

Tablo 6.6 ISODATA ile elde edilen ile elde edilen doğruluk değerleri

	KENT	SU	TOPRAK	Y. ALAN	TOPLAM	ORAN
KENT	33	-	5	2	42	0.75
SU	2	8	-	-	10	0.80
TOPRAK	4	-	3	12	19	0.11
Y. ALAN	8	-	1	20	29	0.68
TOPLAM	47	8	9	34	100	0.62

Elde edilen sonuçlar incelendiğinde ISODATA ile % 62’lik bir genel doğruluk oranı elde edilmiştir. Bu uygulamada kentsel bölgelerin çıkarılması hedeflendiğinden sonuçlar bu doğrultuda incelendiğinde kentsel alanlarda % 75 lik bir doğruluk elde edildiği görülmüştür. Aynı görüntü Fuzzy C-Means ile sınıflandırıldığında elde edilen sonuç Şekil 6.7’de verilmiştir.




Şekil 6.7 Sonuç Haritası a) Uydu Görüntüsü b) Fuzzy C Means

Sınıflandırma doğruluğunun test edilmesi amacıyla bir önceki sonucu değerlendirmek için hazırlanmış olan rassal noktalar kullanılarak Overall Accuracy yöntemi uygulanmıştır. Elde edilen sonuç Tablo 6.7’te verilmiştir.

Tablo 6.7 Fuzzy C-Means ile elde edilen ile elde edilen doğruluk değerleri

SINIFLAR	KENT	SU	TOPRAK	Y. ALAN	TOPLAM	ORAN
KENT	7	-	6	29	42	0.16
SU	1	8	-	1	10	0.8
TOPRAK	4	-	8	7	19	0.44
Y. ALAN	-	-	5	24	29	0.82
TOPLAM	12	8	19	61	100	0.46

Elde edilen sonuçlar incelendiğinde Fuzzy C-Means ile % 46’lık bir genel doğruluk oranı elde edildiği görülmüştür. Bu uygulamada kentsel bölgelerin çıkarılması hedeflendiğinden sonuçlar bu doğrultuda incelendiğinde kentsel alanlarda %16’lık bir doğruluk elde edildiği görülmüştür. Aynı görüntü SOM ile sınıflandırıldığında elde edilen sonuç Şekil 6.8’de verilmiştir.



Şekil 6.8 Sonuç Haritası a) Uydu Görüntüsü b) SOM

Sınıflandırma doğruluğunun test edilmesi amacıyla bir önceki sonucu değerlendirmek için hazırlanmış olan rassal noktalar kullanılarak Overall Accuracy yöntemi uygulanmıştır. Elde edilen sonuç Tablo 6.8’te verilmiştir.


Tablo 6.8 SOM ile elde edilen ile elde edilen doğruluk değerleri

SINIFLAR	KENT	SU	TOPRAK	Y. ALAN	TOPLAM	ORAN
KENT	25	15	4	-	44	0.57
SU	-	10	-	-	10	1
TOPRAK	5	2	11	-	18	0.61
Y. ALAN	13	12	3	-	28	0
TOPLAM	43	39	18	0	100	0.46

Elde edilen sonuçlar incelendiğinde SOM ile % 46’lık bir genel doğruluk oranı elde edildiği görülmüştür. Bu uygulamada kentsel bölgelerin çıkarılması hedeflendiğinden sonuçlar bu doğrultuda incelendiğinde kentsel alanlarda %57’lik bir doğruluk elde edildiği görülmüştür.

6.1.3 Çalışma Alanı 3: Gemlik

Geliştirilen algoritmanın test edilmesi amacıyla seçilen alanlardan bir diğeri Gemlik bölgesidir. Bursa ili sınırları içerisinde bulunan Gemlik bölgesinin batısında Marmara Denizi yer alır. Bölgede bulunan bitki örtüsü zeytinlikler, tarım arazileri ve meralardan oluşmaktadır. Bu çalışma bölgesinin seçilmesindeki amaç ise algoritmanın Kent ve Yeşil alanları çıkarmadaki başarısının test edilmesidir. Seçilen bölgenin Sentinel 2 uydusuna ait görüntüsünün bantları 10 m çözünürlük elde etmek amacıyla IHS yöntemiyle keskinleştirilmiştir. 10 m çözünürlüklü görüntü geliştirilen algoritma ile sınıflandırılmıştır. Elde edilen sonuçlar Şekil 6.9’da verilmiştir.




Şekil 6.9 Sonuç Haritası a) Uydu Görüntüsü b) Önerilen Algoritma

Sınıflandırma doğruluğunun test edilmesi amacıyla Overall Accuracy yöntemi uygulanmıştır. Geliştirilen algoritma ile elde edilen sonuç Tablo 6.9’da verilmiştir.

Tablo 6.9 Geliştirilen Algoritma için doğruluk analizi sonuçları

SINIFLAR	KENT	SU	TOPRAK	Y. ALAN	TOPLAM	ORAN
KENT	43	-	-	-	43	1
SU	-	6	-	-	6	1
TOPRAK	3	-	3	-	6	0.5
Y. ALAN	-	-	-	45	45	1
TOPLAM	46	6	3	45	100	0.97

Elde edilen sonuçlar incelendiğinde geliştirilen algoritma ile % 97’lik bir genel doğruluk oranı elde edildiği görülmüştür. Bu uygulamada yeşil alanlar ile kentsel bölgelerin çıkarılması hedeflendiğinden sonuçlar bu doğrultuda incelendiğinde yeşil alanların ve kentsel alanların tamamının başarıyla çıkarılabildiği gözlemlenmiştir. Aynı görüntü ISO_DATA ile sınıflandırıldığında elde edilen sonuç Şekil 6.10’da verilmiştir.



Şekil 6.10 Sonuç Haritası a) Uydu Görüntüsü b) ISODATA


ISODATA ile elde edilen sınıflandırma sonuçlarının doğruluğunun test edilmesi amacıyla Overall Accuracy yöntemi uygulanmıştır. Bu amaçla bir önceki sonucu

değerlendirmek için hazırlanmış olan rassal noktalar kullanılmıştır. Sonuçlar Tablo 6.10’de verilmiştir.

Tablo 6.10 ISODATA için doğruluk analizi sonuçları

SINIFLAR	KENT	SU	TOPRAK	Y. ALAN	TOPLAM	ORAN
KENT	43	-	-	-	43	1
SU	-	6	-	-	6	1
TOPRAK	4	1	1	-	6	0.17
Y. ALAN	2	32	-	11	45	0.24
TOPLAM	49	39	1	11	100	0.61

Elde edilen sonuçlar incelendiğinde ISODATA algoritması ile % 61’lik bir genel doğruluk oranı elde edildiği görülmüştür. Bu uygulamada yeşil alanlar ile kentsel bölgelerin çıkarılması hedeflendiğinden sonuçlar bu doğrultuda incelendiğinde kentsel alanların tamamı çıkarılmışken yeşil alanlarda bu oran % 24 civarında kalmıştır. Aynı görüntü Fuzzy C-Means ile sınıflandırıldığında elde edilen sonuç Şekil 6.11’de verilmiştir.




Şekil 6.11 Sonuç Haritası a) Uydu Görüntüsü b) Fuzzy C- Means

Elde edilen sınıflandırma sonuçlarının doğruluğunun test edilmesi amacıyla Overall Accuracy yöntemi uygulanmıştır. Bu amaçla bir önceki sonucu değerlendirmek için hazırlanmış olan rassal noktalar kullanılmıştır. Sonuçlar Tablo 6.11’de verilmiştir.

Tablo 6.11 Fuzzy C- Means için doğruluk analizi sonuçları

SINIFLAR	KENT	SU	TOPRAK	Y. ALAN	TOPLAM	ORAN
KENT	10	34	-	-	44	0.23
SU	-	6	-	-	6	1
TOPRAK	3	1	2	-	6	0
Y. ALAN	-	6	38	-	44	0.86
TOPLAM	13	47	40	0	100	0.54

Elde edilen sonuçlar incelendiğinde Fuzzy C Means algoritması ile % 54'lük bir genel doğruluk oranı elde edildiği görülmüştür. Bu uygulamada yeşil alanlar ile kentsel bölgelerin çıkarılması hedeflendiğinden sonuçlar bu doğrultuda incelendiğinde kentsel alanların çıkarılmasının başarı oranının %23 yeşil alanlarda ise % 86 olduğu görülmüştür. Aynı görüntü SOM ile sınıflandırıldığında elde edilen sonuç Şekil 6.12'de verilmiştir.



Şekil 6.12 Sonuç Haritası a) Uydu Görüntüsü b) SOM

Elde edilen sınıflandırma sonuçlarının doğruluğunun test edilmesi amacıyla Overall Accuracy yöntemi uygulanmıştır. Bu amaçla bir önceki sonucu değerlendirmek için hazırlanmış olan rassal noktalar kullanılmıştır. Sonuçlar Tablo 6.12’de verilmiştir.

Tablo 6.12. *SOM için doğruluk analizi sonuçları*

SINIFLAR	KENT	SU	TOPRAK	Y. ALAN	TOPLAM	ORAN
KENT	38	6	-	-	44	0.86
SU	-	6	-	-	6	1
TOPRAK	3	3	-	-	6	0
Y. ALAN	1	26	-	17	44	0.39
TOPLAM	42	41	0	17	100	0.61

Elde edilen sonuçlar incelendiğinde SOM ile % 61’lik bir genel doğruluk oranı elde edildiği görülmüştür. Bu uygulamada yeşil alanlar ile kentsel bölgelerin çıkarılması hedeflendiğinden sonuçlar bu doğrultuda incelendiğinde kentsel alanların çıkarılmasında elde edilen başarı oranının %86 yeşil alanlarda ise % 39 olduğu görülmüştür

6.2 Etiketleme


Sınıflandırma sonuçlarının otomatik olarak etiketlenilmesi amacıyla geliştirilen yaklaşımlar farklı coğrafi bölgelere ait görüntülerle test edilmiştir. Bu doğrultuda Sinop, Hatay, Gemlik bölgelerine ait Sentinel 2 görüntüleri elde edilmiştir. Bu görüntülerin mekânsal çözünürlüğü IHS yöntemiyle 10 m’ye yükseltilmiştir.

6.2.1 Geliştirilen Yöntem

Çalışma kapsamında geliştirilen etiketleme algoritması Gemlik, Sinop ve Hatay bölgelerinde test edilmiştir. Çalışma kapsamında başlangıç olarak ‘toprak’, ‘yeşil tarım alanı’, ‘orman’, ‘kentsel alanlar’ ve ‘ekilmemiş tarım alanları’ nın etiketlenmesi hedeflenmiştir.

6.2.1.1 Sinop Çalışma Alanı

Sinop bölgesine ait görüntüde bulunan sınıfların geliştirilen etiketlenilme algoritması ile belirlendiğinde elde edilen sonuç Şekil 6.13’te verilmiştir.



Şekil 6.13 Etiketleme Sonucu a) Uydu Görüntüsü b) Etiketleme Sonucu

Elde edilen sonuca uygulanan doğruluk analizi ile elde edilen doğruluk oranları Tablo 6.13’de verilmiştir.


Tablo 6.13 Geliştirilen Yöntem için doğruluk analizi sonuçları

SINIFLAR	KENT	NADAS	ORMAN	SU	YEŞİL TARIM ALANI	TOPLAM	ORAN
KENT	22	1	-	-	-	23	0.96
NADAS	9	16	1	-	1	27	0.6
ORMAN	-	-	22	-	1	23	0.96
SU	-	-	-	26	-	26	1
YEŞİL TARIM ALANI	-	-	-	-	3	3	1
TOPLAM	31	17	23	26	5	102	0.87

Doğruluk analizi sonuçları incelendiğinde genel olarak başarılı sonuçlar elde edilmiş olduğu görülmektedir. Su ve kentsel alanlar yüksek doğrulukla ayrılabilirken nadas bırakılmış olan alanların kentsel alanlarla karıştırıldığı gözlemlenmiştir. Bunun yanında orman ve yeşil tarım alanlarının başarıyla etiketlendiği gözlemlenmiştir.

6.2.1.2 Gemlik Çalışma Alanı

Geliştirilen etiketleme yaklaşımının test edilmesi amacıyla Gemlik bölgesine ait görüntüde bulunan sınıfların geliştirilen etiketlendirilme algoritması ile belirlendiğinde elde edilen sonuç Şekil 6.14’te verilmiştir.



Şekil 6.14 Etiketleme Sonucu a) Uydu Görüntüsü b) Etiketleme Sonucu

Elde edilen sonuca uygulanan doğruluk analizi ile elde edilen doğruluk oranları Tablo 6.14’te verilmiştir.


Tablo 6.14. *Geliştirilen Yöntem için doğruluk analizi sonuçları*

SINIF	KENT	NADAS	ORMAN	SU	TOPRAK	Y. ALAN	Y. TARIM ALANI	TOPLAM	ORAN
KENT	42	-	-	-	-	-	-	42	1
NADAS	-	-	-	-	-	-	-	0	0
ORMAN	-	38	-	-	-	-	-	38	1
SU	-	-	7	-	-	-	-	7	1
TOPRAK	3	-	-	-	-	-	-	3	0
Y. ALAN	-	6	-	1	-	-	3	10	0.3
Y. TARIM ALANI	-	-	-	-	-	-	-	0	0
TOPLAM	45	44	7	1	0	0	3	90	0.90

Doğruluk analizi sonuçları incelendiğinde genel doğruluk oranının % 90 olduğu görülmektedir. Su ve kentsel alanlar yüksek doğrulukla ayrılabilirken toprak alanların ve orman alan dışında kalan yeşil alanların belirlenememiş olduğu gözlemlenmiştir.

6.2.1.3 Hatay Çalışma Alanı

Hatay bölgesine ait görüntüde bulunan sınıfların geliştirilen etiketlendirilme algoritması ile belirlendiğinde elde edilen sonuç Şekil 6.15’de verilmiştir.



Şekil 6.15 Etiketleme Sonucu a) Uydu Görüntüsü b) Etiketleme Sonucu

Elde edilen sonuca uygulanan doğruluk analizi ile elde edilen doğruluk oranları Tablo 6.15’te verilmiştir.

Tablo 6.15 Hatay Bölgesi Hata Matrisi

SINIFLAR	KENT	NADAS	ORMAN	SU	TOPRAK	Y. ALAN	Y. TARIM ALANI	TOPLAM	ORAN
KENT	52	3	-	-	1	-	-	56	0.93
NADAS	-	7	-	-	-	-	-	7	1
ORMAN	-	1	3	-	-	-	4	8	0.38
SU	-	-	-	9	-	-	-	9	1
TOPRAK	2	1	-	-	-	-	-	3	0
Y.ALAN	-	-	-	-	-	-	2	2	0
Y. TARIM ALANI	-	5	5	-	-	-	5	15	0.33
TOPLAM	54	17	8	9	1	0	11	100	0.76


Doğruluk analizi sonuçları incelendiğinde su, kentsel alanların ve orman alanlarının belirlenmesinde genel olarak başarılı sonuçlar elde edilmiş olduğu görülmektedir. Ancak bölgede bulunan çıplak toprak alanlarının kentsel alanlarla karıştığı gözlemlenmiştir. Bunun yanında birbirine çok yakın spektral yansımalar içeren yeşil boş arazilerle ormanlık alanların ayrıştırılmasında problemler olduğu görülmektedir.

6.2.2 Geliştirilen Yöntem ve Corine Verilerinin Birlikte Kullanılması

Sınıflandırılmış verilerin etiketlerini belirlenmesi için geliştirilen ikinci yaklaşım, spektral yansıma değerlerinin benzer olduğu yeşil tarım alanı/ orman ve nadas/ toprak alanı sınıflarında Corine verisinden yararlanmaktır. Bu doğrultuda geliştirilen algoritma Sinop, Gemlik ve Hatay bölgelerine ait görüntüler kullanılarak test edilmiştir. Bu görüntüler etiketleme algoritmasının test edildiği görüntülerle aynı görüntüler olup, doğruluk analizi için kullanılan yöntemde ve bu amaçla kullanılan rassal oluşturulmuş nokta /nokta değerlerinde bir değişiklik yapılmamıştır.

6.2.2.1 Sinop Çalışma Alanı

Sinop bölgesine ait sınıflandırılmış görüntünün etiketlendirmesi amacıyla kullanılan bölgeye ait Corine arazi sınıfları Şekil 6.16’da verilmiştir.



Şekil 6.16 Sinop Bölgesi a) Uydu Görüntüsü b) Corine Sınıfları


Çalışma alanını kapsayan Corine sınıfları 100 m mekânsal çözünürlüklü olarak hazırlanmıştır. Corine sınıflarının daha yüksek çözünürlüklü görüntülerin analizlerinde kullanılabilirliğini incelemek amacıyla “Over All “ doğruluk analizi gerçekleştirilmiştir. Elde edilen sonuçlar Tablo 6.16’da verilmiştir.

Tablo 6.16 Corine Sınıflarına uygulanan doğruluk analizi sonuçları

SINIF	KENT	NADAS	ORMAN	SU	TARIM	YEŞİL TARIM ALANI	TOPLAM	ORAN
KENT	16	-	1	2	5	-	24	0.67
NADAS	1	-	-	-	25	-	26	0.96
ORMAN	2	-	13	-	7	-	22	0.59
SU	-	-	-	26	-	-	26	1
TARIM	-	-	-	-	-	-	0	0
YEŞİL TARIM ALANI	-	-	-	-	4	-	4	1
TOPLAM	19	0	14	28	41	0	102	0.84

Doğruluk analizi gerçekleştirilirken, diğer etiketleme algoritmasını test etmek amacıyla hazırlanmış olan noktalar ve bu noktaların gerçek değerleri kullanılmıştır. Elde edilen sonuçlar incelendiğinde tarım ve su sınıflarında %100 ‘e yakın doğrulukla etiketlerin oluşturulduğu görülmektedir. Bunun yanında etiketleme doğruluğunda en az doğruluğun orman alanları ve kentsel bölgelerde elde edildiği görülmüştür.

Sinop bölgesine ait görüntüde bulunan sınıfların geliştirilen etiketlendirilme algoritması ve Corine arazi örtüsü sınıfları birlikte kullanıldığında elde edilen sonuç Şekil 6.17’de verilmiştir.



Şekil 6.17 Etiketleme Sonucu a) Uydu Görüntüsü b) Etiketleme Sonucu

Uygulanan doğruluk analizi sonucunda elde edilen doğruluk analizi sonuçları Tablo 6.17’de verilmiştir


Tablo 6.17 Sinop Bölgesi Hata Matrisi

SINIFLAR	KENT	NADAS	ORMAN	SU	Y. TARIM ALANI	TOPLAM	ORAN
KENT	19	5	-	-	-	24	0.79
NADAS	1	25	-	-	-	26	0.96
ORMAN	-	-	12	-	10	22	0.55
SU	-	-	-	26	-	26	1
Y. TARIM ALANI	-	1	-	-	3	4	0.75
TOPLAM	20	31	12	26	10	102	0.83

Elde edilen sonuçlar incelendiğinde % 83 oranında genel doğruluk elde edildiği görülmüştür. Corine arazi sınıflarının etiketleme algoritması ile birlikte kullanımının nadas alanlarının kentsel alanlardan ayrımını kolaylaştırdığı gözlemlenmiştir.

6.2.2.2 Gemlik Çalışma Alanı

Gemlik bölgesine ait sınıflandırılmış görüntünün etiketlendirmesi amacıyla kullanılan bölgeye ait Corine arazi sınıfları Şekil 6.18’de verilmiştir.



Şekil 6.18 Gemlik Bölgesi a) Uydu Görüntüsü b) Corine Sınıfları


Çalışma alanını kapsayan Corine sınıflarına uygulanan “Over all “ doğruluk analizi sonuçları Tablo 6.18’de verilmiştir.

Tablo 6.18 Corine Sınıflarına uygulanan doğruluk analizi sonuçları

SINIFLAR	KENT	ORMAN	SU	TARIM	TOPRAK	YEŞİL ALAN	TOPLAM	ORAN
KENT	29	8	1	4	-	-	42	0.69
ORMAN	-	38	-	-	-	-	38	1
SU	-	-	7	-	-	-	7	1
TARIM	-	-	-	-	-	-	0	0
TOPRAK	2	1	-	-	-	-	3	0
YEŞİL ALAN	4	2	-	4	-	-	10	0

GENEL TOPLAM	35	49	8	8	0	0	100	0.74
-----------------	----	----	---	---	---	---	-----	-------------

Gemlik bölgesine ait görüntüde bulunan sınıfların geliştirilen etiketlendirilme algoritması ile Corine arazi sınıflarını birlikte kullanarak elde edilen sonuç haritası Şekil 6.19’da verilmiştir.



Şekil 6.19 Etiketleme Sonucu a) Uydu Görüntüsü b) Etiketleme Sonucu

Elde edilen sonuca uygulanan doğruluk analizi ile elde edilen doğruluk oranları Tablo 6.19’da verilmiştir


Tablo 6.19 Gemlik Bölgesi Hata Matrisi

SINIFLAR	KENT	NADAS	ORMAN	SU	YEŞİL TARIM ALANI	TOPRAK	YEŞİL ALAN	TOPLAM	ORAN
KENT	39	-	-	3	-	-	-	42	0.93
NADAS	-	-	-	-	-	-	-	0	0
ORMAN	-	38	-	-	-	-	-	38	1
SU	-	-	7	-	-	-	-	7	1
YEŞİL TARIM ALANI	-	-	-	-	-	-	-	0	0
TOPRAK	3	-	-	-	-	-	-	3	0
YEŞİL ALAN	1	7	-	-	2	-	-	10	0.2
TOPLAM	43	45	7	3	2	0	0	100	0.86

Doğruluk analizi sonuçları incelendiğinde genel doğruluk oranının % 86 olduğu görülmektedir. Su, orman ve kentsel alanlar yüksek doğrulukla ayrılabilirken toprak alanların ve orman alan dışında kalan yeşil alanların belirlenememiş olduğu gözlemlenmiştir.

6.2.2.3 Hatay Çalışma Alanı

Hatay bölgesine ait sınıflandırılmış görüntünün etiketlendirmesi amacıyla kullanılan bölgeye ait Corine arazi sınıfları Şekil 6.20’de verilmiştir.




Şekil 6.20 Hatay Bölgesi a) Uydu Görüntüsü b) Corine Sınıfları

Çalışma alanını kapsayan Corine arazi sınıflarına uygulanan “Over all “ doğruluk analizi sonuçları Tablo 6.20’de verilmiştir.

Tablo 6.20 Corine Sınıflarına uygulanan doğruluk analizi sonuçları

SINIFLAR	KENT	NADAS	ORMAN	SU	TOPRAK	TARIM	Y. ALAN	Y. TARIM ALANI	TOP.	ORAN
KENT	51	-	-	-	-	2	3	-	56	0.91
NADAS	-	-	-	-	-	7	-	-	7	1
ORMAN	5	-	2	-	-	1	-	-	8	0.25
SU	1	-	-	8	-	-	-	-	9	0.89
TOPRAK	2	-	-	-	-	1	-	-	3	0
TARIM	-	-	-	-	-	-	-	-	0	0
Y.ALAN	2	-	-	-	-	-	-	-	2	0
Y. TARIM ALANI	5	-	-	-	-	7	3	-	15	0.20
TOPLAM	66	0	2	8	0	18	6	0	100	0.71

Hatay bölgesine ait görüntüde bulunan sınıfların geliştirilen etiketlendirilme algoritması ile belirlendiğinde elde edilen sonuç Şekil 6.21’de verilmiştir.



Şekil 6.21 Hatay Bölgesi a) Uydu Görüntüsü b) Etiketleme Sonucu

Elde edilen sonuca uygulanan doğruluk analizi ile elde edilen doğruluk oranları Tablo 6.21’de verilmiştir

Tablo 6.21 *Hatay Bölgesi Etiketleme Doğruluk Analizi*

SINIF	KENT	NADAS	ORMAN	SU	TOPRAK	Y. ALAN	Y. TARIM ALANI	TARIM	TOP.	ORAN
KENT	52	-	3	-	-	1	-	-	56	0.93
NADAS	2	-	5	-	-	-	-	-	7	0.71
ORMAN	-	-	-	2	-	6	-	-	8	0.25
SU	-	-	-	-	-	-	-	9	9	1
TOPRAK	2	-	1	-	-	-	-	-	3	0
Y.ALAN	-	-	1	-	-	1	-	-	2	0
Y. TARIM ALANI	-	-	2	3	-	10	-	-	15	0.67
TARIM	-	-	-	-	-	-	-	-	0	0
TOPLAM	56	0	12	5	0	18	0	9	100.	0.78

Doğruluk analizi sonuçları incelendiğinde genel doğruluk oranının % 78 olduğu görülmektedir. Su, kent ve nadas bırakılmış tarım alanları yüksek doğrulukla ayrılabilirken diğer sınıflarda daha düşük bir başarı elde edildiği gözlemlenmiştir.

7. TARTIŞMA

7.1 Sınıflandırma Algoritması

KontROLSÜZ sınıflandırma yöntemlerinin uydu görüntülerini sınıflandırmak için spektral bantlardaki verilerin yanında eğitim verisi, sınıf sayısı, öğrenme oranı, iterasyon sayısı gibi parametrelerle çalışıyor olması bu yöntemin dezavantajlarından biridir. Çalışılan alanla ilgili ön bilgisi bulunmayan ya da görüntü işleme yöntemleri ile ilgili sınırlı bilgisi olan kullanıcıların en yüksek doğruluğu sağlayacak sınıflandırma parametrelerini bilmesi zordur. En doğru sonucun bulunabilmesi için pek çok deneme yapılması gerekmektedir.

Bu çalışmada eğitim verisi, sınıf sayısı, iterasyon sayısı, durma kriteri gibi ön bilgiler olmadan verileri otomatik olarak sınıflandıran bir algoritma geliştirilmiştir. Bu doğrultuda spektral bantlardaki değerler kullanılarak veri havuzunu genişleten ve bu verileri kalite indisleri doğrultusunda optimize eden bir yaklaşım geliştirilmiştir. Önerilen bu algoritma ile elde edilen sonuçlara uygulanan doğruluk analizi çıktıları literatürde sıklıkla kullanılan algoritmalarla elde edilen sonuçlarla karşılaştırılmıştır.

Çalışma alanlarından biri olan Sinop bölgesinde önerilen yöntemle elde edilen genel doğruluk oranı %92 olarak elde edilmiştir. Yapılan uygulamada elde edilen sınıflardan kent, yeşil alan ve su alanları %90'ın üstünde bir doğrulukla belirlenmiştir. Aynı görüntü ISODATA, Fuzzy C Means ve SOM yöntemleriyle sınıflandırıldığında genel doğruluğun % 80' in altında kaldığı gözlemlenmiştir.

Bir diğer çalışma alanı olan Hatay bölgesidir. Bu bölgede önerilen yöntemle elde edilen sınıflandırma sonuçlarının genel doğruluğu % 86 olarak hesaplanmıştır. Aynı görüntü diğer yöntemlerle sınıflandırıldığında elde edilen en yüksek genel doğruluğun % 62 olduğu gözlemlenmiştir. Bu bölgenin seçilmesindeki amaç kentsel alanların sınıflandırılmasında yöntemin başarısının test edilmesidir. Bu doğrultuda sonuçlar değerlendirildiğinde önerilen yöntemle kentsel alanlar % 86'lık bir doğrulukla sınıflandırılırken diğer yöntemlerde bu oran % 75'in üzerine çıkamamıştır.

Son çalışma alanı olan Gemlik bölgesinde önerilen yöntem ile %97 oranında bir genel doğruluk elde edilmiştir. Bu bölgenin çalışma bölgesi olarak seçilmesinin amacı yeşil alan ve kentsel alanların belirlenmesi olduğundan sonuçlar bu doğrultuda incelendiğinde önerilen yöntemle bu alanların başarılı bir şekilde çıkarıldığı görülmüştür. Diğer yöntemlerle elde edilen başarı oranları incelendiğinde bu alanların her ikisinin de

başarılı bir şekilde sınıflandırıldığı bir sonuç bulunmamaktadır. Bu durum, algoritmanın kullanıcının belirli alanları en iyi çıkaran katmanlara verdiği öncelikle sınıflandırma yapabilme özelliğinin bir sonucudur.

Bu bölgedeki sonuçlarda tespit edilen bir diğer durumda alansal olarak çok küçük olan toprak alanların belirlenme oranının genel olarak çok düşük olmasıdır (Şekil 7.1). Toprak alanlar önerilen algoritma ile % 50 doğrulukla belirlenmiştir. Diğer yöntemlerin toprak alanları sınıflandırma doğruluğu incelendiğinde ISO_DATA ile %17, diğer yöntemlerle %0 lık bir doğruluk elde edildiği belirlenmiştir.



Şekil 7.1 Gemlik Bölgesindeki Toprak Alanlar

Farklı çalışma alanlarında gerçekleştirilen uygulamalarda kullanılan SOM dışındaki tüm algoritmalar işlem yinleme sayısı, oluşturulacak sınıf sayısı gibi parametreler gerektirmektedir. SOM algoritmasının, sınıf sayısı parametresini kullanmadan sonuç üretiyor olması açısından uygulamalarda özellikle tercih edilmiştir. Bu çalışmada geliştirilen algoritma ile elde edilen doğruluk analizi sonuçları SOM ile karşılaştırıldığında, geliştirilen algoritmanın tüm çalışma alanlarında çok daha yüksek doğruluklu sonuçlar ürettiği görülmüştür.

7.2 Etiketleme

Kontrolsüz sınıflandırma yöntemleriyle elde edilen sonuçlarda sınıf etiketlerinin üretilmiyor olması, sonuçların kullanıcılar tarafından yorumlanması zorunluluğunu getirmektedir. Bu durum çalışılan alanla ilgili detaylı bilgi birikimi gerektirmektedir. Ayrıca kullanıcıya olan bağımlılığı arttırmaktadır.

Bu çalışmada kontrolsüz sınıflandırma yöntemleriyle sınıflandırılmış olan verilerin otomatik olarak etiketlenmesi amacıyla bir yaklaşım önerilmiştir. Bu doğrultuda çalışmada öncelikli olarak Sentinel 2 görüntüleri kullanılarak yeşil tarım alanı, orman, nadas, kent ve su sınıflarının belirlenmesi hedeflenmiştir. Çalışmada öncelikle spektral indislerin arazi örtüsü sınıfları için zamansal ve coğrafi değişimi incelenmiştir. Bu analizler sonucunda sınıfların belirlenmesi için eşik değerler belirlenmiştir. Elde edilen eşik değerler ve geliştirilen algoritma üç farklı çalışma alanında test edilmiştir.

Çalışma alanlarından biri olan Sinop'ta geliştirilen yöntem ile elde edilen sonucun genel doğruluk oranı %87 olarak elde edilmiştir. Etiketlenen sınıflar incelendiğinde bu bölgede yer alan nadas alanlarının % 60 lık bir doğrulukla etiketlenebildiği görülmüştür. Bunun nedeni nadas bırakılan alanların spektral yansıma değeri çok yakın olan kentsel alanlarla karıştırıldığı tespit edilmiştir.

İkinci çalışma alanı olan Gemlik bölgesinde gerçekleştirilen etiketlemenin sonucunda elde edilen genel doğruluk oranının %90 olduğu görülmüştür. Bu bölgede sınıflar incelendiğinde toprak alanlarının ve yeşil alanların doğruluk oranlarının % 30 ve altı olduğu görülmüştür. Benzer bir durum son çalışma alanı olan Hatay'da da belirlenmiştir. Genel doğruluk oranı %76 iken spektral yansımaları yakın olan sınıflarda bu oran düşmektedir. Bu problemin giderilebilmesi için etiketleme yaklaşımına Corine arazi sınıfları dâhil edilmiştir. Bu yaklaşımla spektral yansıma değerleri benzer olan kent/ toprak/ nadas gibi sınıfların doğruluğunda artış gözlemlenmiştir. Ancak elde edilen genel doğruluğun ilk sonuçlara göre daha düşük olduğu gözlemlenmiştir. Bunun sebebi Corine arazi sınıflarının mekânsal çözünürlüğünün çok düşük olmasıdır. Örneğin Corine sınıflarında kent merkezinde bulunan küçük park alanları, yeşil alanlar ayrılarak belirtilmemiştir. Ya da geniş orman alanındaki küçük ve seyrek görülen tarlalar belirtilmemiş bu alan olduğu gibi orman olarak tanımlanmıştır.

Elde edilen sonuçlar genel olarak değerlendirildiğinde önerilen yaklaşımın hedef sınıfların belirlenmesinde etkili sonuçlar ortaya çıkardığı gözlemlenmektedir. Bu da

spektral indislerin arazi sınıflarının etiketlenmesi konusunda kullanılabileceğini ortaya koymaktadır. Ayrıca spektral indislerin değişimini incelemek amacıyla kullanılan bölgelerin genişletilmesi ve zamansal olarak daha geniş bir aralık kullanılmasının doğruluk oranlarını ve hedef sınıf çeşitliliğini arttıracakı düşünülmektedir.



8. SONUÇ VE ÖNERİLER

8.1 Sınıflandırma

Uzaktan algılama teknolojilerinin hızlı gelişimi, kullanıcıların veri analizi noktasında güçlü ve etkili alternatifler geliştirmenin yollarını aramasına yol açmıştır. Uydu görüntülerinden tematik haritaların üretimi için kullanılan sınıflandırma yaklaşımlarından biri kontrolsüz sınıflandırma yöntemleridir. Özellikle eğitim verisi gerektirmediğinden kullanıcıya olan bağımlılığın azalması bu yöntemleri avantajlı hale getirmektedir. Ancak yine de sınıflandırma bilgisi olmayan ya da alanla ilgili önbilgisi olmayan kullanıcılardan sınıf sayısı, iterasyon sayısı gibi önbilgiler istemesi ve genellikle düşük başarı oranları ile çalışması kontrolsüz sınıflandırma yöntemlerinin dezavantajları olarak sayılabilmektedir.

Bu çalışmada uydu görüntülerini otomatik olarak sınıflandırılması amacıyla yeni bir sınıflandırma yöntemi geliştirilmiştir. Bu yöntemde temel yaklaşım, kullanıcının sağladığı görüntüde bulunan verilerin analiz edilmesi, yeni bilgiler üretilmesi ve bu verilerden elde edilen sınıfların optimize edilmesine yöneliktir. Bu doğrultuda görüntüde bulunan spektral bantlardaki verilerden spektral indisler, görüntü filtreleri ve boyut indirgeme yöntemleri yardımıyla yeni veriler üretilmektedir. Yöntem bu sayede kullanıcıdan sınıf sayısı, iterasyon sayısı vb. gibi ön bilgi istemeden tam otomatik olarak sınıflandırma yapabilmektedir. Önerilen yöntemin bir diğer avantajı, kullanıcıya hedeflediği sınıflar bazında daha hassas çalışma imkânı sağlamaktadır. Örneğin kullanıcı bitki ürün deseni üzerinde çalışıyorsa ya da sulak alanların çıkarılmasını hedefliyorsa yöntemin ürettiği yeni verilere ağırlık vererek hedefine uygun sınıflandırma yapılmasını sağlayabilmektedir.

Geliştirilmiş olan bu yöntem Türkiye’de bulunan üç farklı çalışma alanında test edilmiştir. Bu çalışma alanları farklı nitelikteki coğrafi ve spektral verileri içermeleri nedeniyle seçilmiştir. Elde edilen tüm sonuçlar Tablo 8.1’de verilmiştir.

Tablo 8.1. Sınıflandırma İşlem Sonuçları

ÇALIŞMA ALANI	SINIFLAR	YÖNTEM			
		ÖNERİLEN YÖNTEM	ISODATA	FUZZY-CMEANS	SOM
SINOP	KENT	0.96	0.52	0.52	1
	SU	1	1	0.72	0
	TOPRAK	0.77	0.72	0.88	1
	YEŞİL ALAN	0.96	0.85	1	1
	GENEL DOĞRULUK	0.92	0.78	0.77	0.71
GEMLİK	KENT	1	1	0.23	0.86
	SU	1	1	1	1
	TOPRAK	0.5	0.17	0	0
	YEŞİL ALAN	1	0.24	0.86	0.39
	GENEL DOĞRULUK	0.97	0.61	0.54	0.61
HATAY	KENT	0.86	0.75	0.16	0.57
	TOPRAK	0.8	0.8	0.8	1
	Y.ALAN	0.9	0.11	0.44	0.61
	SU	0.86	0.68	0.82	0
	GENEL DOĞRULUK	0.86	0.62	0.46	0.46

Elde edilen sonuçlar incelendiğinde geliştirilen yöntem ile elde edilen sonuçların doğruluğunun literatürdeki yöntemlerden daha yüksek olduğu görülmektedir.

8.2 Etiketleme

Bu çalışmanın amaçlarından ikincisi kontrolsüz sınıflandırma sonuçlarının etiketlendirilmesidir. Çalışmada bu amaçla bir yöntem geliştirilmiştir. Geliştirilen yöntemde göre elde edilen sınıflarda bulunan spektral değerler eşik değerlerle karşılaştırılmakta ve uygun sınıfa atanmaktadır. Bu yöntemde bulunan eşik değerlerin belirlenmesi amacıyla farklı iklim ve coğrafi özellikler taşıyan Akdeniz ve Karadeniz bölgelerinin Ocak, Nisan, Haziran, Eylül ve Kasım aylarına ait görüntüleri incelenmiştir. Belirlenen sınıflara ait eşik değerler bu analiz sonucunda belirlenmiştir. Geliştirilmiş olan yaklaşım farklı bölgelere ait görüntülere uygulanmıştır. Elde edilen tüm sonuçlar Tablo 8.2’de verilmiştir.

Tablo 8.2 Etiketleme Sonuçları

ÇALIŞMA ALANI	SINIFLAR	YÖNTEM		
		ÖNERİLEN YÖNTEM	CORINE	ÖNERİLEN YÖNTEM + CORINE
SİNOP	KENT	0.96	0.67	0.79
	NADAS	0.6	0.96	0.96
	ORMAN	0.96	0.59	0.55
	SU	1	1	1
	YEŞİL TARIM ALANI	1	1	0.75
	GENEL DOĞRULUK	0.87	0.84	0.83
GEMLİK	KENT	1	0.69	0.93
	ORMAN	1	1	1
	SU	1	1	1
	TOPRAK	0	0	
	YEŞİL ALAN	0.3	0	0.2
	GENEL DOĞRULUK	0.9	0.74	0.86
HATAY	KENT	0.93	0.91	0.93
	NADAS	1	1	0.71
	ORMAN	0.38	0.25	0.25
	SU	1	0.89	1
	TOPRAK	0	0	0
	YEŞİL ALAN	0.00	0	0
	Y.TARIM ALANI	0.33	0.2	0.67
	GENEL DOĞRULUK	0.76	0.71	0.78

Oluşturulan etiketlere uygulanan doğruluk analizi sonucunda yüksek doğruluklu sonuçlar elde edilmiştir. Çalışmada spektral yansıma değerleri yakın olan sınıfların etiketleme doğruluk sonuçlarının artırılabilmesi amacıyla Corine verilerinin kullanıldığı ikinci bir yaklaşım geliştirilmiştir. Bu yaklaşımın uygulanması sonucu sınıflar bazında incelendiğinde Hatay bölgesinde yeşil tarım alanlarının doğruluk oranı % 33'ten % 67' ye arttırmıştır. Benzer şekilde Sinop bölgesinde nadas bırakılmış alanlar %60' tan % 96'ya artmıştır.

Çalışmada geliştirilmiş olan sınıflandırma ve etiketleme algoritmalarının yanında bir diğer özgün değeri de geliştirilen bu algoritmalarının uygulanması ve test edilebilmesi amacıyla Python programlama dilinde kodlanmış olmasıdır. Ayrıca bu algoritmaların

kullanıcı tarafından kolaylıkla kullanılabilmesi amacıyla bir arayüz geliştirilmiştir. Bu arayüz optimize edildikten sonra açık kaynak kodlu platformlara yüklenecektir.

8.3 Çalışma Sonucundaki Öneriler

Geliştirilen sınıflandırma algoritması bünyesinde kullanılan veri havuzunu geliştirme yaklaşımı uygulanırken literatürde bulunan pek çok spektral indis, filtreleme veya boyut indirgeme yöntemi incelenmiştir. Geliştirilen arayüze literatürdeki gelişmelere bağlı olarak yeni indisleri, ya da görüntü filtrelerini ekleyebilmesi için modüler bir yapı geliştirilebilir.

Çalışma kapsamında geliştirilen modüllerin çalışma hızları ticari yazılımlarda bulunan algoritmalarla karşılaştırılarak optimize edilmelidir. Böylece çalışmada geliştirilen sınıflandırma algoritması çok yüksek çözünürlüklü görüntülerde veya hiperspektral görüntülerde de optimum sürede rahatlıkla kullanılabilir.

Bunun yanında sınıflandırma modülünün kullanım kolaylığını artırmak için çalışılması planlanan uydunun bir bölgeye ait belirli bir tarihteki görüntüsünü otomatik olarak indirme ve pan-sharpening uygulama özelliği eklenebilir.

Çalışmanın başlangıcında, geliştirilecek olan etiketleme yaklaşımının toprak, su, nadas, yeşil tarım alanı, orman ve kentsel alanların etiketlenmesi amaçlanmıştır. Çalışmada geliştirilen yaklaşımla elde edilen başarılı sonuçlar bu yaklaşımın farklı arazi örtüsü sınıfları için de uygulanabilir olduğunu göstermiştir. Gerçekleştirilen analiz bu doğrultuda genişletilerek daha kapsamlı bir veri havuzu elde edilebilecektir. Bunun yanında çalışma kapsamında elde edilen etiketleme yaklaşımında kullanılan eşik değerler Sentinel 2 görüntülerinden faydalanılarak elde edilmiştir. Bu yaklaşım farklı uydulardan elde edilen görüntüler içinde uygulanabilirliği test edilebilir. Bunun yanında etiketleme algoritması Corine arazi sınıfları ile beraber kullanıldığında benzer spektral değerlere sahip olan sınıfların ayrılmasında daha başarılı sonuçlar elde edildiği gözlemlenmiştir. Bu noktadan yola çıkılarak Open Street Map, UASİS gibi kaynakların etiketleme sistemine dâhil edilmesinin etiketleme başarısına etkileri araştırılabilir.

KAYNAKÇA

- Al-Doski, J., Mansori, S. B., & Shafri, H. Z. M. (2013). Image classification in remote sensing. *Department of Civil Engineering, Faculty of Engineering, University Putra, Malaysia*.
- Anifah, L., Purnomo, M., Mengko, T., & Purnama, I. (2018). *Osteoarthritis Severity Determination using Self Organizing Map Based Gabor Kernel*. Paper presented at the IOP Conference Series: Materials Science and Engineering.
- Ashourloo, D., Shahrabi, H. S., Azadbakht, M., Aghighi, H., Nematollahi, H., Alimohammadi, A., & Matkan, A. A. (2019). Automatic canola mapping using time series of sentinel 2 images. *Isprs Journal of Photogrammetry and Remote Sensing*, 156, 63-76.
- Ball, G. H., & Hall, D. J. (1965). *ISODATA, a novel method of data analysis and pattern classification*. Retrieved from
- Bandyopadhyay, S., Maulik, U., & Mukhopadhyay, A. (2007). Multiobjective genetic clustering for pixel classification in remote sensing imagery. *IEEE transactions on Geoscience and Remote Sensing*, 45(5), 1506-1511.
- Beleites, C., Neugebauer, U., Bocklitz, T., Krafft, C., & Popp, J. (2013). Sample size planning for classification models. *Analytica chimica acta*, 760, 25-33.
- Bezdek, J., Trivedi, M., Ehrlich, R., & Full, W. (1981). Fuzzy clustering: A new approach for geostatistical analysis. *Int. J. Syst., Meas, Decision*, 1, 13-23.
- Bezdek, J. C., Ehrlich, R., & Full, W. (1984). FCM: The fuzzy c-means clustering algorithm. *Computers & Geosciences*, 10(2-3), 191-203.
- Bhandari, A. K., Kumar, A., & Singh, G. K. (2015). Improved feature extraction scheme for satellite images using NDVI and NDWI technique based on DWT and SVD. *Arabian Journal of Geosciences*, 8(9), 6949-6966.
- Bhatti, S. S., & Tripathi, N. K. (2014). Built-up area extraction using Landsat 8 OLI imagery. *GIScience & remote sensing*, 51(4), 445-467.
- Birant, D., & Kut, A. (2007). ST-DBSCAN: An algorithm for clustering spatial-temporal data. *Data & Knowledge Engineering*, 60(1), 208-221.

- Bouzekri, S., Lasbet, A. A., & Lachehab, A. (2015). A new spectral index for extraction of built-up area using Landsat-8 data. *Journal of the Indian Society of Remote Sensing*, 43(4), 867-873.
- Caliński, T., & Harabasz, J. (1974). A dendrite method for cluster analysis. *Communications in Statistics-theory and Methods*, 3(1), 1-27.
- Calvo, S., Ciraolo, G., & Loggia, G. I. (2003). Monitoring Posidonia oceanica meadows in a Mediterranean coastal lagoon (Stagnone, Italy) by means of neural network and ISODATA classification methods. *International Journal of Remote Sensing*, 24(13), 2703-2716.
- Campbell, J. B., & Wynne, R. H. (2011). *Introduction to remote sensing*: Guilford Press.
- Cassano, E. N., Lynch, A. H., Cassano, J. J., & Koslow, M. R. (2006). Classification of synoptic patterns in the western Arctic associated with extreme events at Barrow, Alaska, USA. *Climate Research*, 30(2), 83-97.
- Chan, E. Y., Ching, W. K., Ng, M. K., & Huang, J. Z. (2004). An optimization algorithm for clustering using weighted dissimilarity measures. *Pattern Recognition*, 37(5), 943-952.
- Chen, C.-Y., & Ye, F. (2012). *Particle swarm optimization algorithm and its application to clustering analysis*. Paper presented at the Electrical Power Distribution Networks (EPDC), 2012 Proceedings of 17th Conference on.
- Chen, T.-W., Chen, Y.-L., & Chien, S.-Y. (2008). *Fast image segmentation based on K-Means clustering with histograms in HSV color space*. Paper presented at the Multimedia Signal Processing, 2008 IEEE 10th Workshop on.
- Chin-Wei, B., & Rajeswari, M. (2010). Multiobjective optimization approaches in image segmentation-the directions and challenges. *Int. J. Advance. Soft Comput. Appl*, 2(1), 40-64.
- Ciaccia, P., Patella, M., & Zezula, P. (1997). *M-tree: An Efficient Access Method for Similarity Search in Metric Spaces*. Paper presented at the Proceedings of the 23rd VLDB conference, Athens, Greece.
- Cococcioni, M., Ducange, P., Lazzerini, B., & Marcelloni, F. (2007). *Evolutionary multi-objective optimization of fuzzy rule-based classifiers in the ROC space*. Paper presented at the Fuzzy Systems Conference, 2007. FUZZ-IEEE 2007. IEEE International.

- Coléou, T., Poupon, M., & Azbel, K. (2003). Unsupervised seismic facies classification: A review and comparison of techniques and implementation. *The Leading Edge*, 22(10), 942-953.
- Comert, R., Avdan, U., & Gorum, T. (2018). Rapid Mapping Of Forested Landslide From Ultra-High Resolution Unmanned Aerial Vehicle Data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 3.
- Çömert, R., Matci Küçük, D., & Avdan, U. (2019). Object Based Burned Area Mapping With Random Forest Algorithm. *International Journal of Engineering and Geosciences*, 4(2), 78-87.
- Congalton, R. G., & Green, K. (2002). *Assessing the accuracy of remotely sensed data: principles and practices*: CRC press.
- Dai, W., Yu, C., & Jiang, Z. (2016). An Improved Hybrid Canopy-Fuzzy C-Means Clustering Algorithm Based on MapReduce Model. *Journal of Computing Science and Engineering*, 10(1), 1-8.
- Davies, D. L., & Bouldin, D. W. (1979). A cluster separation measure. *IEEE transactions on pattern analysis and machine intelligence*(2), 224-227.
- Deering, D. (1975). *Measuring" forage production" of grazing units from Landsat MSS data*. Paper presented at the Proceedings of the Tenth International Symposium of Remote Sensing of the Environment.
- Deng, J., Wang, K., Deng, Y., & Qi, G. (2008). PCA-based land-use change detection and analysis using multitemporal and multisensor satellite data. *International Journal of Remote Sensing*, 29(16), 4823-4838.
- Ding, C., Liu, X. N., Huang, F., Li, Y., & Zou, X. Y. (2017). Onset of drying and dormancy in relation to water dynamics of semi-arid grasslands from MODIS NDWI. *Agricultural and Forest Meteorology*, 234, 22-30.
- diyot.net. (2019). FM ve AM Modülasyonu. Retrieved from <https://diyot.net/fm-ve-am-modulasyonu/>
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., . . . Martimort, P. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment*, 120, 25-36.

- Du, Q., & Fowler, J. E. (2007). Hyperspectral image compression using JPEG2000 and principal component analysis. *IEEE Geoscience and Remote Sensing Letters*, 4(2), 201-205.
- Du, Q., Zhu, W., Yang, H., & Fowler, J. E. (2009). Segmented principal component analysis for parallel compression of hyperspectral imagery. *IEEE Geoscience and Remote Sensing Letters*, 6(4), 713-717.
- Du, Y., Zhang, Y., Ling, F., Wang, Q., Li, W., & Li, X. (2016). Water bodies' mapping from Sentinel-2 imagery with modified normalized difference water index at 10-m spatial resolution produced by sharpening the SWIR band. *Remote Sensing*, 8(4), 354.
- Duda, T., & Canty, M. (2002). Unsupervised classification of satellite imagery: choosing a good algorithm. *International Journal of Remote Sensing*, 23(11), 2193-2212.
- Dunn, J. C. (1973). A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters.
- Dunn, J. C. (1974). Well-separated clusters and optimal fuzzy partitions. *Journal of cybernetics*, 4(1), 95-104.
- El Bahi, H., & Zatni, A. (2018). Document Text Detection In Video Frames Acquired By A Smartphone Based On Line Segment Detector And Dbscan Clustering. *Journal of Engineering Science and Technology*, 13(2), 540-557.
- Enderle, D. I., & Weih Jr, R. C. (2005). Integrating supervised and unsupervised classification methods to develop a more accurate land cover classification. *Journal of the Arkansas Academy of Science*, 59(1), 65-73.
- Engdahl, M. E., & Hyypä, J. M. (2003). Land-cover classification using multitemporal ERS-1/2 InSAR data. *Ieee Transactions on Geoscience and Remote Sensing*, 41(7), 1620-1628.
- EOS. (2019). 6 Spectral Indexes On Top Of Ndvi To Make Your Vegetation Analysis Complete. Retrieved from <https://eos.com/blog/6-spectral-indexes-on-top-of-ndvi-to-make-your-vegetation-analysis-complete/>
- Epting, J., & Verbyla, D. (2005). Landscape-level interactions of prefire vegetation, burn severity, and postfire vegetation over a 16-year period in interior Alaska. *Canadian Journal of Forest Research*, 35(6), 1367-1377.

- ESA. (2018). SENTINEL-2. Retrieved from <https://sentinel.esa.int/web/sentinel/missions/sentinel-2>
- Escadafal, R. (1989). Remote sensing of arid soil surface color with Landsat thematic mapper. *Advances in space research*, 9(1), 159-163.
- Eshtehardi, A., Ebadi, H., Valadan, Z., & Mohammadzadeh, A. (2007). *Image fusion of Landsat ETM+ and SPOT satellite images using IHS, Brovey and PCA*. Paper presented at the Conference on information extraction from SAR and optical data, with emphasis on developing countries.
- Ester, M., Kriegel, H.-P., Sander, J., Wimmer, M., & Xu, X. (1998). *Incremental clustering for mining in a data warehousing environment*. Paper presented at the VLDB.
- Ettehad Osgouei, P., Kaya, S., Sertel, E., & Alganci, U. (2019). Separating Built-Up Areas from Bare Land in Mediterranean Cities Using Sentinel-2A Imagery. *Remote Sensing*, 11(3), 345.
- Ezzine, H., Bouziane, A., Ouazar, D., & Hasnaoui, M. D. (2017). Downscaling of Open Coarse Precipitation Data through Spatial and Statistical Analysis, Integrating NDVI, NDWI, Elevation, and Distance from Sea. *Advances in Meteorology*.
- Fathian, M., Amiri, B., & Maroosi, A. (2007). Application of honey-bee mating optimization algorithm on clustering. *Applied Mathematics and Computation*, 190(2), 1502-1513.
- Fauvel, M., Chanussot, J., & Benediktsson, J. A. (2009). Kernel principal component analysis for the classification of hyperspectral remote sensing data over urban areas. *EURASIP Journal on Advances in Signal Processing*, 2009(1), 783194.
- Fayos, J., & Fayos, C. (2007). Wind data mining by Kohonen neural networks. *PLoS One*, 2(2), e210.
- Féret, J.-B., & Asner, G. P. (2014). Mapping tropical forest canopy diversity using high-fidelity imaging spectroscopy. *Ecological Applications*, 24(6), 1289-1296.
- Feyisa, G. L., Meilby, H., Fensholt, R., & Proud, S. R. (2014). Automated Water Extraction Index: A new technique for surface water mapping using Landsat imagery. *Remote Sensing of Environment*, 140, 23-35.
- Gao, B.-C. (1995). *Normalized difference water index for remote sensing of vegetation liquid water from space*. Paper presented at the Imaging Spectrometry.

- García, M. L., & Caselles, V. (1991). Mapping burns and natural reforestation using Thematic Mapper data. *Geocarto International*, 6(1), 31-37.
- Ge, Y., Chen, Y., Stein, A., Li, S., & Hu, J. (2016). Enhanced subpixel mapping with spatial distribution patterns of geographical objects. *Ieee Transactions on Geoscience and Remote Sensing*, 54(4), 2356-2370.
- Gemlik_Belediyesi. (2019). Gemlik. Retrieved from <http://gemlik.bel.tr/tr/gemlik>
- Gitelson, A., & Merzlyak, M. N. (1994). Spectral reflectance changes associated with autumn senescence of *Aesculus hippocastanum* L. and *Acer platanoides* L. leaves. Spectral features and relation to chlorophyll estimation. *Journal of Plant Physiology*, 143(3), 286-292.
- Gitelson, A. A., Gritz, Y., & Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology*, 160(3), 271-282.
- Goldblatt, R., You, W., Hanson, G., & Khandelwal, A. (2016). Detecting the boundaries of urban areas in india: A dataset for pixel-based image classification in google earth engine. *Remote Sensing*, 8(8), 634.
- Gonçalves, M., Costa, J., & Netto, M. (2011). Land-cover classification using self-organizing maps clustered with spectral and spatial information. In *Self Organizing Maps-Applications and Novel Algorithm Design*: IntechOpen.
- Goncalves, M., Netto, M., Costa, J., & Zullo Junior, J. (2008). An unsupervised method of classifying remotely sensed images using Kohonen self-organizing maps and agglomerative hierarchical clustering methods. *International Journal of Remote Sensing*, 29(11), 3171-3207.
- Guha, S., Rastogi, R., & Shim, K. (1998). *CURE: an efficient clustering algorithm for large databases*. Paper presented at the ACM Sigmod Record.
- Guha, S., Rastogi, R., & Shim, K. (2000). ROCK: A robust clustering algorithm for categorical attributes. *Information systems*, 25(5), 345-366.
- Guyot, G., & Baret, F. (1988). *Utilisation de la haute resolution spectrale pour suivre l'etat des couverts vegetaux*. Paper presented at the Spectral Signatures of Objects in Remote Sensing.

- Hämäläinen, J., Jauhiainen, S., & Kärkkäinen, T. (2017). Comparison of internal clustering validation indices for prototype-based clustering. *Algorithms*, 10(3), 105.
- Han, J., Pei, J., & Kamber, M. (2011). *Data mining: concepts and techniques*: Elsevier.
- Hansen, P., & Schjoerring, J. (2003). Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression. *Remote Sensing of Environment*, 86(4), 542-553.
- Hardisky, M., Klemas, V., & Smart, M. (1983). The influence of soil salinity, growth form, and leaf moisture on the spectral radiance of. *Spartina alterniflora*, 49, 77-83.
- Hartigan, J. A., & Wong, M. A. (1979). Algorithm AS 136: A k-means clustering algorithm. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, 28(1), 100-108.
- Hatay_Valiliği, T. C. (2019). Sosyal ve Coğrafi Durum. Retrieved from <http://www.hatay.gov.tr/sosyal-ve-cografi-durum>
- He, K., Sun, J., & Tang, X. (2010). *Guided image filtering*. Paper presented at the European conference on computer vision.
- Hong, Y., Chiang, Y. M., Liu, Y., Hsu, K. L., & Sorooshian, S. (2006). Satellite-based precipitation estimation using watershed segmentation and growing hierarchical self-organizing map. *International Journal of Remote Sensing*, 27(23), 5165-5184.
- Huang, Z.-K., Ma, Y.-L., Lu, L., Rao, F.-X., & Hou, L.-Y. (2016). *Chinese historic image threshold using adaptive K-means cluster and Bradley's*. Paper presented at the International conference on intelligent computing.
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295-309.
- Ioannidis, C., Psaltis, C., & Potsiou, C. (2009). Towards a strategy for control of suburban informal buildings through automatic change detection. *Computers, Environment and Urban Systems*, 33(1), 64-74.
- Isa, N. A. M., Salamah, S. A., & Ngah, U. K. (2009). Adaptive fuzzy moving K-means clustering algorithm for image segmentation. *IEEE Transactions on Consumer Electronics*, 55(4).

- Islam, M. M., & Sado, K. (2000). Flood hazard assessment in Bangladesh using NOAA AVHRR data with geographical information system. *Hydrological Processes*, 14(3), 605-620.
- Jang, S.-W., Kim, G.-Y., & Byun, S. (2014). Clustering-based pattern abnormality detection in distributed sensor networks. *International Journal of Distributed Sensor Networks*, 10(4), 438468.
- Jensen, J. R. (2009). *Remote sensing of the environment: An earth resource perspective 2/e*: Pearson Education India.
- Jensen, J. R., & Cowen, D. C. (1999). Remote sensing of urban/suburban infrastructure and socio-economic attributes. *Photogrammetric engineering and remote sensing*, 65, 611-622.
- Jensen, J. R., & Lulla, K. (1987). Introductory digital image processing: a remote sensing perspective.
- Ji, C. (2000). Land-use classification of remotely sensed data using Kohonen self-organizing feature map neural networks. *Photogrammetric engineering and remote sensing*, 66(12), 1451-1460.
- Jiang, Z., Huete, A. R., Didan, K., & Miura, T. (2008). Development of a two-band enhanced vegetation index without a blue band. *Remote Sensing of Environment*, 112(10), 3833-3845.
- Johnson, S. C. (1967). Hierarchical clustering schemes. *Psychometrika*, 32(3), 241-254.
- Jolliffe, I. (2011). *Principal component analysis*: Springer.
- Jovanovic, N., Garcia, C. L., Bagan, R. D. H., Teich, I., & Rodriguez, C. M. G. (2014). Validation of remotely-sensed evapotranspiration and NDWI using ground measurements at Riverlands, South Africa. *Water Sa*, 40(2), 211-220.
- Karypis, G., Han, E.-H., & Kumar, V. (1999). Chameleon: Hierarchical clustering using dynamic modeling. *Computer*, 32(8), 68-75.
- Khan, K., Rehman, S. U., Aziz, K., Fong, S., & Sarasvady, S. (2014). *DBSCAN: Past, present and future*. Paper presented at the The Fifth International Conference on the Applications of Digital Information and Web Technologies (ICADIWT 2014).
- Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. *Biological cybernetics*, 43(1), 59-69.

- Kohonen, T., Kangas, J., Laaksonen, J., & Torkkola, K. (1992). *Lvqpak: A software package for the correct application of learning vector quantization algorithms*. Paper presented at the Neural Networks, 1992. IJCNN., International Joint Conference on.
- Kwon, Y., Lee, H., & Lee, H. (2018). Implication of the cluster analysis using greenhouse gas emissions of Asian countries to climate change mitigation. *Mitigation and adaptation strategies for global change*, 23(8), 1225-1249.
- Langley, S. K., Cheshire, H. M., & Humes, K. S. (2001). A comparison of single date and multitemporal satellite image classifications in a semi-arid grassland. *Journal of Arid Environments*, 49(2), 401-411.
- Li, Y., Zhang, Y., Huang, X., & Yuille, A. L. (2018). Deep networks under scene-level supervision for multi-class geospatial object detection from remote sensing images. *Isprs Journal of Photogrammetry and Remote Sensing*, 146, 182-196.
- Lillesand, T., Kiefer, R. W., & Chipman, J. (2014). *Remote sensing and image interpretation*: John Wiley & Sons.
- Liu, J. G., & Mason, P. J. (2013). *Essential image processing and GIS for remote sensing*: John Wiley & Sons.
- Liu, R.-j., Zhang, J.-b., & Liu, R. (2008). Fuzzy c-means clustering algorithm. *Journal of Chongqing Institute of Technology (Natural Science Edition)*, 2, 036.
- Louhaichi, M., Borman, M. M., & Johnson, D. E. (2001). Spatially located platform and aerial photography for documentation of grazing impacts on wheat. *Geocarto International*, 16(1), 65-70.
- Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28(5), 823-870. doi:10.1080/01431160600746456
- Ma, E. W., & Chow, T. W. (2004). A new shifting grid clustering algorithm. *Pattern Recognition*, 37(3), 503-514.
- MacQueen, J. (1967). *Some methods for classification and analysis of multivariate observations*. Paper presented at the Proceedings of the fifth Berkeley symposium on mathematical statistics and probability.
- Manickavasagan, A., & Jayasuriya, H. (2014). *Imaging with electromagnetic spectrum: applications in food and agriculture*: Springer.

- Mao, H. Y., Feng, Z. K., Gong, Y. X., & Yu, J. X. (2014). Researches of Soil Normalized Difference Water Index (NDWI) of Yongding River Based on Multispectral Remote Sensing Technology Combined with Genetic Algorithm. *Spectroscopy and Spectral Analysis*, 34(6), 1649-1655.
- Marsett, R. C., Qi, J., Heilman, P., Biedenbender, S. H., Watson, M. C., Amer, S., . . . Marsett, R. (2006). Remote sensing for grassland management in the arid southwest. *Rangeland Ecology & Management*, 59(5), 530-540.
- Martín, M., Gómez, I., & Chuvieco, E. (2005). *Performance of a burned-area index (BAIM) for mapping Mediterranean burned scars from MODIS data*. Paper presented at the Proceedings of the 5th International Workshop on Remote Sensing and GIS Applications to forest fire management: fire effects assessment.
- Martin, M. P. (1998). *Cartografía e inventario de incendios forestales en la Península Ibérica a partir de imágenes NOAA-AVHRR*. (Doctoral Thesis), Universidad de Alcalá,
- Martinuzzi, S., Gould, W. A., & Gonzalez, O. M. R. (2007). Land development, land use, and urban sprawl in Puerto Rico integrating remote sensing and population census data. *Landscape and Urban Planning*, 79(3-4), 288-297.
- Mather, P. M., & Koch, M. (2011). *Computer processing of remotely-sensed images: an introduction*: John Wiley & Sons.
- McCallum, A., Nigam, K., & Ungar, L. H. (2000). *Efficient clustering of high-dimensional data sets with application to reference matching*. Paper presented at the Proceedings of the sixth ACM SIGKDD international conference on Knowledge discovery and data mining.
- McFeeters, S. K. (2013). Using the Normalized Difference Water Index (NDWI) within a Geographic Information System to Detect Swimming Pools for Mosquito Abatement: A Practical Approach. *Remote Sensing*, 5(7), 3544-3561.
- Merzlyak, M. N., Gitelson, A. A., Chivkunova, O. B., & Rakitin, V. Y. (1999). Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. *Physiologia plantarum*, 106(1), 135-141.
- Mihaescu, M. C., & Burdescu, D. D. (2012). Using m tree data structure as unsupervised classification method. *Informatica*, 36(2).

- Murtagh, F., & Contreras, P. (2017). Algorithms for hierarchical clustering: an overview, II. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 7(6).
- Ng, H., Ong, S., Foong, K., Goh, P., & Nowinski, W. (2006). *Medical image segmentation using k-means clustering and improved watershed algorithm*. Paper presented at the Image Analysis and Interpretation, 2006 IEEE Southwest Symposium on.
- Orman_Bakanlığı, T. T. v. (2015). Corine Projesi. Retrieved from <https://corine.tarimorman.gov.tr/corineportal/turkiyecalismalar.html>
- Ozesmi, S. L., & Bauer, M. E. (2002). Satellite remote sensing of wetlands. *Wetlands ecology and management*, 10(5), 381-402.
- Pal, M., & Mather, P. (2006). Some issues in the classification of DAIS hyperspectral data. *International Journal of Remote Sensing*, 27(14), 2895-2916.
- Park, J., Harada, I., & Kwak, Y. (2016). Object-Based Classification and Change Detection of Hokkaido, Japan. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 8.
- Pearson, K. (1895). X. Contributions to the mathematical theory of evolution.—II. Skew variation in homogeneous material. *Philosophical Transactions of the Royal Society of London.(A.)*(186), 343-414.
- Penuelas, J., Baret, F., & Filella, I. (1995). Semi-empirical indices to assess carotenoids/chlorophyll a ratio from leaf spectral reflectance. *Photosynthetica*, 31(2), 221-230.
- Pinty, B., & Verstraete, M. (1992). GEMI: a non-linear index to monitor global vegetation from satellites. *Vegetatio*, 101(1), 15-20.
- Pohl, C., & Van Genderen, J. L. (1998). Review article multisensor image fusion in remote sensing: concepts, methods and applications. *International Journal of Remote Sensing*, 19(5), 823-854.
- Poser, K., & Dransch, D. (2010). Volunteered geographic information for disaster management with application to rapid flood damage estimation. *Geomatica*, 64(1), 89-98.
- Qiao, C., Luo, J. C., Sheng, Y. W., Shen, Z. F., Zhu, Z. W., & Ming, D. P. (2012). An Adaptive Water Extraction Method from Remote Sensing Image Based on NDWI. *Journal of the Indian Society of Remote Sensing*, 40(3), 421-433.

- Rasul, A., Balzter, H., Ibrahim, G., Hameed, H., Wheeler, J., Adamu, B., . . . Najmaddin, P. (2018). Applying built-up and bare-soil indices from Landsat 8 to cities in dry climates. *Land*, 7(3), 81.
- Richards, J. A. (2013). Supervised classification techniques. In *Remote Sensing Digital Image Analysis* (pp. 247-318): Springer.
- Richards, J. A., & Richards, J. (1999). *Remote sensing digital image analysis* (Vol. 3): Springer.
- Rondeaux, G., Steven, M., & Baret, F. (1996). Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment*, 55(2), 95-107.
- Rossum, G. (1995). Python reference manual.
- Rousseeuw, P. J. (1987). Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. *Journal of computational and applied mathematics*, 20, 53-65.
- Roux, M. (2015). A comparative study of divisive hierarchical clustering algorithms. *arXiv preprint arXiv:1506.08977*.
- Salomonson, V. V., & Appel, I. (2004). Estimating fractional snow cover from MODIS using the normalized difference snow index. *Remote Sensing of Environment*, 89(3), 351-360.
- Sander, J., Ester, M., Kriegel, H.-P., & Xu, X. (1998). Density-based clustering in spatial databases: The algorithm gdbscan and its applications. *Data mining and knowledge discovery*, 2(2), 169-194.
- Schavemaker, J. G., Reinders, M. J., Gerbrands, J. J., & Backer, E. (2000). Image sharpening by morphological filtering. *Pattern Recognition*, 33(6), 997-1012.
- Shah, V. P., Younan, N. H., & King, R. L. (2008). An efficient pan-sharpening method via a combined adaptive PCA approach and contourlets. *Ieee Transactions on Geoscience and Remote Sensing*, 46(5), 1323-1335.
- Shahi, K., Shafri, H. Z., Taherzadeh, E., Mansor, S., & Muniandy, R. (2015). A novel spectral index to automatically extract road networks from WorldView-2 satellite imagery. *The Egyptian Journal of Remote Sensing and Space Science*, 18(1), 27-33.
- Shen, L., & Li, C. (2010). *Water body extraction from Landsat ETM+ imagery using adaboost algorithm*. Paper presented at the 2010 18th International Conference on Geoinformatics.

- Sinergise. (2017). Sentinel 2 EO products. Retrieved from https://www.sentinel-hub.com/develop/documentation/eo_products/Sentinel2EOproducts
- Singh, K. V., Setia, R., Sahoo, S., Prasad, A., & Pateriya, B. (2015). Evaluation of NDWI and MNDWI for assessment of waterlogging by integrating digital elevation model and groundwater level. *Geocarto International*, 30(6), 650-661.
- Sinha, P., Verma, N. K., & Ayele, E. (2016). Urban built-up area extraction and change detection of Adama municipal area using time-series Landsat images. *International Journal of Advanced Remote Sensing and GIS*, 5(8), 1886-1895.
- Sinop_Valiliği, T. C. (2019). Coğrafya. Retrieved from <http://www.sinop.gov.tr/cografya>
- Sokal, R. R. (1974). Classification: purposes, principles, progress, prospects. *Science*, 185(4157), 1115-1123.
- Sorooshian, S., Hsu, K.-L., Gao, X., Gupta, H. V., Imam, B., & Braithwaite, D. (2000). Evaluation of PERSIANN system satellite-based estimates of tropical rainfall. *Bulletin of the American Meteorological Society*, 81(9), 2035-2046.
- Sun, H., Zhao, X., Chen, Y. H., Gong, A. D., & Yang, J. (2013). A new agricultural drought monitoring index combining MODIS NDWI and day-night land surface temperatures: a case study in China. *International Journal of Remote Sensing*, 34(24), 8986-9001.
- Tatiraju, S., & Mehta, A. (2008). Image Segmentation using k-means clustering, EM and Normalized Cuts. *Department of EECS*, 1, 1-7.
- Thapa, R. B., & Murayama, Y. (2009). Urban mapping, accuracy, & image classification: A comparison of multiple approaches in Tsukuba City, Japan. *Applied geography*, 29(1), 135-144.
- Thomson, A. (1998). Supervised versus unsupervised methods for classification of coasts and river corridors from airborne remote sensing. *International Journal of Remote Sensing*, 19(17), 3423-3431.
- Tou, J. T., & Gonzalez, R. C. (1974). Pattern recognition principles.
- Tu, T.-M., Su, S.-C., Shyu, H.-C., & Huang, P. S. (2001). A new look at IHS-like image fusion methods. *Information fusion*, 2(3), 177-186.
- Tucker, C. J. (1980). A spectral method for determining the percentage of green herbage material in clipped samples. *Remote Sensing of Environment*, 9(2), 175-181.

- URL. (2019). T.C. Gemlik Kaymakamlığı. Retrieved from <http://www.gemlik.gov.tr/ilcemiz>
- Van Deventer, A., Ward, A., Gowda, P., & Lyon, J. (1997). Using Thematic Mapper data to identify contrasting soil plains and tillage practices. *Photogrammetric engineering and remote sensing*, 63, 87-93.
- Venkateswarlu, N., & Raju, P. (1992). Fast ISODATA clustering algorithms. *Pattern Recognition*, 25(3), 335-342.
- Villmann, T., Merényi, E., & Hammer, B. (2003). Neural maps in remote sensing image analysis. *Neural Networks*, 16(3), 389-403.
- Wang, Z.-t., Zhao, N.-b., Wang, W.-y., Tang, R., & Li, S.-y. (2015). A fault diagnosis approach for gas turbine exhaust gas temperature based on fuzzy c-means clustering and support vector machine. *Mathematical Problems in Engineering*, 2015.
- Waqar, M. M., Mirza, J. F., Mumtaz, R., & Hussain, E. (2012). Development of new indices for extraction of built-up area & bare soil from landsat data. *Open Access Sci. Rep*, 1(1), 4.
- Warner, T. A., Skowronski, N. S., & Gallagher, M. R. (2017). High spatial resolution burn severity mapping of the New Jersey Pine Barrens with WorldView-3 near-infrared and shortwave infrared imagery. *International Journal of Remote Sensing*, 38(2), 598-616.
- Wilson, E. H., & Sader, S. A. (2002). Detection of forest harvest type using multiple dates of Landsat TM imagery. *Remote Sensing of Environment*, 80(3), 385-396.
- Woebbecke, D. M., Meyer, G. E., Von Bargen, K., & Mortensen, D. (1995). Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE*, 38(1), 259-269.
- Xu, H. (2006). Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 27(14), 3025-3033.
- Yang, S., Wang, M., & Jiao, L. (2012). Fusion of multispectral and panchromatic images based on support value transform and adaptive principal component analysis. *Information fusion*, 13(3), 177-184.

- Yang, X., & Lo, C. (2002). Using a time series of satellite imagery to detect land use and land cover changes in the Atlanta, Georgia metropolitan area. *International Journal of Remote Sensing*, 23(9), 1775-1798.
- Yang, X., Zhao, S., Qin, X., Zhao, N., & Liang, L. (2017). Mapping of urban surface water bodies from Sentinel-2 MSI Imagery at 10 m resolution via NDWI-based image sharpening. *Remote Sensing*, 9(6), 596.
- Younus, Z. S., Mohamad, D., Saba, T., Alkawaz, M. H., Rehman, A., Al-Rodhaan, M., & Al-Dhelaan, A. (2015). Content-based image retrieval using PSO and k-means clustering algorithm. *Arabian Journal of Geosciences*, 8(8), 6211-6224.
- Zeraatpisheh, M., Ayoubi, S., Brungard, C. W., & Finke, P. (2019). Disaggregating and updating a legacy soil map using DSMART, fuzzy c-means and k-means clustering algorithms in Central Iran. *Geoderma*, 340, 249-258.
- Zha, Y., Gao, J., & Ni, S. (2003). Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International Journal of Remote Sensing*, 24(3), 583-594.
- Zhang, T., Ramakrishnan, R., & Livny, M. (1996). *BIRCH: an efficient data clustering method for very large databases*. Paper presented at the ACM Sigmod Record.

ÖZGEÇMİŞ

Adı-Soyadı: Dilek KÜÇÜK MATCI

Yabancı Dil: İngilizce

Doğum Yeri ve Yılı: Eskişehir, 1977

E-Posta: dkmatci@anadolu.edu.tr

Eğitim ve Mesleki Geçmişi:

- 2000, Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Endüstri Mühendisliği Bölümü / Lisans
- 2014, Anadolu Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği A.B.D / Yüksek Lisans
- 2002-2004, Planlama Sorumlusu, SARAR A.Ş.
- 2007-2011, Bilgi İşlem Uzmanı, Kılıçoğlu Endel A.Ş.
- 2011 - , Öğretim Görevlisi, Anadolu Üniversitesi

Yayınları ve Bilimsel/Sanatsal Faaliyetleri:

- Küçük Matcı D. , Acar I. (2019) Modelling And Optimization Of The Exam Invigilator Assignment Problem Based On Preferences. Turkish Journal of Engineering, 3(140-148).
- Küçük Matcı D. , Avdan U. (2019) Optimization of Remote Sensing Image Attributes to Improve Classification Accuracy. International Journal of Environment and Geoinformatics, 6(1) 50-56
- Çömert, R. , Küçük Matcı, D. , Avdan, U. , (2018) Detection Of Collapsed Building From Unmanned Aerial Vehicle Data With Object Based Image Classification. Anadolu Üniversitesi Bilim Ve Teknoloji Dergisi - B Teorik Bilimler, 6, (109,116).
- Küçük Matcı, D. , Avdan, U. , (2018) Address standardization using the natural language process for improving geocoding results. Computers Environment And Urban Systems,70, (1-8).
- Çömert, R. Küçük Matcı, D. Emir, H. Avdan, U. , (2017) Nesne Tabanlı Sınıflandırma ile Yanmış Orman Alanlarının Tespiti. Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi, 17, Özel Sayı (27-34).

EKLER

Ek 1. Kareniz Bölgesine Ait Görüntülerde Bulunan Sınıflara Ait Alanların Spektral İndislere Ait Değerleri.

AYLAR	ORMAN		YEŞİL TARIM ALANI		NADAS		TOPRAK		KENT		SU		Spektral İndis
OCAK	-9000	0	-9000	0	-17000	-9000	-17000	-9000	-17000	-9000	0	1300	AWEI
NİSAN	-9000	0	-9000	0	-17000	-9000	-17000	-9000	-20000	-8000	0	2000	
HAZİRAN	-10000	0	-10000	0	-20000	-10000	-20000	-10000	-20000	-8000	0	5000	
EYLÜL	-10000	0	-10000	0	-20000	-10000	-20000	-10000	-20000	-1000	0	3000	
KASIM	-10000	0	-15000	8000	-20000	-10000	-20000	-10000	-20000	-5000	0	3000	
OCAK	-1	0	-1	0	0	1	0	1	0	1	-1	0	BI
NİSAN	-0.5	0	-0.5	0	-0.1	0.1	-0.1	0.1	-0.08	0.2	-1	0	
HAZİRAN	-1	0	-1	0	0	1	0	1	-0.08	0.2	-1	0	
EYLÜL	-1	0	-1	0	0	1	0	1	-0.08	0.2	-1	0	
KASIM	-1	0	-1	0	0	0.5	0	0.5	0	0.5	-1	0	
OCAK	0	500	0	500	500	5000	500	5000	500	5000	0	500	Mavi
NİSAN	700	900	700	900	1200	3000	1200	3000	900	3000	700	900	
HAZİRAN	0	850	850	1200	1000	1600	1000	1600	1300	7000	800	1500	
EYLÜL	0	900	900	1200	1000	2000	1000	2000	1300	4000	800	1200	
KASIM	0	300	200	600	500	1000	500	1000	1000	4000	0	400	
OCAK	-5000	-200	5000	-200	-4000	500	-4000	500	-4000	500	0	1000	EGI
NİSAN	-5000	-2000	5000	-2000	-5000	-1500	-5000	-1500	-1500	0	0	1000	
HAZİRAN	-5000	-1000	5000	-1000	-1500	-500	-1500	-500	-1500	0	0	2000	
EYLÜL	-3000	-300	-3000	-300	-1500	0	-1500	0	-1500	0	0	2000	
KASIM	-5000	-1000	-4000	-1500	-5000	-1500	-5000	-1500	-1500	0	0	2000	
OCAK	200	500	500	800	400	1000	400	1000	300	6000	0	300	YEŞİL
NİSAN	0	1000	1000	1300	1200	1600	1200	1600	1100	6000	0	600	
HAZİRAN	600	1200	600	1200	900	1700	900	1700	1500	4000	500	1500	
EYLÜL	600	1000	600	1000	1000	2000	1000	2000	1200	4000	500	1500	
KASIM	200	600	600	1000	700	2000	700	2000	1300	6000	100	1500	
OCAK	-2000	-100	-2000	-100	-3000	-800	-3000	-800	-30000	-1000	-100	30	GVI
NİSAN	-3000	-1000	-3000	-1000	-6000	-3000	-6000	-3000	-15000	-3500	-1000	0	
HAZİRAN	-4000	-1000	-4000	-1000	-4000	-1000	-4000	-1000	-9000	-2500	-2000	0	
EYLÜL	-2500	-1000	-2500	-1000	-5000	-2000	-5000	-2000	-9000	-2500	-2000	0	

KASIM	-2500	0	-2500	0	-9000	-2500	-9000	-2500	-9000	-2500	0	0	
OCAK	-3000	0	-3000	0	30	1300	30	1300	500	4000	0	30	MSBI
NİSAN	-6000	-500	-1000	1000	500	2000	500	2000	0	2000	0	200	
HAZİRAN	-2000	0	-1500	1000	500	2000	500	2000	500	3000	0	500	
EYLÜL	-2000	0	-1500	1000	500	3000	500	3000	1500	3000	0	200	
KASIM	-2000	0	-700	900	500	3000	500	3000	500	4000	0	200	
OCAK	0	1	0	1	-0.1	0.2	-0.1	0.2	-0.3	0.3	0	0	NBR
NİSAN	0	0.5	0	0.5	-0.5	0	-0.5	0	-0.5	0	0	0	
HAZİRAN	0	1	0	1	-2	0	-2	0	-2	0	-0.3	1	
EYLÜL	0	1	0	1	-2	0	-2	0	-2	0	0	1	
KASIM	0	0.6	0	0.6	-2	0.1	-2	0.1	-2	0.3	-1	1	
OCAK	-1	-0.3	-1	-0.3	-1	-0.3	-1	-0.3	-1	0.3	0	1	NDSI
NİSAN	-1	-0.1	-1	-0.1	-1	-0.3	-1	-0.3	0	0	0	1	
HAZİRAN	-1	-0.3	-1	-0.3	-1	-0.3	-1	-0.3	-0.3	0	0	1	
EYLÜL	-0.5	0.5	-0.5	0.5	-0.5	-0.3	-0.5	-0.3	-0.3	0	0	1	
KASIM	-0.9	-0.3	-0.6	-0.4	-0.5	0.12	-0.5	0.12	-0.5	0.12	0	1	
OCAK	0.3	1	0.3	1	0	0.3	0	0.5	-0.1	0.3	0	0.3	NDVI
NİSAN	0.3	1	0.3	1	0	0.3	0	0.3	0	0.3	-1	0	
HAZİRAN	-0.6	1	0.4	0.6	0.1	0.4	0.1	0.4	-0.02	0.3	-1	0	
EYLÜL	-0.5	1	0.3	0.6	0.1	0.4	0.1	0.4	-0.04	0.3	-1	0	
KASIM	0.6	1	0.3	1	0	0.3	0	0.3	0	0.3	-1	0	
OCAK	-1	-0.6	-1	-0.6	0	0.6	0	0.6	0	0.6	0	1	NDWI
NİSAN	-1	-0.6	-1	-0.6	-0.5	0	-0.5	0	-0.5	0	0	1	
HAZİRAN	-1	-0.5	-1	-0.5	-0.5 - 0	0	-0.5 - 0	0	-0.5 - 0	0	0	1	
EYLÜL	-1	-0.5	-1	-0.5	-0.5 - 0	0	-0.5 - 0	0	-0.5 - 0	0	0	1	
KASIM	-1	-0.5	-1	-0.5	-0.5 - 0	0.04	-0.5 - 0	0.04	-0.5 - 0	0.04	0	1	
OCAK	0	1	0	1	-1	0	-1	0	-1	0	10	2000	NRAVI
NİSAN	0	0.1	0	0.1	-1	0	-1	0	-1	0	0	0.6	
HAZİRAN	0	0.1	0	0.1	-1	0	-1	0	-1	0	0.1	1	
EYLÜL	0	0.1	0	0.1	-1	0	-1	0	-1	0	0.2	1	
KASIM	0	0.1	0	0.1	-1	0	-1	0	-1	0	0.1	200	
OCAK	0.5	1	0.5	1	0	0.5	0	0.5	-1	0.03	-1	0	OSAVI
NİSAN	0.5	1	0.5	1	0	0.5	0	0.5	0	0.5	-1	0	
HAZİRAN	0.5	1	0.5	1	0.1	0.3	0.1	0.3	-0.03	0.2	-1	0	
EYLÜL	0.5	1	0.5	1	0.2	0.5	0.2	0.5	-0.03	0.2	-1	0	
KASIM	0.5	1	0.5	1	-0.03	0.5	-0.03	0.5	-0.03	0.3	-1	0	
OCAK	-1000	-300	-1000	-300	-1000	-300	-1000	-300	-2000	-900	-30	0	SATVI
NİSAN	-500	-100	-500	-100	-2000	-500	-2000	-500	-2000	-500	-100	0	
HAZİRAN	-500	-200	-900	-500	-2000	-900	-2000	-900	-3500	-900	-200	0	
EYLÜL	-600	0	-900	-500	-2000	-900	-2000	-900	-3000	-500	-100	0	
KASIM	-500	-100	-1500	-500	-1000	-250	-1000	-250	-4000	-800	-100	0	

OCAK	0.5	3	0.5	3	0	0.5	0	0.5	0	0.5	-1	0	REM
NİSAN	0.9	4	0.9	4	0	1	0	1	0	1	-1	0	
HAZİRAN	0.5	5	0.1	0.5	0	0.5	0	0.5	0	0.5	-5	0.2	
EYLÜL	0.9	5	0.9	5	0	0.7	0	0.7	0	0.5	-1	0	
KASIM	0.9	5	0.5	5	0	0.7	0	0.7	0	0.5	-5	0.2	
OCAK	0.5	3	0.5	3	0.1	0.5	0.1	0.5	0	0.5	-4	0	SAWI
NİSAN	0.5	2	0.5	2	-0.5	0.5	-0.5	0.5	0	0.5	-1	0.2	
HAZİRAN	1	2	0.5	1	0	0.5	0	0.5	0	0.5	-1	0	
EYLÜL	0.5	2	0.5	2	0	0.7	0	0.7	0	0.3	-1	0	
KASIM	0.5	2	0.5	2	0	0.7	0	0.7	0	0.7	-1	0	
OCAK	-400	600	-400	600	-2000	-800	-2000	-800	-3000	-800	0	200	WETNESS
NİSAN	-400	900	0	-1400	-2000	-400	-2000	-400	-2000	-400	0	600	
HAZİRAN	300	-500	500	-1500	-3000	-1500	-3000	-1500	-2500	-1000	0	500	
EYLÜL	0	1000	0	1000	-2000	0	-2000	0	-3000	0	0	500	
KASIM	-500	-1000	-500	-1000	-2500	-1000	-2500	-1000	-3000	1000	0	500	

EK 2. Akdeniz Bölgesine Ait Görüntülerde Bulunan Sınıflara Ait Alanların Spektral İndislere Ait Değerleri.

AYLAR	ORMAN		YEŞİL TARIM ALANI		NADAS		TOPRAK		KENT		SU		Spektral İndis
OCAK	-9000	-4000	-9000	-4000	-17000	-9000	-17000	-9000	-9000	0	0	8000	AWEI
NİSAN	-9000	-2000	-9000	-2000	-17000	-7000	-17000	-7000	-12000	20000	0	5000	
HAZİRAN	-15000	-7000	-15000	-7000	-25000	-10000	-25000	-10000	-15000	4000	-3000	5000	
EYLÜL	-5000	0	-5000	0	-20000	-5000	-20000	-5000	-15000	-4000	0	2000	
KASIM	-10000	-2000	-10000	-9000	-30000	-10000	-30000	-10000	-15000	-2000	-5000	4000	
OCAK	0	1	0	1	0	1	0	1	0	1	-1	0	BI
NİSAN	-0.5	0.05	-0.5	0.05	-0.5	1	-0.5	1	0	1	-1	0	
HAZİRAN	-1	0	-1	0	0	1	0	1	0	1	-1	0	
EYLÜL	-1	0	-1	0	-0.5	1	-0.5	1	-0.5	0.5	-1	0	
KASIM	-1	0	-1	0	0	0.5	0	0.5	0	1	-1	0	
OCAK	0	500	0	500	500	5000	500	5000	500	5000	0	1500	Mavi
NİSAN	0	600	0	600	1000	5000	1000	5000	1000	10000	0	1000	
HAZİRAN	0	600	0	600	1000	5000	1000	5000	1000	10000	0	1000	
EYLÜL	0	500	0	500	500	5000	500	5000	1000	9000	0	500	
KASIM	0	600	0	600	1000	6000	1000	6000	1000	5000	0	1000	
OCAK	-5000	-1000	-5000	-1000	-1500	500	-1500	500	-1000	1000	0	2000	EGI
NİSAN	-5000	-1000	-5000	-1000	-4000	0	-2500	0	-1000	6000	0	2000	
HAZİRAN	-5000	-1000	-5000	-2000	-2500	0	-2500	0	-3000	2000	0	2000	
EYLÜL	-3000	-500	-3000	-500	-500	0	-500	0	-1500	0	0	1000	
KASIM	-4000	-1000	-4000	-1000	-4000	-1500	-4000	-1500	-1500	0	0	2000	
OCAK	0	500	0	1000	1000	3000	1000	3000	300	6000	0	2000	YEŞİL
NİSAN	0	1000	0	1000	500	5000	500	5000	1200	12000	0	2000	
HAZİRAN	0	1500	0	2000	1500	5000	1500	5000	2000	10000	0	800	
EYLÜL	0	1000	0	1000	500	5000	500	5000	500	5000	0	400	
KASIM	0	1000	0	1500	1500	3000	1500	3000	1200	12000	0	800	
OCAK	-3000	-100	-3000	-100	-13000	-3000	-13000	-3000	-15000	-3000	-2000	200	GVI

NİSAN	-3000	-100	-3000	-100	-6000	-2000	-6000	-2000	-50000	-5000	-2000	500	
HAZİRAN	-3000	-100	-3000	-100	-15000	-3000	-15000	-3000	-50000	-3000	-2000	100	
EYLÜL	-2000	0	-2000	0	-5000	-1000	-5000	-1000	-30000	-1000	-2000	0	
KASIM	-2500	0	-2500	0	-7000	-2000	-7000	-2000	-35000	-3500	-2000	0	
OCAK	-3000	0	-3000	300	500	3000	500	3000	500	4000	0	500	MSBI
NİSAN	-3000	500	-300	1000	1000	6000	1000	6000	-900	3000	-9000	1000	
HAZİRAN	-3000	0	0	2000	1000	6000	1000	6000	1000	7000	0	1000	
EYLÜL	-3000	0	-3000	50	300	2000	300	2000	100	4000	0	200	
KASIM	-2500	1000	-2500	1000	1000	3000	1000	3000	0	2500	0	500	NBR
OCAK	0	1	0	1	-0.1	0.2	-0.1	0.2	-0.3	0.3	0	1	
NİSAN	0	0.5	0	0.5	-1	0	-1	0	-0.5	0	-0.3	1	
HAZİRAN	0	1	0	1	-1	0	-1	0	-0.5	0.5	-1	0.5	
EYLÜL	0	1	0	1	-1	0	-1	0	-0.5	0.5	-1	0	NDSI
KASIM	0	0.6	0	0.6	-0.5	0	-0.5	0	0	0.4	-0.05	0.3	
OCAK	-1	-0.3	-1	-0.3	-0.35	0	-0.35	0	-0.3	0.3	0	1	
NİSAN	-1	-0.3	-1	-0.3	-0.5	0	-0.5	0	-0.4	0.2	0	1	
HAZİRAN	-1	-0.4	-1	-0.4	-0.5	0	-0.5	0	-0.3	0.5	0	1	NDVI
EYLÜL	-1	-0.4	-1	-0.4	-0.5	0	-0.5	0	-0.3	0.5	0	1	
KASIM	-0.5	0	-0.5	0	-0.5	0	-0.5	0	-0.5	0	0	1	
OCAK	0.3	1	0.3	1	0	0.5	0	0.5	-0.1	0.3	-1	0	
NİSAN	0.3	1	0.3	1	-0.5	0	-0.5	0	-0.5	0	-1	0	NDWI
HAZİRAN	0.5	1	0.5	1	-0.5	0.2	-0.5	0.2	-0.1	0.3	-1	0.3	
EYLÜL	0.5	1	0.5	1	-0.04	0.6	-0.04	0.6	-0.6	0.3	-1	0	
KASIM	0.3	1	0.3	1	0	0.2	0	0.2	-0.1	0.3	-1	0.3	
OCAK	-1	-0.4	-1	-0.4	-0.5	0	-0.5	0	-0.5	0.1	0	1	NRAVI
NİSAN	-1	-0.4	-1	-0.4	-0.2	0.5	-0.2	0.5	-0.5	0.4	-0.2	1	
HAZİRAN	-1	-0.4	-1	-0.4	-0.5	0	-0.5	0	-0.5	0.1	0	1	
EYLÜL	-1	-0.5	-1	-0.5	-0.6	0	-0.6	0	-0.6	0.2	0.5	1	
KASIM	-1	-0.4	-1	-0.4	-0.5	-0.05	-0.5	-0.05	-0.5	0.1	0	1	
OCAK	0	1	0	1	-1	0	-1	0	-1	0.03	0	20	
NİSAN	0	1	0	1	-1	0	-1	0	-1	0	0	2	
HAZİRAN	0	0.5	0	0.5	-0.2	0	-0.2	0	-0.2	0	0	50	
EYLÜL	0	0.5	0	0.5	-1	0	1	0	-1	0	0	200	
KASIM	0	0.5	0	0.5	-1	0	1	0	-1	0.03	0	20	

OCAK	0.4	1	0.4	1	0	0.4	0	0.4	-0.03	0.2	-1	0	OSAVI
NİSAN	0.2	1	0.2	1	-0.3	0.4	-0.3	0.4	-0.3	0.5	-0.5	1	
HAZİRAN	0.4	1	0.4	1	0	0.4	0	0.4	0	0.4	-1	0.4	
EYLÜL	0.4	1	0.4	1	0	0.7	0	0.7	-0.2	0.5	-1	0	
KASIM	0.4	1	0.4	1	0	0.4	0	0.4	-0.2	0.5	-1	0.1	
OCAK	-1000	0	-500	0	-1000	-500	-1000	-500	-2000	-300	-180	0	SATVI
NİSAN	-1000	0	-1000	0	-3000	-1000	-3000	-1000	-3000	-1000	-200	0	
HAZİRAN	-600	0	-1000	0	-3000	-1000	-3000	-1000	-7000	-1000	-300	0	
EYLÜL	-600	0	-1000	0	-2000	-650	-2000	-650	-3000	-500	-200	0	
KASIM	-600	0	-1000	0	-2000	-800	-2000	-800	-2000	-500	-200	0	
OCAK	0.5	3	0.5	4	0	0.5	0	0.5	-0.5	0.5	-2	0.2	REM
NİSAN	0.5	3	0.5	4	0	0.5	0	0.5	-0.2	0.4	-1	0	
HAZİRAN	0.5	5	1	10	-0.03	0.5	-0.03	0.5	-0.1	0.5	-5	0.2	
EYLÜL	0.5	5	0.1	2	0.1	1	0.1	1	-0.5	0.5	-0.5	0	
KASIM	0.5	5	0.5	5	-0.04	0.5	-0.04	0.5	-0.5	0.5	-0.5	0	
OCAK	0.5	3	0.5	3	0.1	0.5	0.1	0.5	-0.09	0.5	-2	0.3	SAWI
NİSAN	0.5	3	0.5	3	-0.5	0.2	-0.5	0.2	-1.5	0	-1	1.5	
HAZİRAN	0.5	3	0.5	3	-0.5	0.5	-0.5	0.5	-0.5	0.5	-2	0	
EYLÜL	0.5	2	0.5	2	-0.5	0.5	-0.5	0.5	-0.5	0.5	-1.5	0	
KASIM	0.5	2	0.5	2	-0.5	0.5	-0.5	0.5	0	0.5	-1	0.3	
OCAK	-1500	600	-1500	600	-2000	300	-2000	300	-3000	2000	0	600	WETNESS
NİSAN	-1500	600	-1500	600	-2500	-800	-2500	-800	-8000	300	0	1200	
HAZİRAN	-2000	600	-2000	600	-3000	-1000	-3000	-1000	-3000	2000	0	600	
EYLÜL	-800	0	-1000	500	-2000	-800	-2000	-800	-2000	0	0	200	
KASIM	-1200	300	-900	300	-3000	-800	-3000	-800	-2000	0	0	900	