



T.C.

**ÇANAKKALE ONSEKİZ MART ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

COĞRAFI BİLGİ TEKNOLOJİLERİ ANABİLİM DALI

**KIYI ŞERİDİ ARAZİ KULLANIM VE BİTKİ ÖRTÜSÜ DEĞİŞİM
DİNAMİĞİNİN UYDU VERİLERİ YARDIMIYLA BELİRLENMESİ:
GÜNEY-DOĞU MARMARA ÖRNEĞİ**

YÜKSEK LİSANS TEZİ

EDA AŞCI

Tez Danışmanı

PROF. DR. LEVENT GENÇ

ÇANAKKALE – 2023



T.C.

ÇANAKKALE ONSEKİZ MART ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

COĞRAFİ BİLGİ TEKNOLOJİLERİ ANABİLİM DALI

**KIYI ŞERİDİ ARAZİ KULLANIM VE BİTKİ ÖRTÜSÜ DEĞİŞİM
DİNAMİĞİNİN UYDU VERİLERİ YARDIMIYLA BELİRLENMESİ:
GÜNEY-DOĞU MARMARA ÖRNEĞİ**

YÜKSEK LİSANS TEZİ

EDA AŞCI

Tez Danışmanı
PROF. DR. LEVENT GENÇ

ÇANAKKALE – 2023

ETİK BEYAN

Çanakkale Onsekiz Mart Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kuralları'na uygun olarak hazırladığım bu tez çalışmada; tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi, tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu, tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi, kullanılan verilerde herhangi bir değişiklik yapmadığımı, bu tezde sunduğum çalışmanın özgün olduğunu, bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi taahhüt ve beyan ederim.

Eda AŞCI
19/09/2023

TEŐEKKÜR

Öncelikle tez yazma aşamasında sonsuz sabrıyla her daim yanımda olan, yaşamın ancak iyilikle ilerleyebildiğini ve bu zor yolculukta sorunların çözümüne dair önemli bilgileri öğrendiğim, meslek hayatımda ve akademide yapacağım işe daha çok bağlanmamı sağlayan saygıdeğer hocam Prof. Dr. Levent GENÇ' e teşekkürlerimi sunuyorum. Çalışma boyunca zamansız katkılarından ve başarılı bir akademisyen olmanın örneđi olan hocam Dr. Melis İNALPULAT' a teşekkür ederim. Her zaman sonsuz güven duygularıyla beni desteklemenin de ötesinde oldukları için, öncelikle yoluma ışık olan dedem Yaşar Faris AŐCI'ye, beni yetiştiren babam Mehmet Nasip AŐCI, annem Saniye AŐCI ve ablalarım Ayşe ŐEN ve Çađla BEYAZOĐLU' na minnettarım, siz olmadan olmazdı. Bu zor süreçte uzakları yakın ederek, mesleki yardımlarını hiç esirgemeyen kıymetli yol arkadaşım Nejdet DEREBEY'e, motivasyonumu diri tutan canım dostlarım Merve YILMAZ' a, bana sınırsız deđer katan Melike DEMİREL' e ve desteklerini hep neşeli şekilde hissettiren ComAgEnPlan laboratuvar ekibimize çok teşekkür ederim.”

Eda AŐCI
Çanakkale, Ağustos 2023

ÖZET

KIYI ŞERİDİ ARAZİ KULLANIM VE BİTKİ ÖRTÜSÜ DEĞİŞİM DİNAMİĞİNİN UYDU VERİLERİ YARDIMIYLA BELİRLENMESİ: GÜNEY-DOĞU MARMARA ÖRNEĞİ

Eda AŞCI

Çanakkale Onsekiz Mart Üniversitesi

Lisansüstü Eğitim Enstitüsü

Coğrafi Bilgi Teknolojileri Anabilim Dalı Yüksek Lisans Tezi

Danışman: Prof. Dr. Levent GENÇ

25/08/2023, 112

Arazi Kullanım ve Bitki Örtüsü(AKBÖ) dinamikleri hızlı nüfus artışı ve göçün, gelişmekteki yatırım bölgelerine ilerlemesiyle dengesiz olarak artmaktadır. Kontrolsüz kentsel büyüme vejetasyonda değişimlere, ekonomik ve çevresel sorunlara sebep olmaktadır. Dolayısıyla değişimlerin etkisi özellikle kıyı bölgelerinde önem kazanmaktadır. Öyle ki Türkiye'nin iç denizi olan Marmara Denizi gelişmelerden derinden etkilenmekte ve deniz etrafındaki bitki örtüsündeki değişimin kaçınılmaz olduğu anlaşılmaktadır. Ülkemizde sanayi bölgesi olarak bilinen ve TOGG fabrikasının yapımı ile yatırımları canlandıracağı düşünülen Güney-Doğu Marmara bölgesi çalışma alanı olarak belirlenmiştir. Çalışmada Yalova ili Armutlu ilçesi ve Bursa ili Osmangazi, Mudanya ve Gemlik ilçelerinde sahil bandından karaya doğru 5 km'lik tampon bölge seçilerek, 2016 ve 2020 yıllarında 3 sezon sınıflandırma işlemi uygulanmıştır. Sentinel-2A' da orijinal 10 banda Rastgele Orman(RF) ve Nesne Tabanlı Sınıflandırma teknikleri, 21 tane indeksle oluşturulan görüntülere ve Ana Bileşenler ile oluşturulan görüntülere RF sınıflandırması uygulanmıştır. ArcGIS programıyla hesaplanan yer yüzey sıcaklığı değerleri AKBÖ sonuçları, 4 meteoroloji istasyonu ve Google Earth Engine verileriyle karşılaştırılmıştır. AKBÖ ve yer yüzey sıcaklığı ile sosyoekonomik değişimlerin ilişkilendirilmesi ve meteorolojik verilerle anlamlandırılmasıyla kentsel planlama ve gelişme potansiyelinin belirlenmesi amaçlanmıştır. Çalışma 2016 kış, ilkbahar ve yaz sezonları için en yüksek doğruluğu OI₁₂, ORO ve yine ORO; 2020'de OI₅, ORO ve OI₆ sınıflandırmalarında göstermiştir. Güney-Doğu Marmara'da bulunan zeytin ve yerleşim

alanlarının yıllar içindeki deęişiminin nüfus artışı ve çeşitli yatırım kararları ile oluştuęu sonucuna varılmıştır. Çalışmada ayrıca yer yüzey sıcaklığı verileri ile AKBÖ verileri karşılaştırılmış, 3 sezonda bitki örtüsünün sıcaklığı düşürdüęü anlaşılmıştır.

Anahtar Kelimeler: Arazi Kullanımı/Bitki Örtüsü, Yer Yüzey Sıcaklığı, Sentinel-2A, Güney-Doęu Marmara, NDVI, Uzaktan Algılama



ABSTRACT

DETERMINATION OF LAND USE AND VEGETATION COVER CHANGE DYNAMICS OF THE COASTLINE WITH USING SATELLITE DATA: THE CASE OF SOUTH-EAST MARMARA

Eda Aşci

Canakkale Onsekiz Mart University

School of Graduate Studies

Master of Science Thesis in Geographic Information Technologies

Prof. Dr. Levent GENC

25/08/2023, 112

Land Use and Land Cover (LULC) dynamics are unevenly increasing due to rapid population growth and migration to developing investment areas. Uncontrolled urban growth leads to changes in vegetation, economic and environmental problems. Therefore, the impact of these changes is particularly important in coastal areas. In fact, the Marmara Sea, which is the inland sea of Turkey, is deeply affected by the developments and it is understood that the change in vegetation around the sea is inevitable. The South-Eastern Marmara region, which is known as an industrial region in our country and is thought to revitalize investments with the construction of the TOGG factory, was determined as the study area. In the study, a 5 km buffer zone from the coastal band to the land in Armutlu district of Yalova province and Osmangazi, Mudanya and Gemlik districts of Bursa province was selected and 3 seasons classification process was applied in 2016 and 2020. In Sentinel-2A, Random Forest (RF) and Object Based Classification techniques were applied to the original 10 bands, and RF classification was applied to images created with 21 indices and images created with Principal Components. Land surface temperature values calculated with ArcGIS program were compared with the results of LULC, 4 meteorological stations and Google Earth Engine data. It is aimed to determine the urban planning and development potential by associating socio-economic changes with LULC and ground surface temperature and making sense of meteorological data. The study showed the highest accuracy for the winter, spring and summer seasons of 2016 in the OI₁₂, ORO and again ORO classifications, and in 2020 in the OI₅, ORO and OI₆ classifications. It is concluded that the change in olive and settlement areas in South-

East Marmara over the years is caused by population growth and various investment decisions. In the study, ground surface temperature data were also compared with LULC data, and it was understood that vegetation cover decreased the temperature in 3 seasons.

Keywords: Land Use/Land Cover, Land Surface Temperature, Sentinel-2A, The South-East Marmara, NDVI, Remote Sensing



İÇİNDEKİLER

Sayfa No

ETİK BEYAN.....	i
TEŞEKKÜR.....	ii
ÖZET	iii
ABSTRACT	iv
İÇİNDEKİLER	vii
SİMGELER ve KISALTMALAR.....	ix
TABLolar DİZİNİ.....	x
ŞEKİLLER DİZİNİ.....	xii

BİRİNCİ BÖLÜM

GİRİŞ

1

İKİNCİ BÖLÜM

ÖNCEKİ ÇALIŞMALAR

4

ÜÇÜNCÜ BÖLÜM

MATERYAL YÖNTEM

13

3.1. Çalışma Alanı	13
3.1.1. İklim	15
3.2. Yazılım / Program	16
3.3. Uydu Görüntüleri	17
3.3.1. Sentinel – 2A	17
3.3.2. Landsat – 8 OLI / TIRS	18
3.4. Yöntem	19
3.4.1. Sınıflama Öncesi İşlemler	21
3.4.2. Sınıflandırma	22
Kontrollü Sınıflandırma	25
Nesne Tabanlı Sınıflandırma	28
İndeks ile Sınıflandırma	30

Ana Bileşenler Analizi ile Sınıflandırma	31
3.5. Yer Yüzey Sıcaklığı	32
3.6. Doğruluk Analizi	35
3.7. Sosyoekonomik Verilerin Toplanması	33
DÖRDÜNCÜ BÖLÜM	
ARAŞTIRMA BULGULARI	
4.1. AKBÖ Sınıflama Sonuçları.....	38
4.1.1. Yıllara Göre Alan Sonuçları	38
4.1.2. AKBÖ Sınıflandırmasının Doğruluk Analizi Sonuçları	74
4.2. YYS Sonuçları	79
4.3. YYS – AKBÖ İlişkisi	90
BEŞİNCİ BÖLÜM	
SONUÇ ve ÖNERİLER	
KAYNAKÇA	99

SİMGELER VE KISALTMALAR

AB	Ana Bileşen
ABA	Ana Bileşenler Analizi
AKBÖ	Arazi Kullanım Bitki Örtüsü
CBS	Coğrafi Bilgi Teknolojileri
EPR	Son Nokta Oranı
ESA	Avrupa Uzay Ajansı
GEE	Google Earth Engine
GHKM	Guangdong, Hong Kong ve Makao Bölgesi
GSYH	Gayri Safi Yerli Hasıla
KBÖ	Kısmi Bitki Örtüsü
LLR	Doğrusal Çizgi Oranı
MGM	Meteoroloji Genel Müdürlüğü
MNDWI	Modifiye Edilmiş Normalleştirilmiş Fark Su İndeksi
NASA	Ulusal Havacılık ve Uzay Dairesi
NDVI	Normalleştirilmiş Fark Bitki İndeksi
NTS	Nesne Tabanlı Sınıflandırma
OLI	Operasyonel Arazi Görüntüleyici
RO	Rastgele Orman
TIR	Termal Kızılötesi
TIRS	Termal Kızılötesi Sensör
TL	Türk Lirası
TM	Tematik Haritalayıcı
TOGG	Türkiye'nin Otomobil Girişim Grubu
TÜİK	Türkiye İstatistik Kurumu
UA	Uzaktan Algılama
USGS	Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu
VIR	Görünür Kızılötesi
YYE	Yer Yüzey Emissivitesi
YYS	Yer Yüzey Sıcaklığı

TABLULAR DİZİNİ

Tablo No	Tablo Adı	Sayfa No
Tablo 1	Çalışma alanında bulunan köy ve mahallelerin listesi	11
Tablo 2	Meteorolojik istasyonların bilgisi	13
Tablo 3	Sentinel-2A uydusundan elde edilen görüntülerin tarihleri	15
Tablo 4	Sentinel-2A uydusunun teknik özellikleri	15
Tablo 5	Landsat-8 TIRS uydusundan elde edilen görüntülerin tarihleri	16
Tablo 6	Landsat-8 OLI/TIRS uydusunun teknik özellikleri	16
Tablo 7	Sınıflandırmada kullanılan bantlar ve özellikleri	20
Tablo 8	Sınıflandırmada kullanılan bantlar ve özellikleri-2	21
Tablo 9	2016 yılı için sınıflamaların doğruluk analizi sonuçları (yeşil: en yüksek, mavi: en düşük)	76
Tablo 10	2020 yılı için sınıflamaların doğruluk analizi sonuçları (yeşil: en yüksek, mavi: en düşük)	77
Tablo 11	Sınıflandırma sonucunda en yüksek doğrulukta çıkan kombinasyonların alanlarının (ha) değişimi	78
Tablo 12	2016 kış sezonu arazi sınıflarının düşük ve yüksek sıcaklıkları	84
Tablo 13	2016 bahar sezonu arazi sınıflarının düşük ve yüksek sıcaklıkları	84
Tablo 14	2016 yaz sezonu arazi sınıflarının düşük ve yüksek sıcaklıkları	84
Tablo 15	2020 kış sezonu arazi sınıflarının düşük ve yüksek sıcaklıkları	85
Tablo 16	2020 bahar sezonu arazi sınıflarının düşük ve yüksek sıcaklıkları	85
Tablo 17	2020 yaz sezonu arazi sınıflarının düşük ve yüksek sıcaklıkları	85
Tablo 18	2016 yılı için R ² cinsinden sınıfların değerleri (kış ilkbahar, yaz)	89

Tablo 19	2020 yılı için R ² cinsinden sınıfların deęerleri (kış, ilkbahar, yaz)	89
Tablo 20	2016-2020 yılları arasında arazi sınıflarına göre sıcaklık deęişimi (°C bazında)	91
Tablo 21	2016 - 2020 yıllarındaki sınıflara göre alan deęişimi (% bazında)	92



ŞEKİLLER DİZİNİ

Şekil No	Şekil Adı	Sayfa No
Şekil 1	Çalışmaya ait akış şeması	9
Şekil 2	Çalışma alanı	10
Şekil 3	Çalışma alanına ait arazi görüntüleri (a), (b), (c), (d), (e), (f)	12
Şekil 4	Çalışma alanında bulunan meteorolojik istasyonların gösterimi	13
Şekil 5	Sentinel-2A uydusundan elde edilen görüntülerle sınıflama süreci	17
Şekil 6	RO sınıflandırma tekniğinin ağaç yapısının gösterimi	22
Şekil 7	NTS sınıflandırma tekniğinin segmentasyon kriterleri	26
Şekil 8	ABA işleminde elde edilen AB'lerin X koordinatlarında gösterimi	28
Şekil 9	ABA işleminde elde edilen ABA'ların Y koordinatlarında gösterimi	29
Şekil 10	Landsat-8 TIRS verilerinden elde edilen YYS haritalarının oluş şeması	30
Şekil 11	Çalışma alanındaki yer kontrol noktalarının gösterimi	33
Şekil 12	2016-2020 yıllarında gelişen önemli olaylar	34
Şekil 13	2016-2020 yıllarında ülke düzeyinde nüfus artışı ve artış hızı sayısal gösterimi	35
Şekil 14	2016-2020 yıllarında çalışma alanına ait nüfus artışı ve artış hızı sayısal gösterimi	35
Şekil 15	2016 yılında Dolar ve Euro (a), 2020 yılında Dolar ve Euro (b) düzeyinde kur değişim	36
Şekil 16	2016 (a) – 2020 (b) yıllarında sektörlerdeki cari fiyatlarla GSYH yüzdelik paylarının gösterimi	37

Şekil 17	O _{RO} / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	45
Şekil 18	O _{NTS} / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	46
Şekil 19	O _{I5} / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	47
Şekil 20	O _{I6} / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	48
Şekil 21	O _{I7} / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	49
Şekil 22	O _{I8} / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	50
Şekil 23	O _{I8a} / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	51
Şekil 24	O _{I11} / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	52
Şekil 25	O _{I12} / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	53
Şekil 26	O _{I5BO6} / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	54
Şekil 27	O _{I5BO7} / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	55
Şekil 28	O _{I6BO6} / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	56
Şekil 29	O _{I6BO7} / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	57
Şekil 30	O _{I7BO6} / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	58
Şekil 31	O _{I7BO7} / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	59
Şekil 32	O _{I8BO6} / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	60
Şekil 33	O _{I8BO7} / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	61

Şekil 34	Oİ _{8a} BO ₆ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	62
Şekil 35	Oİ _{8a} BO ₇ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	63
Şekil 36	Oİ ₁₁ BO ₆ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	64
Şekil 37	Oİ ₁₁ BO ₇ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	65
Şekil 38	Oİ ₁₂ BO ₆ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	66
Şekil 39	Oİ ₁₂ BO ₇ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz	67
Şekil 40	Sınıflandırma işlemindeki kompozit indekslerin grafiklerinin toplu gösterimi (2016)	68
Şekil 41	Sınıflandırma işlemindeki kompozit indekslerin grafiklerinin toplu gösterimi (2020)	71
Şekil 42	Tüm sınıflamaların doğruluk analizi sonuçlarının zamansal olarak gösterimi	75
Şekil 43	(a1, a2) 2016 kış sezonu, (b1, b2) 2016 bahar sezonu, (c1, c2) 2016 yaz sezonu, (YYSArcGIS, YYS _{GEE})	81
Şekil 44	(a1, a2) 2020 kış sezonu, (b1, b2) 2020 bahar sezonu, (c1, c2) 2020 yaz sezonu, (YYSArcGIS, YYS _{GEE})	82
Şekil 45	2015-2020 arasında hesaplanan yer yüzey sıcaklığı grafikleri	83
Şekil 46	YYSArcGIS için noktasal sıcaklıklar; (a1-a2) 2016 kış sezonu, (b1-b2) 2016 bahar sezonu, (c1-c2) 2016 yaz sezonu	88
Şekil 47	YYSArcGIS için noktasal sıcaklıklar; (a1-a2) 2020 kış sezonu, (b1-b2) 2020 bahar sezonu, (c1-c2) 2020 yaz sezonu	88

BİRİNCİ BÖLÜM

GİRİŞ

Bölgesel ve küresel ölçekte, doğal nedenler, insan kaynaklı olaylar ve sosyoekonomik durumlarla gelişen (Anand ve Oinam, 2020) ekolojik değişimler (Tadese vd., 2020) Arazi Kullanım ve Bitki Örtüsü (AKBÖ) dinamiklerinin incelenmesiyle anlaşılmaktadır. Bölgesel düzeyde AKBÖ değişimleri düzensiz nüfus artışı ve göçün sanayii alanlarına olması nedeniyle hızlı veya kontrolsüz olarak gerçekleşebilmektedir. Göç ile kontrolsüz şekilde artan nüfus bu bölgelerde sosyoekonomik ve insan kaynaklı ihtiyaçlar nedeniyle yapılaşmanın beklenmedik artışında, vejetasyonun düzensiz dağılışında ve yöre ekonomisinde değişen durumlar yaratmaktadır. Bu nedenlerle AKBÖ değişiminin anlaşılması; kentsel gelişimin doğal ekosisteme yaptığı baskı ile oluşan dönüşümleri belirlemek için kritik öneme sahiptir (Chandra Pandey vd., 2019).

Kentlerin kıyı bölgelerinde AKBÖ değişimlerinin araştırılması büyük bir öneme sahiptir (Batunacun vd., 2018; Sundarakumar vd., 2012). Özellikle Türkiye'nin tek iç denizi olan Marmara kıyılarında kentsel gelişime bağlı olarak meydana gelen AKBÖ değişimleri çevre açısından da araştırılmalıdır. Öyle ki Marmara Denizi'nde çevre kirliliğinin sebeplerinin (kentleşme, sanayileşme faaliyetleri, düzensiz göç hareketleri ile) artışı ile oluşan müsülaj vakası AKBÖ değişimine örnek olmaktadır (Colkesen vd., n.d.; Genc vd., 2021; Kavzoglu vd., 2023). Özellikle, Bursa ili gelişimin dinamik olduğu ve daha önceki tarihlerde iki araba fabrikasını geçmiş hafızasında taşıyan, limanlara yakınlığı ile taşımada ve ulaşımda zorluğun olmadığı ve buna bağlı olarak aktif sanayi faaliyetleri ile, kıyı bölgelerinde nüfusun hızlıca artmasına ve sosyoekonomik yapıda değişimlere dolayısıyla da AKBÖ değişimlerine neden olmaktadır. AKBÖ değişimleri ile ilgili uluslararası programlarda kentsel alanlarla ilgili gelişme ve değişimleri araştırmak üzere çok sayıda çalışma yapılmıştır (Aggarwal, 2004; Inalpulat ve Genc, 2021; Mallupattu ve Sreenivasula Reddy, 2013). Bu değişim sonucu ortaya çıkan durumun belirlenmesinde son 50 yıldır Uzaktan Algılama (UA) teknolojisi yoğun olarak kullanılmaktadır (Chaudhry vd., 2015; Feng vd., 2015; Ok vd., 2017; Sobrino ve Raissouni, 2000; Wong vd., 2021).

AKBÖ değişimlerinin orta mekânsal çözünürlüğe (10-30 m) sahip görüntülerle ucuz ve hızlı bir şekilde erişim sağlanan Landsat (Ulusal Havacılık ve Uzay Dairesi (NASA)) görünür ve kızılötesi (VIR ve TIR) serisi ve Sentinel-1-2 (Avrupa Uzay Ajansı (ESA))

görüntüleri sıkça kullanılmaktadır (Hu vd., 2021). AKBÖ dinamiklerinin belirlenmesi açısından nicel veriler üretmede UA ile birlikte Coğrafi Bilgi Sistem (CBS) teknikleri kullanılmaktadır (Dewidar, 2010; Joshi vd., 2011; Phiri vd., 2020).

Lokal düzeyde değişimlerin belirlenmesi, sosyoekonomik strateji planlarının yapılması açısından bölgesel ve hatta ulusal düzeydeki AKBÖ değişimlerinin başlangıç noktaları olması nedeni ile oldukça önemlidir. Bu alanların yeni yatırım alanları, sanayi bölgeleri ve kıyı şeritleri ile çakışması ayrıca AKBÖ değişimlerini önemli kılmaktadır. Bilgi teknolojilerindeki (UA ve CBS gibi) baş döndürücü değişim, uluslararası düzeyde kentsel alanlar ve kıyı bölgelerindeki AKBÖ değişim çalışmalarını da hızlandırmıştır (Y. Liu ve Chen, 2021). Dang vd., (2021)'de Vietnam'da, 4 ayrı yılın UA görüntülerini kullanıp kıyı değişimini belirleyerek sosyoekonomik ve çevresel durumun anlaşılmasında kullanmıştır. Birçok çalışmada farklı UA teknikleri kullanarak görüntülerden maksimum doğruluğu elde edeceğimiz matematiksel ve istatistiksel çıkarımlar yardımıyla, görüntülerin sınıflandırılması gerçekleştirilir. Xianju vd., (2017)'de ise Çin'in Dunhuang havzasında yaptığı araştırmada, orijinal bantlara kırmızı kenar bandını ekleyerek analiz yapmıştır ve çıktılar bitki örtüsü varlığı açısından daha yüksek doğruluk değeri vermiştir. Ayrıca ülkemizde, yapılan çalışmalardan bazıları bölgesel düzeyde yapılmış fakat sonuçlarının stratejik planlara ve geleceğe yönelik yönetsel çıktılara dönüşmesi için daha detaylı ve farklı ölçekte çalışmalar yapılması gerekliliği doğmuştur. Asci vd., (2021)'de yapmış olduğu çalışmada Bursa ili merkez ilçeleri AKBÖ haritaları üretilerek ormanlık alanlarda meydana gelen değişiklikleri araştırmışlardır. Yiğit vd., (2022)'de Marmara Gölü'nün kıyı şeridi ve çevresindeki değişimleri 1985-2020 arasında 5'er yıllık periyotlarda modifiye edilmiş normalleştirilmiş fark su indeksini (MNDWI) ve nesne tabanlı sınıflandırma (NTS) tekniğini kullanarak, doğrusal regresyon oranı ve son nokta oranı (EPR, LRR) gibi istatistiksel yöntemlerle analiz etmişlerdir.

AKBÖ değişimlerini hedefe yönelik görüntü oluşturma amaçlı, farklı indeksler ve istatistiksel yöntemler kullanılarak Rastgele Orman (RO) (Chehata vd., 2009; Nguyen vd., 2020; Scornet, 2015) ve NTS (Blaschke, 2010; Wang vd., 2004; Ye vd., 2018) gibi farklı sınıflandırma teknikleri ile işlemler yapılacaktır. Ayrıca Yer Yüzey Sıcaklığı (YYS) değişim hesaplamalarını, AKBÖ değişimi ile ilişkilendirmek ve oluşan düzensiz değişimin YYS'ye olan etkisi ile arazi sınıfları arasındaki ilişkinin önemli olduğu düşünülerek meteorolojik veriler yardımıyla açıklanmaya çalışılacaktır.

Ülkemizde uzun yıllardır serbest sanayi bölgesi olan ve 18 Temmuz 2020 yılında TOGG araç üretim fabrikasının yapımıyla birlikte başka yatırımlara neden olacağı öngörülen Güney-Doğu Marmara bölgesi çalışma alanı olarak belirlenmiştir. Çalışmada, Güney-Doğu Marmara sınırları içinde yer alan Yalova ili Armutlu ilçesi ve Bursa ili Osmangazi, Mudanya ve Gemlik ilçeleri sahil bandı referans alınarak oluşturulan 5 km'lik tampon bölgede 2016 ve 2020 yıllarındaki 3 sezonluk (kış, ilkbahar ve yaz) AKBÖ sınıflandırması gerçekleştirilmiştir.

Çalışma, 2016 ve 2020 periyodunda sahil bandında meydana gelen AKBÖ ve YYS değişiminin sosyoekonomik veriler arasındaki ilişkilerinin belirlenmesi ve meteorolojik veriler dikkate alınarak kentsel planlama ve gelişme potansiyelinin belirlenmesi amaçlanmıştır.

Çalışmada amaca ulaşmak için üç hedef belirlenmiştir. Bunlar;

a) Çalışma alanı ve sahil bandındaki değişim, uydu görüntülerinden elde edilen orjinal on bant kompozitinin Rastgele Orman (RO) ve Nesne Tabanlı Sınıflandırma (NTS) ile, farklı vejetatif indeksler ile oluşturulan görüntü kombinasyonlarının ve Ana Bileşenler Analizi ile elde edilen görüntülerin RO tekniğinin yardımı ile sınıflandırılarak en yüksek doğruluk analizinin olduğu kombinasyonun araştırılması (Bu amaçla AKBÖ sınıfları; Mera(M), Orman (O), Su alanları (S), Tarım (T), Yerleşim Alanları (Y) ve Zeytin (Z) olarak belirlenmiştir)

b) Elde edilen en yüksek doğruluktaki harita verileriyle mevcut sosyoekonomik verilerin değişimi anlamlandırılması ve

c) Mevcut meteorolojik veriler yardımıyla çalışma alanına ait AKBÖ ile YYS ilişkilendirilmesi, YYS işleminde ArcGIS yazılımı ve Google Earth Engine makine öğrenimi karşılaştırılarak alandaki değişimin belirlenmesidir.

İKİNCİ BÖLÜM

ÖNCEKİ ÇALIŞMALAR

AKBÖ analizlerinde kullanılan arazi kullanımı kavramı, araştırmada belirlenen alanın insan etkisi ile ortaya çıkan durumunu ifade ederken; bitki örtüsü kavramı kullanılan arazi örtüsü özelliklerini tanımlamaktadır. Yeryüzünün tamamında AKBÖ değişimini belirlemede UA ve CBS yardımıyla yapılmış çalışmalar oldukça yaygındır. Birçok araştırmacı uluslararası literatürde UA ve CBS kullanarak AKBÖ değişimini anlamak için çalışmalar yapmışlardır (Chaudhry vd., 2015; Q. Wu vd., 2006; Xiuwan, 2002). Uygun sınıflama yapmak ve sonucunda sınıflama doğruluğunu geliştirmek amacıyla farklı tekniklerin karşılaştırıldığı (Alshari ve Gawali, 2021) çalışmaların yanında Ana Bileşenler Analizi (ABA) gibi teknikler ve doğrudan sınıflandırma metriklerinin kullanıldığı yaklaşımlar sıkça kullanılmıştır (Baysal, 2006; Dengiz ve Demirağ Turan, 2014; Lawrence vd., 2006; D. Liu ve Xia, 2010; Pal, 2005; Qu vd., 2021). AKBÖ değişimini anlamak için Sentinel-2A ve Landsat-8 Operasyonel Arazi Görüntüleyici (OLI) ve Termal Kızılötesi Sensör (TIRS) gibi açık erişimli uydu görüntüleri kullanılarak, çeşitli sınıflandırma teknikleri (RO ve NTS) ile farklı nitelikleri ortaya çıkaran matematiksel işlemler, istatistiksel modeller ile sınıflandırma ve doğruluk analizi yapılmaktadır.

Yapılan AKBÖ belirleme çalışmalarının ortak noktası, değişik yöntemlerle alan hakkında sayısal ve analiz edilebilir veri üretimi yanında üretilen verilerin analizi ile mevcut durumun anlaşılması, geçmiş ve gelecekle olan ilişkisinin daha hızlı ve ekonomik olarak belirlenmesidir. Bu amaçla Sentinel-2A ve Landsat-5 Tematik Haritalayıcı (TM) verileri kullanılarak Himalayalar'da (Mishra vd., 2020) 1988–1996, 1996–2008 ve 2008–2017 dönemlerinde üretilen haritalar aracılığı ile AKBÖ değişikliklerin izlenmesi için denetimli sınıflandırma yöntemi kullanılmıştır. Dewidar, (2010) sahil yolu inşaat ile oluşan AKBÖ değişikliklerinin tespiti için Landsat-5 TM görüntülerinde denetimli ve denetimsiz sınıflandırma teknikleri kullanmış ve 1984-1997 yılı için %78 ve %80 doğruluk değeri hesaplanmıştır. Farklı mekansal çözünürlüğe sahip uydular incelenerek, AKBÖ değişikliklerinde CBS ve UA tekniklerinin kullanılmasının önemi ve özellikle NTS tekniğinin piksel tabanlı sınıflama tekniklerine kıyasla avantajları Blaschke, (2010) tarafından rapor edilmiştir. Sentinel-2 görüntüleri kullanılarak yapılan diğer araştırmada (Cavur vd., 2019), NTS tekniğinin doğruluk sonuçları %83,64 olarak belirlenmiştir. Bir başka çalışmada, Goodin vd., (2015), Ukrayna ve Polonya sınırındaki AKBÖ değişimi için

NTS tekniđi ile piksel tabanlı sınıflandırma tekniđini kullanmış ve sırasıyla %89 ve %88 doğruluk sonuçları elde edilmiştir. Çalışmada sınıflama teknikleri arasında, doğruluk analiz sonuçları açısından %1 fark olduğu görülmüştür. Piksel tabanlı sınıflandırma tekniđi olan RO sınıflandırmasının kullanıldığı ve Sentinel-2 uydu verilerininin %93 doğruluk ile oluşturduğu çalışmada, Fas'ta bulunan iki sulak alanda AKBÖ haritaları üretilmiştir (Htitiou vd., 1976). Landsat uydu görüntüleri ile Tanzania'daki Kilombero havzasında AKBÖ değışikliklerini belirlemek amacıyla 1974, 1994, 2004 ve 2014 yıllarında yapılan RO sınıflandırmasında farklı vejetasyon indeksleri de kullanılmış ve AKBÖ 2004 yılı doğruluk analizi değeri %73 olarak hesaplanmıştır (Thonfeld vd., 2020). İspanya'nın 14 arazi kategorisi ile AKBÖ değışimini anlamak için Sentinel-2 verilerinde RO sınıflandırma tekniđi kullandığı çalışmada doğruluk analizi sonucunda %92 oranına ulaşılmıştır (Rodriguez-Galiano vd., 2012). Bu çalışma için oldukça başarılı sayılan bir doğruluk sonucudur. Başka bir RO ile ilgili çalışmada, İran'ın Şiraz şehrindeki AKBÖ haritalandırması için Landsat-8 OLI/TIRS uydu görüntüleri kullanılarak RO sınıflandırma tekniđinin de içinde bulunduğu altı farklı teknik test edilmiş ve RO tekniđinde doğruluk analizi sonucu % 99.85 olarak belirlenmiştir (Jamali ve Abdul Rahman, 2019).

AKBÖ değışimi, arazi örtüsünün kara yüzeylerindeki dönüşümü kadar kıyı ve sulak alanlardaki değışiklikleri belirlemede, UA teknikleri kullanılmaktadır. Yeni Delhi'de bulunan Yamua nehir yatađı ve çevresinde 1997-1999-2002-2009 yıllarındaki AKBÖ değışikliğinde, UA ve CBS denetimli sınıflandırma tekniklerinin %88.6 doğruluk değeri verdiği belirlenmiştir ve değışikliđin doğal-insan kökenli etkilerden kaynaklı geliştiiđi anlaşılmıştır (Joshi vd., 2011). Güney Zambia'da sulak alan fenolojisinin ve çevresinin değışikliđi için AKBÖ haritaları, bantlardaki yoğunluđun azaltılarak ham veriye en yakın görüntü ABA sınıflandırma yöntemi ile hesaplanmıştır (Munyati, 2004). AKBÖ değışikliđi için kullanılan ABA tekniđi ile 1986 – 2006 yılları arasında Nijerya, Kaduna'da kompozit bantlardaki sınıflandırmanın karşılaştırma haritaları, Landsat Geliştirilmiş Tematik Eşleyici (ETM+) görüntüleri kullanarak yapılmıştır. ABA sınıflandırmasının kompozit görüntülerle yapılan sınıflandırmadan daha iyi sonuçlar verdiği, tarım arazilerinin kentsel araziye dönüştüđü anlaşılmıştır (Abdu, 2019). ABA sınıflandırması dışında uydu bantlarıyla ilişkili indeksler ile de sınıflandırma yapılarak, karşılaştırma haritaları oluşturulmaktadır. Gitelson vd. (2002) çalışmasında, atmosferik etkilere karşı duyarlılıđı NDVI, kırmızı kenar (700 nm) bitki örtüsü indeksi vb. indeksler kullanılarak, sınıflandırma işlemi yapmış ve NDVI'in daha yüksek sonuçlar verdiği görülmüştür. Xianju et al. (2017)' de yaptığı uygulamada, Çin'in

Dunhuang şehrinde kırmızı kenar bandı ve bitki örtüsü indekslerini içeren setlerle RO sınıflandırması yapmışlardır. Sonuçlar, kırmızı kenar bandı ile oluşturulan kompozit indeksin daha iyi doğruluk analiz sonuçları verdiğini göstermiştir.

Sınıflandırmada oluşan AKBÖ değişimlerinin etkilediği sıcaklık normallerini UA ile belirlemek amaçlı çeşitli çalışmalar yapılmıştır. Landsat-8 OLI/TIRS uydu görüntüsünde YYS için kullanılan algoritmalar tartışılmıştır ve sonuçlar parlaklık sıcaklığı, emisyon ve su buharı parametrelerinin model tutarlılığı sebebiyle bölünmüş pencere algoritmasında YYS'nin daha iyi bir doğrulukla elde edebileceğini göstermiştir (Du vd., 2015). Çin'in farklı iklim bölgelerinde ve birbirinden farklı aylardaki AKBÖ türlerinde YYS değerleri hesaplanmış, kentsel ve çorak arazilerin çalışma alanında en yüksek sıcaklık değerlerinde olduğu belirlenmiştir (Agugliaro vd., 2022). 2002–2020 yılları arasında Nijerya, Ilorin'de AKBÖ, yükseklik ve YYS arasındaki ilişki incelenmiştir ve yüksekliğin etkileyici bir parametre olmadığı anlaşılmıştır. Hesaplamalar sonucunda şehirde 0 °C ve 41 °C minimum ve maksimum sıcaklıkların olduğu tespit edilmiştir (Njoku ve Tenenbaum, 2022). 1990-2005-2020 yıllarında Bangladeş, Chittagong şehrinde oluşan AKBÖ değişiminin YYS ile olan ilişkisi Landsat-8 TIRS uydu görüntüleriyle araştırılmıştır. Bu çalışmada; yerleşim, su ve tarım alanlarının sırasıyla %4,57, %1,04 ve %0,94 arttığı, bitki örtüsünün ve çıplak alanların %0,34 ve %0,87 oranında azaldığı görülmüştür. Bununla yerleşim ve su alanlarında sıcaklıkların beklendiği gibi arttığı anlaşılmıştır (Abdullah vd., 2022).

Yapılan tüm analizlerde gelişen çevrede oluşan negatif ve pozitif olayların AKBÖ değişimini etkilediği ve sosyoekonomik nedenlerin bu değişimde büyük pay sahibi olduğu görülmüştür. Çin, Hangzhou bölgesinde 1978–2008 yılları arasında oluşan AKBÖ değişimi Landsat MSS/TM/ETM+ görüntüleriyle bulunmuştur ve AKBÖ değişim sonuçlarıyla bağlantılı olarak 2000 yılı için toplam Gayri Safi Yerli Hasıla (GSYH) 31,71 kat ve 1978–2008'de toplam nüfusun %72,40 arttığı görülmüştür. Buna bağlı olarak toplumun temelinde yatan ekosistem işlevlerinden (iklim düzenlemesi, toprak koruma, atık arıtımı vb.) elde edilen yaşamsal faydaları ifade eden ekosistem hizmet değerindeki %24.04'lük düşüşün, AKBÖ-sosyoekonomik sebeplerden dolayı olduğu belirtilmiştir (K. Y. Wu vd., 2013). 1990-1995-2000-2005 yıllarında AKBÖ değişim sınıfları, Li vd. (2016)'da ekilebilir arazi, yerleşim alanı ve su alanı olarak ele alınmıştır ve sonuçlarda ekilebilir arazilerin ekonomik kalkınma amacıyla dönüşmesinden kaynaklı azaldığını ortaya çıkarmıştır. Nüfus, sanayileşme gibi sosyoekonomik sebeplerin AKBÖ'deki bu değişimi tetiklediği

görülmüştür. Bir başka araştırma, sanayileşme ile birlikte GSYH'deki değişimin, gayrimenkul yatırımları ve tüketim mallarının satışlarındaki toplam artışın, Güney Çin'de bulunan Guangdong, Hong Kong ve Makao (GHKM) bölgesini etkilediğini ve otuz yılda (1986-2017) artan düzensiz kentleşmenin tarım arazilerindeki azalmaya bağlı AKBÖ değişimine neden olduğunu göstermiştir (Hasan vd., 2019).

Yapılan araştırmalara bakıldığında çalışma alanlarında genellikle RO, NTS, ABA ve YYS gibi analizlerin yapıldığı görülmüştür. Bu çalışmada Sentinel 2 serisi mavi, yeşil, kırmızı (band4), kırmızı kenar (band5, band6, band7) ve kızılötesi bantları (band8, band8a, band11, band12) kullanılmıştır. Basit oran (BO) ve NDVI matematiğiyle ayrı ayrı oluşturulan indekslerin, literatürdeki çalışmalarda oldukça fazla olduğu görülmektedir. Bu nedenle mevcut indeksleri kullanmanın yanında yeni indeksler ile band kombinasyonları oluşturarak sınıflamalarda 3 sezon için en yüksek doğruluğun araştırılması çalışmayı özgün yapmaktadır. Ayrıca bu bölgede devlet eli ile yapılan yatırımın etkilerini yeni indeksler ile inceleyen ilk çalışma olması açısından da özgündür. Bu bağlamda çalışmanın UA bilimine uygulamalı katkıda bulunma potansiyeli vardır.

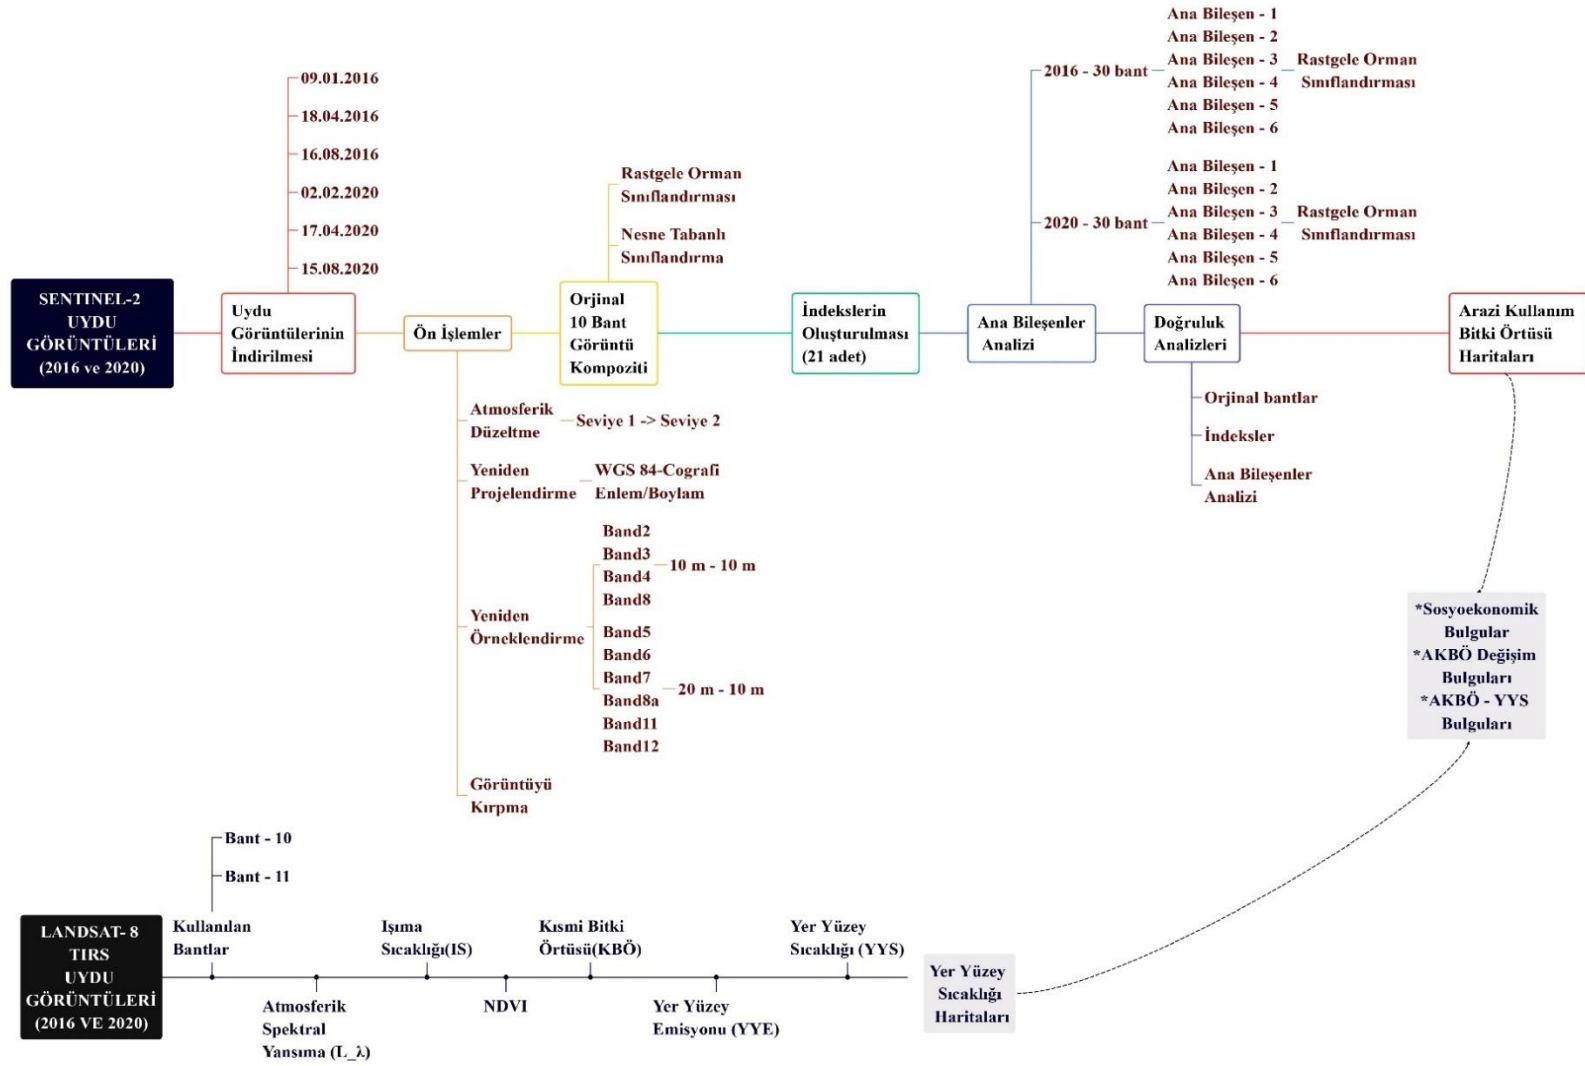
ÜÇÜNCÜ BÖLÜM

MATERYAL VE YÖNTEM

Sistemantik bir yol izlenerek yapılan bu araştırma, amacına uygun bir akış şeması ile şekillendirilmiştir ve Şekil 1 izlenilen bu yolu açık bir şekilde göstermektedir. 2016 ve 2020 yıllarında sezonluk tarihlere dikkat edilerek en uygun görüntüler Sentinel-2A uydusundan seçilmiştir. Seçilen görüntülere atmosferik düzeltme, yeniden projeksiyonlandırma, yeniden örnekleme ve kırpma ön işlemleri uygulanmıştır. Hazır hale gelen görüntüler öncelikle orjinal 10 bantlı (B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12) kompozit görüntüye dönüştürülmüş ve ayrı ayrı RO ve NTS sınıflama teknikleri ile sınıflandırılmıştır. Ardından NDVI matematiği kullanılarak 7 adet görüntü, NDVI ve BO matematiği birlikte kullanılarak 14 adet görüntü; toplamda 21 adet indeksli görüntü oluşturulmuş ve tüm görüntüler RO sınıflama tekniğiyle sınıflandırılmıştır. 2016 ve 2020 yıllarında ayrı ayrı 30 bantlık ABA görüntüsü oluşturulmuş, sonucunda 6 ana bileşene dönüştürülmüş ve RO sınıflama işlemi uygulanmıştır. Tüm sınıflama işlemleri bittikten sonra sınıflanmış görüntülere doğruluk analizi yapılmıştır.

Çalışma alanını içine alacak şekilde 2016 ve 2020 yıllarında sınıflanmış görüntülerin tarihleri göz önünde bulundurularak en uygun Landsat-8 TIRS uydu görüntüleri seçilmiştir. YYS hesaplamalarında kullanılacak algoritma için 10 ve 11 termal bantları seçilmiştir. Atmosferik spektral yansıma, ışıma sıcaklığı, NDVI, kısmi bitki örtüsü, yer yüzey emisivitesi ve sonucunda YYS işlemi ArcGIS programı ve Google Earth Engine (GEE) programlama dili ile ayrı ayrı hesaplanmıştır. Oluşan görüntüler YYS haritaları şeklinde oluşturulmuştur.

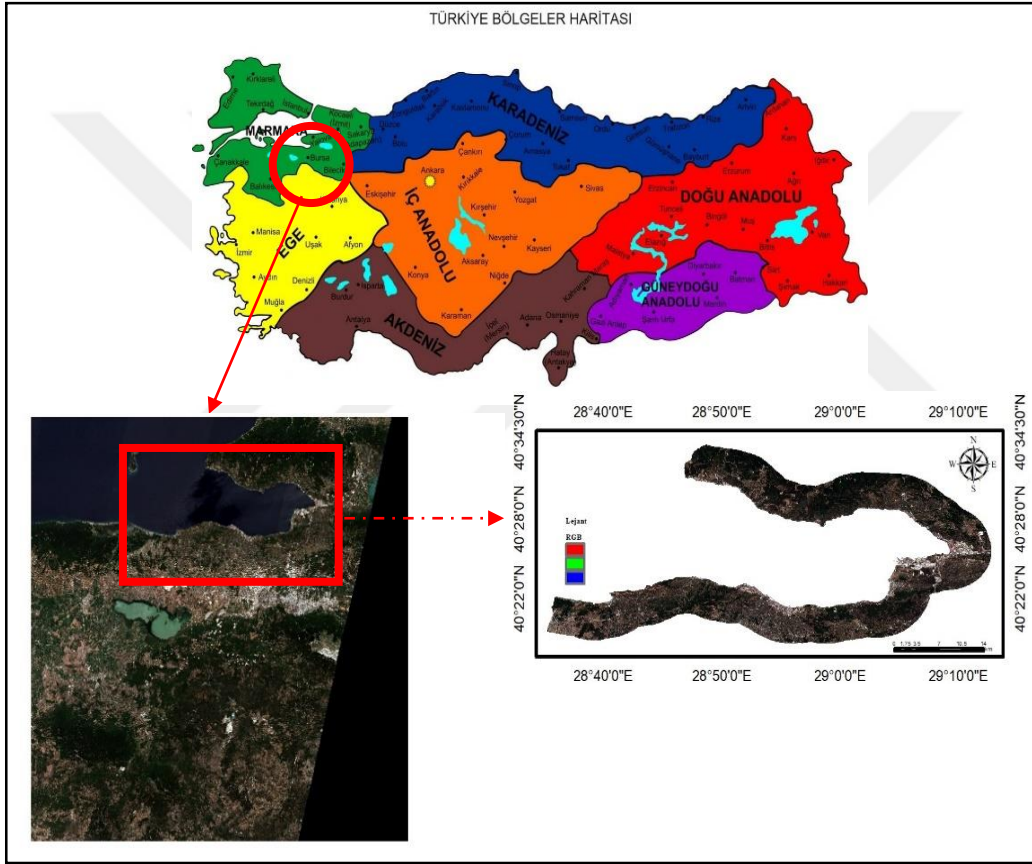
Sınıflanmış görüntüler ile AKBÖ haritaları oluşturulmuş ve sonuç kısmında sosyoekonomik sebepler, YYS çıktıları ile ilişkilendirilmiştir.



Şekil 1. Çalışma akış şeması

3.1. Çalışma Alanı

Çalışma alanı Marmara'nın güneydoğusunda bulunan Yalova'nın Armutlu ilçesinde 7 köyü, Bursa'nın Gemlik ilçesinde 7 köy 6 mahalleyi, yine Bursa'nın Osmangazi ilçesinde 2 mahalle ve Mudanya ilçesinde 17 mahalleyi kapsamaktadır (Tablo 1). Çalışma alanı sahil bandından anakaraya doğru 5 km'lik tampon bölge seçilerek oluşturulmuştur. Buna göre çalışma alanı toplamda 495.864 km²'lik bir alanda bulunmaktadır (Şekil 2).




Şekil 2. Güney – Doğu Marmara çalışma alanı

Çalışma alanına ait Şekil 3'de bulunan fotoğraflar, arazi çalışması esnasında ve aynı zamanda görüntü sınıflandırma işleminden sonraki adım olan doğruluk analizi işleminde yer kontrol noktalarının teyidinin yapılabilmesi için kayda alınmıştır. Fotoğraflarda yol, zeytinlik alanlar, ormanlıklar, mera alanları ve tarım arazisi görülmektedir (Şekil 3 (a), (b), (c), (d), (e), (f)).

Tablo 1

Çalışma alanında bulunan köy ve mahallelerin listesi

İl	Bulunan İlçe	Köy/Mahalle
Bursa	Gemlik	Cihatlı Köyü
		Engürücük Köyü
		Karacaali Köyü
		Kurtul Köyü
		Küçükkumla Köyü
		Narlı Köyü
		Yeniköy Köyü
		Ata Mahallesi
		Büyükkumla Mahallesi
		Gençali Mahallesi
		Kumla Mahallesi
		Kurşunlu Mahallesi
		Parsbey Mahallesi
		Osmangazi
	Gündoğdu Mahallesi	
	Mudanya	Altıntaş Mahallesi
		Aydınpınar Mahallesi
		Burgaz Mahallesi
		Çamlık Mahallesi
		Çepni Mahallesi
		Eğerce Mahallesi
		Esence Mahallesi
		Göynüklü Mahallesi
		Halitpaşa Mahallesi
		Işıklı Mahallesi
		Kumyaka Mahallesi
		Mesudiye Mahallesi
		Söğütpınar Mahallesi
		Tirilye Mahallesi
		Yalı Mahallesi
		Yalıçiftlik Mahallesi
	Yaman Mahallesi	
	Yörükali Mahallesi	
Yalova	Armutlu	Hayriye Köyü
		Fıstıklı Köyü
		Kapaklı Köyü
		Mecidiye Köyü
		Bayır Mahallesi
		Karşıyaka Mahallesi
		50.Yıl Mahallesi



Şekil 3. Çalışma alanına ait arazi görüntüleri (a), (b), (c), (d), (e), (f)

3.1.1. İklim

Çalışma alanındaki Bursa ili Gemlik, Osmangazi ve Mudanya ilçeleri ve Yalova ili Armutlu ilçesi sıcak ve ılıman iklim koşullarını yansıtmaktadır. Yıllık ortalama sıcaklık değerleri Gemlik, Osmangazi, Mudanya ve Armutlu ilçeleri sırasıyla 13.8 °C, 12.6 °C, 14.6 °C ve 15.1 °C olmaktadır (Climate-Data, n.d).

Bu bağlamda iklimin değişkenliğini nicel olarak gösteren kontrolörler olarak çalışma alanında bulunan 4 ilçeyi de kapsayan meteoroloji istasyonlarının koordinat bilgileri Tablo 2’de ve harita üzerindeki gösterimi Şekil 4’de gösterilmektedir.

Tablo 2

Meteorolojik istasyonların bilgisi

Kod	Meteoroloji İstasyonu	Koordinatlar	
18110	Armutlu	40°32'52.1"N	28°50'26.9"E
17663	Gemlik	40°26'24.4"N	29°09'01.4"E
18741	Gündoğdu(Osmangazi)	40°19'27.8"N	29°02'38.0"E
18385	Mudanya	40°22'07.0"N	28°54'06.1"E



Şekil 4. Çalışma alanında bulunan meteorolojik istasyonların konumlarının gösterimi

3.2. Yazılım / Program

Araştırmada AKBÖ haritalarının elde edilmesi için uydu verilerinin sınıflandırması yapılmadan önceki tüm ön işlemler ve verilere uygulanan tüm RO sınıflandırma tekniği SNAP 7.0 programı ile, NTS tekniği eCognition Developer programı ile yapılmıştır. ABA görüntüsünün baştan sona tüm ön işlemleri Erdas IMAGINE programı ile elde edilmiştir.

Ham verilere indekslerin eklenmesi ve orjinal bantlar ile indeksli görüntüler üzerindeki işlemler yine SNAP 7.0 programı ile oluşturulmuştur. Sınıflandırılmış verilere uygulanan doğruluk analizi işlemleri Google Earth Pro programının yardımı ile elde edilmiştir.

Son olarak YYS_{ArcGIS} hesaplama işlemleri ArcGIS 10.3 programı ile, YYS_{GEE} işlemleri ise GEE yazılımı ile elde edilmiştir. Çıktı olarak AKBÖ haritalarının hazırlanması ve gridlenmesi ArcGIS 10.3 programı ile oluşturulmuştur.

3.3. Uydu Görüntüleri

3.3.1. Sentinel-2A

Sentinel-2A, 23 Haziran 2015'te fırlatılan bitki örtüsü, toprak ve su örtüsünün izlenmesinin yanı sıra mekansal planlama ve kıyı alanlarının gözlemlenmesi de dahil olmak üzere ESA'nın Copernicus Arazi İzleme çalışmalarını destekleyen geniş alanlı, orta çözünürlüklü, çok spektral bir görüntüleme görevidir ("The European Space Agency", t.y.). Sentinel-2A algılayıcısının teknik özellikleri Tablo 4'te verilmiştir.

Sentinel-2A uydu verileri, görüntüleri 13 bant aralığında kaydetmektedir. Elektromanyetik spektrumda kıyı, görünür, kırmızı kenar, kızılötesi ve su buharı bölümlerinden oluşmaktadır. 10 m, 20 m ve 60 m yersel çözünürlükte görüntülere sahip (Zhang vd, 2021), görüş alanı 290 km ve uydunun görüntüleme sıklığı 10 gündür ("The European Space Agency", t.y.).

Bu tez çalışmasında, 09.01.2016, 18.04.2016, 16.08.2016 ve 02.02.2020, 17.04.2020 ve 15.08.2020 tarihli Sentinel-2A uydu verileri (Tablo 3) kullanılmış ve band 1, band 9 ve band 10 spektral değerleri hariç toplamda 10 bant üzerinden işlemler yapılmıştır. Her iki yıl için mevsimlik değişimleri görmek adına 3 sezonu kapsayacak şekilde tarihler görüntülerin kullanılabilirlik durumuna göre tercih edilmiştir. Sentinel-2A görüntüleri ESA'nın internet sitesinden (<https://scihub.copernicus.eu/>) açık erişimli olarak elde edilmiştir.

Tablo 3
Sentinel-2A uydusundan elde edilen görüntülerin tarihleri

Kullanılan uydu	Tarih
<i>Sentinel-2A</i>	09.01.2016
<i>Sentinel-2A</i>	18.04.2016
<i>Sentinel-2A</i>	16.08.2016
<i>Sentinel-2A</i>	02.02.2020
<i>Sentinel-2A</i>	17.04.2020
<i>Sentinel-2A</i>	15.08.2020

Tablo 4
Sentinel-2A uydusunun teknik özellikleri

Sentinel-2 Bands	Orta Dalgaboyu(μm)	Çözünürlük (m)
Band 1 – Kıyı Aeresolu	0.443	60 m
Band 2 – Mavi	0.492	10 m
Band 3 – Yeşil	0.560	10 m
Band 4 – Kırmızı	0.665	10 m
Band 5 – Kırmızı Kenar Bitki Örtüsü	0.704	20 m
Band 6 – Kırmızı Kenar Bitki Örtüsü	0.741	20 m
Band 7 – Kırmızı Kenar Bitki Örtüsü	0.783	20 m
Band 8 – Kızılötesi	0.833	10 m
Band 8a – Yakın Kızılötesi	0.865	20 m
Band 9 – Su Buharı	0.945	60 m
Band 10 – Kısa Dalga Kızılötesi – SIRRUS	0.1374	60 m
Band 11 – Kısa Dalga Kızılötesi	0.1614	20 m
Band 12 – Kısa Dalga Kızılötesi	0.2202	20 m

3.3.2. Landsat-8 OLI / TIRS

Landsat-8, 11 Şubat 2013'te OLI ve TIRS'in da içinde bulunduğu araçlarla fırlatılan, su ve orman kaynaklarının izlenmesi, kıyı bölgesi gözlemleri ve evapotranspirasyon gibi misyonları edinen uydu görevidir. OLI ve TIRS araçları birlikte uydu verilerini 11 bantta kayıt yapmaktadır. Spektrumda görünür, yakın kızılötesi, kısa dalga kızılötesi ve termal bölgedeki kısımları ölçmektedirler. Şerit genişliği 185 km, pankromatik bantta 15 m, diğer bantlarda mekansal olarak 30 m çözünürlüğe sahiptir ve tekrar etme sıklığı 16 gündür ("United States Geological Survey (USGS)", t.y.).

Çalışmada sınıflandırma işlemi dışında kullanılan ArcGIS ile oluşturulan YYS hesabı için 27.12.2015, 17.04.2016, 22.07.2016 ve 06.12.2019, 12.04.2020 ve 01.07.2020 tarihli Landsat-8 TIRS uydu verileri (Tablo 5) kullanılmıştır ve Band 10 ve Band 11 termal

bantları işleme alınmıştır. Landsat-8 TIRS görüntüleri, ABD Jeoloji Araştırmaları Kurumu (USGS)'nin resmi internet sitesinden (<https://earthexplorer.usgs.gov/>) açık erişimli olarak elde edilmiştir. Araştırmada karşılaştırma yapılabilmesi sebebiyle diğer hesaplama şekli olarak açık erişimli GEE platformu kullanılmış ve YYS hesapları yapılmıştır.

Tablo 5
Landsat-8 TIRS uydusundan elde edilen görüntülerin tarihleri

Kullanılan uydu	Tarih
<i>Landsat-8 TIRS</i>	27.12.2015
<i>Landsat-8 TIRS</i>	17.04.2016
<i>Landsat-8 TIRS</i>	22.07.2016
<i>Landsat-8 TIRS</i>	06.12.2019
<i>Landsat-8 TIRS</i>	12.04.2020
<i>Landsat-8 TIRS</i>	01.07.2020

Tablo 6
Landsat-8 OLI/TIRS uydusunun teknik özellikleri

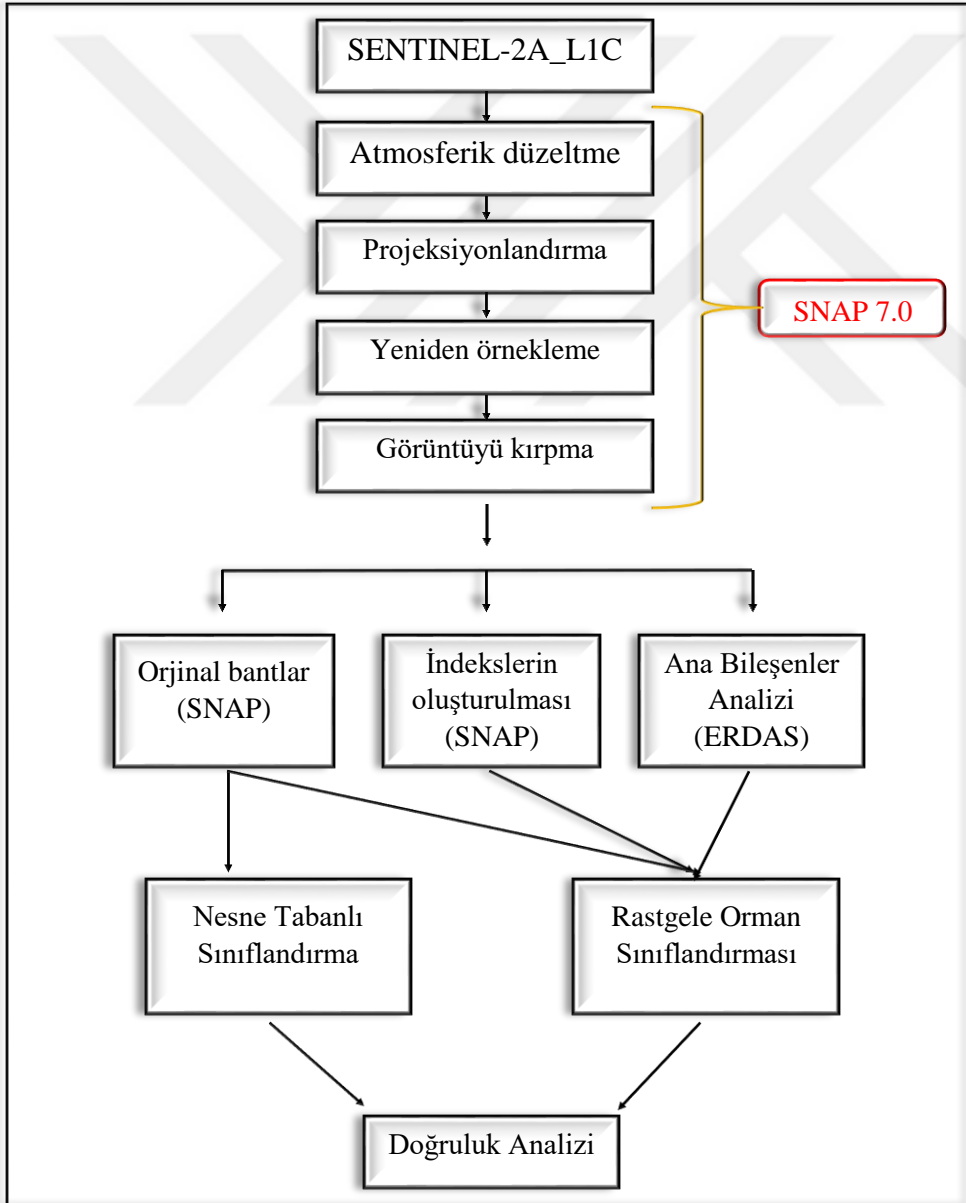
Landsat 8 OLI/TIRS	Dalgaboyu(µm)	Çözünürlük (m)
Band 1 - Kıyı/ Aerosol	0.443 - 0.453	30 m
Band 2 - Mavi	0.450 - 0.515	30 m
Band 3 - Yeşil	0.525 - 0.600	30 m
Band 4 - Kırmızı	0.630 - 0.680	30 m
Band 5 - Yakın Kızılötesi	0.845 - 0.885	30 m
Band 6 - Kısa Dalga Kızılötesi	1.560 - 1.660	30 m
Band 7 - Kısa Dalga Kızılötesi	2.100 - 2.300	30 m
Band 8 - Pankromatik	0.500 - 0.680	15 m
Band 9 - Sırrus	1.360 - 1.390	30 m
Band 10 - Uzun Dalgaboyu Kızılötesi	10.30 - 11.30	100 m
Band 11 - Uzun Dalgaboyu Kızılötesi	11.50 - 12.50	100 m

3.4. Yöntem

Bu araştırmada tercih edilen yöntemler, spektral indeksler ile görüntülerdeki belirgin özelliklerin çıkarılmasına, ABA ile yeni görüntülerin elde edilmesine ve oluşturulan tüm görüntülerin RO ve NTS tekniği ile sınıflandırılmasına bağlı AKBÖ haritalarının karşılaştırılmasına dayanmaktadır. Burada NTS sınıflandırma tekniği (Kindu vd., 2013;

Petropoulos vd., 2013; T. Wu vd., 2021; Yu vd., 2006; Zhou vd., 2008)' e göre ve RO sınıflandırma yöntemi (Chan ve Paelinckx, 2008; Ghimire vd., 2010; Pal, 2005) 'e göre uygulanmıştır.

Çalışma alanında sınıflandırma Mera (M), Orman (O), Su (S), Tarım (T), Yerleşim (Y) ve Zeytin (Z) olmak üzere altı AKBÖ sınıfı ile oluşturulmuştur. Sınıfların seçimi, AKBÖ değişikliğinin tespiti ve pekiştirilmesi için arazi çalışması sonucunda görsel yorumlamayla belirlenmiştir. Sentinel-2A uydu verisinin temin edilmesinden doğruluk analizi ile AKBÖ haritalarının oluşturulmasına kadar geçen süreç Şekil 5'de gösterilmektedir.



Şekil 5. Sentinel-2A uydusundan elde edilen görüntülerle sınıflama süreci

Bitki örtüsü haritalarını karşılaştırırken literatürde sık kullanılan NTS (Johnsson, 1994; Kindu vd., 2013; Radoux vd., 2010; Wang vd., 2004; Zhou vd., 2008) ve RO (Adam vd., 2014; Kupidura, 2019; Thonfeld vd., 2020; Zafari vd., 2019) teknikleri, piksel ve nesne tabanlı sınıflandırmanın farklarını çalışma alanı üzerinde anlamak amacıyla tercih edilmiştir. NTS sınıflandırma tekniği yalnızca orjinal on bant üzerinden oluşturulan kompozit görüntüye (2016, 2020) uygulanmıştır. RO tekniği ise; orjinal on banttan oluşturulan görüntülerde, orjinal bantlara eklenen indeksli görüntülerde ve ABA hesaplanan görüntülerde kullanılmıştır. Bu sınıflandırmaların yanısıra, meteoroloji istasyonlarından alınan günlük sıcaklık (min, ort, max) verileriyle karşılaştırılmak üzere; çalışma alanında bulunan dört istasyon (Armutlu, Gemlik, Gündoğdu, Mudanya) üzerinde YYS hesaplanmıştır. YYS hesaplanırken ArcGIS programı ile yapılan hesaplarda AKBÖ ile karşılaştırma yapılmıştır. Kodlar ile hesaplanan YYS ise yalnızca manuel sıcaklık sonuçlarıyla karşılaştırılmıştır. Sınıflandırmalardan çıkan doğruluk sonuçları kendi içinde analiz edilerek GSYH içindeki kriterler ve sosyoekonomik sebepler ile birlikte yorumlanmıştır, YYS hesaplanan ve Meteoroloji Genel Müdürlüğü (MGM)'nden alınan veriler ile entegrasyonuna bakılarak alandaki sıcaklık değişimlerinin sebepleri açıklanmıştır.

3.4.1. Sınıflama Öncesi İşlemler

Uydu görüntüleri çeşitli hatalar içerebilmektedir. Böyle durumlarda verilere ön işleme yapılması çalışmanın uygunluğu için önem arz etmektedir. Çalışmada ESA tarafından kullanıcıya atmosferik düzeltme yapılmadan sunulan Sentinel-2A - Seviye-1 uydu verilerine düzeltme işlemi uygulanmıştır. Düzeltelen bu görüntülere yeniden projelendirme işlemi uygulanmış ve uydu görüntüsünün mekânsal çözünürlüğü birbirinden farklı olan bantlara (10m, 20m, 60m), tutarlı bir çözünürlüğe sabitlenmesi için yeniden örnekleme yapılmıştır (Zhang vd., 2021). Matematiksel işlemlerden sonra araştırma bölgesini gösteren kırpma işlemi uygulanmıştır. Söz konusu işlemlerin tüm adımları SNAP 7.0 programı ile yapılmıştır. Uydu görüntülerine, oluşturulacak AKBÖ haritalarının sınıflandırma performanslarının artırılması için veri ön işleme adımı gerçekleştirilmiştir.

3.4.2. Sınıflandırma

AKBÖ'deki farklı türlerin belirlenmesinde ve değerlendirilmesinde UA teknolojilerindeki küresel ve devamlı veriler olan uydu görüntülerini kullanmak Dünya'nın değişimini anlamaya yardımcı olup, multispektral görüntü sınıflandırma yöntemlerinin uygulamalarını dinamikleştirmektedir (Sekertekin vd., 2018). Kullanılan bu uydu görüntüleri, farklı çalışma alanları için farklı piksel değerleri ve spektral özelliklere sahip olabilmektedir (Richards ve Jia, 2006). Girdi özelliklere bağlı olarak oluşturulan bilgi sınıflarının gruplandırılmasındaki işlem görüntü sınıflandırması olarak adlandırılmaktadır. Görüntü sınıflandırması, AKBÖ için oluşturulacak verilerin anlamlı hale gelmesini sağlamak için uydu verilerindeki gerekli bilgileri kullanmaktadır (Sundarakumar vd., 2012). Piksellerin herhangi bir sınıfın özelliklerine göre otomatik olarak atanması ya da nesnelere komşuluk ilişkilerine göre çıkarım yapılması ile oluşturulan veriler görüntü sınıflandırması işlemlerinin sonucunda elde edilmektedirler. Bu bağlamda literatürde en çok tercih edilen haliyle ve bu çalışmada kullanılan şekliyle sınıflandırma işlemleri kontrollü ve nesne tabanlı sınıflandırma olarak ikiye ayrılmaktadır (Qu vd., 2021; Radoux vd., 2010; Stumpf ve Kerle, 2011).

Bu tez çalışmasında 6 sınıfın alanına göre yaklaşık olarak toplamda yaklaşık olarak 2050 nokta atılarak sınıflandırma işlemi yapılmıştır. Sınıflandırma işlemlerinde kullanılan bantların ve yeni kombinasyonların isimlendirmeleri ile ilgili bilgilendirme Tablo 7 ve Tablo 8 'de gösterilmektedir. Buna göre tabloda O-İ-BO harfleriyle adlandırılan kombinasyonların açılımı şu şekildedir: O; orijinal bantları, İ; NDVI matematiği ile oluşturulan yeni bantı, BO ise; basit oran matematiği kullanılarak oluşturulan yeni bantı ifade etmektedir.

Tablo 7

Sınıflandırmada kullanılan bantlar ve özellikleri

Ad	Kullanılan Bant	Formül	Sınıflama Tekniği	Kullanılan Algoritma	Referanslar
O _{NTS}	B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12	$B2+B3+B4+B5+B6+B7+B8+B8A+B11+B12$	Çoklu Çözünürlük Segmentasyon	En Yakın Komşu	-
O _{RO}	B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12	$B2+B3+B4+B5+B6+B7+B8+B8A+B11+B12$	Rastgele Orman	Makine Öğrenmesi	-
ABA	PCA-B1, B2, B3, B4, B5, B6	$PC1+PC2+PC3+PC4+PC5+PC6$ $(B2+B3+B4+B5+B6+B7)$	Rastgele Orman	Makine Öğrenmesi	-
O _{İ5}	B2, B3, B4, B6, B7, B8, B8A, B11, B12	$B2+B3+B4+B6+B7+B8+B8A+B11+B12$ $+\left(\frac{B5-B4}{B5+B4}\right)$	Rastgele Orman	Makine Öğrenmesi	(Ahamed et al., 2011; Gitelson et al., 2002)
O _{İ6}	B2, B3, B4, B5, B7, B8, B8A, B11, B12	$B2+B3+B4+B5+B7+B8+B8A+B11+B12$ $+\left(\frac{B6-B4}{B6+B4}\right)$	Rastgele Orman	Makine Öğrenmesi	(Xianju et al., 2017)
O _{İ7}	B2, B3, B4, B5, B6, B8, B8A, B11, B12	$B2+B3+B4+B5+B6+B8+B8A+B11+B12$ $+\left(\frac{B7-B4}{B7+B4}\right)$	Rastgele Orman	Makine Öğrenmesi	(Zarco-Tejada et al., 2001)
O _{İ8}	B2, B3, B4, B5, B6, B7, B8A, B11, B12	$B2+B3+B4+B5+B6+B7+B8A+B11+B12$ $+\left(\frac{B8-B4}{B8+B4}\right)$	Rastgele Orman	Makine Öğrenmesi	(Barnes et al., 2000; Herrmann et al., 2011; Le Maire et al., 2004; Main et al., 2011; Penuelas et al., 1997; C. Wu et al., 2008)
O _{İ8a}	B2, B3, B4, B5, B6, B7, B8, B11, B12	$B2+B3+B4+B5+B6+B7+B8+B11+B12$ $+\left(\frac{B8A-B4}{B8A+B4}\right)$	Rastgele Orman	Makine Öğrenmesi	(Tsfaye et al., n.d.; Tucker, 1980; Zhang et al., n.d.)
O _{İ11}	B2, B3, B4, B5, B6, B7, B8, B8A, B12	$B2+B3+B4+B5+B6+B7+B8+B8A+B12$ $+\left(\frac{B11-B4}{B11+B4}\right)$	Rastgele Orman	Makine Öğrenmesi	(Panigrahy et al., 2009; Tucker, 1979)
O _{İ12}	B2, B3, B4, B5, B6, B7, B8, B8A, B11,	$B2+B3+B4+B5+B6+B7+B8+B8A+B11$ $+\left(\frac{B12-B4}{B12+B4}\right)$	Rastgele Orman	Makine Öğrenmesi	-

Tablo 8

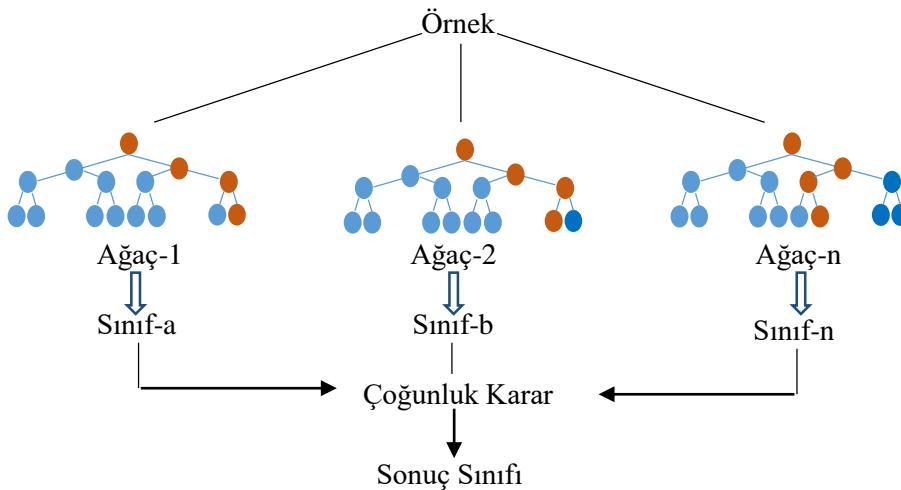
Sınıflandırmada kullanılan bantlar ve özellikleri-2

O ₅ BO ₆	B2, B3, B4, B7, B8, B8A, B11, B12	B2+B3+B4+ B7+ B8+B8A+ B11+B12+ $(\frac{B5-B4}{B5+B4})+(\frac{B6}{B5})$	Rastgele Orman	Makine Öğrenmesi	-
O ₅ BO ₇	B2, B3, B4, B6, B8, B8A, B11, B12	B2+B3+B4+ B6+ B8+B8A+ B11+B12+ $(\frac{B5-B4}{B5+B4})+(\frac{B7}{B5})$	Rastgele Orman	Makine Öğrenmesi	-
O ₆ BO ₆	B2, B3, B4, B7, B8, B8A, B11, B12	B2+B3+B4+ B7+ B8+B8A+ B11+B12+ $(\frac{B6-B4}{B6+B4})+(\frac{B6}{B5})$	Rastgele Orman	Makine Öğrenmesi	-
O ₆ BO ₇	B2, B3, B4, B8, B8A, B11, B12	B2+B3+B4+ B8+B8A+ B11+B12+ $(\frac{B6-B4}{B6+B4})+(\frac{B7}{B5})$	Rastgele Orman	Makine Öğrenmesi	-
O ₇ BO ₆	B2, B3, B4, B8, B8A, B11, B12	B2+B3+B4+ B8+B8A+ B11+B12+ $(\frac{B7-B4}{B7+B4})+(\frac{B6}{B5})$	Rastgele Orman	Makine Öğrenmesi	-
O ₇ BO ₇	B2, B3, B4, B6, B8, B8A, B11, B12	B2+B3+B4+ B6+ B8+B8A+ B11+B12+ $(\frac{B7-B4}{B7+B4})+(\frac{B7}{B5})$	Rastgele Orman	Makine Öğrenmesi	-
O ₈ BO ₆	B2, B3, B4, B7, B8A, B11, B12	B2+B3+B4+ B7+ B8A+ B11+B12+ $(\frac{B8-B4}{B8+B4})+(\frac{B6}{B5})$	Rastgele Orman	Makine Öğrenmesi	-
O ₈ BO ₇	B2, B3, B4, B6, B8A, B11, B12	B2+B3+B4+ B6+ B8+B8A+ B11+B12+ $(\frac{B8-B4}{B8+B4})+(\frac{B7}{B5})$	Rastgele Orman	Makine Öğrenmesi	-
O _{8a} BO ₆	B2, B3, B4, B7, B8, B11, B12	B2+B3+B4+ B7+ B8+ B11+B12+ $(\frac{B8A-B4}{B8A+B4})+(\frac{B6}{B5})$	Rastgele Orman	Makine Öğrenmesi	-
O _{8a} BO ₇	B2, B3, B4, B6, B8, B11, B12	B2+B3+B4+ B6+ B8+ B11+B12+ $(\frac{B8A-B4}{B8A+B4})+(\frac{B7}{B5})$	Rastgele Orman	Makine Öğrenmesi	-
O ₁₁ BO ₆	B2, B3, B4, B7, B8, B8A, B12	B2+B3+B4+ B7+ B8+B8A+ B12+ $(\frac{B11-B4}{B11+B4})+(\frac{B6}{B5})$	Rastgele Orman	Makine Öğrenmesi	-
O ₁₁ BO ₇	B2, B3, B4, B6, B8, B8A, B12	B2+B3+B4+ B6+ B8+B8A+ B12+ $(\frac{B11-B4}{B11+B4})+(\frac{B7}{B5})$	Rastgele Orman	Makine Öğrenmesi	-
O ₁₂ BO ₆	B2, B3, B4, B7, B8, B8A, B11	B2+B3+B4+ B7+ B8+B8A+ B11 + $(\frac{B12-B4}{B12+B4})+(\frac{B6}{B5})$	Rastgele Orman	Makine Öğrenmesi	-
O ₁₂ BO ₇	B2, B3, B4, B6, B8, B8A, B11	B2+B3+B4+ B6+ B8+B8A+ B11 + $(\frac{B12-B4}{B12+B4})+(\frac{B7}{B5})$	Rastgele Orman	Makine Öğrenmesi	-

Kontrollü Sınıflandırma

Kontrollü sınıflandırmada seçilen her arazi örtüsü sınıfı için eğitim alanının tanımlanmasının ardından (Rwanga ve Ndambuki, 2017), bilinmeyen pikseller için bilinen piksellerden imza toplanmasıyla oluşan sınıflandırma işlemi yapılmaktadır (Perumal ve Bhaskaran, 2010). Kontrollü sınıflandırma işleminde kullanılan farklı türde birçok sınıflandırma seçeneği bulunmaktadır (Jog ve Dixit, 2016). Bunlardan biri ve en çok tercih edileni RO sınıflandırma tekniğidir.

RO tekniğinde amaç, eğitim alanlarının ve oluşturulan değişkenlerin üzerinde rastgele seçim yapılarak ağaç dallandırması oluşturmaktır (Stumpf ve Kerle, 2011). Başka bir deyişle, her ağaç oluşturulan eğitim alanlarından ve bunlardan bağımsız gelişen değişkenlerden oluşturulan vektörlerin kombinasyonuna bağlı olarak açıklanmaktadır (Breiman, 2001). Bu şekilde ulaşılan karar açısından, diğer makine öğrenmesi tekniklerine bakıldığında hızlı, az sayıda eğitim örneğiyle iş yapabilme kabiliyetine sahip, eğitim setlerindeki gürültüye daha az duyarlı bir yapıya sahiptir (Zafari vd., 2019). Bu yapıda sınıflandırma üzerinde girdi verilerindeki değişikliklerin küçük yapılması, sınıflandırmada doğruluk derecesinde stabiliteye ulaşılmasını sağlar (Magidi vd., 2021). RO tekniğinin çoklu ağaç yapısındaki seçimlerin gösterimi Şekil 6'da gösterilmektedir.



Şekil 6. RO sınıflandırma tekniğinin ağaç yapısının gösterimi

RO tekniğinde ağaç şemasının öğrenilmesi için önyükleme toplama veya torbalama tekniği uygulanmaktadır. Eğitim alanlarının alınmasından sonra, x' rastgele örneklerindeki tahminler, x' için oluşan tüm bireysel tahminler için, regresyon ağaçlarının ortalaması alınarak yapılır (“Algoritma”, 2022, “Torbalama”, paragraf 2). Denklem 3.4.2.1’e göre;

$$\hat{f} = \frac{1}{B} \sum_{b=1}^B f_b(x') \quad (3.4.2.1)$$

B = torbalamanın tekrar sayısı(örnek/ağaç sayısı)

f_b = regresyon ağacı

x' = rastgele örnek sayısı

\hat{f} = tahminlerin ortalaması

Önyükleme yapılarak oluşturulan örneklemede, ağaçlara farklı eğitim setleri göstererek bozunma yaşanabileceği düşünülmektedir. Bu sebeple Denklem 3.4.2.2’ye göre yapılan tahminin belirsizliğinin de tahmini hesaplanarak, x' için oluşan tüm bireysel regresyon ağaçlarının standart sapması yapılmaktadır (“Algoritma”, 2022, “Torbalama”, paragraf 3-4).

$$\sigma = \sqrt{\frac{\sum_{b=1}^B (f_b(x') - \hat{f})^2}{B-1}} \quad (3.4.2.2)$$

σ = standart sapma

Rastgele ormanların piksel değerlerindeki komşuluk şemasına göre, oluşturulan ağırlıklı fonksiyon değeri Denklem 3.4.2.3’ te gösterilmiştir (Lin ve Jeon, 2006).

$$\hat{y} = \sum_{i=1}^n W(x_i, x') y_i \quad (3.4.2.3)$$

$\hat{y} = x'$ noktaları için komşuluk tahmini

$W(x_i, x')$ = i'inci eğitim alanındaki noktanın yeni x noktasına göre negatif olmayan ağırlığı

$y_i = y$ noktasının ağırlığının tekrarı

Ağaçlardan oluşturulan ormanların tahmin edilmesi Denklem 3.4.2.4'e göre aşağıdaki şekildedir (Lin ve Jeon, 2006).

$$\hat{y} = \frac{1}{m} \sum_{j=1}^m \sum_{i=1}^n W_j(x_i, x') y_i = \sum_{i=1}^n \left(\frac{1}{m} \sum_{j=1}^m W_j(x_i, x') \right) y_i \quad (3.4.2.4)$$

W_j = bireysel ağırlık fonksiyonu

m = ağaç kümesi

Ağaçlar sonlu orman yapısını tahmin etmek için KerF birimleriyle hesaplanarak birleştirilir (Scornet, 2015). Bu birleştirme işleminin kontakt hali Denklem 3.4.2.5'e göre aşağıda gösterilmektedir.

$$\left. \begin{aligned} m_{M,n}(x, \theta_1, \dots, \theta_M) &= \frac{1}{M} \sum_{j=1}^M m_n(x, \theta_j) \\ m_n &= \sum_{i=1}^n \frac{Y_i 1_{X_i \in A_n(x, \theta_j)}}{N_n(x, \theta_j)} \\ X \in [0,1]^d, m_{M,n}(x, \theta_1, \dots, \theta_M) &= \frac{1}{M} \sum_{j=1}^M \left(\sum_{i=1}^n \frac{Y_i 1_{X_i \in A_n(x, \theta_j)}}{N_n(x, \theta_j)} \right) \\ \tilde{m}_{M,n}(x, \theta_1, \dots, \theta_M) &= \frac{1}{\sum_{j=1}^M N_n(x, \theta_j)} \sum_{j=1}^M \sum_{i=1}^n Y_i 1_{X_i \in A_n(x, \theta_j)} \end{aligned} \right\} \quad (3.4.2.5)$$

X, Y = bağımsız rastgele değişkenler

$m_n(x, \theta_j)$ = x noktasında j 'inci derecede tahmin edilen değer

$x, \theta_1, \dots, \theta_M$ = bağımsız rastgele değişkenler

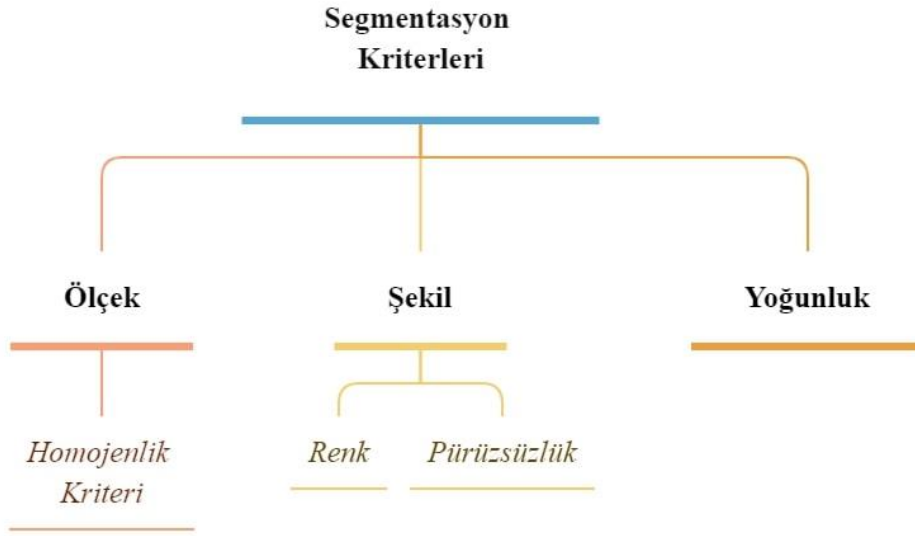
$A_n(x, \theta_j) = x$ bağımsız değişkenini içeren hücre

Çalışmada AKBÖ haritalarının çıktısı; orijinal görüntüler, orijinal bantlara indekslerin eklenerek oluşturulduğu görüntüler ve ABA uygulanarak elde edilen görüntülere uygulanan RO sınıflandırma tekniği ile elde edilmiştir. Çalışma alanı için tüm kombinasyonlarda altı ayrı sınıfa ait vektörler sınıfın kapladığı alan içinde homojen olarak seçilmiş, toplamda yaklaşık olarak 2050 noktadan vektör alınmıştır ve ESA'nın açık erişimli olarak sunduğu SNAP 7.0 programı ile RO ağaç yapısına uygun algoritma üzerinde sınıflandırma işlemleri tamamlanmıştır.

Nesne Tabanlı Sınıflandırma

NTS tekniğinin ilk ve önemli adımı segmentasyon işlemidir. Segmentasyon, görüntülerdeki homojen olarak dağılmış piksellerin komşu pikseller ile gruplandırılma işlemidir (Lourenço vd., 2021; Meinel ve Neubert, 2004). Bu gruplandırma işlemi yapılırken dikkat edilmesi gereken hususlar; ölçek, şekil ve yoğunluk özellikleridir (Şekil 12). Şekil ve doku özellikleri nispeten daha az etkilemekle birlikte, ölçek parametresi segmentasyonun nesne boyutuyla doğrudan bağlantı kurmaktadır (Q. Li vd., 2015; Norman vd., 2021). Manuel olarak oluşturulan ölçek parametresi, belirlenen eşiği aşana kadar nesnelerin heterojenliğini en aza indirmektedir (Trimble, 2007). NTS için kullanılan denklemlerin tümü (Denklem 3.4.2.6, Denklem 3.4.2.7, Denklem 3.4.2.8, Denklem 3.4.2.9, Denklem 3.4.2.10) Ouyang, (2015)'den alınmıştır.

Böylece görüntüdeki nesneler, görüntü bölütlemesiyle spektral açıdan homojen nesnelere dönüşmektedir ve sonucunda nesneler tek tek sınıflandırılmaktadır (D. Liu ve Xia, 2010). Bir başka deyişle, bu sınıflandırma prosedürü ham görüntü nesnelерinin komşu pikseller ile spektral ortaklığına bağlı olarak sınıflandırarak öğretmeyi amaçlamaktadır (Kindu vd., 2013).



Şekil 7. NTS sınıflandırma tekniğinin segmentasyon kriterleri

$$S_f = w_{color} * h_{color} + (1 - w_{color}) * h_{shape} \quad (3.4.2.6)$$

S_f = genel segmentasyon fonksiyonu

$$h = \sum_{k=1}^m w_k * \sigma_k \quad (3.4.2.7)$$

h = spektral heterojenlik

w_k = katman ağırlığı

σ_k = katman

$$h_{color} = \sum_{k=1}^m w_k [n_{mg} * \sigma_k^{mg} - (n_{ob1} * \sigma_k^{b1} + n_{ob2} * \sigma_k^{b2})] \quad (3.4.2.8)$$

h_{color} = renk kriteri

m, k = bantlar

n_{ob1} = nesne boyutları

$$cpt = \frac{1}{\sqrt{n}} \quad smooth = \frac{1}{b} \quad (3.4.2.9)$$

cpt = yoğunluk

smooth = pürüzsüzlük


$$\left. \begin{aligned} h_{cpt} &= n_{mg} * \frac{l_{mg}}{\sqrt{n_{mg}}} - \left[n_{ob1} * \frac{l_{ob1}}{\sqrt{n_{ob1}}} + n_{ob2} * \frac{l_{ob2}}{\sqrt{n_{ob2}}} \right] \\ h_{smooth} &= n_{mg} * \frac{l_{mg}}{b_{mg}} - \left[n_{ob1} * \frac{l_{ob1}}{b_{ob1}} + n_{ob2} * \frac{l_{ob2}}{b_{ob2}} \right] \\ h_{shape} &= W_{cpt} * h_{cpt} + (1 + W_{cpt}) * h_{smooth} \end{aligned} \right\} \quad (3.4.2.10)$$

Çalışmada NTS uygulanmadan önce yapılan segmentasyon işleminde, çoklu çözünürlük segmentasyonu türü seçilmiştir ve girdi olarak verilen parametreler sırasıyla ölçek, şekil ve yoğunluk; 100, 0.5, 0.1 olarak belirlenmiştir. Segmente edilmiş görüntü üzerinde altı ayrı sınıf için homojen seçimler yapılmıştır ve nesnelerin spektral özellikleri algoritmaya tanıtılmıştır. Oluşan görüntülerde en yakın komşuluk algoritması çalıştırılmıştır ve nesnelerin gruplandırması için işlemler tamamlanmıştır. Son olarak sınıflandırma işlem adımı ile AKBÖ haritasının verisi oluşturulmuştur.

İndeks ile Sınıflandırma

UA'da spektral indeksler, bir görüntünün çeşitli spektral bantlarına uygulanan matematiksel denklemler bütünüdür. Görüntüde çıkarılmak istenen spesifik özelliklere göre spektral bantlarda kombinasyonlar oluşturulmaktadır. Oluşan matematiksel ifadelerle araştırmanın amacına uygun olarak bitki örtüsünün ve arazi kullanımının belirgin özellikleri ortaya çıkarılmak istenmektedir.

Çalışmada toplamda 21 adet indeks hesaplanmıştır. Bu yeni indeksler hesaplanırken, NDVI ve BO formülünden yararlanılmıştır. İndeks matematiğinin içerdiği spektral bantlardan kırmızı bant dışında kalan bant, orijinal on bandın içerisinde çıkarılmıştır. Yeni



Şekil 9. ABA işleminde elde edilen ABA'ların yeni Y koordinatlarında gösterimi (Genç ve Smith, 2005)

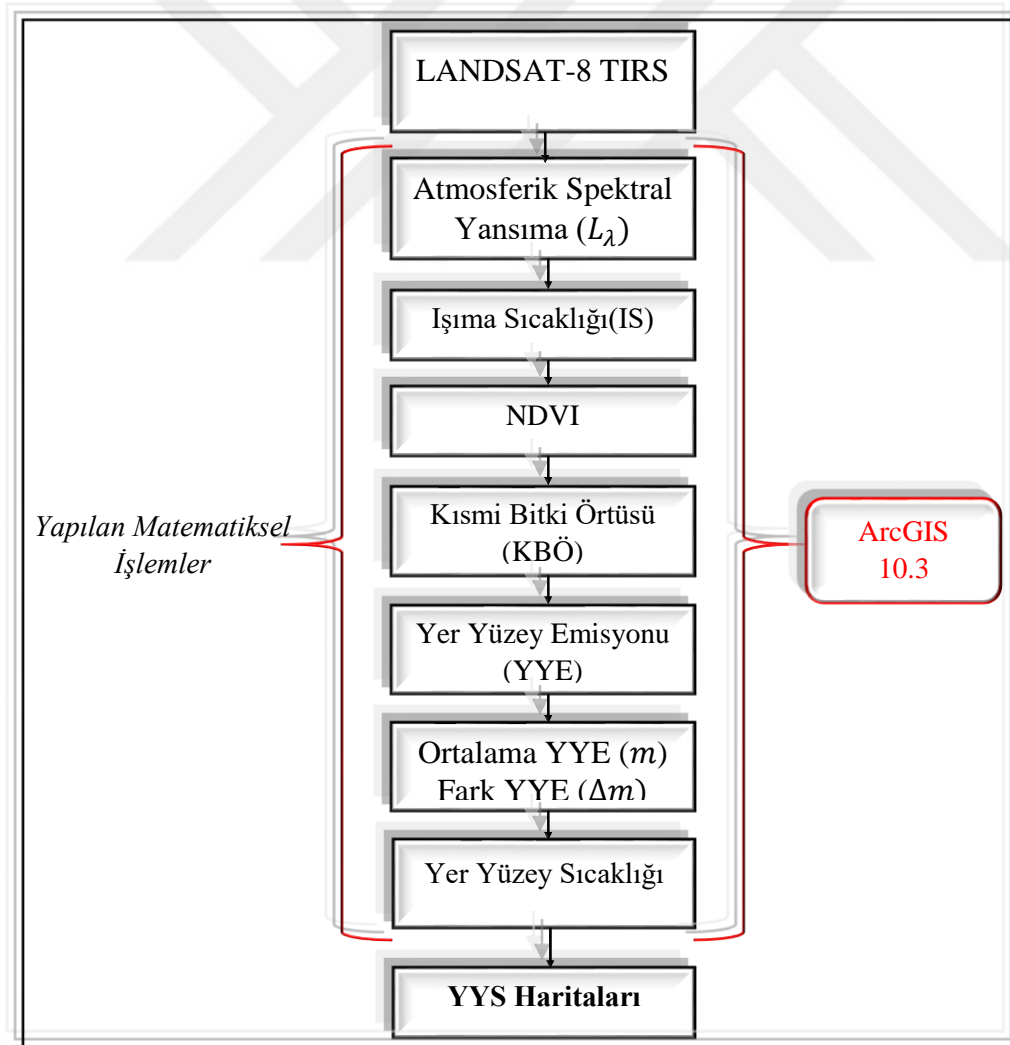
Çalışmada kullanılan iki ayrı yıl için (2016 ve 2020) toplamda otuzar bant ile çalışılan orijinal görüntü üzerine ABA işlemi uygulanmıştır. 2016 ve 2020 yılları için ham verilerdeki otuzar bant ABA işlemi uygulandıktan sonra AB1, AB2, AB3, AB4, AB5 ve AB6 olmak üzere hesaplanmıştır. Ana görüntüdeki otuz bandın gerçekte altı bant ile temsil edileceği anlaşılmıştır. Elde edilen bu hesaplanmış yeni görüntü ERDAS Imagine yazılımı ile oluşturulmuştur. Oluşan görüntünün RO tekniği ile sınıflandırılma işlemi ise SNAP 7.0 programı ile yapılmıştır.

3.5. Yer Yüzey Sıcaklığı

YYs, Dünya yüzeyinin termal veya ısı enerjisinin ölçülebilir haline dönüşmesiyle arazilerin ve etkilediği yüzey üstü oluşumların yaydığı sıcaklığın bir ölçüsü olarak karşımıza çıkmaktadır. Yüzeyin çeşitli sebeplerle ısınmasından dolayı değişen sıcaklık AKBÖ üzerinde de oldukça etki sağlamaktadır. Değişen bu sıcaklığın değeri, UA'da kullanılan uydu verilerinde bulunan termal kızılötesi teknoloji ile hesaplanmaktadır (Latif, 2014).

Çalışmada YYS, Landsat-8 TIRS uydu verilerinden band 10 ve band 11 kullanılarak ArcGIS 10.3 programı ile manuel olarak ve GEE programı ile kod yardımıyla hesaplanmıştır. Atmosferik düzeltmesi otomatik gerçekleşmemiş dijital sayı içeren seviye 1 ürünleri yardımıyla hesaplama gerçekleştirilmiştir. İlk olarak atmosfer üstü yansımaları (L_{λ})

(Denklem 3.5.1) hesaplanmıştır. Bu sayede ham görüntü spektral parlaklık içeren görüntüye dönüşmektedir (Latif, 2014). Sonrasında görüntüde gölgesiz ve bulutsuz koşulların oluşması için (Welch vd., 2021) ışınma sıcaklığı (IS) (Denklem 3.5.2) hesaplanmıştır. Daha sonra vejetasyon indekslerinin en bilineni olan NDVI (Denklem 3.5.3) çıkarılmıştır (Baeza ve Paruelo, 2020). NDVI indeksinin görüntüde aldığı değerler kullanılarak Kısmi Bitki Örtüsü (KBÖ) hesaplanmıştır. KBÖ hesabı (Denklem 3.5.4) görüntü üzerinden indeksin değişimine bakarak matematiksel bir değer üretimi için gereklidir. Daha sonra YYS için en önemli değer olan ve YYS'nin yeterli doğrulukta hesap edilmesini sağlayan (Jiménez-Muñoz vd., 2009) Yer Yüzey Emissivitesi (YYE) (Denklem 3.5.5) hesaplanmıştır. Yüzeyledeki kinetik enerjinin dönüştüğü verimliliğin bir ölçüsü olarak kabul edilmektedir ve yayılan parlaklığı tahmin etmek için Planck yasasını kullanır (Jiménez-Muñoz vd., 2006). Son olarak da hesaplanan tüm değerler YYS hesaplaması (Denklem 3.5.8) için kullanılmıştır (Şekil 10).



Şekil 10. Landsat-8 TIRS verilerinden elde edilen YYS haritalarının oluş şeması

$$L_{\lambda} = (M_L) * DN + A_L \quad (3.5.1)$$

L_{λ} = atmosfer yansımaları

M_L = Landsat metadata dosyasındaki radiance_add değeri

A_L = Landsat metadata dosyasındaki radiance_mult değeri

DN = Landsat metadata dosyasındaki bandın piksel değeri

$$IS = \frac{K_2}{\log\left(1 + \frac{K_1}{L_{\lambda}}\right)} - 273.15 \quad (3.5.1)$$

IS = ısıma sıcaklığı

K_1, K_2 = Landsat metadata dosyasındaki sabit termal değerleri

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (3.5.3)$$

$$KBÖ = \frac{NDVI - NDVI_{min}}{NDVI_{max} - NDVI_{min}} \quad (3.5.4)$$

$$YYE = \varepsilon_s * (1 - KBÖ) + \varepsilon_v * KBÖ \quad (3.6.5)$$

YYE = yer yüzey emissivitesi

$\varepsilon_s, \varepsilon_v$ = bantlar için emissivite değerleri

$$Ortalama Yer Yüzey Emisyonu(m) = \frac{YYE_{10} + YYE_{11}}{2} \quad (3.5.6)$$

$$Fark Yer Yüzey Emisyonu(\Delta m) = YYE_{10} - YYE_{11} \quad (3.5.7)$$

$$YYs = IS_{10} + C_1 * (IS_{10} - IS_{11}) + C_2 * (IS_{10} - IS_{11})^2 + C_0 + (C_3 + C_4 * W) * (1 - m) + (C_5 + C_6 * W) * \Delta m \quad (3.5.8)$$

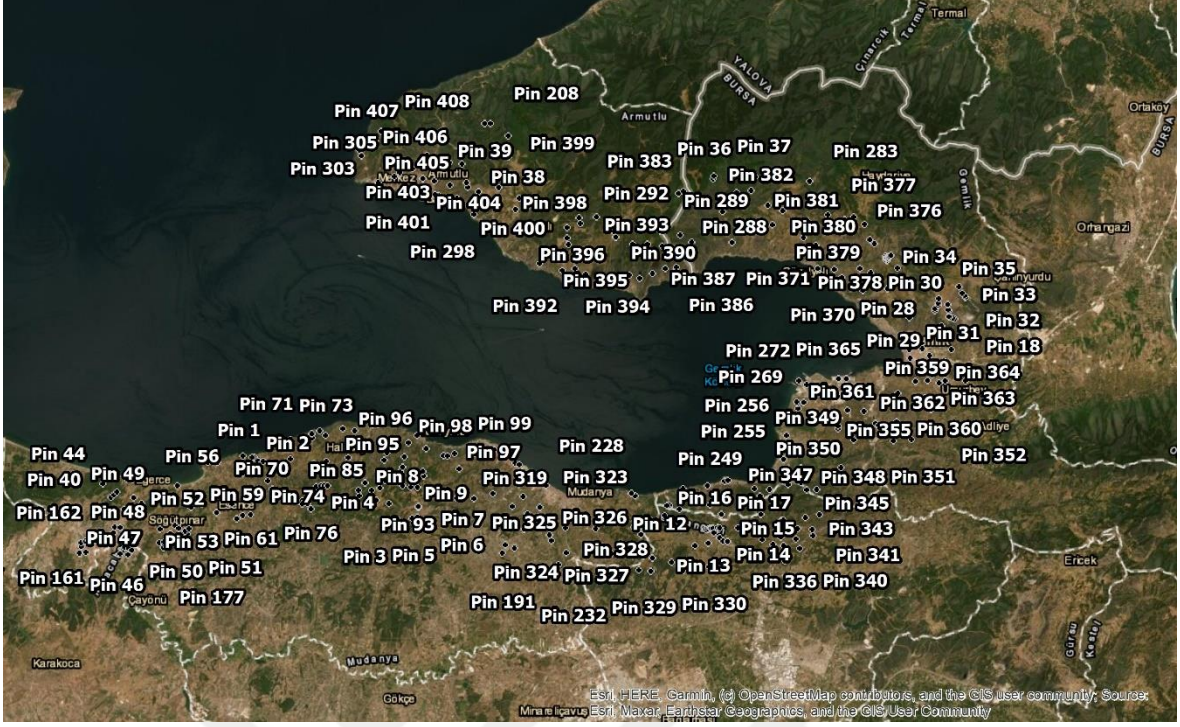
C değerleri = bölünmüş pencere için katsayılar

W = bantlar için sabit katsayı

3.6. Doğruluk Analizi

Uydu görüntüleri ile yapılan sınıflandırmaların ve diğer analizlerin sonucunda yapılan tahminin nicelleştirilmesi adına doğruluk değerlendirme UA ve CBS alanında önemli bir aşama olarak kabul edilmektedir (Abbas ve Jaber, 2020; Manisha B. Patil vd., 2012; Yulianti, 2019). Bu sebeple kullanılan veri setinin yorumlamasının yanlış bilgiler içermemesi için uygun bir doğrulama yapılması gerekmektedir (Di Zhang vd., 2019). Bu bağlamda doğrulama, sınıflandırılan piksellerin kalitesini anlamak için gerçekte karşılık geldiği yer kontrol noktalarıyla arasındaki karşılaştırmayı ölçerek nesnel bir temel oluşturma çabası içindedir. Burada amaç, araştırmanın ve devamında sınıflandırılan verinin amacına uygunluğunu açıklamaktır (Foody, 2009).

Çalışmada, yapılan her sınıflandırma için ayrı ayrı ~410 adet yer kontrol noktası yüksek çözünürlüklü bir referans olması dolayısıyla Google Earth Pro programı yardımıyla oluşturulmuştur. Sınıflandırma kalitesi için oluşturulan 410 yer kontrol noktası Denklem 3.6.1'e göre (Guan vd., 2012) her sınıf için minimum değer üstünde tutularak seçilmiştir. Ayrıca yer örnek noktalarının seçimindeki yaklaşımın daha anlaşılır olması için arazi çalışması yapılmış ve görsel yorumlama çalışmaya katkı sağlamıştır. Çalışma alanında kullanılan yer kontrol noktalarının Google Earth Pro programı içindeki görüntüsü Şekil 11'de gösterilmektedir.



Şekil 1. Çalışma alanındaki yer kontrol noktalarının gösterimi

$$N = \frac{Z^2 * p(100-q)}{E^2} \quad (3.6.1)$$

N = seçilecek nokta sayısı

Z = iki taraflı güven düzeyi(normal standart sapmadan)

p = beklenen yüzde doğruluk

q = mantık operatörü

E= izin verilen hata

3.7. Sosyoekonomik Verilerin Toplanması

Gerek çevresel etkilerden kaynaklı, gerekse kamusal düzenin bir parçası olarak değişen dinamikler AKBÖ durumu için gerekçeler oluşturmaktadır. Özellikle ulusal düzeyde sanayi yatırımlarının yapıldığı bölgelerde meydana gelen hızlı ve dengesiz büyümeler AKBÖ değişimine neden olmaktadır (Dekolo vd., 2015).

Ülkemizde 2016-2020 yılları arasında çalışma alanında sosyo-ekonomik yapıyı etkileyecek gelişmeler Şekil 12’de gösterilmiştir. Çalışma alanında Bursa’ya bağlı Gemlik ilçesinde 7 köy ve 6 mahalle, Mudanya ilçesinde 17 mahalle, Osmangazi ilçesinde 2 mahalle

ve Yalova'ya bađlı Armutlu ilçesinde 7 köy bulunmaktadır. Alanda yatırım kararları ve uygulamaları ile beraber yapılaşmaların hızlanması sonucu geçirimsiz yüzeyler artmıştır. Pandeminin başlaması, ulusal düzeyde ticaret ve göç politikaları ve diđer sosyo-ekonomik gerekçelerle ülke düzeyinde (Şekil 13) ve çalışma alanı için (Şekil 14) nüfus artışı ve artış hızları etkilenmiştir.


2016

- **19 Mart**
Türkiye ile AB arasında mülteci krizinin çözümü için anlaşma sağlanması
- **1 Temmuz**
Osmangazi Köprüsü hizmete girmesi
- **12 Mart 2017**
Gemlik - Bursa Kuzey Kavşađı hizmete girmesi

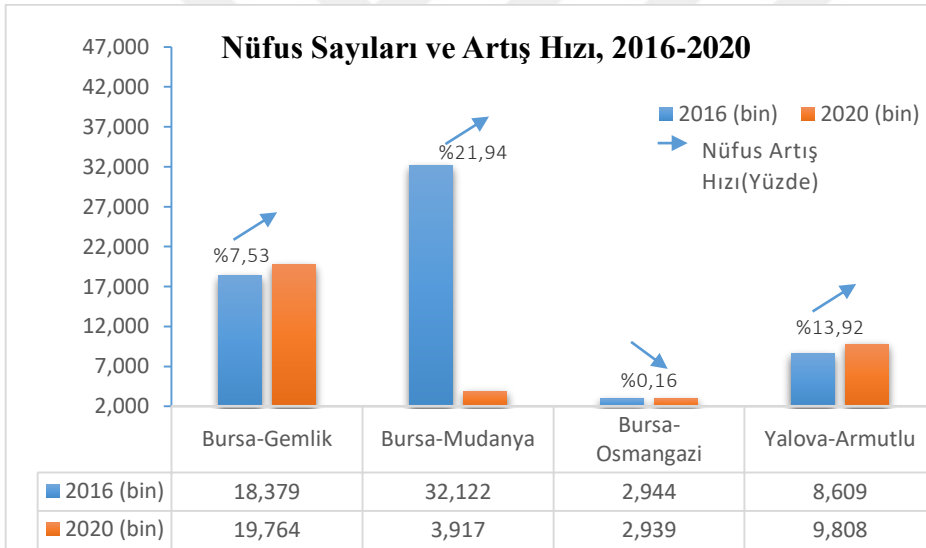
2020

- **10 Ocak**
COVID-19 hastalığı ile mücadele için TC Sağlık Bakanlığı bünyesinde Koronavirüs Bilim Kurulu oluşturulması
- **11 Mart**
TR'de COVID-19 pandemisi: Sağlık Bakanlığı, TR'de ilk kez Koronavirüs vakasına rastlanıldığıının açıklanması
- **18 Temmuz**
TOGG araç üretim fabrikasının yapılmaya başlanması.

Şekil 22. 2016-2020 yıllarında gelişen önemli olaylar



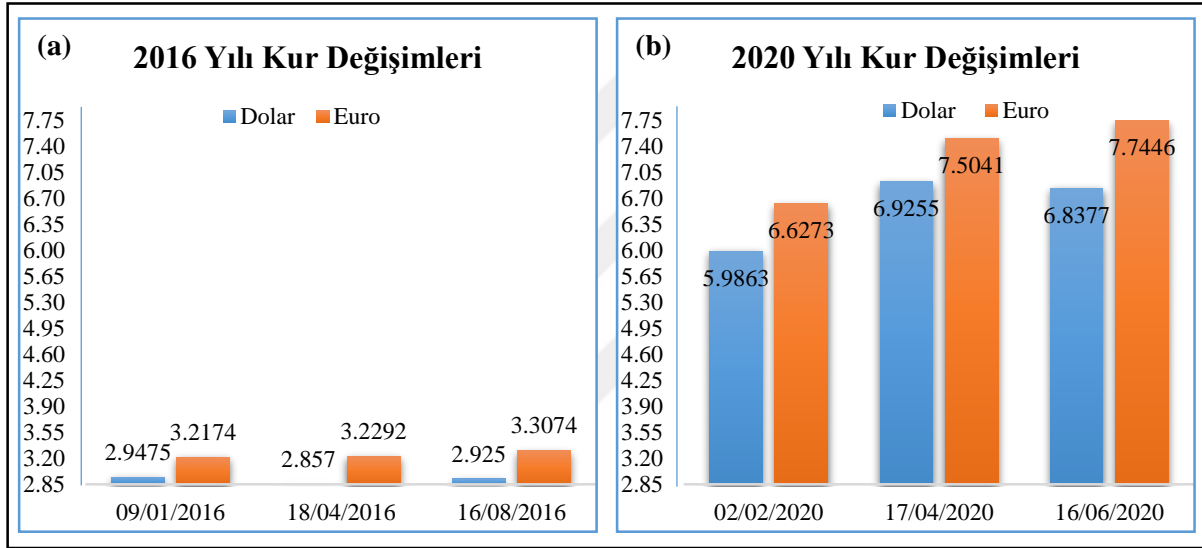
Şekil 13. 2016-2020 yıllarında ülke düzeyinde nüfus artışı ve artış hızı sayısal gösterimi




Şekil 14. 2016-2020 yıllarında çalışma alanına ait nüfus artışı ve artış hızı sayısal gösterimi

Dünyayı etkisi altına alan pandemi sonrasında iki ayrı yılda gerçekleşen kur değişimleri ile TL değerindeki iniş-çıkış formu birçok alanı etkilemiştir (Şekil 15a -Şekil 15b). 2016 ve 2020 yıllarında kış ayında dolar kuru 2.9475 ve 5.9863, euro kuru 3.2174 ve 6.6273 olarak; bahar ayında dolar kuru 2.857 ve 6.9255; euro kuru 3.2292 ve 7.5041 olarak; yaz ayında dolar kuru 2.925 ve 6.8377; euro kuru 3.3074 ve 7.7446 olarak kayda geçmiştir. 4 yılda toplamda minimum %103 artış (kış – dolar) kaydedilirken maksimum %142 artış (yaz – dolar) görülmektedir. Bu bağlamda Şekil 16’da da görüldüğü üzere, GSYH içindeki

carri fiyatlarla oluşan yüzdellik payların oranları değışime uğramıştır. 2016 ve 2020 yılları arasında inřaat sektöründe %8.6 ve %5.2 oranları, gayrimenkul sektöründe %7.7 ve %6.3 oranları, tarım/ormancılık/balıkçılık sektöründe %6.2 ve %6.7 oranları ve insan sađlığı ve sosyal hizmet faaliyetleri sektöründe %2.6 ve %2.8 oranları görölmüştür. Buna göre, inřaat ve gayrimenkul sektörü ařađı ivmede pay almışken, kurdan nispeten başka sebeplerle daha az etkilenen tarım/ormancılık/balıkçılık alanı GSYH içinde artış ile kendini göstermektedir. 2020 yılında oluşan pandemi sürecinin insan sađlığı üzerindeki olumsuz etkilerinin azaltılması adına, sađlık alanının GSYH içindeki payı artırılmıştır.



Şekil 15. 2016 yılında dolar ve euro (a) , 2020 yılında dolar ve euro (b) düzeyinde kur değışim



Şekil 16. 2016 (a) – 2020 (b) yıllarında sektörlerdeki cari fiyatlarla GSYH yüzdelerinin gösterimi

Araştırma alanında gelişen ve gelişmekte olan olaylar yerleşim bölgeleri ve etrafında AKBÖ değişim dinamiğine etki etmiştir. AKBÖ değişiminin belirlenmesi; kentleşmenin kıyı alanları üzerindeki etkilerinin anlaşılmasına, doğal çevrenin, azami kaynakların ve çevresel değişikliklerin izlenmesine katkıda bulunmaktadır (Hussein vd., 2020)

DÖRDÜNCÜ BÖLÜM

ARAŞTIRMA BULGULARI

4.1. AKBÖ Sınıflama Sonuçları

Çalışma alanındaki sınıflandırılmış verilere ait AKBÖ değişikliğinin gösterildiği, orijinal bantlardaki RO ve NTS tekniği ile sınıflama yapılmış haritalar, ABA görüntüsü ile oluşturulmuş haritalar ve indeks ile oluşturulmuş haritalar Şekil 17 - Şekil 39 arasında gösterilmektedir.

Görüldüğü üzere çalışma alanındaki haritalar Mera (M), Orman (O), Su (S), Tarım (T), Yerleşim (Y) ve Zeytin (Z) olarak altı AKBÖ sınıfı ile oluşturulmuştur. Sarı alanlar M sınıfına, koyu yeşil alanlar O sınıfına, açık mavi alanlar S sınıfına, açık yeşil alanlar mevcut T sınıfına, kırmızı alanlar Y sınıfına ve açık turuncu ile gösterilen alanlar Z sınıfına atanan alanları göstermektedir.

Çalışmada, AKBÖ haritaları iki yıl arasındaki değişimler indekslerle incelenerek sınıflandırma sonucunda belirlenen sınıflardaki değişimin açıklaması araştırmanın bulgularında sunulmuştur. Şekil 40 ile Şekil 41 arasında gösterilen grafikler ise oluşturulan indekslerin iki ayrı yıldaki sezonluk farklarına odaklanmıştır.

4.1.1. Yıllara Göre Alan Sonuçları

Şekil 17'deki haritalar orijinal on banda uygulanan RO sınıflandırma tekniğini göstermektedir. Buna göre; 2016-2020 kış sezonunda M sınıfı %10.87 ve Y sınıfı %15.35 arttığı, O sınıfı %0.99, S sınıfı %13.32, T sınıfı %10.98 ve Z sınıfı %0.28 azaldığı; 2016-2020 bahar sezonunda M, Y ve Z sınıfları sırasıyla (%14.46, %27.39 ve %0.60) arttığı, O, S ve T sınıfları sırasıyla (%3.58, %10.40 ve %19.86) azaldığı; 2016-2020 yaz sezonunda O, Y ve Z sınıfları sırasıyla (%3.97, %22.44 ve %0.91) arttığı, M, S ve T sınıfları sırasıyla (%2.98, %86.95 ve %34.17) azaldığı tespit edilmiştir.

Şekil 18'deki haritalar orijinal on banda uygulanan NTS sınıflandırma tekniğini göstermektedir. Buna göre; 2016-2020 kış sezonunda M, S, T, Y ve Z sınıfları sırasıyla (%66.88, %229.63, %0.52, %1.66 ve %3.63) arttığı, O sınıfının %10.86 azaldığı; 2016-2020 bahar sezonunda M, S, T, ve Y sınıfları sırasıyla (%1.06, %34.51, %39.69 ve %25.04) arttığı,

O ve Z sınıfları sırasıyla (%7.57 ve %2.37) azaldığı, 2016-2020 yaz sezonunda S, T, Y ve Z sınıfları sırasıyla (%95.44, %63.07, %5.60 ve %1.72) arttığı, M ve O sınıfları sırasıyla (%6.68 ve %18.23) azaldığı anlaşılmıştır.

Şekil 19'deki haritalar orijinal dokuz bant (B2, B3, B4, B6, B7, B8, B8a, B11, B12) ve İ₅ indeksinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir. Buna göre; 2016-2020 kış sezonunda M, O ve T sınıfları sırasıyla (%61.72, %26.62 ve %66.97) arttığı, S, Y ve Z sınıfları sırasıyla (%56.35, %34.85 ve %9.32) azaldığı; 2016-2020 bahar sezonunda S ve Z sınıfları sırasıyla (%11.59 ve %9.35) arttığı, M, O, T ve Y sınıfları sırasıyla (%23.61, %15.51, %7.26 ve %2.91) azaldığı, 2016-2020 yaz sezonunda M ve Z sınıfları sırasıyla (%25.83 ve %8.49) arttığı, O, S, T ve Y sınıfları sırasıyla (%9.57, %81.52, %34.27 ve %1.00) azaldığı anlaşılmıştır.

Şekil 20'deki haritalar orijinal dokuz bant (B2, B3, B4, B5, B7, B8, B8a, B11, B12) ve İ₆ indeksinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir. Buna göre; 2016-2020 kış sezonunda M, O, T ve Y sınıfları sırasıyla (%104.91, %21.48, %6.74 ve %2.15) arttığı, S ve Z sınıfları sırasıyla (%19.37, ve %9.45) azaldığı; 2016-2020 bahar sezonunda O, S, Y, ve Z sınıfları sırasıyla (%1.27, %10.07, %17.58 ve %0.77) arttığı, M ve T sınıfları sırasıyla (%3.20 ve %30.14) azaldığı, 2016-2020 yaz sezonunda M, Y ve Z sınıfları sırasıyla (%46.07, %2.73 ve %4.46) arttığı, O, S ve T sınıfları sırasıyla (%11.31, %47.03 ve %12.85) azaldığı anlaşılmıştır.

Şekil 21'deki haritalar orijinal dokuz bant (B2, B3, B4, B5, B6, B8, B8a, B11, B12) ve İ₇ indeksinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir. Buna göre; 2016-2020 kış sezonunda M, O, S ve T sınıfları sırasıyla (%62.78, %5.90, %13.28 ve %9.49) arttığı, Y ve Z sınıfları sırasıyla (%0.54, ve %10.07) azaldığı; 2016-2020 bahar sezonunda Y ve Z sınıfları sırasıyla (%24.20 ve %3.28) arttığı, M, O, S ve T sınıfları sırasıyla (%5.00, %7.13, %13.25 ve %29.72) azaldığı, 2016-2020 yaz sezonunda M, O, S ve Z sınıfları sırasıyla (%15.79, %2.00, %52.99 ve %0.50) arttığı, T ve Y sınıfları sırasıyla (%24.15 ve %4.23) azaldığı bulunmuştur.

Şekil 22'deki haritalar orijinal dokuz bant (B2, B3, B4, B5, B6, B7, B8a, B11, B12) ve İ₈ indeksinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir. Buna göre; 2016-2020 kış sezonunda S, T ve Z sınıfları sırasıyla (%61.23, %28.96 ve %2.77) arttığı, M, O ve Y sınıfları sırasıyla (%22.16, %2.42 ve %19.78) azaldığı; 2016-2020 bahar

sezonunda M, S ve Z sınıfları sırasıyla (%8.85, %93.75 ve %10.33) arttığı, O, T ve Y sınıfları sırasıyla (%13.82, %29.50 ve %3.71) azaldığı, 2016-2020 yaz sezonunda M ve Z sınıfları sırasıyla (%24.86 ve %4.62) arttığı, O, S, T ve Y sınıfları sırasıyla (%0.62, %42.34, %17.32 ve %11.67) azaldığı bulunmuştur.

Şekil 23'deki haritalar orijinal dokuz bant (B2, B3, B4, B5, B6, B7, B8, B11, B12) ve İ_{8a} indeksinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir. Buna göre; 2016-2020 kış sezonunda M, O ve T sınıfları sırasıyla (%41.53, %8.85 ve %44.17) arttığı, S, Y ve Z sınıfları sırasıyla (%8.85, %93.75 ve %6.66) azaldığı; 2016-2020 bahar sezonunda O, S ve Y sınıfları sırasıyla (%39.19, %15.17 ve %36.70) arttığı, M, T ve Z sınıfları sırasıyla (%30.18, %24.71 ve %14.66) azaldığı, 2016-2020 yaz sezonunda M, O, S ve Z sınıfları sırasıyla (%50.41, %7.55, %23.09 ve %1.20) arttığı, T ve Y sınıfları sırasıyla (%31.86 ve %3.57) azaldığı bulunmuştur.

Şekil 24'deki haritalar orijinal dokuz bant (B2, B3, B4, B5, B6, B7, B8, B8a, B12) ve İ₁₁ indeksinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir. Buna göre; 2016-2020 kış sezonunda M, O ve T sınıfları sırasıyla (%92.86, %11.13 ve %56.05) arttığı, S, Y ve Z sınıfları sırasıyla (%39.59, %7.78 ve %8.78) azaldığı; 2016-2020 bahar sezonunda M, O, S, T ve Y sınıfları sırasıyla (%37.07, %22.20, %0.13, %10.66 ve %28.25) arttığı, Z sınıfının %12.63 azaldığı, 2016-2020 yaz sezonunda M ve T sınıfları sırasıyla (%89.47 ve %2.58) arttığı, O, S, Y ve Z sınıfları sırasıyla (%2.44, %68.15, %15.76 ve %3.61) azaldığı bulunmuştur.

Şekil 25'deki haritalar orijinal dokuz bant (B2, B3, B4, B5, B6, B7, B8, B8a, B11) ve İ₁₂ indeksinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir. Buna göre; 2016-2020 kış sezonunda M, O ve T sınıfları sırasıyla (%9.6, %13.17 ve %9.59) arttığı, S, Y ve Z sınıfları sırasıyla (%37.05, %1.91 ve %5.77) azaldığı; 2016-2020 bahar sezonunda M, O, S ve Y sınıfları sırasıyla (%10.17, %31.59, %45.61 ve %12.85) arttığı, T ve Z sınıfları sırasıyla (%4.30 ve %12.60) azaldığı, 2016-2020 yaz sezonunda M ve O sınıfları sırasıyla (%47.85 ve %14.39) arttığı, S, T, Y ve Z sınıfları sırasıyla (%41.06, %0.64, %1.48 ve %5.24) azaldığı bulunmuştur.

Şekil 26'deki haritalar orijinal sekiz bant (B2, B3, B4, B7, B8, B8a, B11, B12), İ₅ ve BO₆ indekslerinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir. Buna göre; 2016-2020 kış sezonunda M ve Y sınıfları sırasıyla (%20.50 ve %13.43) arttığı,

O, S, T ve Z sınıfları sırasıyla (%1.50, %33.73, %3.27 ve %1.58) azaldığı; 2016-2020 bahar sezonunda O, S ve Y sınıfları sırasıyla (%1.03, %16.88 ve %34.61) arttığı, M, T ve Z sınıfları sırasıyla (%11.44, %14.13 ve %0.29) azaldığı, 2016-2020 yaz sezonunda M, S, Y ve Z sınıfları sırasıyla (%37.99, %59.85, %17.02 ve %6.35) arttığı, O ve T sınıfları sırasıyla (%2.42 ve %23.18) azaldığı bulunmuştur.

Şekil 27'deki haritalar orijinal sekiz bant (B2, B3, B4, B6, B8, B8a, B11, B12), İ₅ ve BO₇ indekslerinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir. Buna göre; 2016-2020 kış sezonunda M, Y ve Z sınıfları sırasıyla (%59.35, %0.30 ve %2.08) arttığı, O, S ve T sınıfları sırasıyla (%4.87, %43.68 ve %15.17) azaldığı; 2016-2020 bahar sezonunda M, S, Y ve Z sınıfları sırasıyla (%74.90, %35.29, %12.99 ve %4.10) arttığı, O ve T sınıfları sırasıyla (%10.32 ve %18.20) azaldığı, 2016-2020 yaz sezonunda M, S ve Z sınıfları sırasıyla (%73.12, %74.44 ve %6.93) arttığı, O, T ve Y sınıfları sırasıyla (%5.16, %34.75 ve %2.32) azaldığı bulunmuştur.

Şekil 28'deki haritalar orijinal sekiz bant (B2, B3, B4, B7, B8, B8a, B11, B12), İ₆ ve BO₆ indekslerinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir. Buna göre; 2016-2020 kış sezonunda M, Y ve Z sınıfları sırasıyla (%30.33, %2.13 ve %0.36) arttığı, O, S ve T sınıfları sırasıyla (%2.90, %57.45 ve %3.47) azaldığı; 2016-2020 bahar sezonunda M, O, S, Y ve Z sınıfları sırasıyla (%21.29, %9.44, %47.37, %3.77 ve %0.65) arttığı, T sınıfının %31.97 azaldığı, 2016-2020 yaz sezonunda M ve Z sınıfları sırasıyla (%29.44 ve %9.70) arttığı, S, T, Y ve Z sınıfları sırasıyla (%16.13, %54.52, %14.30 ve %1.76) azaldığı bulunmuştur.

Şekil 29'deki haritalar orijinal yedi bant (B2, B3, B4, B8, B8a, B11, B12), İ₆ ve BO₇ indekslerinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir. Buna göre; 2016-2020 kış sezonunda O, T, Y ve Z sınıfları sırasıyla (%6.06, %9.30, %4.84 ve %0.17) arttığı, M ve S sınıfları sırasıyla (%21.52 ve %55.89) azaldığı; 2016-2020 bahar sezonunda M, S, Y ve Z sınıfları sırasıyla (%37.40, %23.93, %10.56 ve %6.09) arttığı, O ve T sınıfları sırasıyla (%18.30 ve %14.28) azaldığı, 2016-2020 yaz sezonunda M, S ve Z sınıfları sırasıyla (%17.66, %35.60 ve %11.36) arttığı, O, T ve Y sınıfları sırasıyla (%14.45, %27.05 ve %8.13) azaldığı bulunmuştur.

Şekil 30'deki haritalar orijinal yedi bant (B2, B3, B4, B8, B8a, B11, B12), İ₇ ve BO₆ indekslerinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir. Buna

göre; 2016-2020 kış sezonunda M, O, T ve Y sınıfları sırasıyla (%11.74, %3.83, %9.88 ve %16.10) arttığı, S ve Z sınıfları sırasıyla (%7.22 ve %5.49) azaldığı; 2016-2020 bahar sezonunda O, S, Y ve Z sınıfları sırasıyla (%5.20, %37.81, %17.21 ve %2.59) arttığı, M ve T sınıfları sırasıyla (%38.95 ve %35.94) azaldığı, 2016-2020 yaz sezonunda S, Y ve Z sınıfları sırasıyla (%40.66, %2.72 ve %15.45) arttığı, M, O ve T sınıfları sırasıyla (%31.31, %18.78 ve %19.65) azaldığı bulunmuştur.

Şekil 31'deki haritalar orijinal sekiz bant (B2, B3, B4, B6, B8, B8a, B11, B12), İ₇ ve BO₇ indekslerinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir. Buna göre; 2016-2020 kış sezonunda M, Y ve Z sınıfları sırasıyla (%0.60, %21.34 ve %0.89) arttığı, O, S ve T sınıfları sırasıyla (%3.87, %78.15 ve %22.12) azaldığı; 2016-2020 bahar sezonunda O, S, Y ve Z sınıfları sırasıyla (%7.99, %48.00, %25.24 ve %1.49) arttığı, M ve T sınıfları sırasıyla (%2.54 ve %41.77) azaldığı, 2016-2020 yaz sezonunda M, S, Y ve Z sınıfları sırasıyla (%80.49, %20.86, %6.71 ve %15.18) arttığı, O ve T sınıfları sırasıyla (%18.98 ve %33.67) azaldığı bulunmuştur.

Şekil 32'deki haritalar orijinal yedi bant (B2, B3, B4, B7, B8a, B11, B12), İ₈ ve BO₆ indekslerinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir. Buna göre; 2016-2020 kış sezonunda M ve T sınıfları sırasıyla (%75.23 ve %29.95) arttığı, O, S, Y ve Z sınıfları sırasıyla (%3.65, %23.37, %1.88 ve %2.07) azaldığı; 2016-2020 bahar sezonunda M, Y ve Z sınıfları sırasıyla (%109.44, %41.50 ve %2.51) arttığı, O, S ve T sınıfları sırasıyla (%6.05, %28.65 ve %38.84) azaldığı, 2016-2020 yaz sezonunda M, S ve Z sınıfları sırasıyla (%24.88, %39.15 ve %14.64) arttığı, O, T ve Y sınıfları sırasıyla (%23.29, %15.49 ve %4.07) azaldığı bulunmuştur.

Şekil 33'deki haritalar orijinal yedi bant (B2, B3, B4, B6, B8a, B11, B12), İ₈ ve BO₇ indekslerinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir. Buna göre; 2016-2020 kış sezonunda O, T ve Y sınıfları sırasıyla (%0.55, %6.38 ve %6.12) arttığı, M, S ve Z sınıfları sırasıyla (%15.07, %56.95 ve %1.58) azaldığı; 2016-2020 bahar sezonunda M, S, Y ve Z sınıfları sırasıyla (%55.24, %66.67, %41.46 ve %6.06) arttığı, O ve T sınıfları sırasıyla (%17.50 ve %35.90) azaldığı, 2016-2020 yaz sezonunda M, S, Y ve Z sınıfları sırasıyla (%60.90, %92.59, %2.27 ve %12.02) arttığı, O ve T sınıfları sırasıyla (%18.59 ve %25.73) azaldığı bulunmuştur.

Şekil 34'deki haritalar orijinal yedi bant (B2, B3, B4, B7, B8, B11, B12), İ_{8a} ve BO₆ indekslerinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir Buna göre; 2016-2020 kış sezonunda T, Y ve Z sınıfları sırasıyla (%7.90, %19.21 ve %1.36) arttığı, M, O ve S sınıfları sırasıyla (%22.59, %16.28 ve %10.76) azaldığı; 2016-2020 bahar sezonunda M, S, Y ve Z sınıfları sırasıyla (%15.83, %45.03, %42.55 ve %2.42) arttığı, O ve T sınıfları sırasıyla (%6.89 ve %35.89) azaldığı, 2016-2020 yaz sezonunda M, S ve Z sınıfları sırasıyla (%79.08, %52.41 ve %13.53) arttığı, O, T ve Y sınıfları sırasıyla (%21.63, %21.47 ve %5.76) azaldığı bulunmuştur.

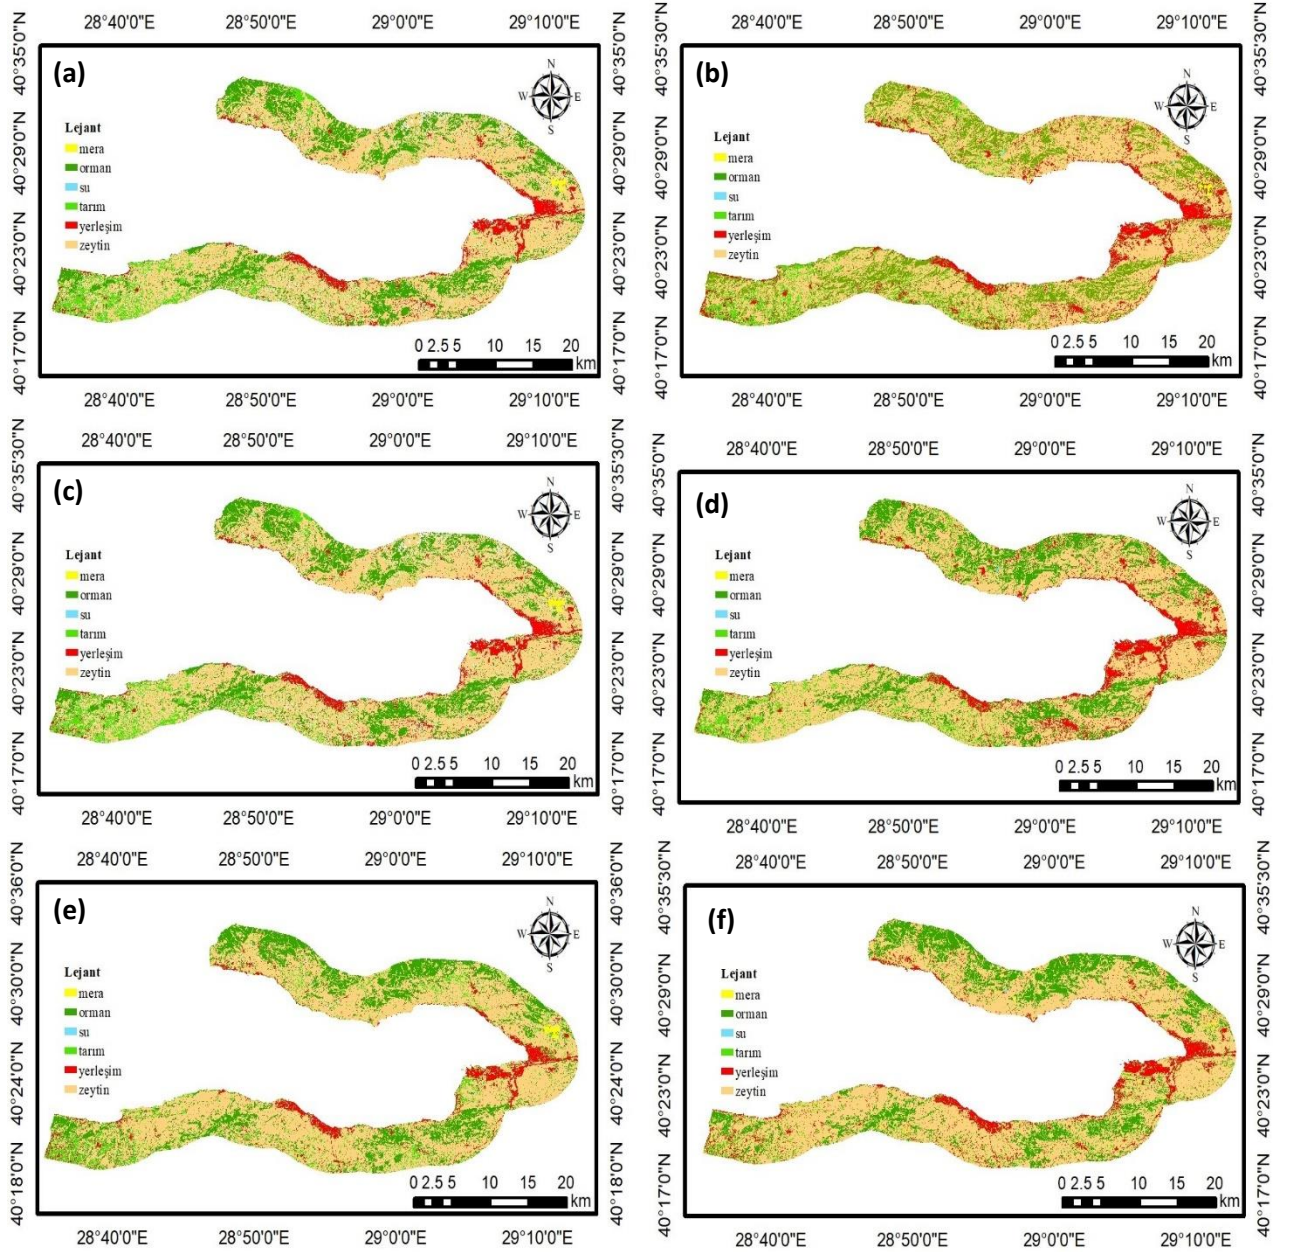
Şekil 35'deki haritalar orijinal yedi bant (B2, B3, B4, B6, B8, B11, B12), İ_{8a} ve BO₇ indekslerinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir Buna göre; 2016-2020 kış sezonunda Y sınıfı %27.30 arttığı, M, O, S, T ve Z sınıfları sırasıyla (%10.42, %9.08, %67.09, %1.37 ve %1.21) azaldığı; 2016-2020 bahar sezonunda M, S ve Z sınıfları sırasıyla (%19.97, %39.44 ve %4.86) arttığı, O, T ve Y sınıfları sırasıyla (%5.09, %2.54 ve %3.43) azaldığı, 2016-2020 yaz sezonunda M, S ve Z sınıfları sırasıyla (%36.97, %33.33 ve %3.70) arttığı, O, T ve Y sınıfları sırasıyla (%3.85, %16.91, %3.40 ve %5.24) azaldığı bulunmuştur.

Şekil 36'deki haritalar orijinal yedi bant (B2, B3, B4, B7, B8, B8a, B12), İ₁₁ ve BO₆ indekslerinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir. Buna göre; 2016-2020 kış sezonunda Y ve Z sınıfları sırasıyla (%8.89 ve %3.45) arttığı, M, S, T ve Y sınıfları sırasıyla (%13.45, %9.79, %67.99 ve %10.98) azaldığı; 2016-2020 bahar sezonunda S, Y ve Z sınıfları sırasıyla (%116.23, %6.10 ve %5.23) arttığı, M, O ve T sınıfları sırasıyla (%31.71, %5.88 ve %24.75) azaldığı, 2016-2020 yaz sezonunda S ve Z sınıfları sırasıyla (%43.73 ve %5.93) arttığı, M, O, T ve Y sınıfları sırasıyla (%9.88, %7.33, %4.75 ve %15.02) azaldığı bulunmuştur.

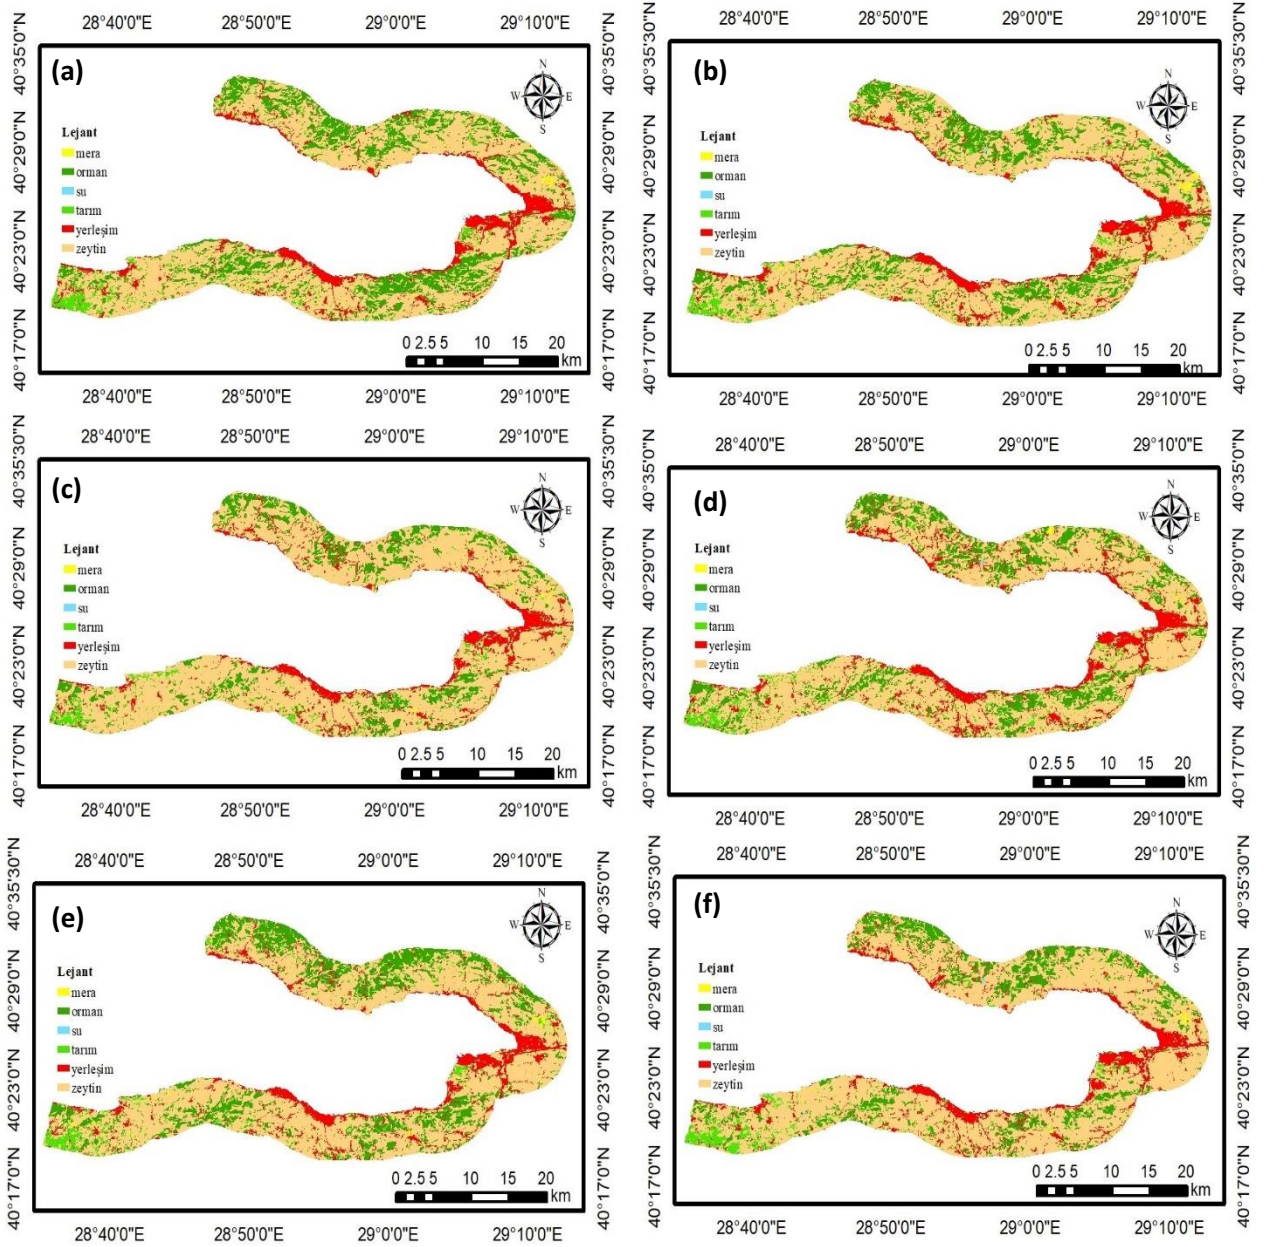
Şekil 37'deki haritalar orijinal yedi bant (B2, B3, B4, B6, B8, B8a, B12), İ₁₁ ve BO₇ indekslerinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir. Buna göre; 2016-2020 kış sezonunda T ve Y sınıfları sırasıyla (%4.16 ve %20.24) arttığı, M, O, S ve Z sınıfları sırasıyla (%13.67, %8.45, %49.30 ve %1.96) azaldığı; 2016-2020 bahar sezonunda S, Y ve Z sınıfları sırasıyla (%102.56, %13.26 ve %10.75) arttığı, M, O ve T sınıfları sırasıyla (%30.31, %18.95 ve %30.39) azaldığı, 2016-2020 yaz sezonunda S ve Z sınıfları sırasıyla (%84.21 ve %4.63) arttığı, M, O, T ve Y sınıfları sırasıyla (%17.90, %7.39, %3.42 ve %6.51) azaldığı bulunmuştur.

Şekil 38'deki haritalar orijinal yedi bant (B2, B3, B4, B7, B8, B8a, B11), İ₁₂ ve BO₆ indekslerinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir. Buna göre; 2016-2020 kış sezonunda T ve Y sınıfları sırasıyla (%21.95 ve %28.13) arttığı, M, O, S ve Z sınıfları sırasıyla (%34.09, %9.28, %58.44 ve %3.93) azaldığı; 2016-2020 bahar sezonunda S, Y ve Z sınıfları sırasıyla (%39.56, %30.83 ve %1.43) arttığı, M, O ve T sınıfları sırasıyla (%19.50, %2.57 ve %28.09) azaldığı, 2016-2020 yaz sezonunda S, Y ve Z sınıfları sırasıyla (%90.45, %3.16 ve %2.52) arttığı, M, O ve T sınıfları sırasıyla (%10.99, %1.07 ve %25.99) azaldığı bulunmuştur.

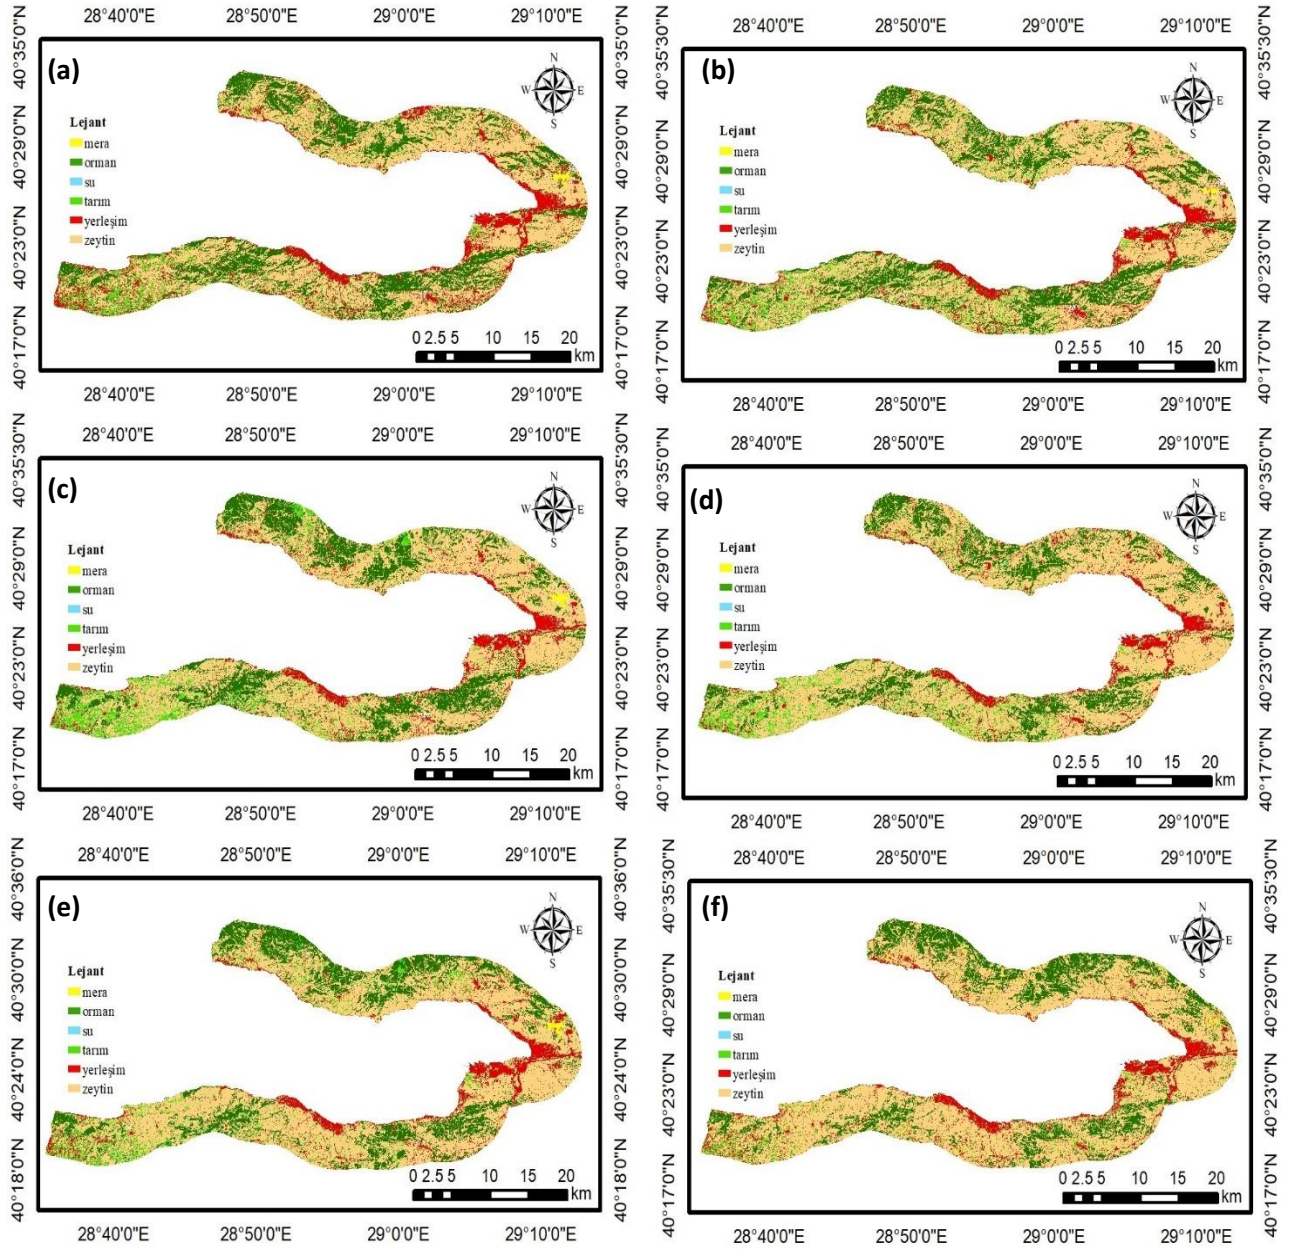
Şekil 39'deki haritalar orijinal yedi bant (B2, B3, B4, B6, B8, B8a, B11), İ₁₂ ve BO₇ indekslerinin birleşiminin RO sınıflandırma tekniğiyle elde edilmesini göstermektedir. Buna göre; 2016-2020 kış sezonunda T ve Z sınıfları sırasıyla (%13.50 ve %16.70) arttığı, M, O, S ve Z sınıfları sırasıyla (%28.96, %10.46, %14.53 ve %0.72) azaldığı; 2016-2020 bahar sezonunda S, Y ve Z sınıfları sırasıyla (%96.15, %14.51 ve %5.95) arttığı, M, O ve T sınıfları sırasıyla (%8.00, %12.21 ve %27.59) azaldığı, 2016-2020 yaz sezonunda S ve Z sınıfları sırasıyla (%44.00 ve %5.62) arttığı, M, O, T ve Y sınıfları sırasıyla (%28.00, %5.90, %25.75 ve %3.70) azaldığı bulunmuştur.



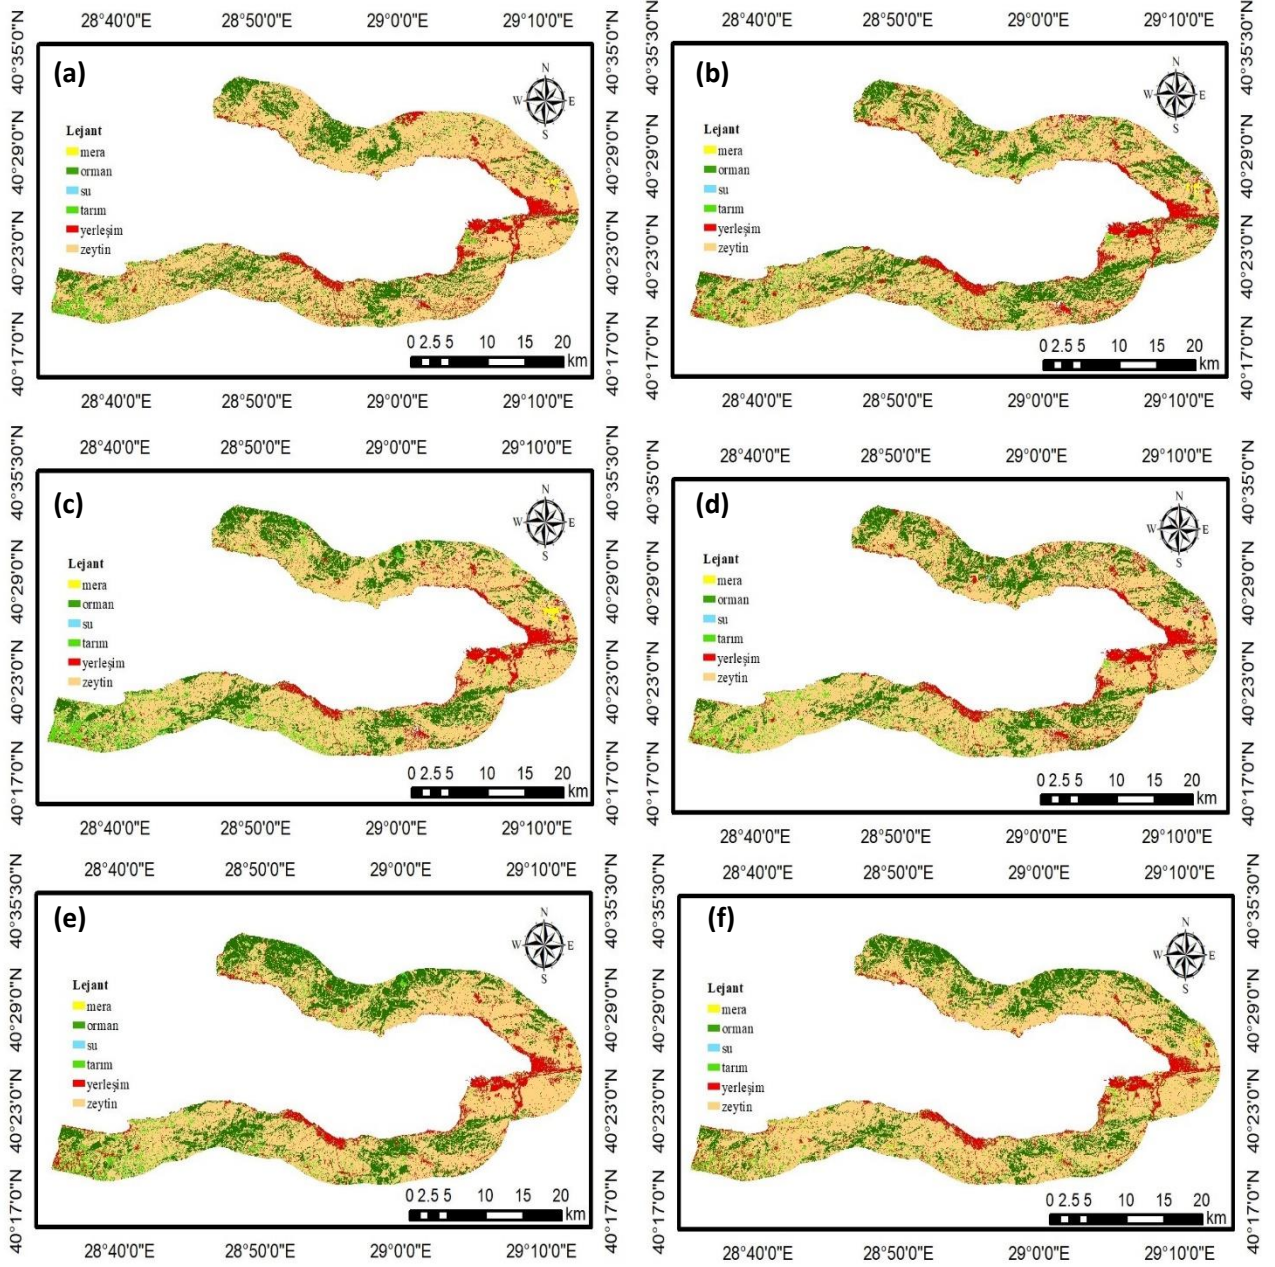
Şekil 3. Oro / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



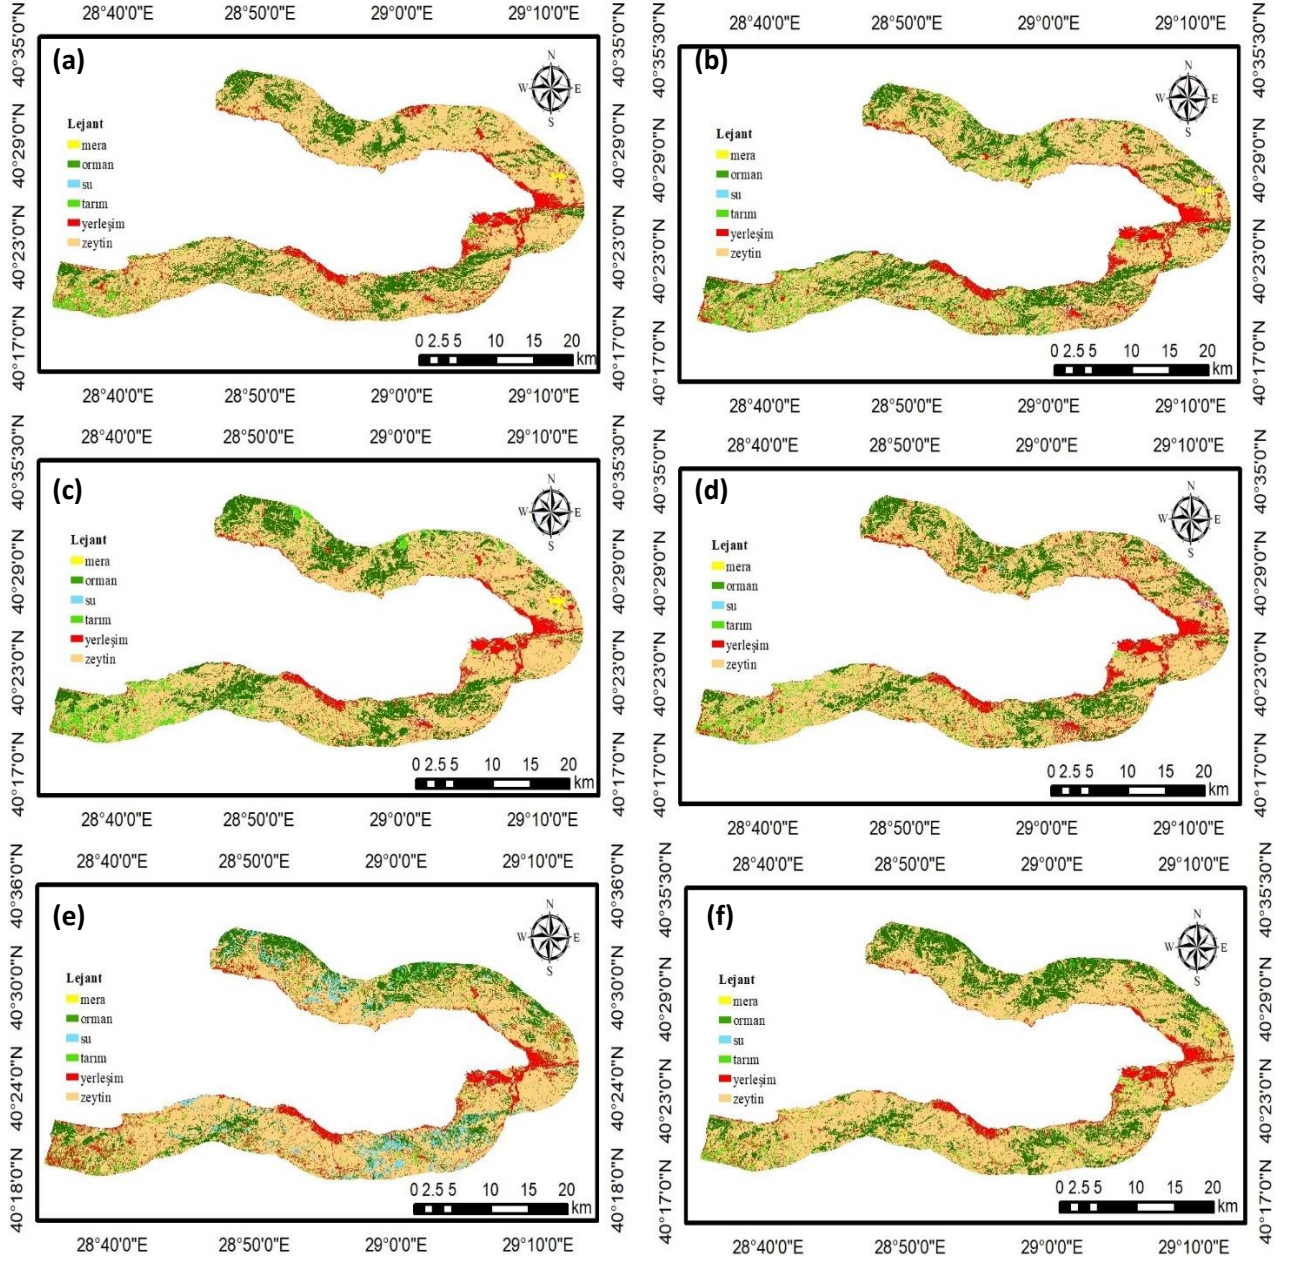
Şekil 4. Oñts / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



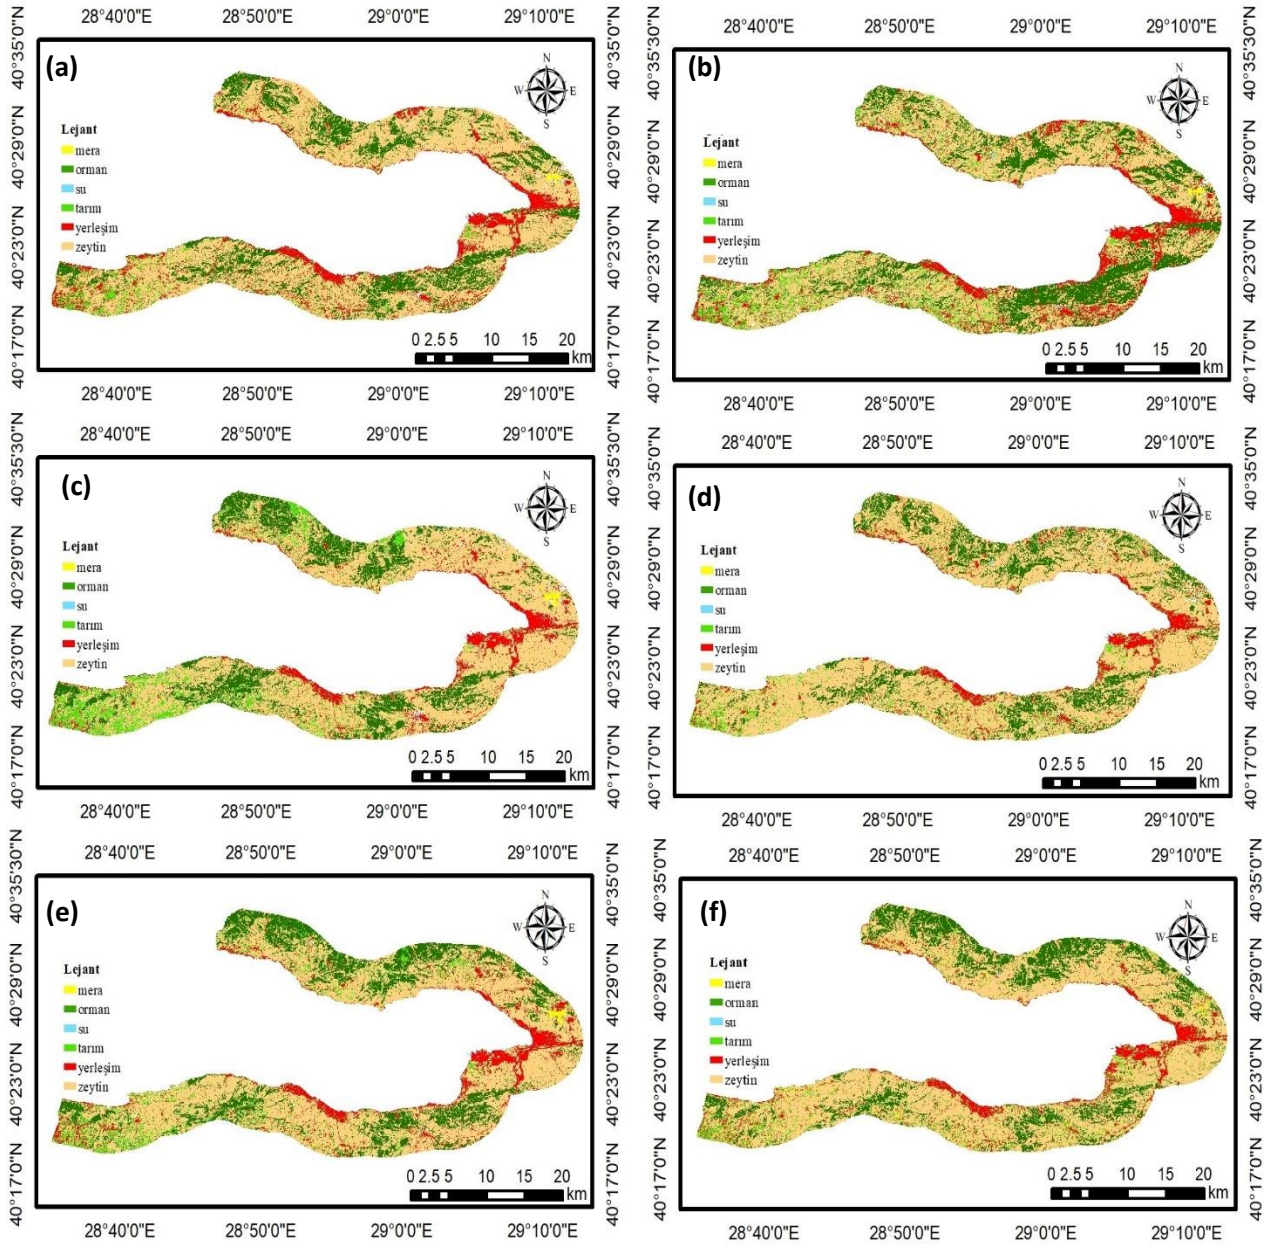
Şekil 5. OI₅ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



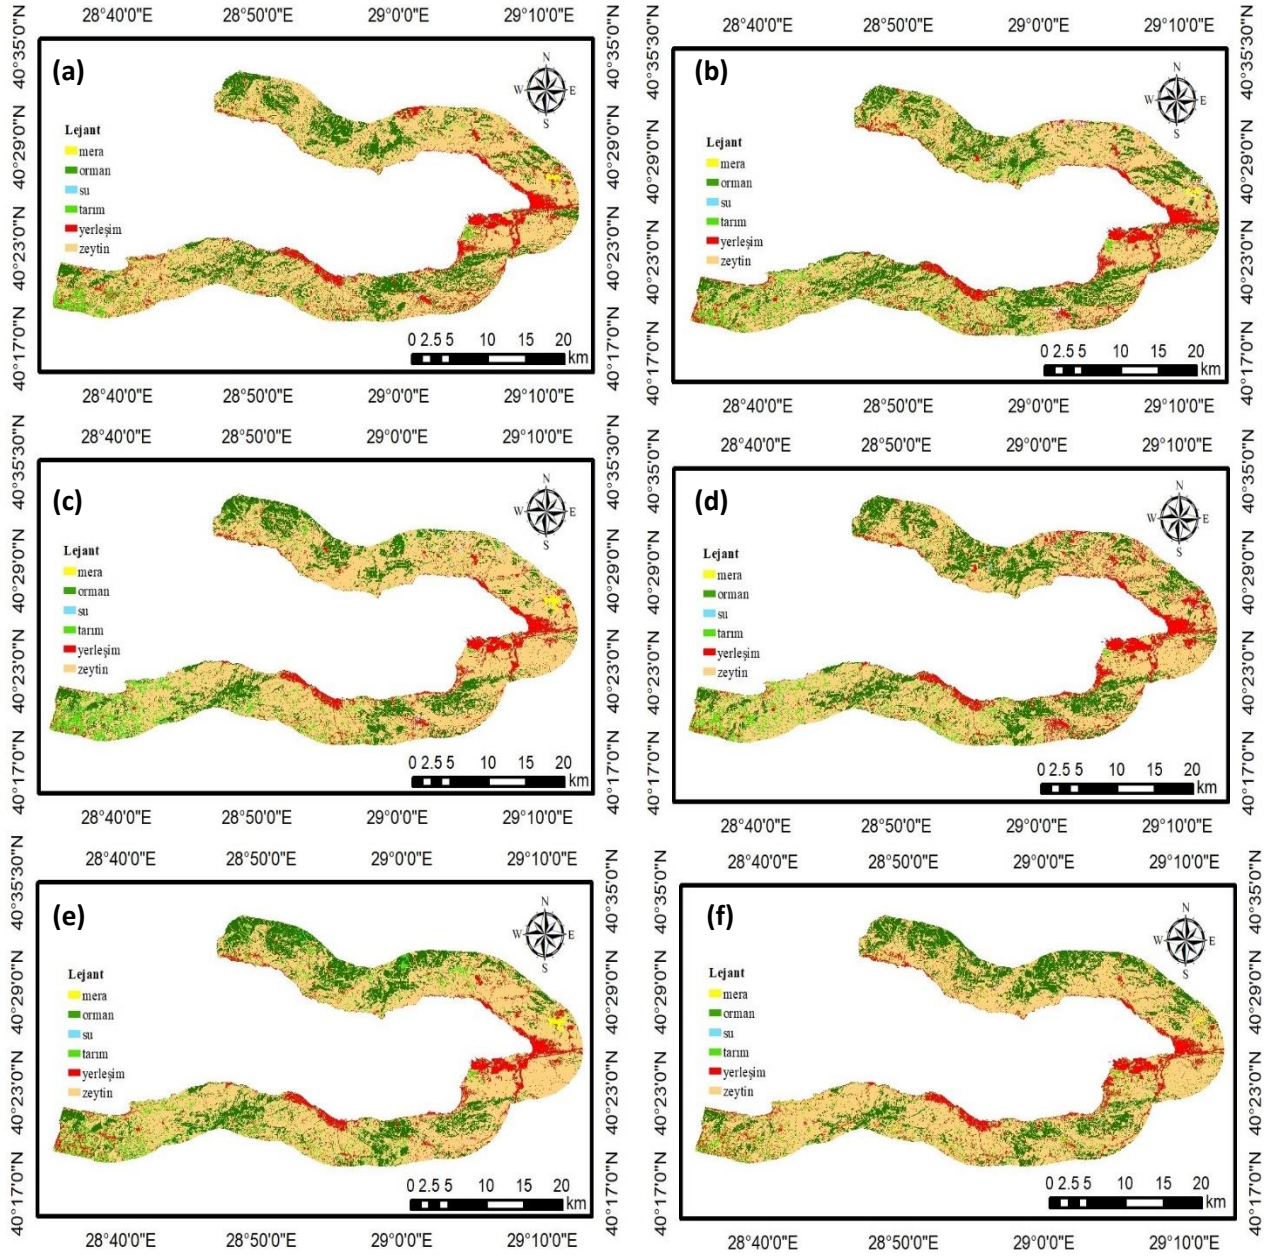
Şekil 6. OI₆ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



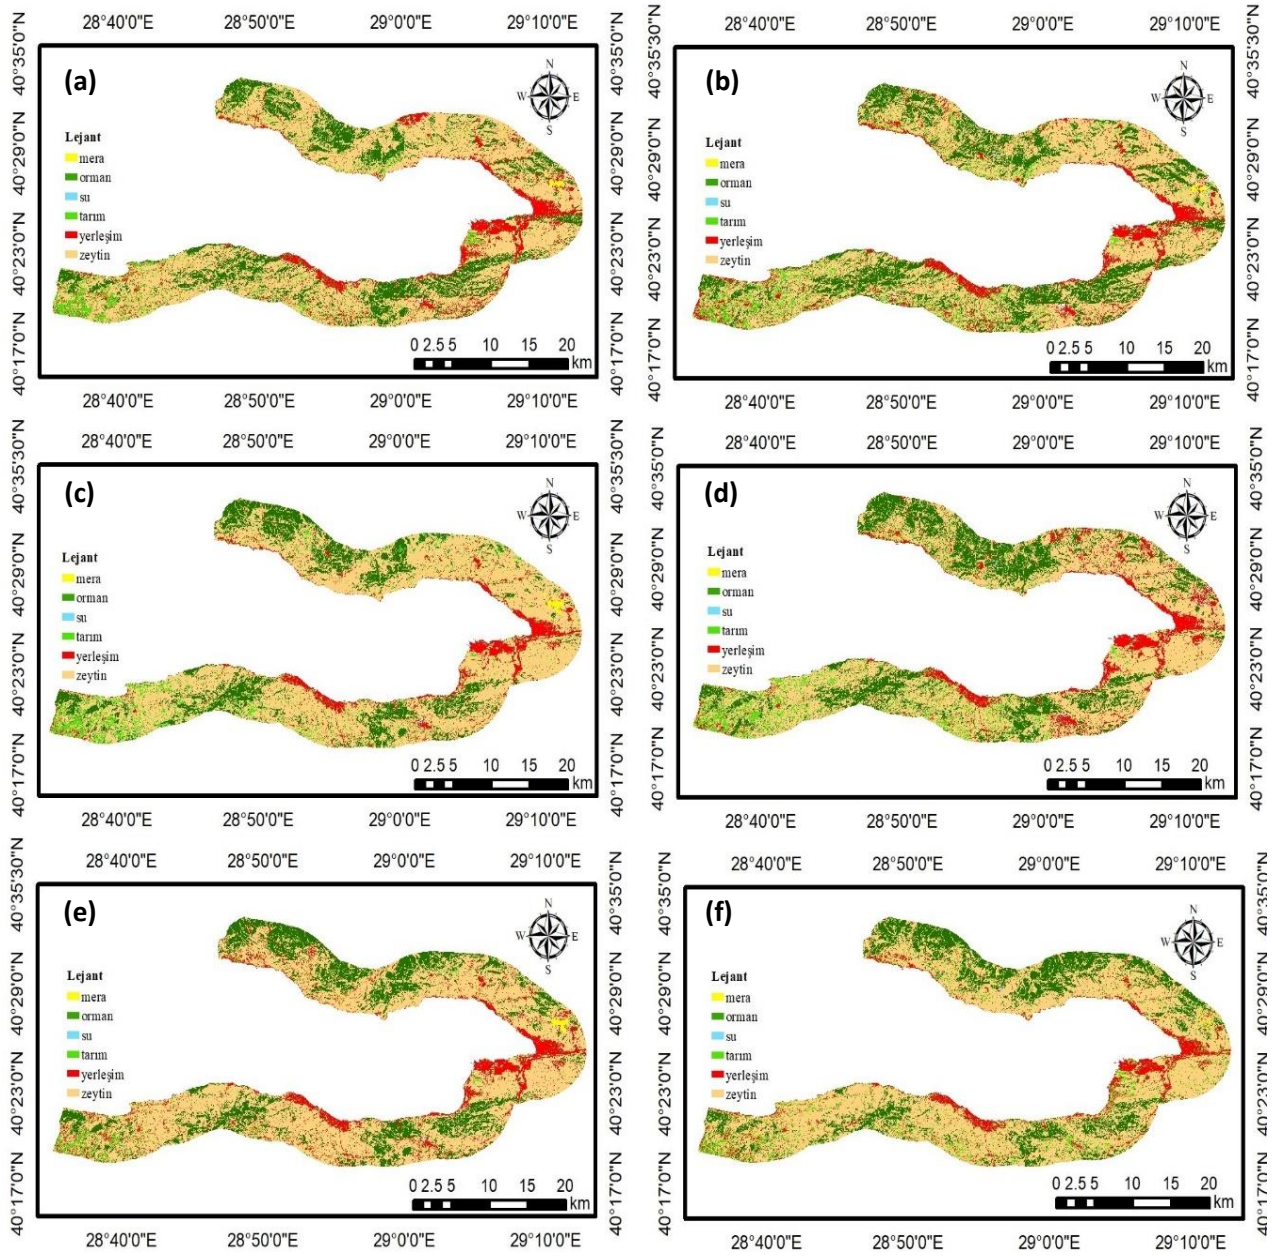
Şekil 7. OI₇ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



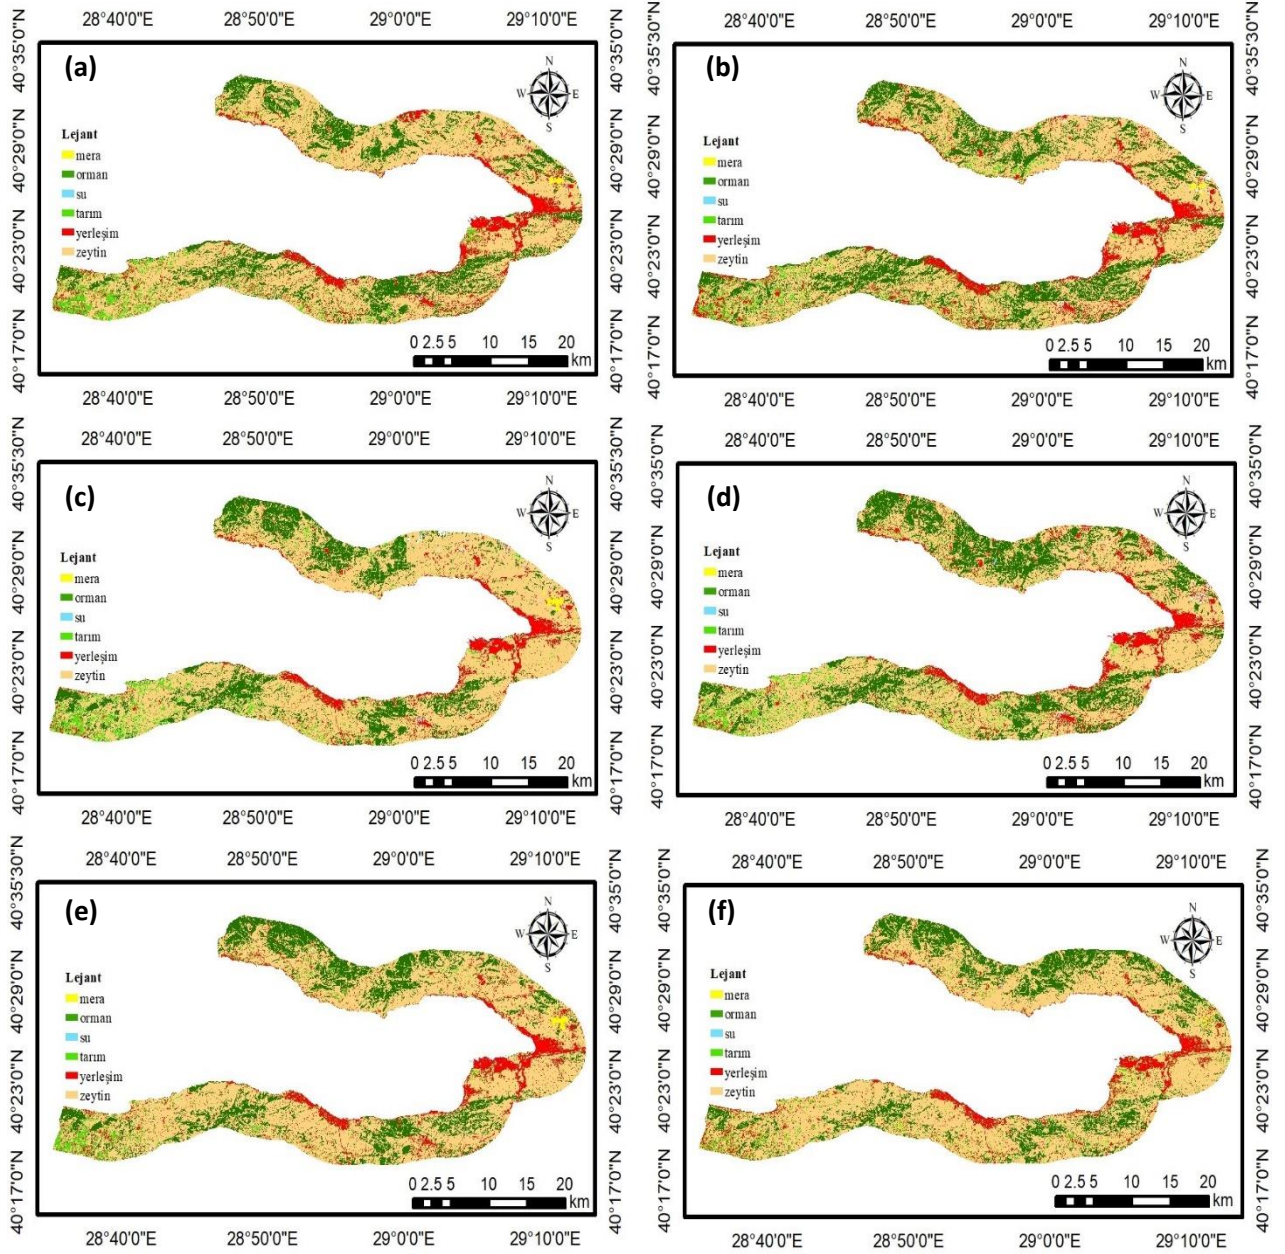
Şekil 8. OI₈ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



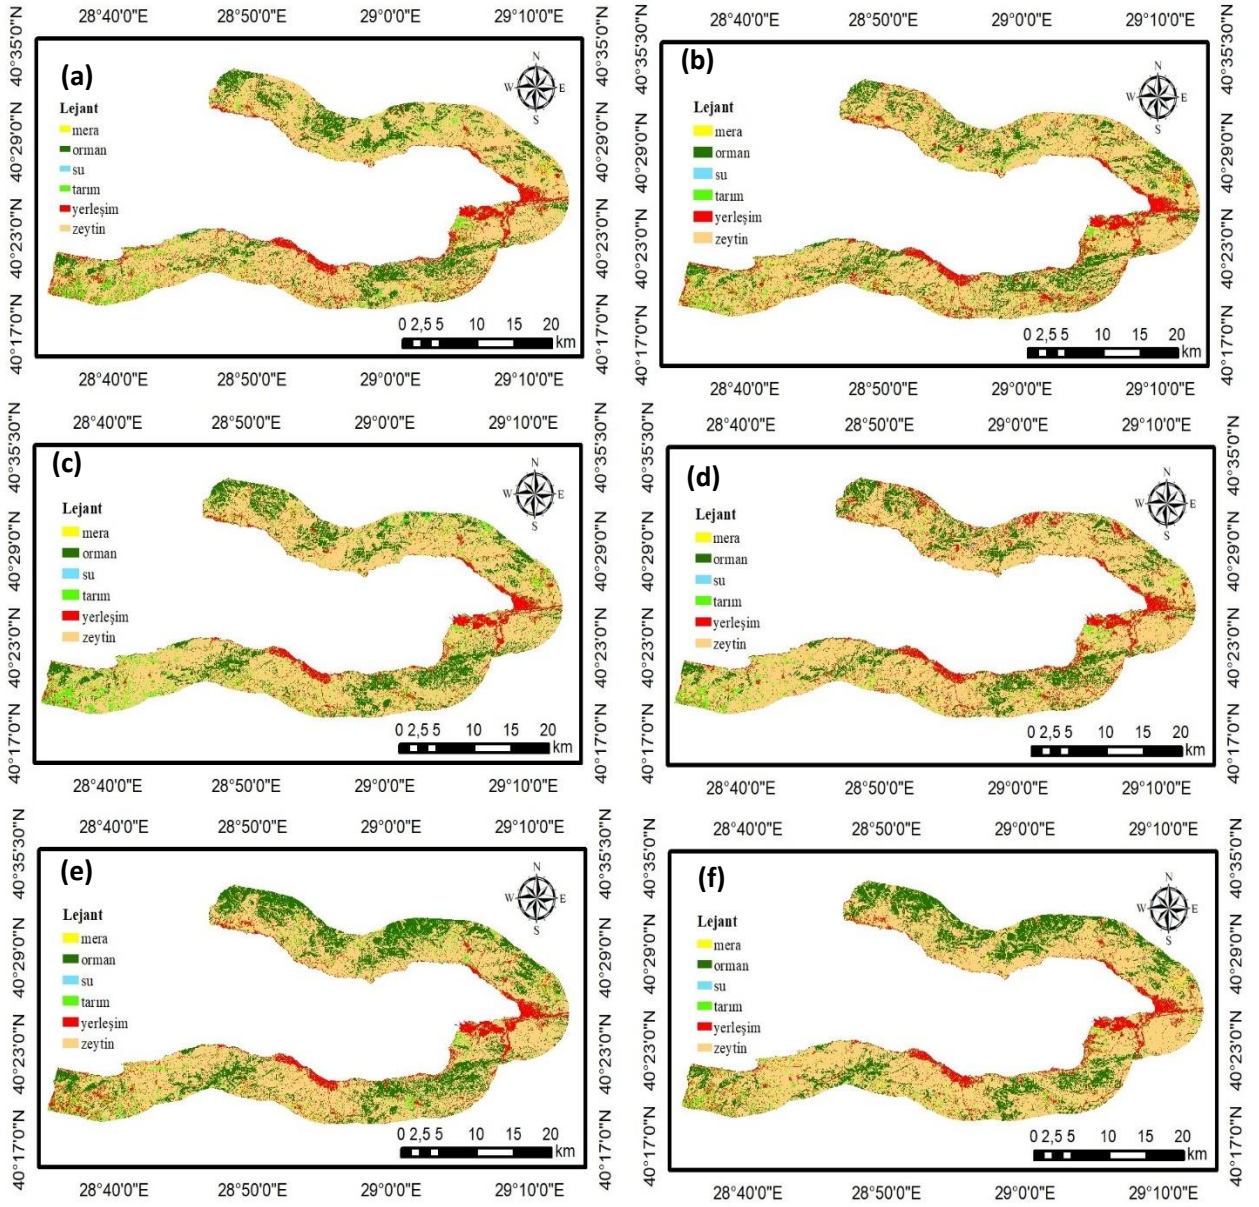
Şekil 9. OI_{8a} / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



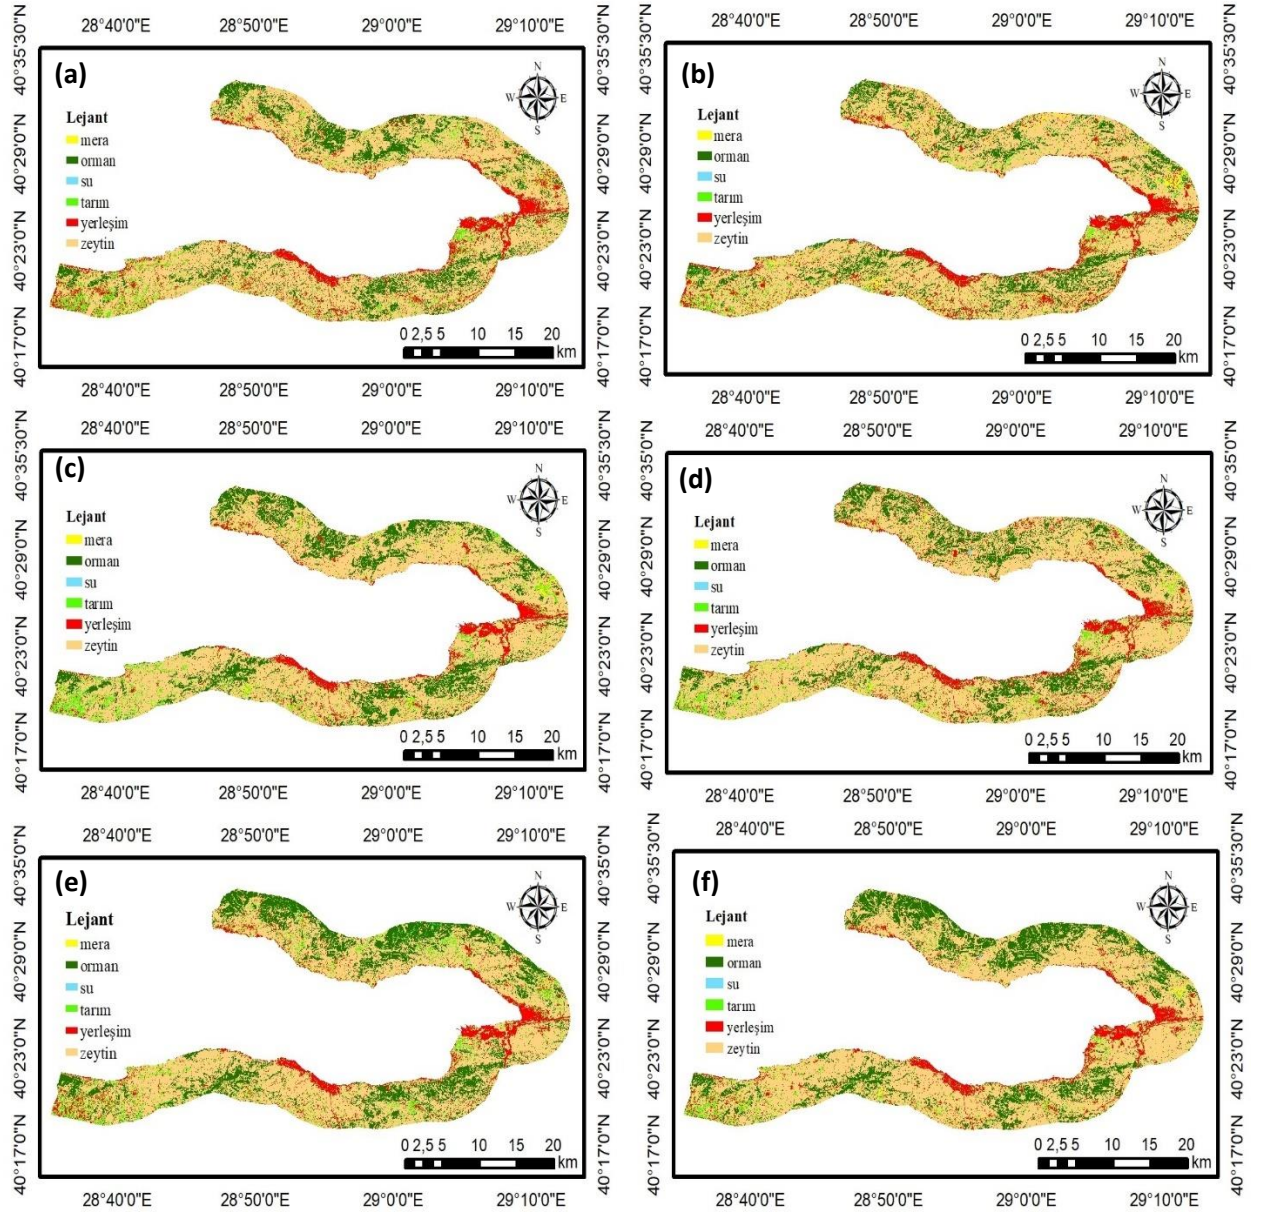
Şekil 10. OI₁₁ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



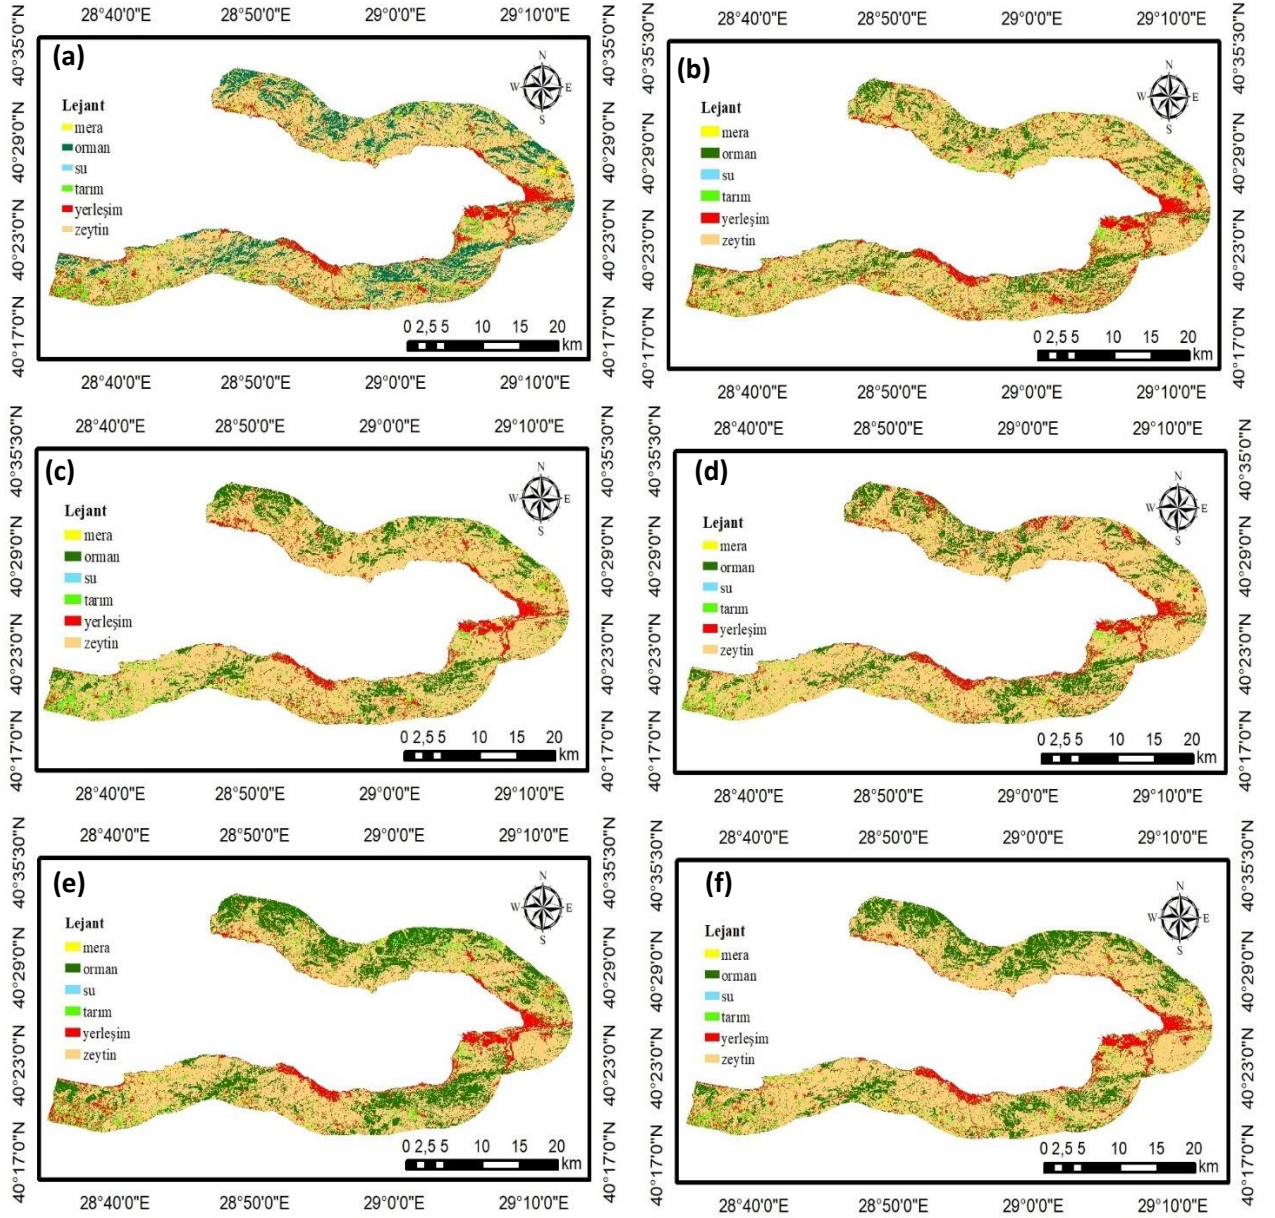
Şekil 11. OĬ₁₂ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



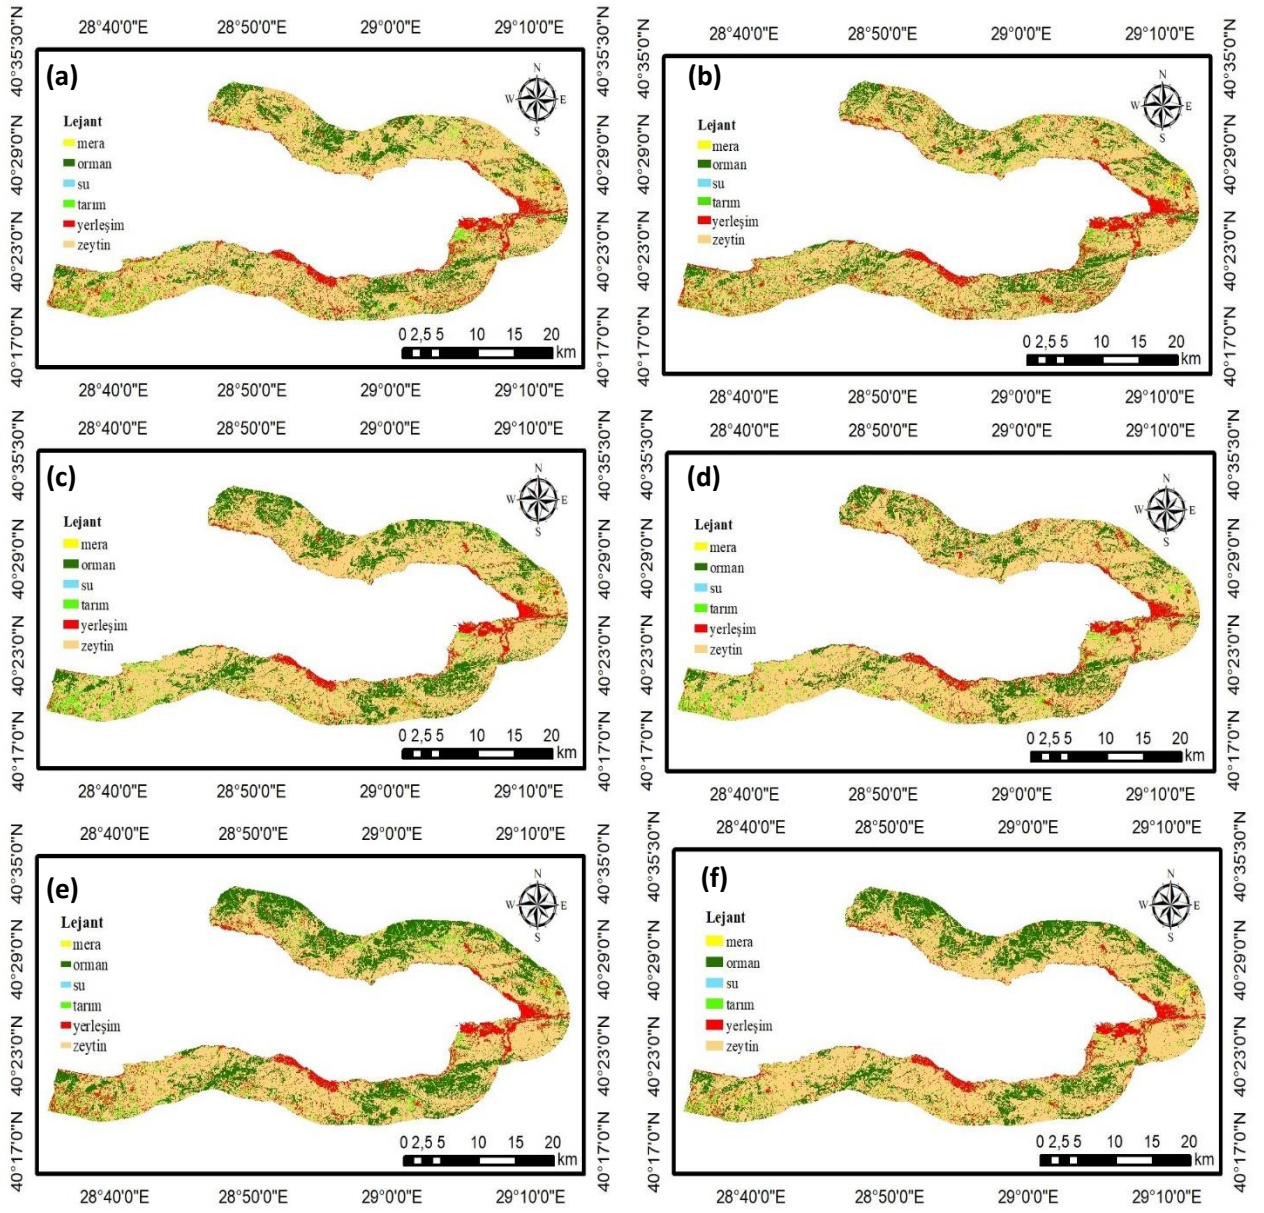
Şekil 12. OI₅BO₆ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



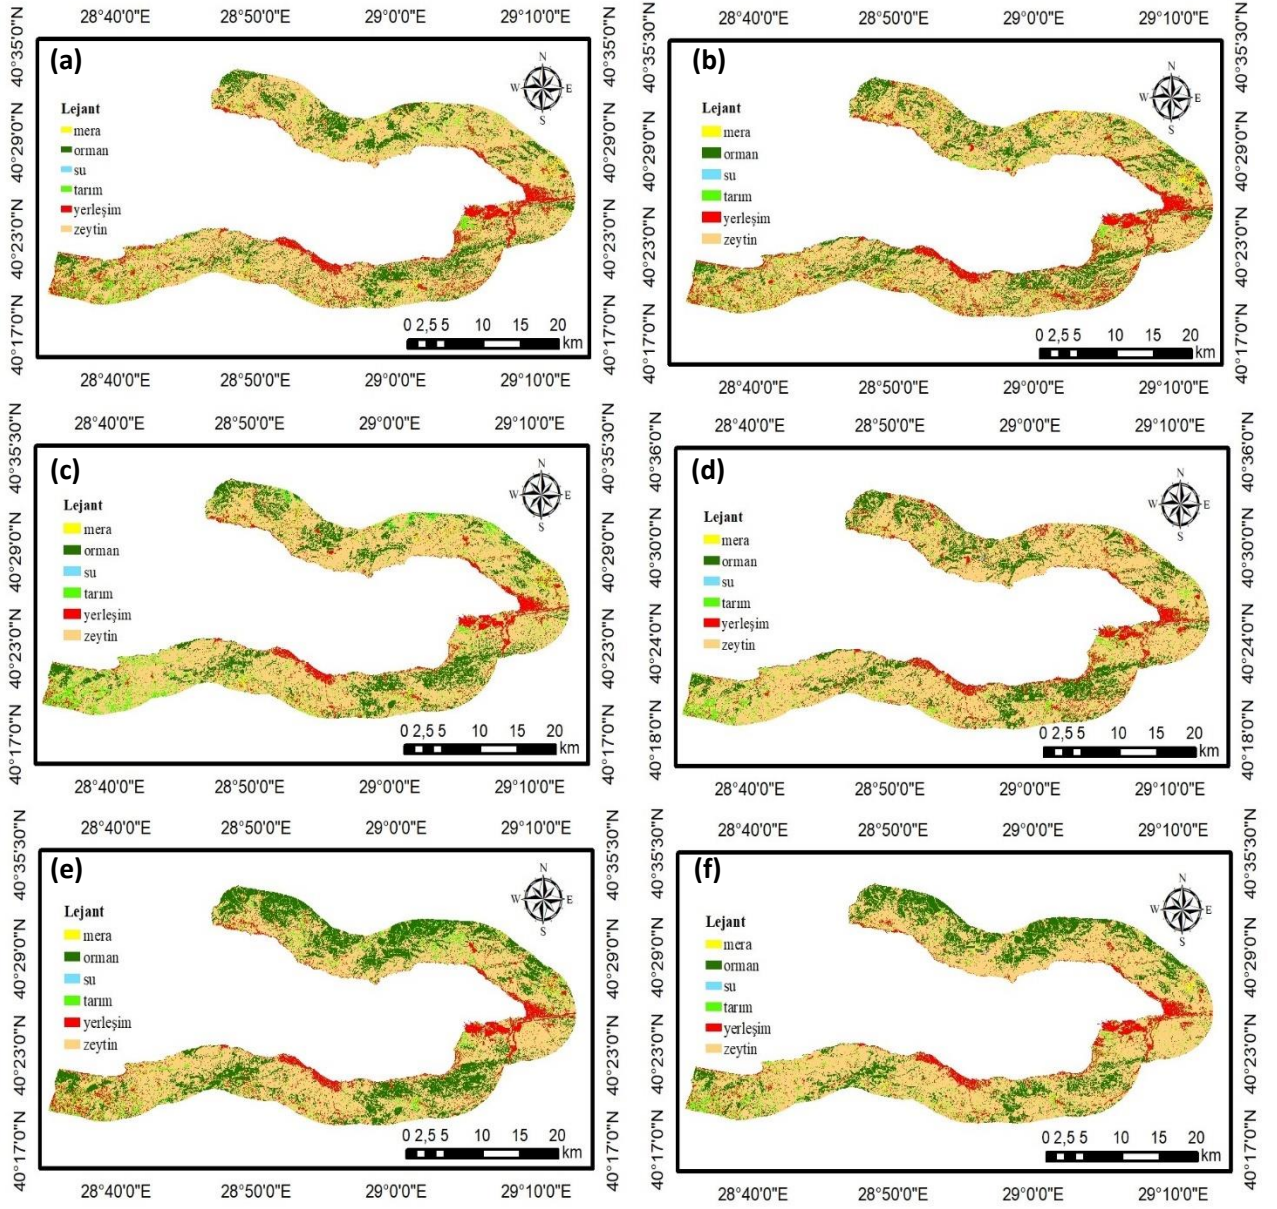
Şekil 13. OI5BO7 / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



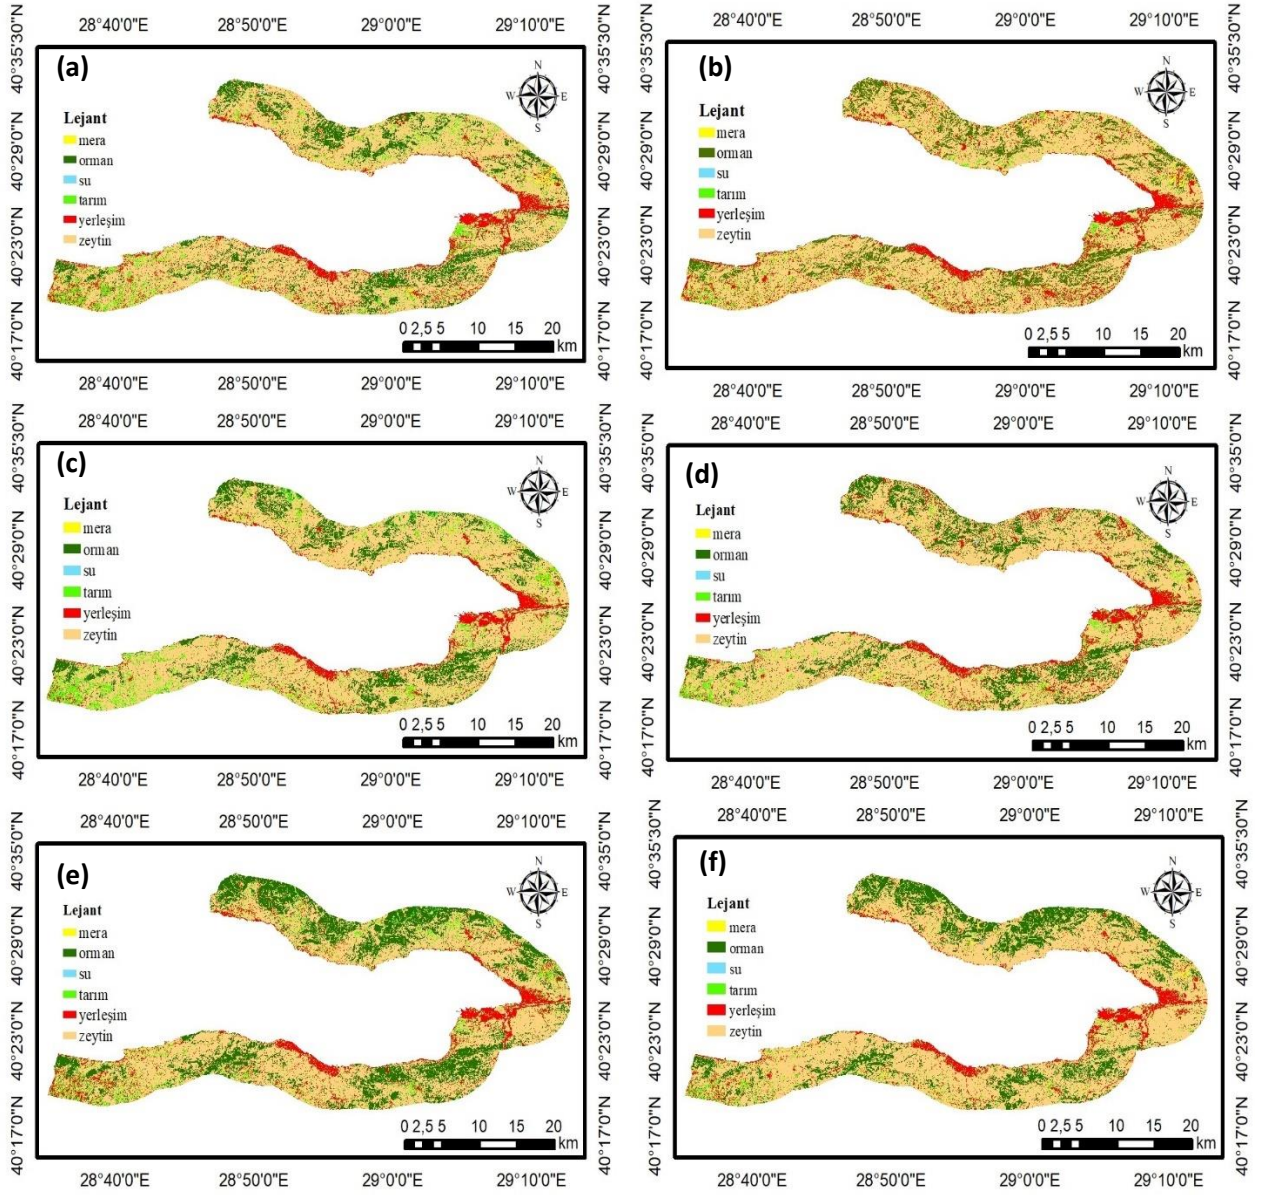
Şekil 14. Oğuzova / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



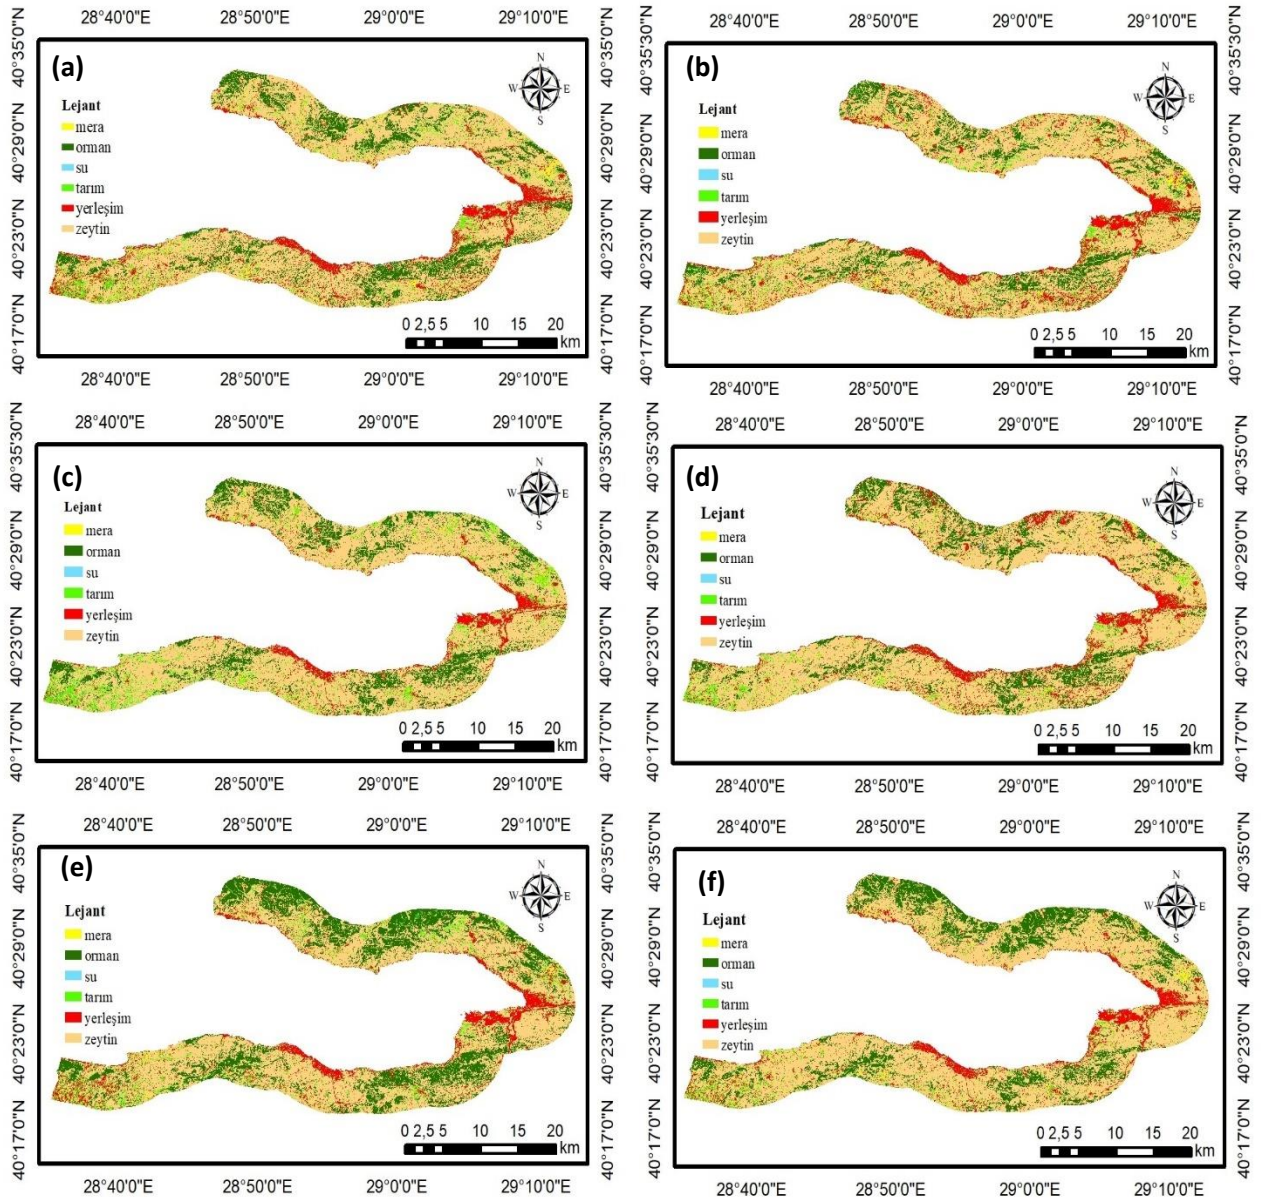
Şekil 15. OI₆BO₇ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



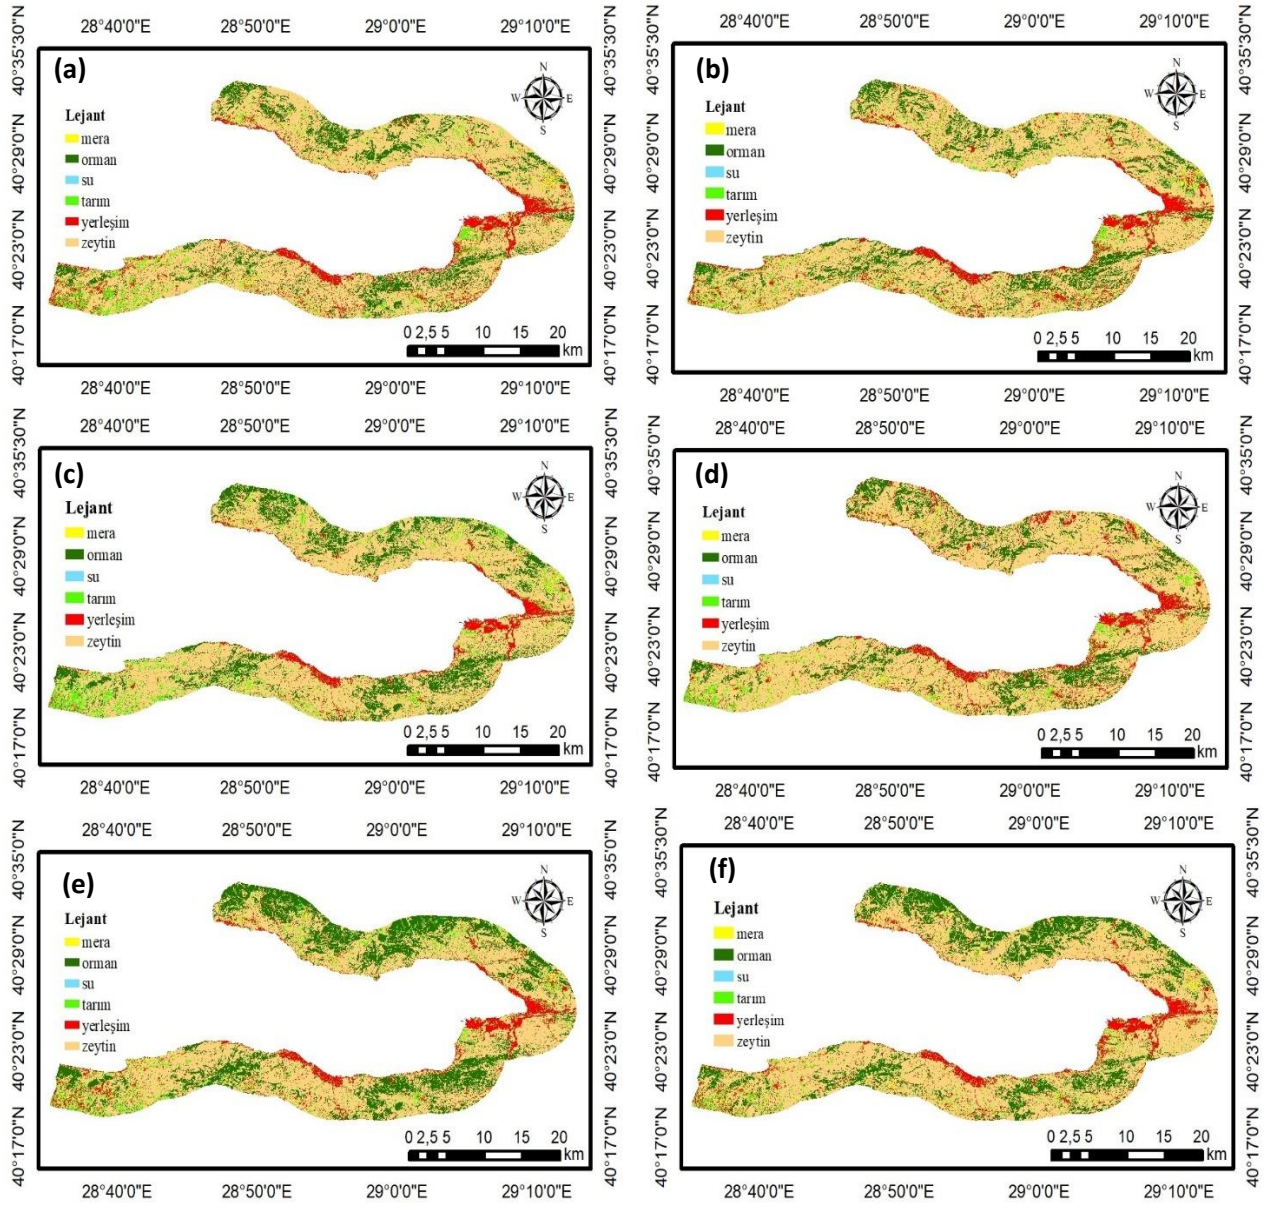
Şekil 16. OI₇BO₆ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



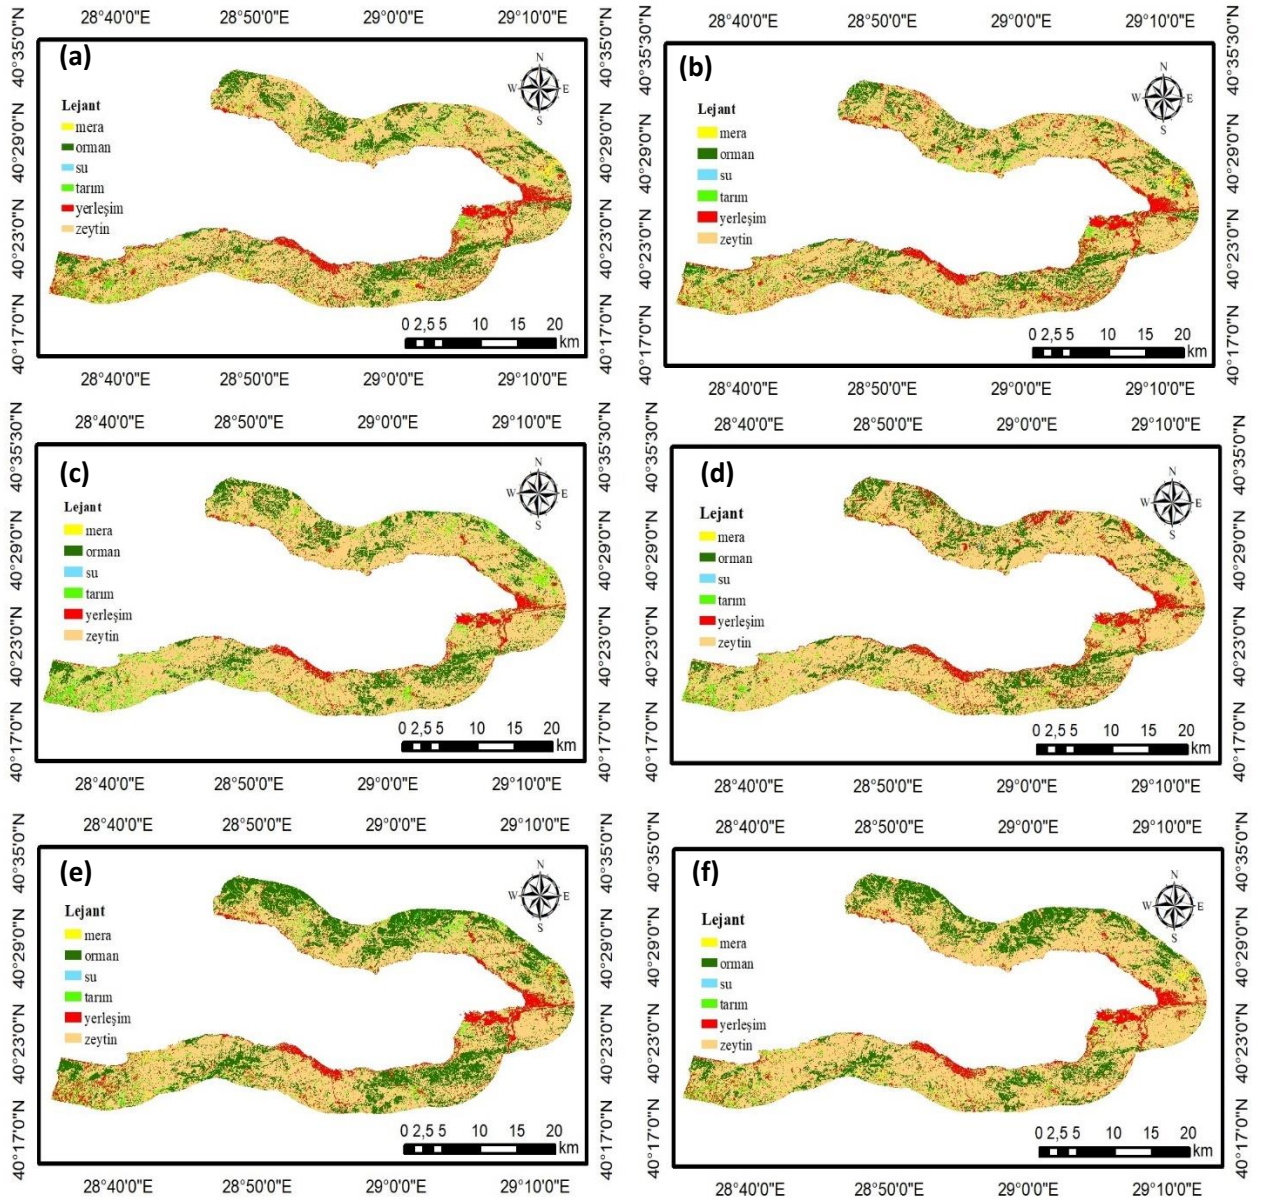
Şekil 17. OI₇BO₇ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



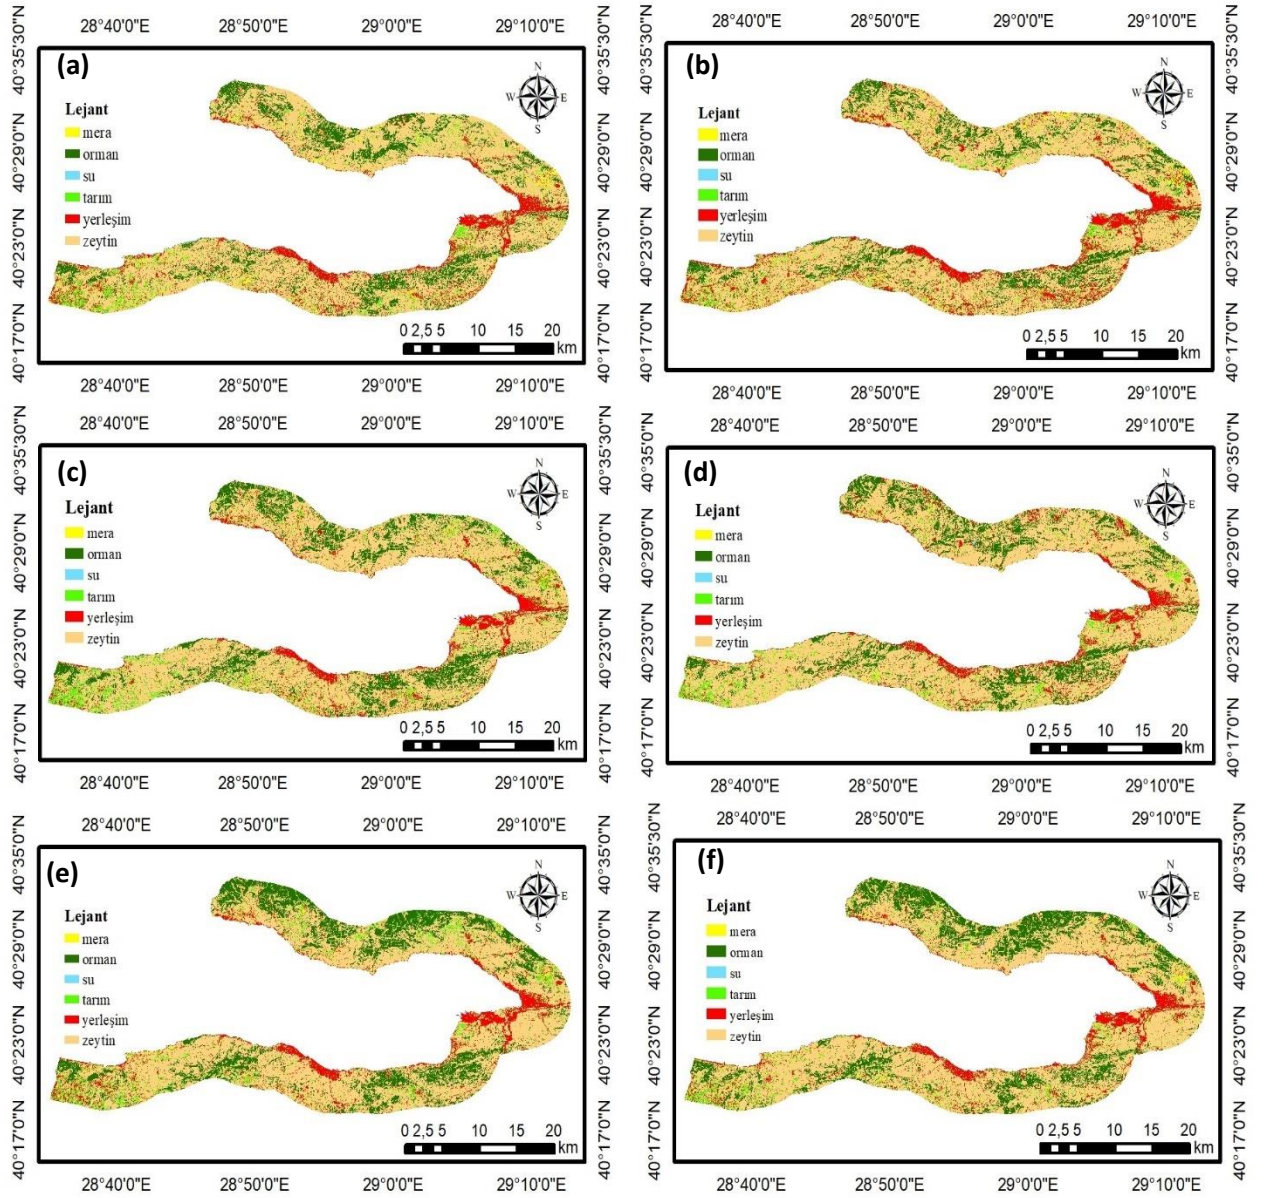
Şekil 18. OğBO₆ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



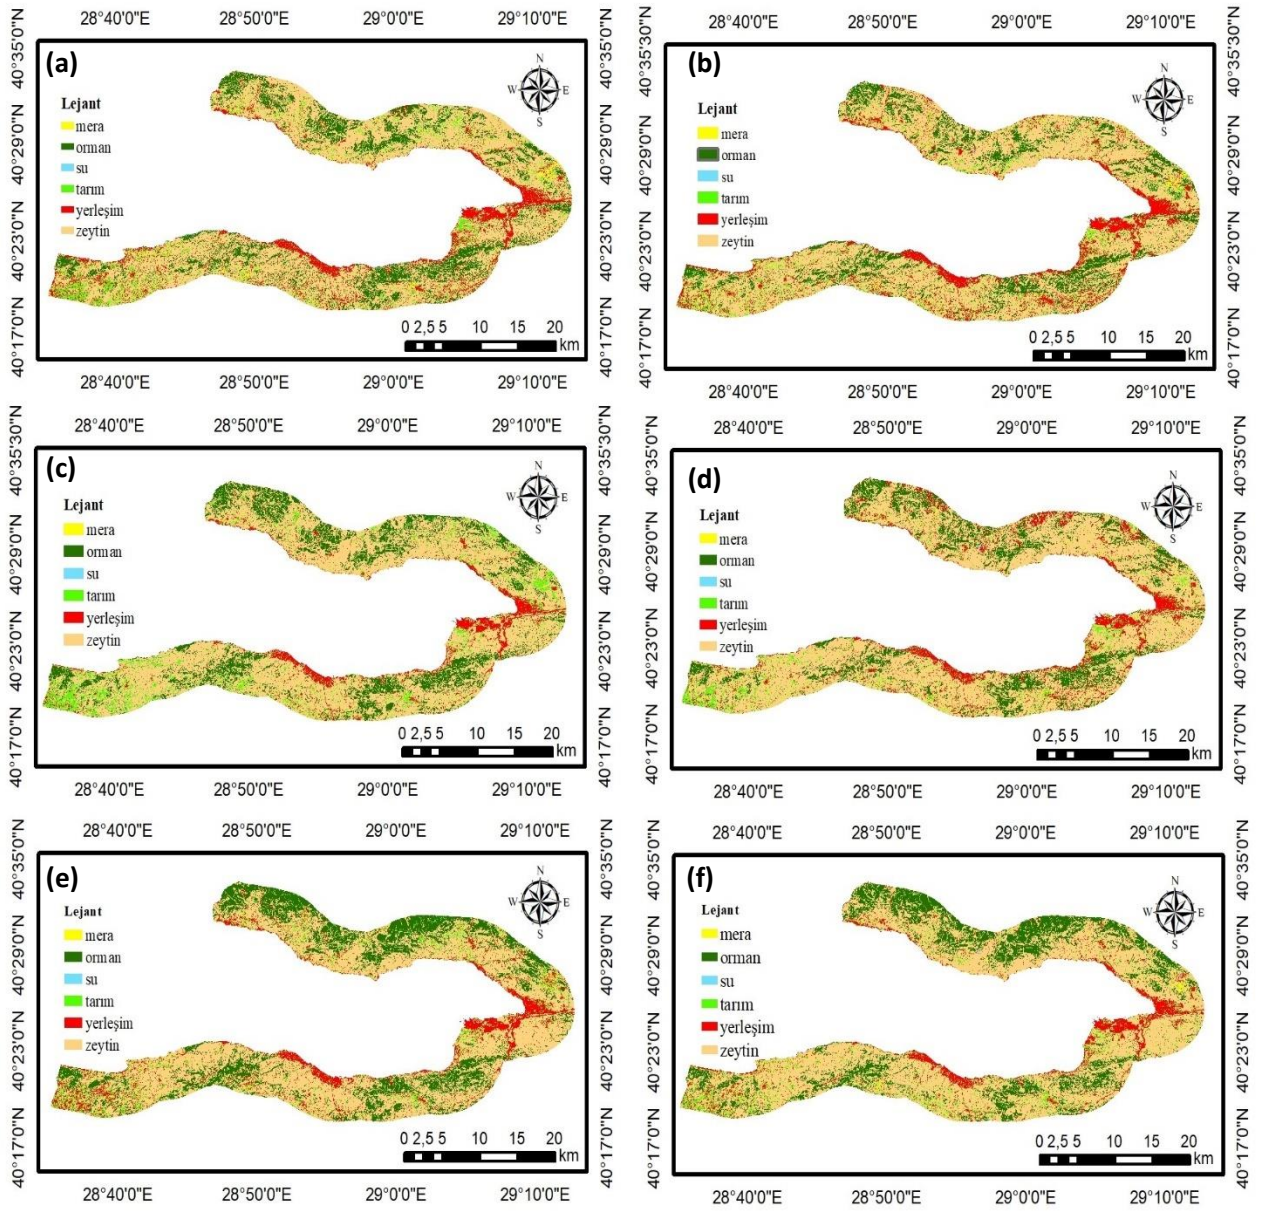
Şekil 19. OğBO7 / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



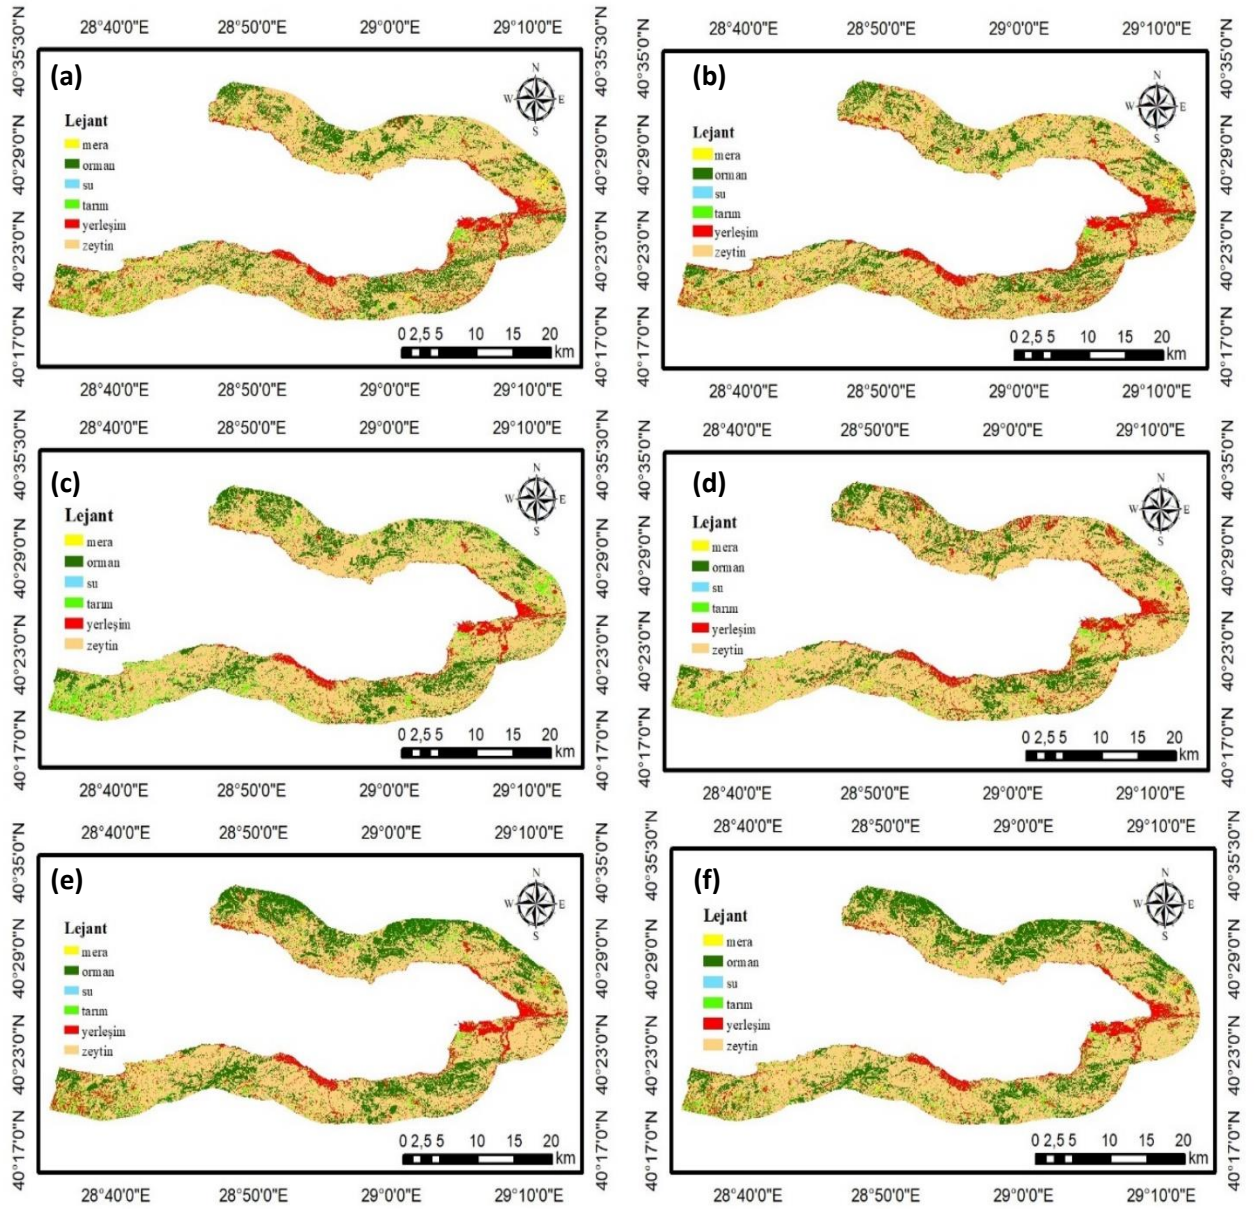
Şekil 20. Oğaba / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



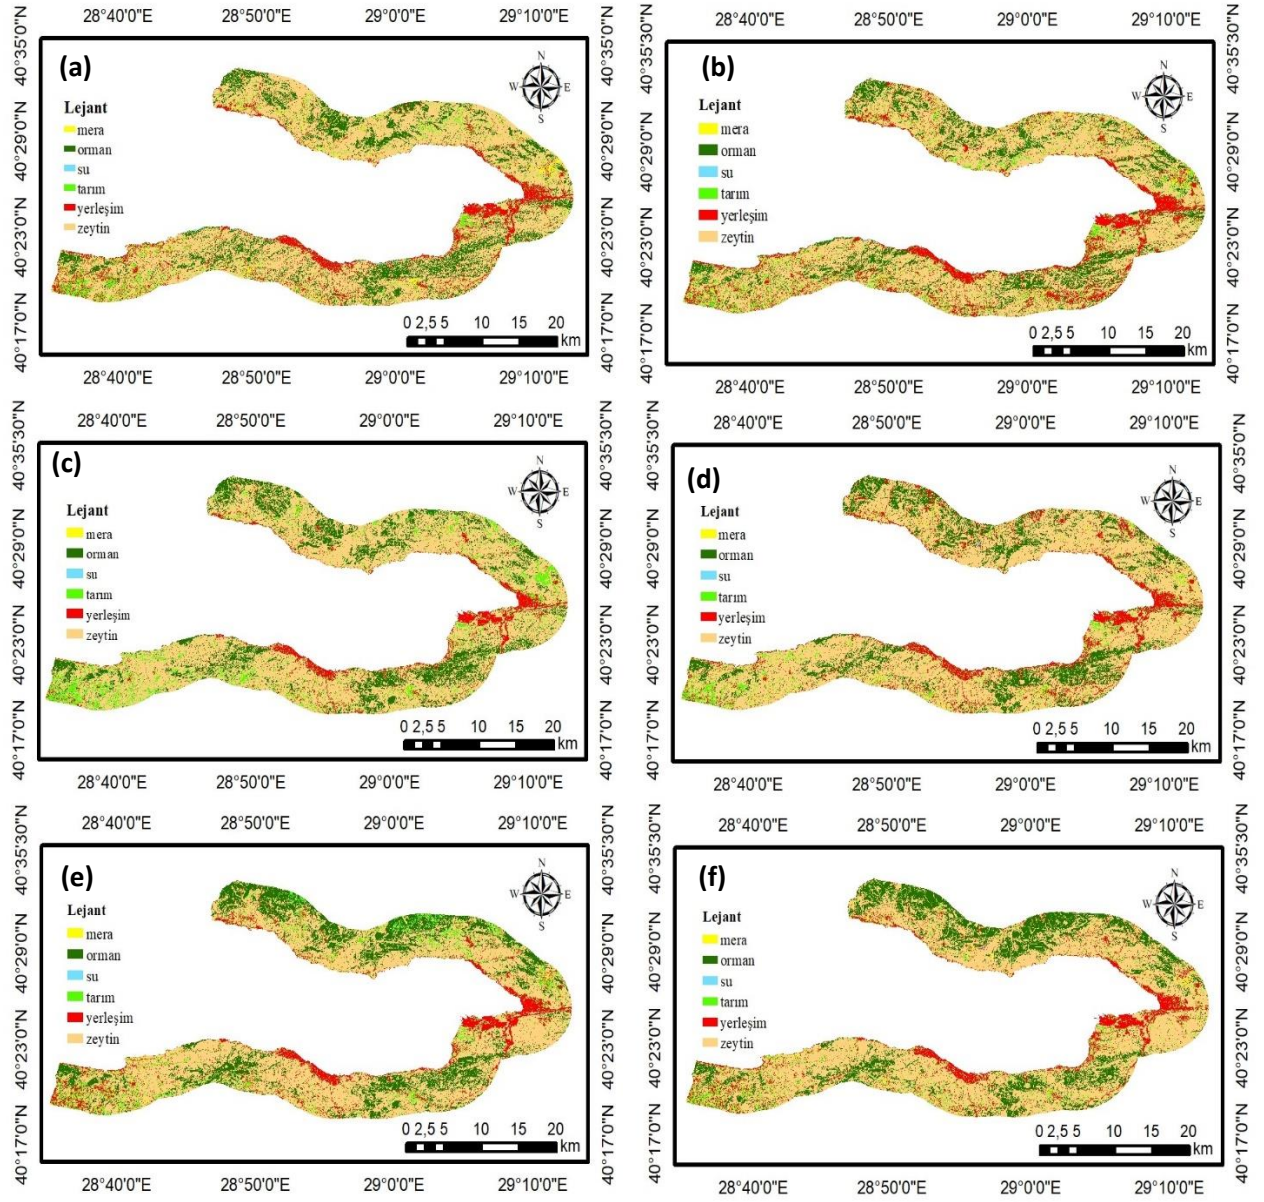
Şekil 21. OI_{8a}BO₇ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



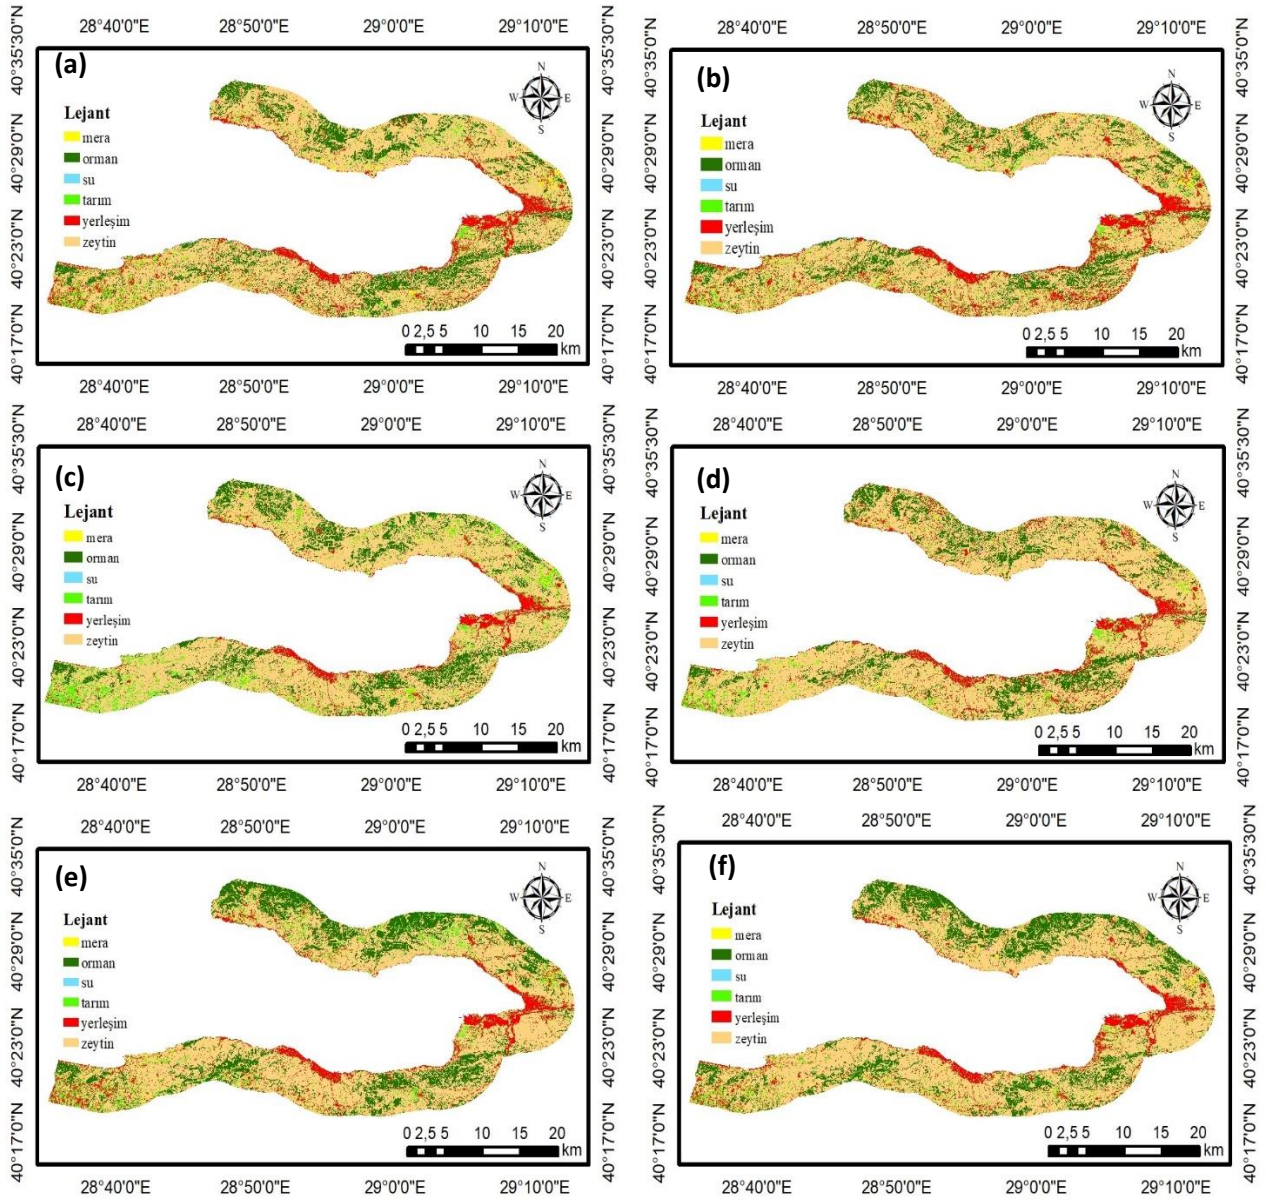
Şekil 22. OI₁₁BO₆ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



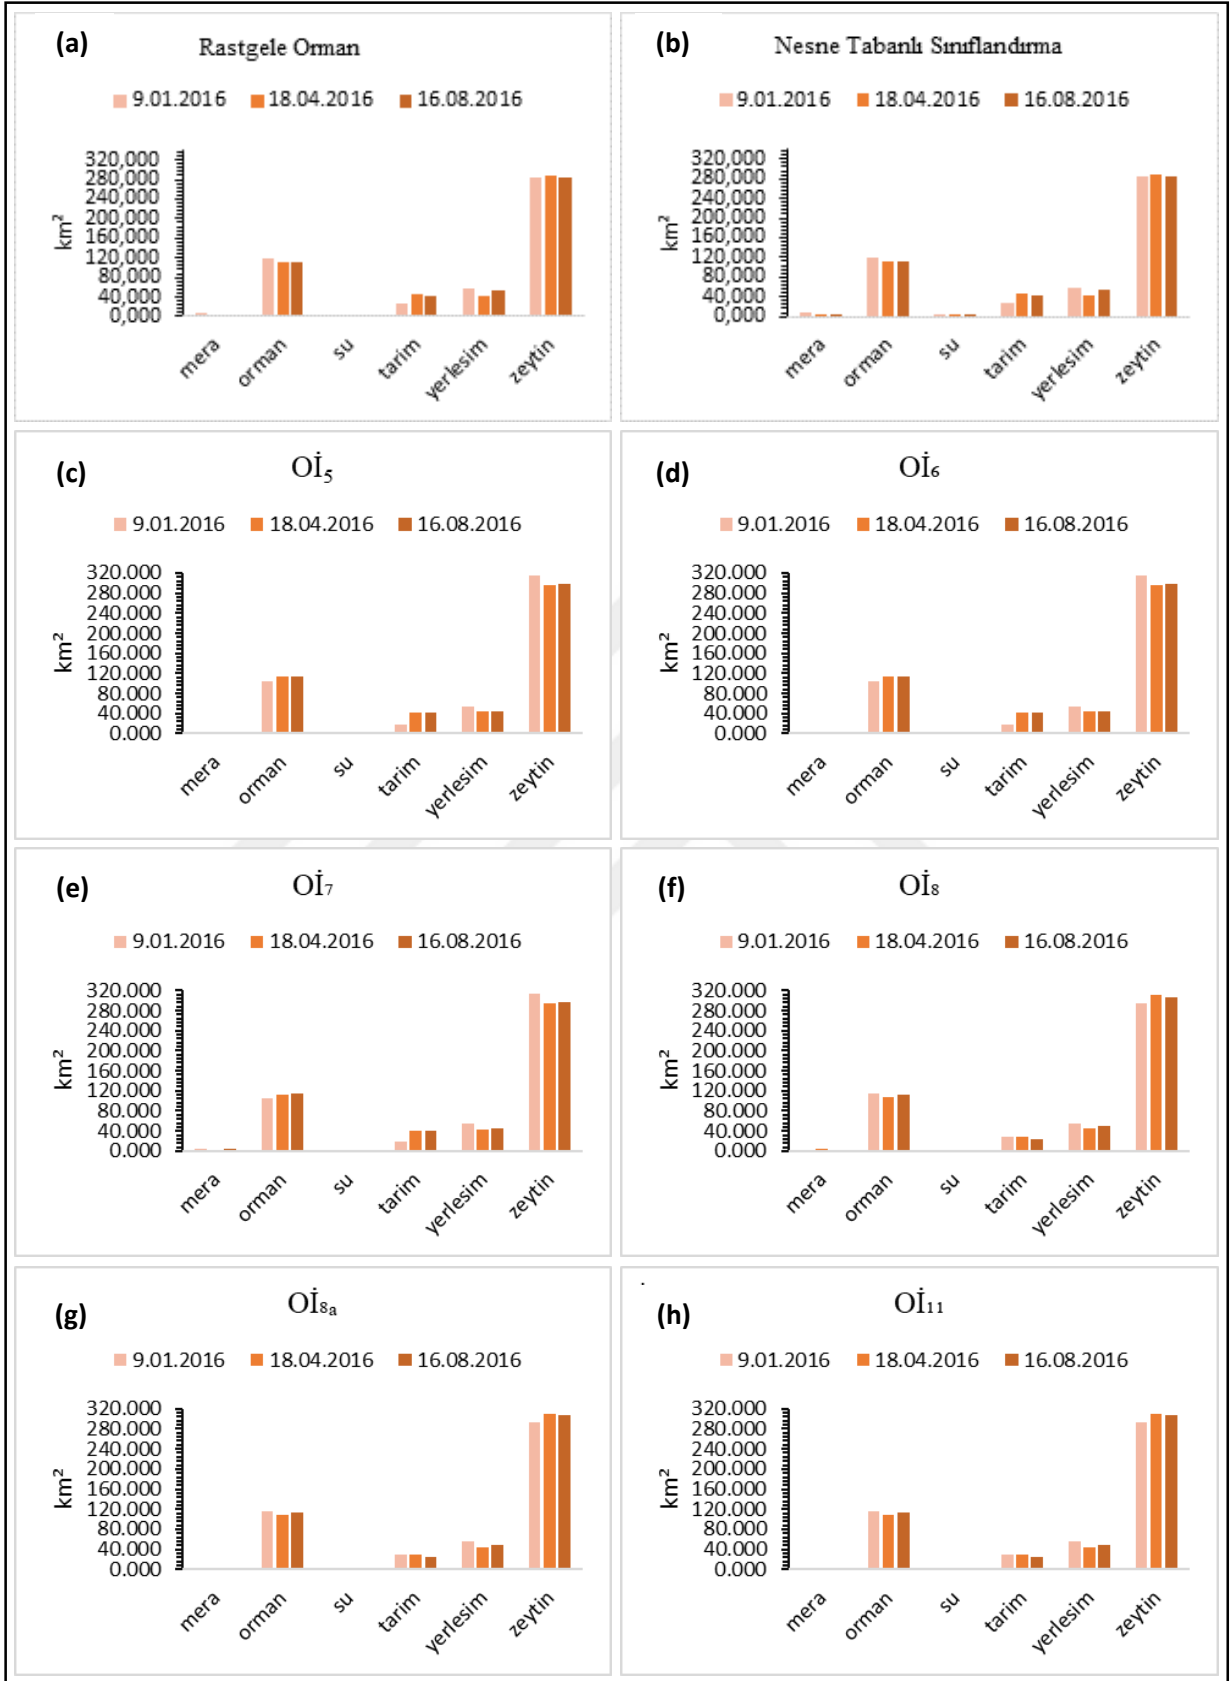
Şekil 23. OI₁₁BO₇ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



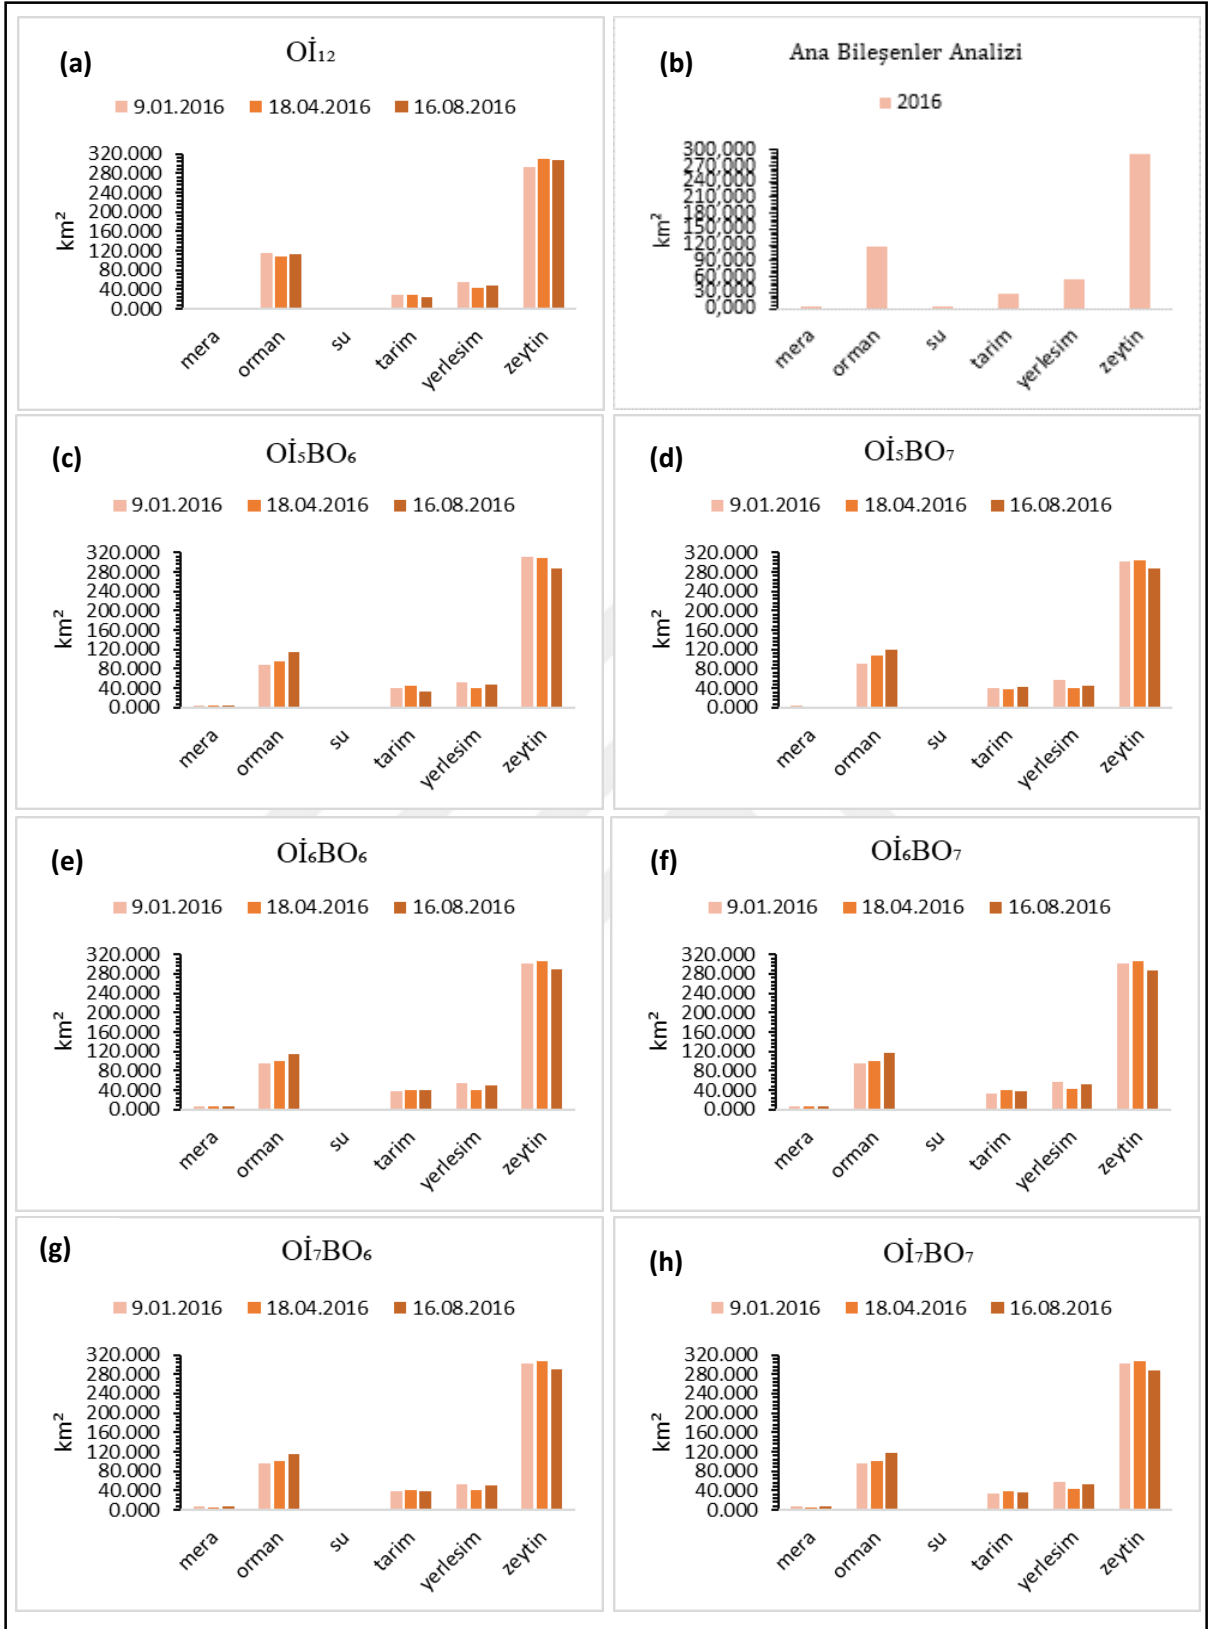
Şekil 24. OI₁₂BO₆ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



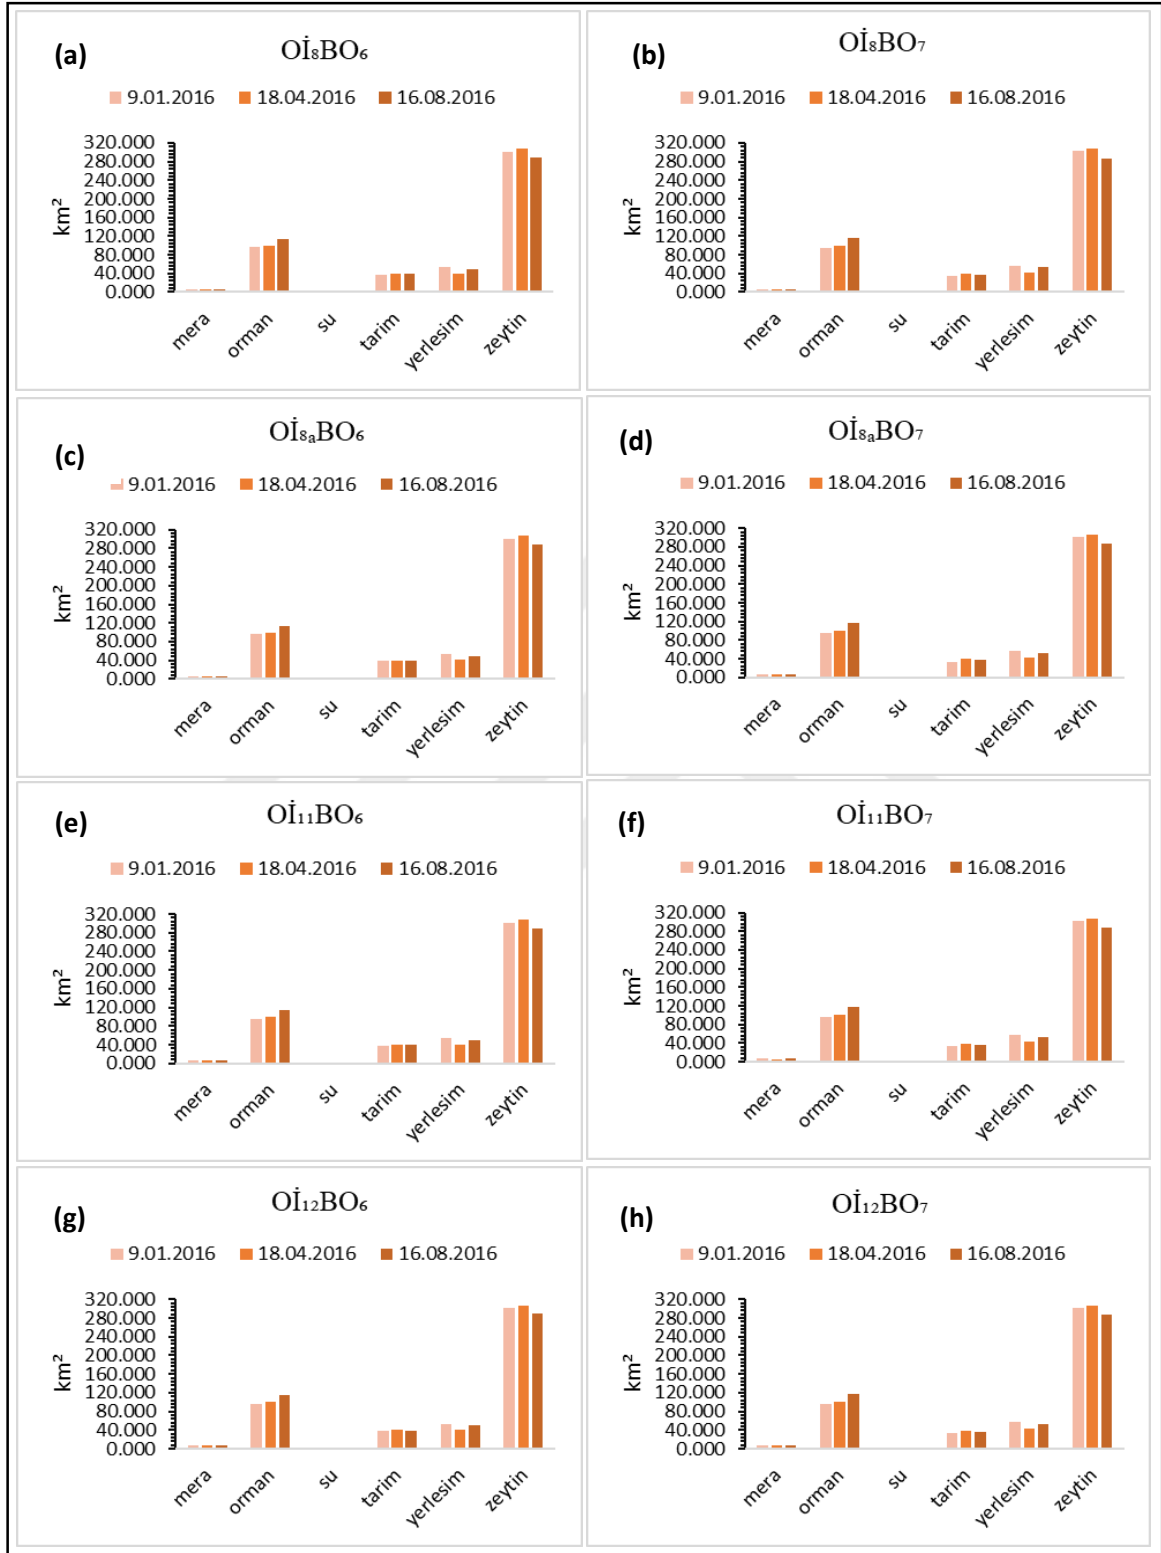
Şekil 25. OI₁₂BO₇ / (a) 2016 kış, (b) 2020 kış, (c) 2016 bahar, (d) 2020 bahar, (e) 2016 yaz, (f) 2020 yaz



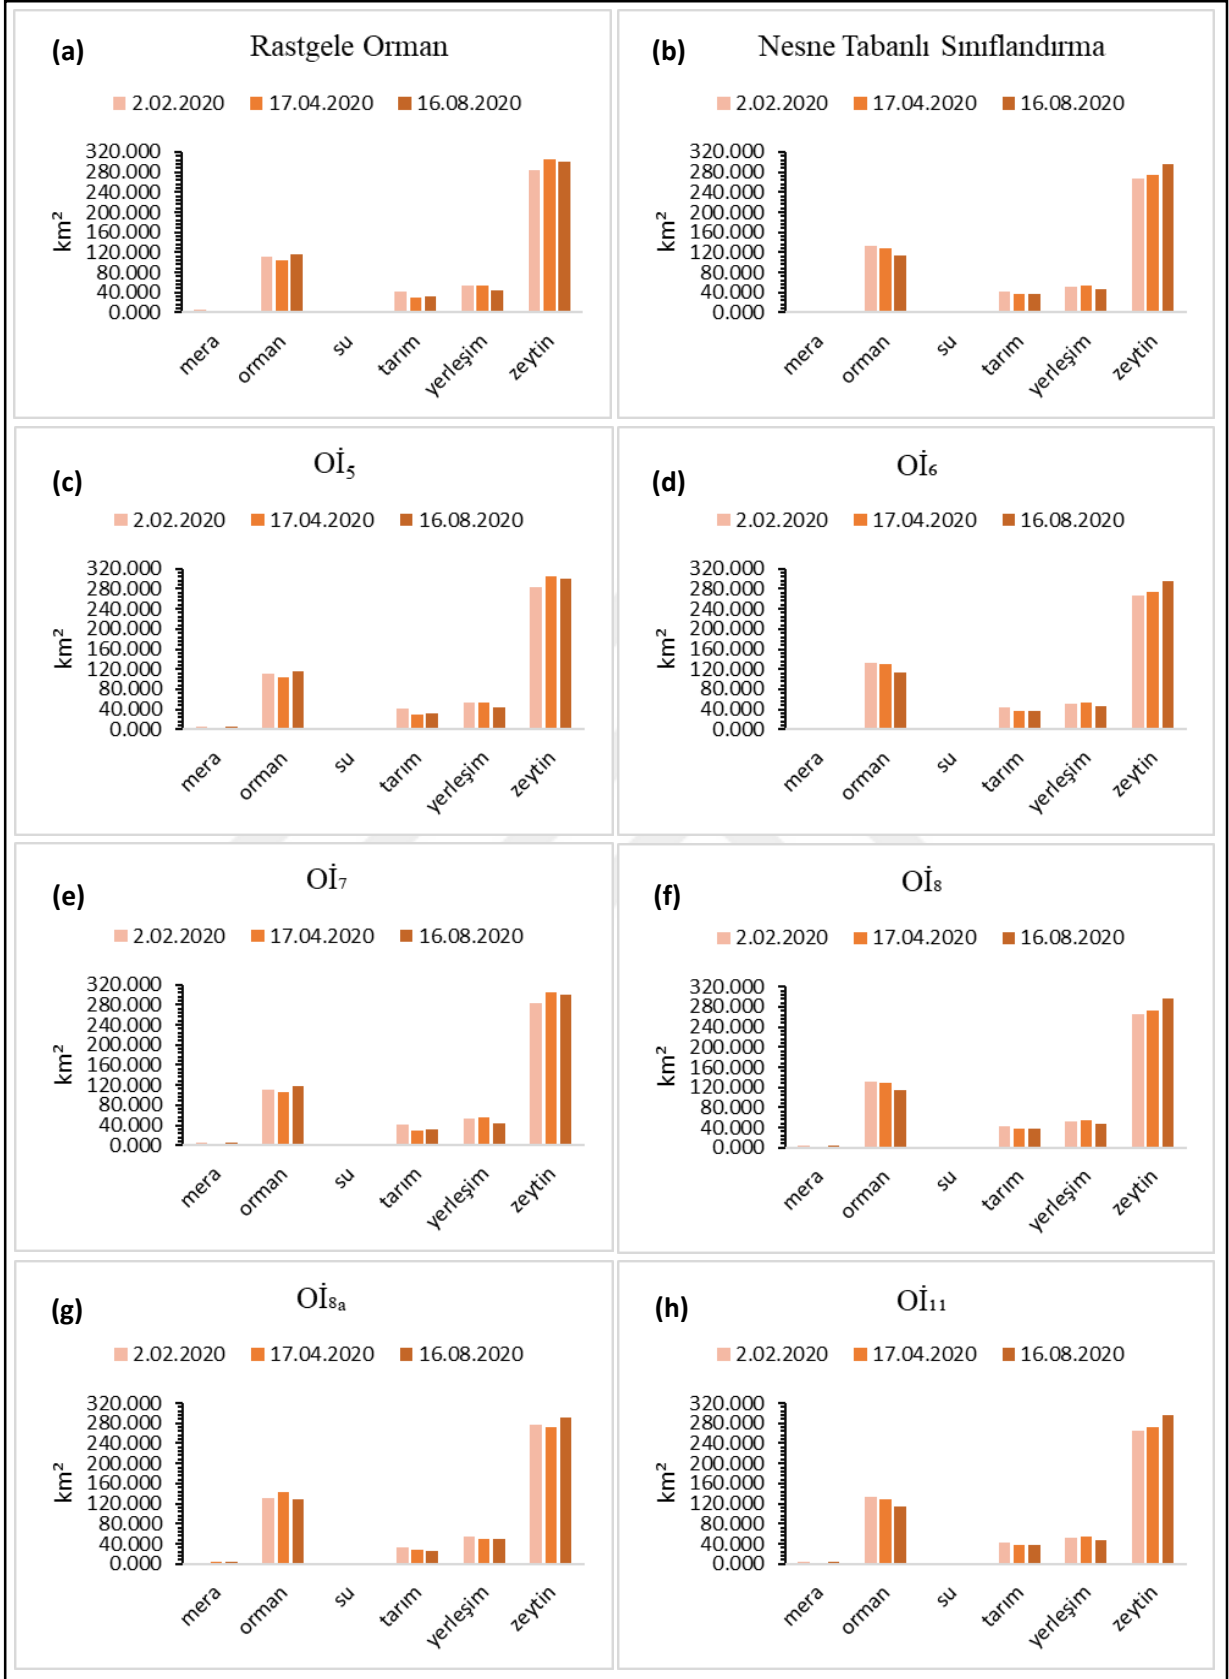
Şekil 26. Sınıflandırma işlemindeki kompozit indekslerin grafiklerinin toplu gösterimi (2016 – (a) O_{RO}, (b) O_{NTS}, (c) O₅, (d) O₆, (e) O₇, (f) O₈, (g) O_{8a}, (h) O₁₁)



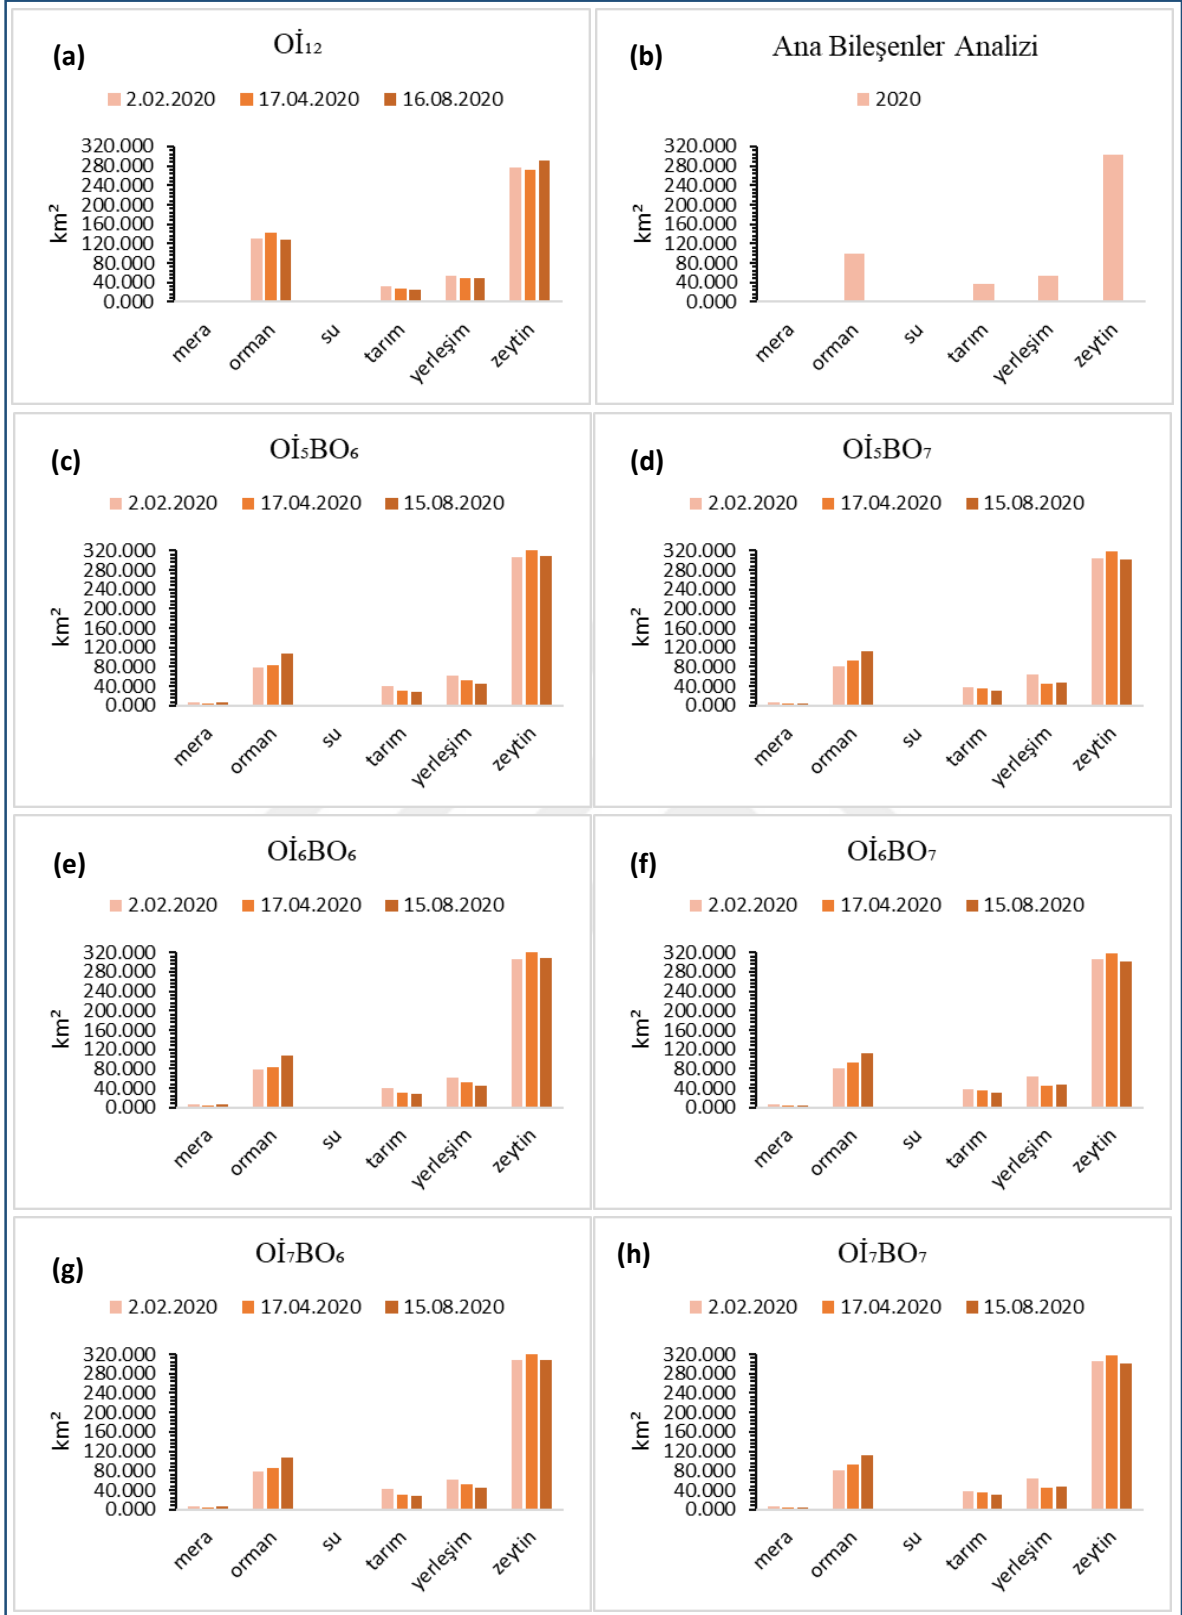
Şekil 40'ın devamı. Sınıflandırma işlemindeki kompozit indekslerin grafiklerinin toplu gösterimi (2016 – (a) O_{12} , (b) ABA, (c) O_5BO_6 , (d) O_5BO_7 , (e) O_6BO_6 , (f) O_6BO_7 , (g) O_7BO_6 , (h) O_7BO_7)



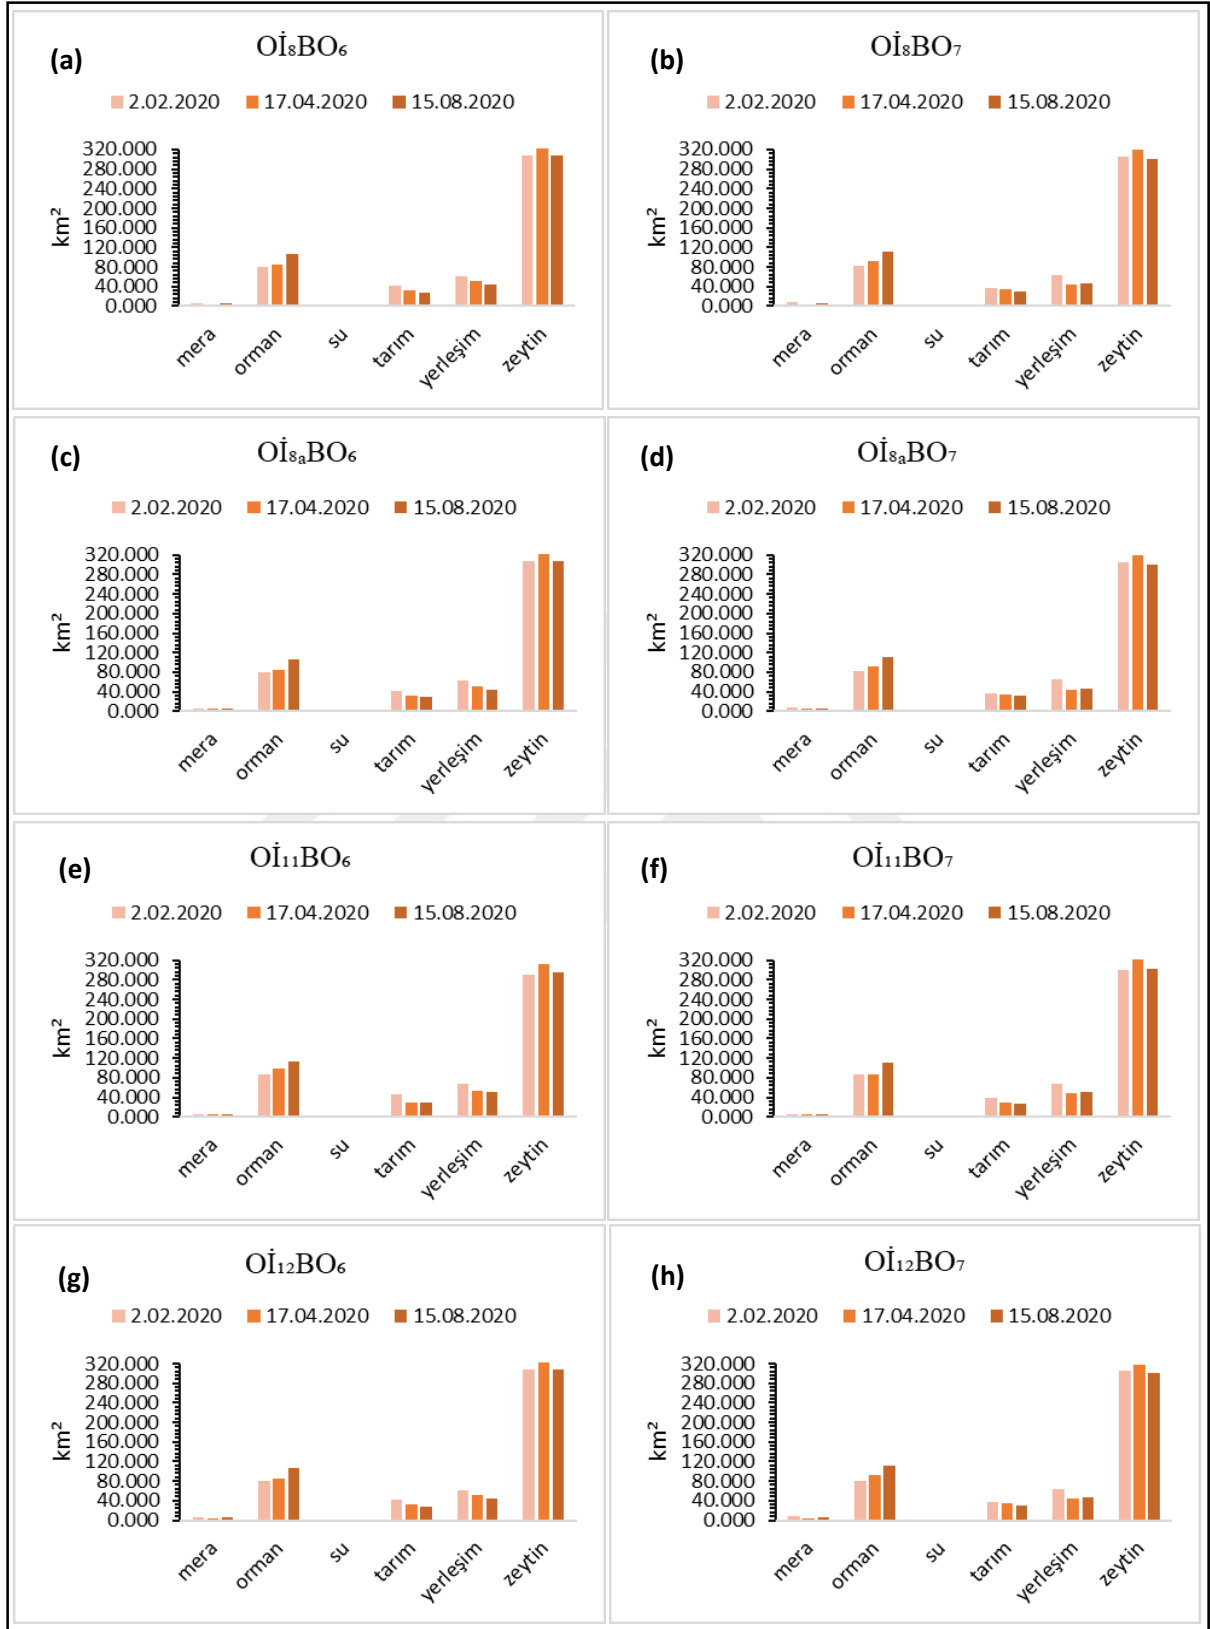
Şekil 40'ın devamı. Sınıflandırma işlemindeki kompozit indekslerin grafiklerinin toplu gösterimi (2016 – (a) O_8BO_6 , (b) O_8BO_7 , (c) $O_{8a}BO_6$, (d) $O_{8a}BO_7$, (e) $O_{11}BO_6$, (f) $O_{11}BO_7$, (g) $O_{12}BO_6$, (h) $O_{12}BO_7$)



Şekil 27. Sınıflandırma işlemindeki kompozit indekslerin grafiklerinin toplu gösterimi (2020 – (a) O_{RO}, (b) O_{NTS}, (c) O₅, (d) O₆, (e) O₇, (f) O₈, (g) O_{8a}, (h) O₁₁)



Şekil 41'in devamı. Sınıflandırma işlemindeki kompozit indekslerin grafiklerinin toplu gösterimi (2020 – (a) O_{12} , (b) ABA, (c) O_5BO_6 , (d) O_5BO_7 , (e) O_6BO_6 , (f) O_6BO_7 , (g) O_7BO_6 , (h) O_7BO_7))




Şekil 41'in devamı. Sınıflandırma işlemindeki kompozit indekslerin grafiklerinin toplu gösterimi (2020 – (a) O_8BO_6 , (b) O_8BO_7 , (c) $O_{8a}BO_6$, (d) $O_{8a}BO_7$, (e) $O_{11}BO_6$, (f) $O_{11}BO_7$, (g) $O_{12}BO_6$, (h) $O_{12}BO_7$)

4.1.2. AKBÖ Sınıflandırmasının Doğruluk Analizi Sonuçları

Doğruluk analizi sonuçları homojen dağılımlı 410 yer örnek noktası ile yapılmıştır. Bütün doğruluk analizi sonuçları içinde 2016 ve 2020 yılları için en düşük ve en yüksek doğruluk oranları; 2016-kış sezonu için sırasıyla (NTS- genel doğruluk: %75.854, kappa: 0.693, Oİ₁₂- %82.927, 0.791), 2016-bahar sezonu için (Oİ₁₁BO₇- %76.156, 0.712, RO- %84.436, 0.815), 2016-yaz sezonu (Oİ_{8a}- %76.642, 0.710, RO- %84.670, 0.826) ve 2020-kış sezonu için sırasıyla (Oİ₁₁BO₇- genel doğruluk: %75.122, kappa: 0.700, RO- %82.716, 0.788), 2020-bahar sezonu için (Oİ₁₂BO₇- %75.122, 0.700, RO- %84.748, 0.817), 2020-yaz sezonu (Oİ₁₁BO₇- %78.049, 0.734, Oİ₆- %84.634, 0.813) oranlarıyla belirlenmiştir. Tüm sınıflandırma bulguları içinde ABA ile yapılan RO sınıflandırma işlemi hem 2016 yılı hem 2020 yılı için tüm sınıflandırmaların içinde en yüksek değeri vermiştir (2016 - %85.51, 2020 - %87.99). Doğruluk analizinde sınıflandırmadaki altı sınıfın ayrı ayrı sonuçlarına bakıldığında, (2016-2020) kış sezonu M, O, S, T, Y ve Z sınıfları için %84,10 artış, %3,49 azalış, %160 artış, %54,96 artış, %3,18 azalış ve %4,26 azalış olduğu görülmüştür.

Tüm sınıflamaların sayısal sonuçları grafiksel olarak Şekil 42'de, indekslerin sınıflama sonuçlarından belirlenen bu odak değerler de Tablo 9 ve Tablo 10'de renklendirilmiş olarak gösterilmiştir. Tablolarda yer alan yeşil renkli veriler sınıflandırmada en yüksek doğrulukta çıkan değerleri, mavi renkteki veriler en düşük sınıflandırma sonuçlarını göstermektedir.



Şekil 28. Tüm sınıflamaların doğruluk analizi sonuçlarının zamansal olarak gösterimi

Tablo 9

2016 yılı için sınıflamaların doğruluk analizi sonuçları (yeşil: en yüksek, mavi: en düşük)

	09.01.2016				18.4.2016				16.8.2016			
	Üretici	Kullanıcı	Genel	Kappa	Üretici	Kullanıcı	Genel	Kappa	Üretici	Kullanıcı	Genel	Kappa
NTS	0.739	0.810	75.854	0.693	0.889	0.923	80.976	0.763	0.783	0.692	80.494	0.753
RO	0.839	0.788	81.220	0.769	0.800	0.711	84.436	0.815	0.619	0.963	84.670	0.826
Oİ ₅	0.926	0.806	79.756	0.773	0.895	0.773	79.512	0.723	0.944	0.791	81.265	0.741
Oİ ₅ BO ₆	0.740	0.673	76.832	0.721	0.840	0.778	78.537	0.744	0.760	0.844	78.586	0.744
Oİ ₅ BO ₇	0.780	0.639	77.75061	0.744	0.700	0.745	79.268	0.723	0.780	0.830	78.345	0.747
Oİ ₆	0.854	0.854	82.439	0.734	0.880	0.786	77.995	0.688	0.833	0.811	79.756	0.769
Oİ ₆ BO ₆	0.780	0.661	77.017	0.717	0.820	0.774	78.832	0.743	0.760	0.826	78.832	0.738
Oİ ₆ BO ₇	0.780	0.661	78.780	0.720	0.680	0.756	77.129	0.717	0.740	0.822	78.838	0.735
Oİ ₇	0.743	0.788	78.293	0.718	0.955	0.824	80.456	0.728	0.774	0.828	81.707	0.752
Oİ ₇ BO ₆	0.780	0.672	76.585	0.721	0.860	0.782	78.780	0.739	0.800	0.833	78.345	0.741
Oİ ₇ BO ₇	0.740	0.627	76.829	0.709	0.860	0.768	76.642	0.739	0.800	0.833	78.102	0.738
Oİ ₈	0.737	0.737	77.317	0.748	0.974	0.804	77.805	0.740	0.875	0.718	79.512	0.764
Oİ ₈ BO ₆	0.780	0.661	76.830	0.720	0.820	0.745	78.431	0.741	0.800	0.833	78.589	0.740
Oİ ₈ BO ₇	0.820	0.661	76.039	0.731	0.860	0.768	78.378	0.749	0.780	0.830	78.398	0.738
Oİ _{8a}	0.828	0.857	76.755	0.708	0.750	0.818	76.341	0.710	0.862	0.543	76.642	0.710
Oİ _{8a} BO ₆	0.780	0.672	77.017	0.722	0.840	0.750	78.780	0.744	0.780	0.830	78.208	0.736
Oİ _{8a} BO ₇	0.780	0.672	76.773	0.719	0.880	0.786	79.024	0.746	0.860	0.827	79.707	0.755
Oİ ₁₁	0.895	0.895	80.813	0.758	0.923	0.750	78.166	0.721	0.862	0.862	80.976	0.761
Oİ ₁₁ BO ₆	0.780	0.661	76.284	0.714	0.760	0.679	76.341	0.714	0.800	0.816	78.832	0.744
Oİ ₁₁ BO ₇	0.800	0.690	78.240	0.737	0.800	0.667	76.156	0.712	0.860	0.827	79.319	0.750
Oİ ₁₂	0.931	0.844	82.927	0.791	0.766	0.818	76.341	0.708	0.750	0.871	80.244	0.755
Oİ ₁₂ BO ₆	0.820	0.683	77.017	0.722	0.740	0.822	77.073	0.722	0.860	0.827	79.218	0.749
Oİ ₁₂ BO ₇	0.828	0.857	76.286	0.716	0.860	0.811	78.398	0.739	0.840	0.824	79.075	0.747
		Üretici			Kullanıcı		Genel				Kappa	
ABA		0.88			0.759		85.507				0.827	

Tablo 9

2020 yılı için sınıflamaların doğruluk analizi sonuçları (yeşil: en yüksek, mavi: en düşük)

	02.02.2020				17.04.2020				16.08.2020							
	Üretici	Kullanıcı	Genel	Kappa	Üretici	Kullanıcı	Genel	Kappa	Üretici	Kullanıcı	Genel	Kappa				
NTS	0.892	0.917	78.537	0.736	0.759	0.880	80.049	0.751	0.833	1.000	79.137	0.744				
RO	0.925	0.803	82.716	0.788	0.828	0.649	84.748	0.817	0.926	0.806	82.439	0.785				
Oİ ₅	0.838	0.775	85.885	0.790	0.920	0.742	83.659	0.798	0.864	0.905	81.944	0.813				
Oİ ₅ BO ₆	0.821	0.657	79.756	0.756	0.844	0.864	78.802	0.795	0.700	0.972	81.220	0.792				
Oİ ₅ BO ₇	0.893	0.610	78.293	0.761	0.857	0.706	75.610	0.739	0.780	0.800	80.244	0.808				
Oİ ₆	0.829	0.850	82.683	0.701	0.935	0.906	84.185	0.783	0.743	0.788	84.634	0.770				
Oİ ₆ BO ₆	0.700	0.778	79.756	0.720	0.844	0.809	82.927	0.757	0.829	0.806	82.809	0.744				
Oİ ₆ BO ₇	0.720	0.766	80.244	0.732	0.778	0.833	78.537	0.728	0.786	0.733	84.146	0.763				
Oİ ₇	0.870	0.930	76.039	0.739	0.853	0.906	82.816	0.741	0.710	0.815	81.573	0.746				
Oİ ₇ BO ₆	0.700	0.745	76.829	0.711	0.857	0.706	79.756	0.749	0.600	0.844	78.922	0.768				
Oİ ₇ BO ₇	0.821	0.657	77.805	0.743	0.857	0.667	77.317	0.748	0.867	0.765	80.488	0.783				
Oİ ₈	0.957	0.898	79.024	0.748	0.813	0.830	79.951	0.800	0.750	0.828	79.024	0.779				
Oİ ₈ BO ₆	0.683	0.778	76.098	0.757	0.800	0.783	79.024	0.749	0.800	0.833	80.779	0.772				
Oİ ₈ BO ₇	0.683	0.757	78.780	0.739	0.711	0.762	78.810	0.708	0.780	0.848	81.951	0.760				
Oİ _{8a}	0.773	0.895	76.098	0.706	0.964	0.871	79.661	0.739	0.778	0.778	81.220	0.768				
Oİ _{8a} BO ₆	0.700	0.778	78.049	0.734	0.667	0.833	79.024	0.747	0.756	0.861	83.659	0.803				
Oİ _{8a} BO ₇	0.700	0.745	76.341	0.714	0.857	0.615	78.537	0.740	0.720	0.837	79.692	0.758				
Oİ ₁₁	0.879	0.967	76.456	0.698	0.882	0.833	77.805	0.714	0.829	0.853	82.022	0.774				
Oİ ₁₁ BO ₆	0.720	0.783	78.537	0.741	0.893	0.595	78.049	0.738	0.740	0.822	78.729	0.743				
Oİ ₁₁ BO ₇	0.700	0.700	75.122	0.700	0.756	0.756	75.610	0.708	0.740	0.787	78.049	0.734				
Oİ ₁₂	0.828	0.857	78.049	0.729	0.867	0.963	80.244	0.748	0.771	0.659	79.775	0.746				
Oİ ₁₂ BO ₆	0.740	0.771	76.585	0.717	0.857	0.686	79.268	0.750	0.740	0.804	78.832	0.744				
Oİ ₁₂ BO ₇	0.740	0.771	76.575	0.716	0.733	0.767	75.122	0.702	0.680	0.773	78.537	0.740				
	Üretici				Kullanıcı				Genel				Kappa			
ABA	0.923076923				0.692				87.990				0.851			

Yukarıdaki tablo ve grafiklerde her sezon için en düşük ve en yüksek doğruluk sonuçlarının gerçekleştiği kombinasyon görülmektedir. Buna bağlı olarak en yüksek doğruluk sonucunu veren kombinasyonların 2016 ve 2020 yılları arasındaki alansal (ha) değişimlerini gösteren tablo aşağıdaki gibidir.

Tablo 11

Sınıflandırma sonucunda en yüksek doğrulukta çıkan kombinasyonların alanlarının (ha) değişimi

	2016 - 2020 KIŞ ALAN (ha)		Değişim
	2016 - Oİ ₁₂	2020 - Oİ ₅	
Mera	2,410	4,437	+
Orman	115,485	111,446	-
Su	0,160	0,716	+
Tarım	28,869	44,737	+
Yerleşim	55,080	53,327	-
Zeytin	293,714	281,188	-

	2016 - 2020 BAHAR ALAN (ha)		Değişim
	2016 - O _{RO}	2020 - O _{RO}	
Mera	4,183	4,788	+
Orman	114,301	110,210	-
Su	0,625	0,560	-
Tarım	46,036	36,894	-
Yerleşim	40,010	50,968	+
Zeytin	290,698	292,432	+

	2016 - 2020 YAZ ALAN (ha)		Değişim
	2016 - O _{RO}	2020 - Oİ ₆	
Mera	4,974	4,095	-
Orman	107,355	109,290	+
Su	1,846	0,161	-
Tarım	45,618	22,725	-
Yerleşim	37,776	54,765	+
Zeytin	301,289	304,822	+

4.2. YYS Sonuçları

YYS haritaları, çalışma alanındaki istasyonların mevcut konumları baz alınarak Landsat-8 TIRS uydu görüntülerinden Bant 10 ve Bant 11 kullanılarak hazırlanmıştır. Split-window algoritması kullanılarak ArcGIS (YYS_{ArcGIS}) ve GEE (YYS_{GEE}) ile sıcaklıklar hesaplanmış ve belirlenen günlerdeki anlık sıcaklık değerleri noktasal olarak elde edilmiştir. Anlık sıcaklıkların yanında MGM'den alınan günlük minimum (min), ortalama (ort) ve maksimum (mak) sıcaklık değerleri de incelenmiş ve tüm veriler karşılaştırılmıştır. YYS_{ArcGIS} ve YYS_{GEE} kullanılarak yapılan YYS haritaları Şekil 43 ve Şekil 44'de, tüm değerlerin (YYS_{ArcGIS}, YYS_{GEE}, MGM değerleri) grafiksel gösterimi Şekil 45'de verilmiştir. Buna göre çalışma alanında bulunan istasyon noktalarındaki noktasal sıcaklıklar;

2016 kış sezonu için sıcaklıklar sırasıyla Armutlu için, YYS_{ArcGIS}: 10.23 °C, YYS_{GEE}: 9.77 °C, mak: 14.40 °C, ort: 5.80 °C ve min: 1.40 °C olarak, Gemlik için sırasıyla 11.67 °C, 11.20 °C, 14.10 °C, 8.90°C, 6.20 °C olarak, Gündoğdu için sırasıyla 9.94 °C, 9.48 °C, 11.70 °C, 7.20 °C, 3.50 °C olarak, Mudanya için sırasıyla 10.99 °C, 10.49 °C, 11.80 °C, 7.10 °C, 3.50 °C olarak elde edilmiştir.

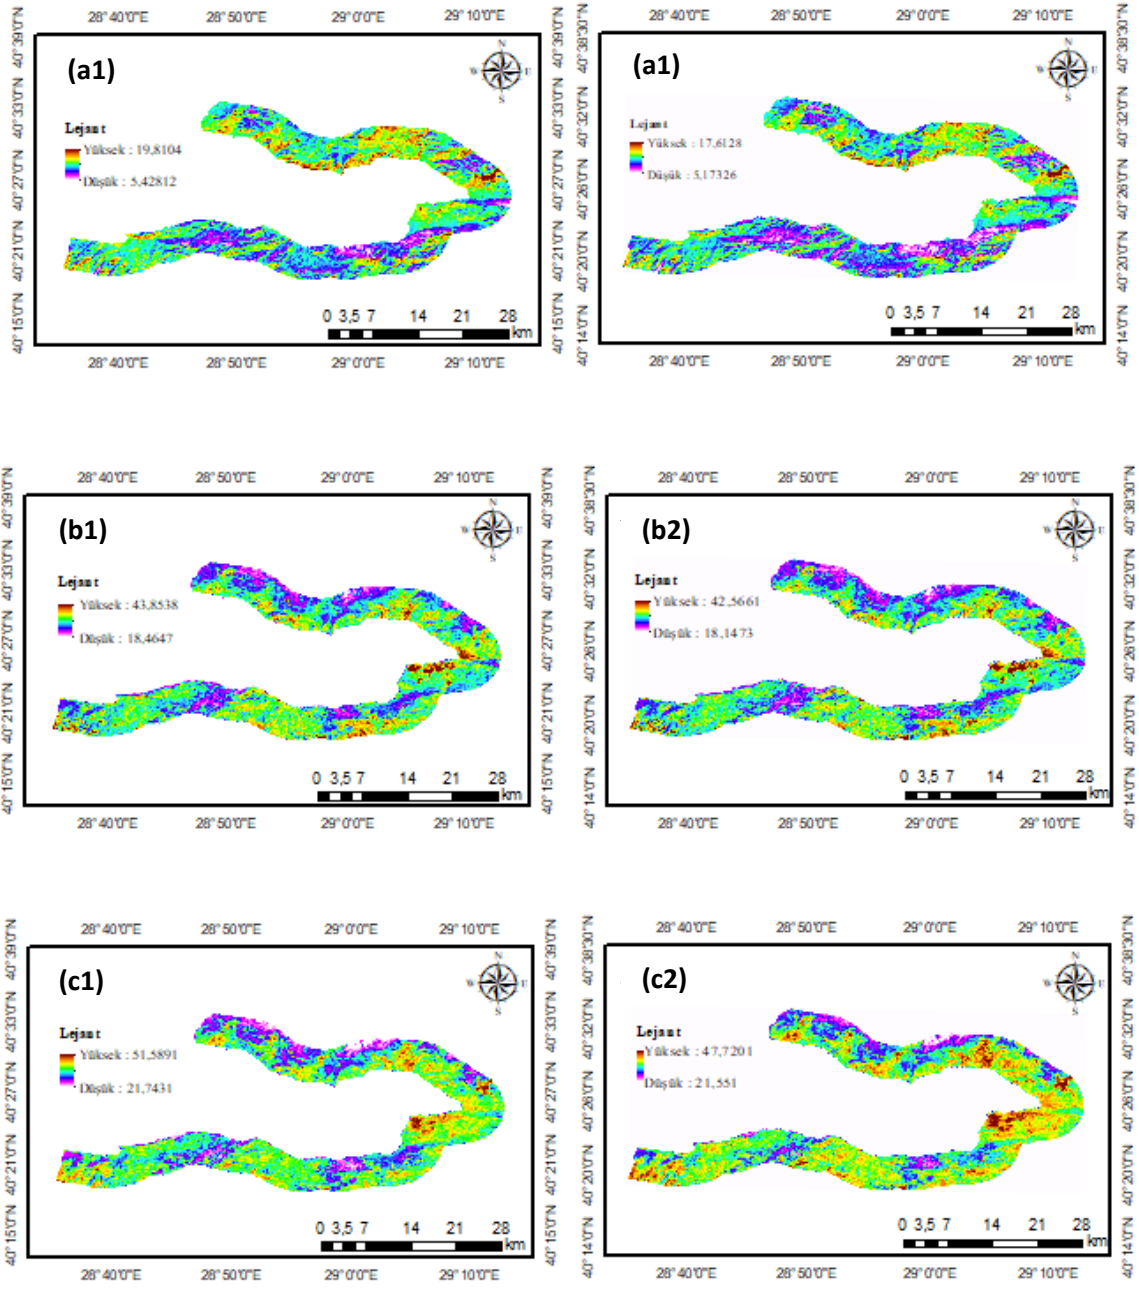
2016 bahar sezonu için sıcaklıklar sırasıyla Armutlu için, YYS_{ArcGIS}: 28.82 °C, YYS_{GEE}: 28.19 °C, mak: 32.70 °C, ort: 21.00 °C ve min: 11.40 °C olarak, Gemlik için sırasıyla 32.02 °C, 31.56 °C, 28.00 °C, 17.90 °C, 15.50 °C olarak, Gündoğdu için sırasıyla 25.00 °C, 28.63 °C, 23.00 °C, 21.00 °C, 20.20 °C olarak, Mudanya için sırasıyla 29.08 °C, 24.68 °C, 26.50 °C, 20.50 °C, 14.90 °C olarak bulunmuştur.

2016 yaz sezonu için sıcaklıklar sırasıyla Armutlu için, YYS_{ArcGIS}: 32.25 °C, YYS_{GEE}: 36.61 °C, mak: 31.90 °C, ort: 23.50 °C ve min: 14.20 °C olarak, Gemlik için sırasıyla 38.38 °C, 37.9 °C, 32.70 °C, 26.50 °C, 19.50 °C olarak, Gündoğdu için sırasıyla 37.00 °C, 36.52 °C, 27.50 °C, 22.70 °C, 18.30 °C olarak, Mudanya için sırasıyla 30.41 °C, 29.94 °C, 30.00 °C, 24.10 °C, 17.50 °C olarak elde edilmiştir.

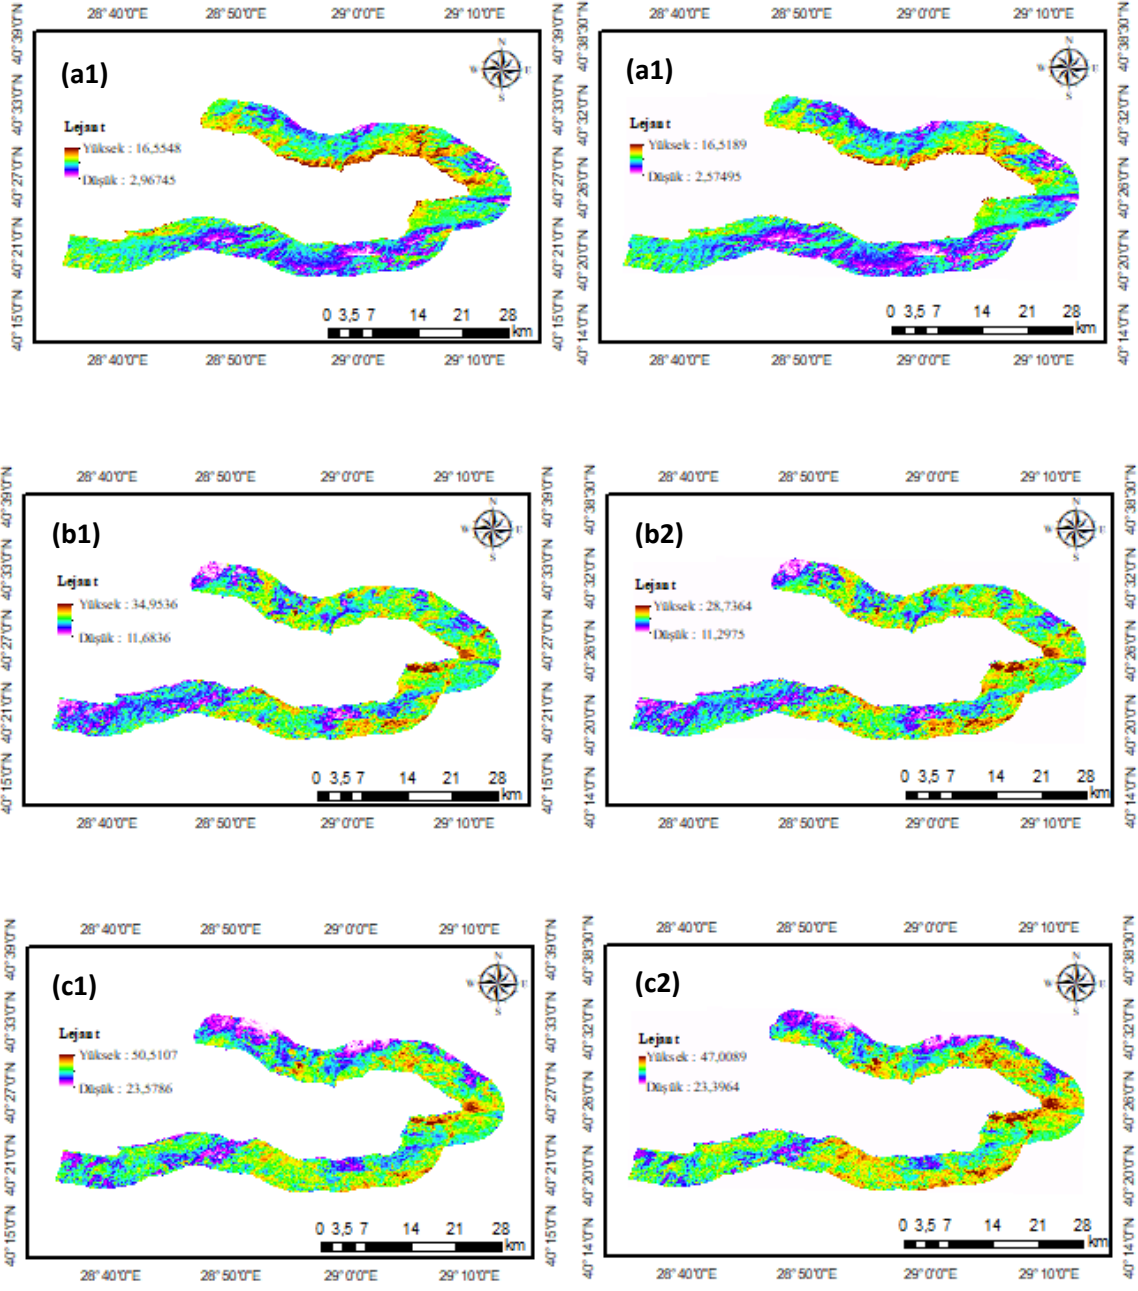
2020 kış sezonu için sıcaklıklar sırasıyla Armutlu için, YYS_{ArcGIS}: 9.45 °C, YYS_{GEE}: 8.94 °C, mak: 13.30 °C, ort: 4.60 °C ve min: 0.30 °C olarak, Gemlik için sırasıyla 11.68 °C, 11.36 °C, 11.00 °C, 8.00 °C, 5.00 °C olarak, Gündoğdu için sırasıyla 6.74 °C, 6.23 °C, 9.20 °C, 4.40 °C, 1.00 °C olarak, Mudanya için sırasıyla 12.33 °C, 11.9 °C, 11.80 °C, 6.50 °C, 2.90 °C olarak ortaya çıkmıştır.

2020 bahar sezonu için sıcaklıklar sırasıyla Armutlu için, YYS_{ArcGIS} : 20.24 °C, YYS_{GEE} : 20.62 °C, mak: 16.80 °C, ort: 13.00 °C ve min: 7.70 °C olarak, Gemlik için sırasıyla 23.12 °C, 22.17 °C, 19.20 °C, 14.20 °C, 9.20 °C olarak, Gündoğdu için sırasıyla 21.88 °C, 21.47 °C, 15.00 °C, 11.20 °C, 7.20 °C olarak, Mudanya için sırasıyla 18.93 °C, 18.55 °C, 17.70 °C, 12.40 °C, 7.00 °C olarak elde edilmiştir.

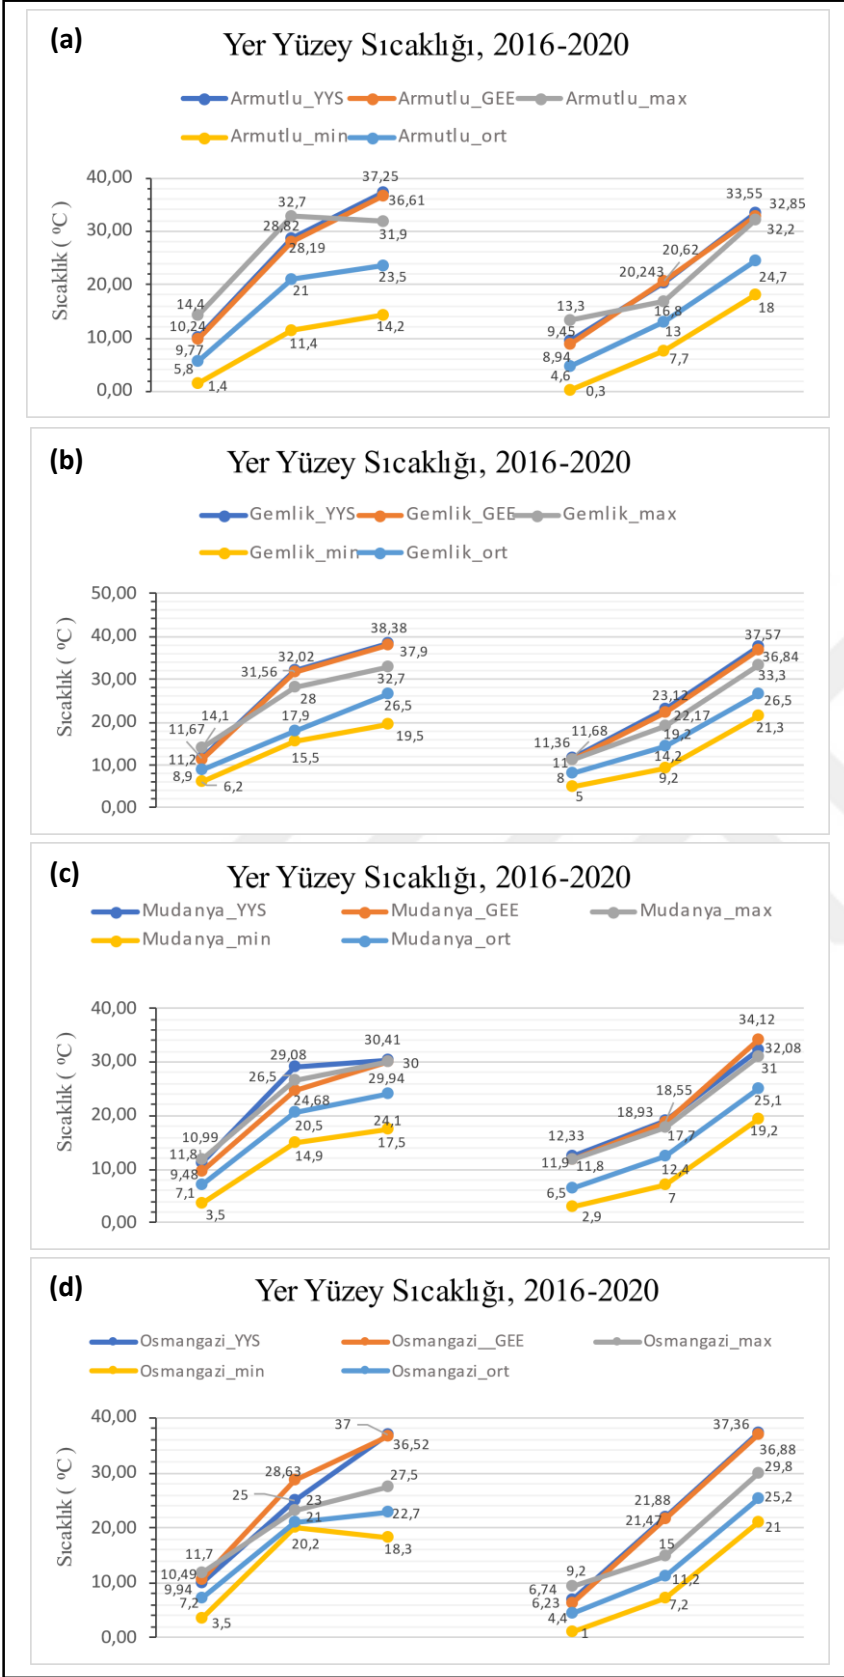
2020 yaz sezonu için sıcaklıklar sırasıyla Armutlu için, YYS_{ArcGIS} : 33.55 °C, YYS_{GEE} : 32.85 °C, mak: 32.20 °C, ort: 24.700 °C ve min: 18.00 °C olarak, Gemlik için sırasıyla 37.57 °C, 36.84 °C, 33.30 °C, 26.50 °C, 21.30 °C olarak, Gündoğdu için sırasıyla 37.36 °C, 36.88 °C, 29.80 °C, 25.20 °C, 21.00 °C olarak, Mudanya için sırasıyla 32.08 °C, 34.12 °C, 31.00 °C, 25.10 °C, 19.20 °C olarak elde edilmiştir.



Şekil 29. (a1, a2) 2016 kış sezonu, (b1, b2) 2016 bahar sezonu, (c1, c2) 2016 yaz sezonu, (YYS_{ArcGIS}, YYS_{GEE})



Şekil 30. (a1, a2) 2020 kış sezonu, (b1, b2) 2020 bahar sezonu, (c1, c2) 2020 yaz sezonu, (YYS_{ArcGIS}, YYS_{GEE})



Şekil 31. 2016-2020 arasında hesaplanan yer yüzey sıcaklığı grafikleri (Armutlu (a), Gemlik (b), Mudanya (c), Osmangazi (d))

İstasyon merkezleri baz alınarak oluşturulan sıcaklık noktalarının çevresine 2 km'lik tampon bölge oluşturulmuştur. Daha sonra tampon bölge içindeki anlık YYS_{ArcGIS} değerleri ile AKBÖ sınıfları arasındaki ilişki belirlenmiştir. Dört istasyona bağlı olarak oluşturulan her tampon bölge içerisinde altı ana sınıfa rastlanmamış olup, belirlenen sınıflarda anlık sıcaklıklar en yüksek ve en düşük olarak elde edilmiştir. Tablo 12 - Tablo 17 arası verilerin tablolaşmış halini, Şekil 46 ve Şekil 47 elde edilen bu değerlere ilişkin haritaları göstermektedir. Buna bağlı olarak;

Tablo 10
2016 kış sezonu arazi sınıflarının düşük ve yüksek sıcaklıkları

2016 - KIŞ								
SINIF	ARMUTLU		GEMLİK		OSMANGAZİ		MUDANYA	
	Düşük Sıcaklık	Yüksek Sıcaklık	Düşük Sıcaklık	Yüksek Sıcaklık	Düşük Sıcaklık	Yüksek Sıcaklık	Düşük Sıcaklık	Yüksek Sıcaklık
Mera	8,47	12,84	10,58	13,37	9,85	12,94	10,21	12,11
Orman	6,17	13,77	7,19	13,06	5,90	12,75	6,53	12,61
Su	8,29	9,37	-	0,00			-	-
Tarım	7,31	14,58	9,02	16,27	9,11	15,78	7,59	14,29
Yerleşim	7,70	14,01	7,20	19,71	5,91	17,62	7,22	15,77
Zeytin	6,75	15,22	7,28	18,71	6,08	16,23	6,70	14,37

Tablo 11
2016 bahar sezonu arazi sınıflarının düşük ve yüksek sıcaklıkları

2016 - BAHAR								
SINIF	ARMUTLU		GEMLİK		OSMANGAZİ		MUDANYA	
	Düşük Sıcaklık	Yüksek Sıcaklık	Düşük Sıcaklık	Yüksek Sıcaklık	Düşük Sıcaklık	Yüksek Sıcaklık	Düşük Sıcaklık	Yüksek Sıcaklık
Mera	25,74	33,55	25,25	34,18	27,20	34,56	28,71	32,08
Orman	21,64	31,46	23,44	32,19	23,98	33,49	23,66	31,76
Su	-	-	-	-	26,74	30,77	-	-
Tarım	21,98	35,32	25,38	31,45	25,79	33,25	24,84	39,99
Yerleşim	24,67	35,67	25,94	39,08	26,53	35,64	23,19	42,11
Zeytin	22,68	36,21	23,80	35,11	24,32	37,49	23,81	34,93

Tablo 12
2016 yaz sezonu arazi sınıflarının düşük ve yüksek sıcaklıkları

2016 - YAZ								
SINIF	ARMUTLU		GEMLİK		OSMANGAZİ		MUDANYA	
	Düşük Sıcaklık	Yüksek Sıcaklık	Düşük Sıcaklık	Yüksek Sıcaklık	Düşük Sıcaklık	Yüksek Sıcaklık	Düşük Sıcaklık	Yüksek Sıcaklık
Mera	35,94	40,71	34,28	46,45	36,19	41,10	37,03	37,03
Orman	26,06	40,06	26,80	40,05	28,98	40,87	29,71	38,46
Su	31,24	31,24	-	-	34,78	35,77	30,20	33,56
Tarım	28,14	43,54	29,79	46,49	32,47	44,09	30,88	42,64
Yerleşim	29,54	47,14	34,04	46,04	31,98	43,89	30,41	43,47
Zeytin	27,31	43,21	27,23	45,62	29,79	44,95	29,87	41,75

Tablo 13

2020 kış sezonu arazi sınıflarının düşük ve yüksek sıcaklıkları

2020 - KIŞ								
SINIF	ARMUTLU		GEMLİK		OSMANGAZİ		MUDANYA	
	Düşük Sıcaklık	Yüksek Sıcaklık	Düşük Sıcaklık	Yüksek Sıcaklık	Düşük Sıcaklık	Yüksek Sıcaklık	Düşük Sıcaklık	Yüksek Sıcaklık
Mera	8,91	13,36	5,72	13,91	4,70	10,56	8,16	11,33
Orman	5,18	11,90	3,17	11,82	3,08	12,77	4,79	10,19
Su	7,30	8,12	9,88	9,88	5,43	5,33	7,04	12,09
Tarım	5,90	13,45	5,48	13,81	5,26	9,08	5,44	11,48
Yerleşim	6,77	13,29	4,35	13,92	4,60	12,38	5,68	13,14
Zeytin	5,60	13,43	3,21	13,84	3,42	12,93	4,67	11,31

Tablo 14

2020 bahar sezonu arazi sınıflarının düşük ve yüksek sıcaklıkları

2020 - BAHAR								
SINIF	ARMUTLU		GEMLİK		OSMANGAZİ		MUDANYA	
	Düşük Sıcaklık	Yüksek Sıcaklık	Düşük Sıcaklık	Yüksek Sıcaklık	Düşük Sıcaklık	Yüksek Sıcaklık	Düşük Sıcaklık	Yüksek Sıcaklık
Mera	19,38	21,62	19,55	24,80	18,84	25,73	21,17	23,88
Orman	12,46	24,59	17,42	25,04	16,02	26,19	15,56	22,48
Su	-	-	-	-	17,72	17,72	21,31	21,31
Tarım	14,36	26,71	18,02	26,07	18,15	27,87	16,75	25,44
Yerleşim	14,02	26,57	17,74	29,99	17,27	29,14	17,01	26,62
Zeytin	12,90	26,18	17,55	25,79	16,76	29,08	16,44	25,35

Tablo 15

2020 yaz sezonu arazi sınıflarının düşük ve yüksek sıcaklıkları

2020 - YAZ								
SINIF	ARMUTLU		GEMLİK		OSMANGAZİ		MUDANYA	
	Düşük Sıcaklık	Yüksek Sıcaklık	Düşük Sıcaklık	Yüksek Sıcaklık	Düşük Sıcaklık	Yüksek Sıcaklık	Düşük Sıcaklık	Yüksek Sıcaklık
Mera	29,04	36,85	30,43	41,05	33,29	45,58	32,84	40,31
Orman	24,97	36,40	27,50	39,20	30,30	42,21	31,21	38,78
Su	-	-	-	-	-	-	-	-
Tarım	25,6959	38,4754	29,3726	45,6233	31,67	46,57	32,26	41,19
Yerleşim	26,8412	41,5104	29,88	46,92	32,58	43,90	30,39	41,90
Zeytin	25,36	41,39	28,14	43,20	30,48	47,11	31,68	41,99

2016 kış sezonunda Armutlu içerisinde, en düşük sıcaklık ve en yüksek sıcaklık değerleri sırasıyla M sınıfı için 8.47 °C ve 12.84 °C, O sınıfı için 6.17 °C ve 13.77 °C, S sınıfı için 8.29 °C ve 9.37 °C, T sınıfı için 7.31 °C ve 14.58 °C, Y sınıfı için 7.70 °C ve 14.01 °C ve Z sınıfı için 6.75 °C ve 15.22 °C; Gemlik içerisinde M için 10.58 °C ve 13.37 °C, O için 7.19 °C ve 13.06 °C, T için 9.02 °C ve 16.27 °C, Y için 7.20 °C ve 19.71 °C ve Z için

7.28 °C ve 18.71 °C; Gündoğdu(Osmangazi) içerisinde M için 9.85 °C ve 12.94 °C, O için 5.90 °C ve 12.75 °C, T için 9.11 °C ve 15.78 °C, Y için 5.91 °C ve 17.62 °C ve Z için 6.08 °C ve 16.23 °C, Mudanya içerisinde M için 10.21 °C ve 12.11 °C, O için 6.53 °C ve 12.61 °C, T için 7.59 °C ve 14.29 °C, Y için 7.22 °C ve 15.77 °C ve Z için 6.70 °C ve 14.37 °C olarak belirlenmiştir.

2016 bahar sezonunda Armutlu içerisinde M sınıfı için 25.74 °C ve 33.55 °C, O için 21.64 °C ve 31.46 °C, T için 21.98 °C ve 35.32 °C, Y için 24.67 °C ve 35.67 °C ve Z için 22.68 °C ve 36.21 °C; Gemlik içerisinde M için 25,25 °C ve 34,18 °C, O için 23,44 °C ve 32,19 °C, T için 25,38 °C ve 31,45 °C, Y için 25,94 °C ve 39,08 °C ve Z için 23,80 °C ve 35,11 °C; Gündoğdu(Osmangazi) içerisinde M için 27,20 °C ve 34,56 °C, O için 23,98 °C ve 33,49 °C, S için 26,74 °C ve 30,77 °C, T için 25,79 °C ve 33,25 °C, Y için 26,53°C ve 35,64 °C ve Z için 24,32 °C ve 37,49 °C, Mudanya içerisinde M için 28,71 °C ve 32,08 °C, O için 23,66 °C ve 31,76 °C, T için 24,84 °C ve 39,99 °C, Y için 23,19°C ve 42,11 °C ve Z için 23,81 °C ve 34,93 °C olarak elde edilmiştir.

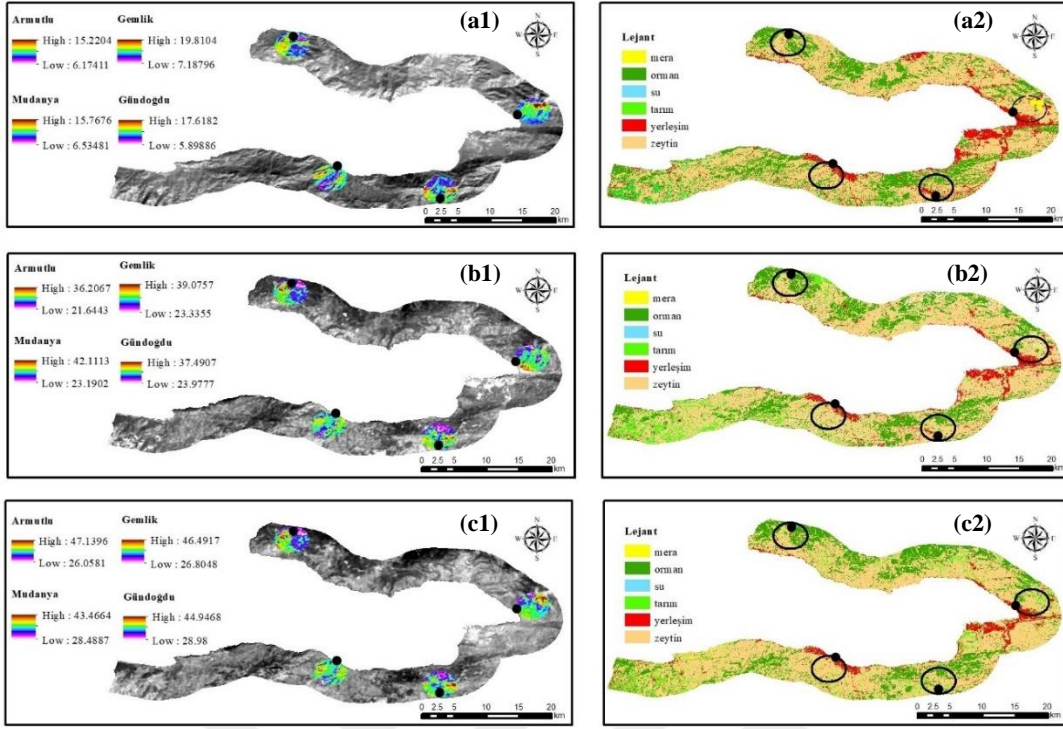
2016 yaz sezonunda Armutlu içerisinde M sınıfı için 35,94 °C ve 40,71 °C, O için 26,06 °C ve 40,06 °C, S için 31,24 °C ve 31,24 °C, T için 28,14 °C ve 43,54 °C, Y için 29,54 °C ve 47,14 °C ve Z için 27,31 °C ve 43,21 °C; Gemlik içerisinde M için 34,28 °C ve 46,45 °C, O için 26,80 °C ve 40,05 °C, T için 29,79 °C ve 46,49 °C, Y için 34,04 °C ve 46,04 °C ve Z için 27,23 °C ve 45,62 °C; Gündoğdu(Osmangazi) içerisinde M için 36,19 °C ve 41,10 °C, O için 28,98 °C ve 40,87 °C, S için 34,78 °C ve 35,77 °C, T için 32,47 °C ve 44,09 °C, Y için 31,98 °C ve 43,96 °C ve Z için 29,79 °C ve 44,95 °C, Mudanya içerisinde M için 37,03 °C ve 37,03 °C, O için 29,71 °C ve 38,46 °C, S için 30,20 °C ve 33,56 °C, T için 30,88 °C ve 42,64 °C, Y için 30,41 °C ve 43,47 °C ve Z için 29,87 °C ve 41,75 °C olarak oluşmuştur.

2020 kış sezonunda Armutlu içerisinde M için 8,91 °C ve 13,36 °C, O için 5,18 °C ve 11,90 °C, S için 7,30 °C ve 8,12 °C, T için 5,90 °C ve 13,45 °C, Y için 6,77 °C ve 13,29 °C ve Z için 5,60 °C ve 13,43 °C; Gemlik içerisinde M için 5,72 °C ve 13,91 °C, O için 3,17 °C ve 11,82 °C, S için 9,88 °C ve 9,92 °C, T için 5,48 °C ve 13,81 °C, Y için 4,35 °C ve 13,92 °C ve Z için 3,21 °C ve 13,84 °C; Gündoğdu(Osmangazi) içerisinde M için 4,70 °C ve 10,56 °C, O için 3,08 °C ve 12,77 °C, S için 5,43 °C ve 5,33 °C, T için 5,26 °C ve 9,08 °C, Y için 4,60 °C ve 12,38 °C ve Z için 3,42 °C ve 12,93 °C, Mudanya içerisinde M için 8,16

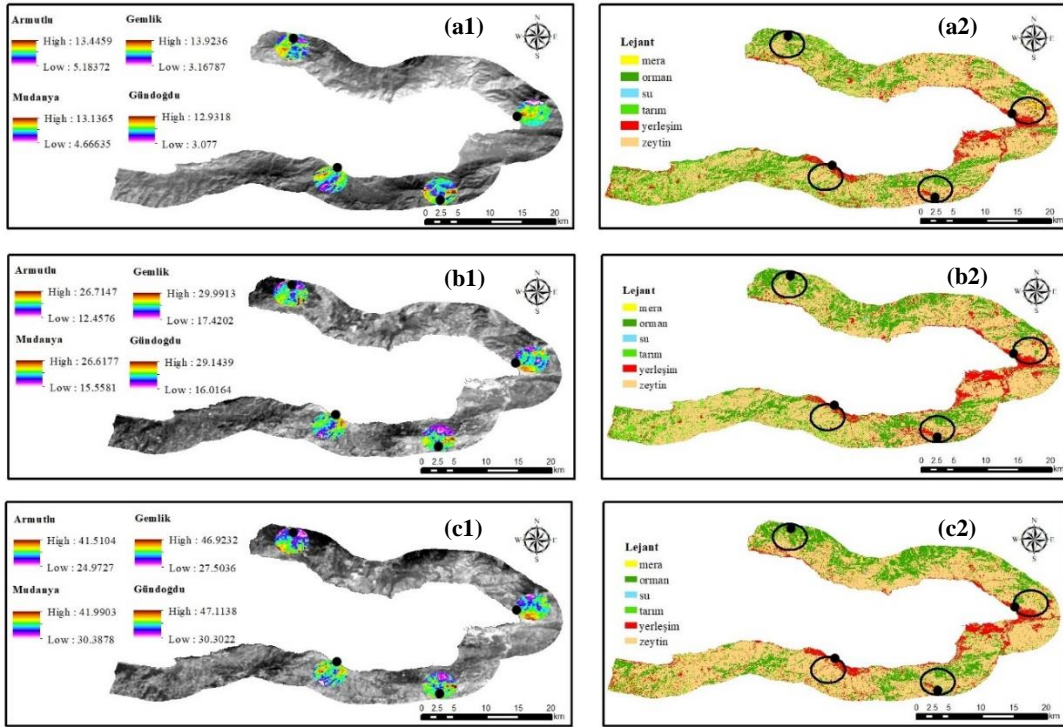
°C ve 11,33 °C, O için 4,79 °C ve 10,19 °C, S için 7,04 °C ve 12,09 °C, T için 5,44 °C ve 11,48 °C, Y için 5,68 °C ve 13,14 °C ve Z için 4,67 °C ve 11,31 °C olarak elde edilmiştir

2020 bahar sezonunda Armutlu içerisinde M için 19,38 °C ve 21,62 °C, O için 12,46 °C ve 24,59 °C, T için 14,36 °C ve 26,71 °C, Y için 14,02 °C ve 26,57 °C ve Z için 12,90 °C ve 26,18 °C; Gemlik içerisinde M için 19,55 °C ve 24,80 °C, O için 17,42 °C ve 25,04 °C, T için 18,02 °C ve 26,07 °C, Y için 17,74 °C ve 29,99 °C ve Z için 17,55 °C ve 25,79 °C; Gündoğdu(Osmangazi) içerisinde M için 18,84 °C ve 25,73 °C, O için 16,02 °C ve 26,19 °C, S için 17,72°C ve 17,99 °C, T için 18,15 °C ve 27,87 °C, Y için 17,27 °C ve 29,14 °C ve Z için 16,76 °C ve 29,08 °C, Mudanya içerisinde M için 21,17 °C ve 23,88 °C, O için 15,56 °C ve 22,48 °C, S için 21,31 °C ve 22,32 °C, T için 16,75 °C ve 25,44 °C, Y için 17,01 °C ve 26,62 °C ve Z için 16,44 °C ve 25,35 °C olarak belirlenmiştir

2020 yaz sezonunda Armutlu içerisinde M için 29,04 °C ve 36,85 °C, O için 24,97 °C ve 36,40 °C, T için 25,70 °C ve 38,48 °C, Y için 26,84 °C ve 41,51 °C ve Z için 25,36 °C ve 41,39 °C; Gemlik içerisinde M için 30,43 °C ve 41,05 °C, O için 27,50 °C ve 39,20 °C, T için 29,37 °C ve 45,62 °C, Y için 29,88 °C ve 46,92 °C ve Z için 28,14 °C ve 43,20 °C; Gündoğdu(Osmangazi) içerisinde M için 33,29 °C ve 45,58 °C, O için 30,30 °C ve 42,21 °C, T için 31,67 °C ve 46,57 °C, Y için 32,58 °C ve 43,90 °C ve Z için 30,48 °C ve 47,11 °C, Mudanya içerisinde M için 32,84 °C ve 40,31 °C, O için 31,21 °C ve 38,78 °C, T için 32,26 °C ve 41,19 °C, Y için 30,39 °C ve 41,90 °C ve Z için 31,68 °C ve 41,99 °C olarak bulunmuştur.



Şekil 32. YYS_{ARC}GIS için noktasal sıcaklıklar; (a1-a2) 2016 kış sezonu, (b1-b2) 2016 bahar sezonu, (c1-c2) 2016 yaz sezonu



Şekil 33. YYS_{ARC}GIS için noktasal sıcaklıklar; (a1-a2) 2020 kış sezonu, (b1-b2) 2020 bahar sezonu, (c1-c2) 2020 yaz sezonu

Bunun yanısıra YYS_{ArcGIS} ve YYS_{GEE} arasındaki ilişkinin daha net olarak ortaya çıkması ve hem ArcGIS programı hem GEE yazılımı kullanılarak yapılan YYS haritalarının sonuç çıktılarının gözle görülür bir fark yaratmadığının anlaşılması için çalışma yapılmıştır. Bu bağlamda çalışma alanına eş koordinatlı 10 nokta atılarak, bu noktaların sıcaklık değerleri iki şekilde de belirlenmiştir. Çıkan sonuçlar, R^2 cinsinden istatistik değerler olup her iki yöntem kullanılarak yapılacak YYS haritalarında oluşturulan AKBÖ sınıflarının birbirlerinin yerine kullanılabilir olduğunu göstermiştir.

Tablo 16

2016 yılı için R^2 cinsinden sınıfların değerleri (kış, ilkbahar, yaz)

R^2	2016		
	Kış	İlkbahar	Yaz
Mera	0,999872708	0,999680313	0,999926685
Orman	0,999803181	0,999315232	0,999781042
Su	0,999873386	0,999927739	0,999964883
Tarım	0,999782431	0,999849685	0,999981818
Yerleşim	0,997468996	0,999850823	0,99994189
Zeytin	0,999363097	0,997912055	0,999800401

Tablo 17

2020 yılı için R^2 cinsinden sınıfların değerleri (kış, ilkbahar, yaz)

R^2	2020		
	Kış	İlkbahar	Yaz
Mera	0,9998147	0,9999802	0,9998358
Orman	0,9997715	0,9999194	0,9997388
Su	0,9994994	0,9998648	0,9998639
Tarım	0,9998601	0,999572	0,9999603
Yerleşim	0,9998131	0,9999413	0,9999697
Zeytin	0,9999774	0,9984311	0,9998932

4.3. YYS - AKBÖ İlişkisi

YYS_{ArcGIS} hesaplamasının yapıldığı dört istasyon (Armutlu, Gemlik, Gündoğdu, Mudanya) konumundan 2 km tampon uygulanarak oluşturulan bölgede arazideki değişimin sıcaklık ile ilişkisine bakılmıştır. Buna göre;

2016-2020 kış sezonunda Armutlu için alan ve sıcaklık değişimi sırasıyla, M (%23,08 ve 0,52 °C artış), O (%19,03 ve 1,87 °C azalış), S (%50,00 ve 1,25 °C azalış), T (%87,79 artış ve 1,13 °C azalış), Y (%30,47 artış ve 0,73 °C azalış) ve Z (%1,63 artış ve 1,79 °C azalış); Gemlik için M (%68,58 ve 0,54 °C artış), O (%14,21 ve 1,24 °C azalış), S (%0,10 ve 9,88 °C artış), T (%23,96 ve 2,46 °C azalış), Y (%3,60 ve 5,79 °C azalış) ve Z (%9,80 ve 4,86 °C azalış); Osmangazi için M (%69,88 artış ve 2,38 °C azalış), O (%5,89 ve 0,03 °C artış), S (%0,20 ve 5,33 °C artış), T (%56,31 ve 6,70 °C azalış), Y (%14,38 ve 5,24 °C azalış) ve Z (%1,13 artış ve 3,29 °C azalış); Mudanya için M (%6,82 ve 0,78 °C azalış), O (%18,26 ve 2,41 °C azalış), S (%0,30 ve 12,09 °C artış), T (%86,07 artış ve 2,81 °C azalış), Y (%0,74 ve 2,63 °C azalış) ve Z (%10,53 ve 3,06 °C azalış) olarak elde edilmiştir.

2016-2020 bahar sezonunda Armutlu için alan ve sıcaklık değişimi sırasıyla, M (%95,24 ve 11,93 °C azalış), O (%12,06 ve 6,87 °C azalış), S (%0,20), T (%5,83 artış ve 8,61 °C azalış), Y (%29,03 artış ve 9,10 °C azalış) ve Z (%25,40 artış ve 10,03 °C azalış); Gemlik için M (%57,81 ve 9,38 °C azalış), O (%21,45 ve 7,15 °C azalış), T (%9,60 artış ve 5,38 °C azalış), Y (%34,81 artış ve 9,08 °C azalış) ve Z (%16,55 artış ve 9,32 °C azalış); Osmangazi için M (%54,11 ve 8,83 °C azalış), O (%8,88 artış ve 7,31 °C azalış), S (%75,00 artış ve 13,05 °C azalış), T (%72,00 artış ve 5,38 °C azalış), Y (%76,13 artış ve 6,49 °C azalış) ve Z (%10,72 ve 8,41 °C azalış); Mudanya için M (%11,11 ve 8,20 °C azalış), O (%29,02 artış ve 9,28 °C azalış), S (%75,00 azalış ve 21,31 °C artış), T (%48,84 artış ve 14,54 °C azalış), Y (%12,69 ve 15,49 °C azalış) ve Z (%10,25 artış ve 9,59 °C azalış) olarak oluşturulmuştur.

2016-2020 yaz sezonunda Armutlu için alan ve sıcaklık değişimi sırasıyla, M (%80,00 artış ve 3,86 °C azalış), O (%7,26 artış ve 3,66 °C azalış), T (%56,07 ve 5,06 °C azalış), Y (%6,55 artış ve 5,63 °C azalış) ve Z (%2,55 artış ve 1,82 °C azalış); Gemlik için M (%61,68 artış ve 5,39 °C azalış), O (%22,40 artış ve 0,85 °C azalış), T (%73,98 ve 0,87 °C azalış), Y (%28,86 ve 0,88 °C artış) ve Z (%16,10 artış ve 2,42 °C azalış); Osmangazi için M (%21,25 ve 4,48 °C artış), O (%2,40 ve 1,34 °C artış), S (%100 azalış), T (%30,52

azalış ve 2,47 °C artış), Y (%79,81 ve 0,01 °C artış) ve Z (%1,28 ve 2,17 °C artış); Mudanya için M (%120,00 ve 3,28 °C artış), O (%25,17 ve 0,32 °C artış), S (%100 azalış), T (%50,06 ve 1,45 °C azalış), Y (%39,94 artış ve 1,56 °C azalış) ve Z (%0,88 azalış ve 0,24 °C artış) olarak elde edilmiştir.

Tablo 20
2016-2020 yılları arasında arazi sınıflarına göre sıcaklık değişimi (°C bazında)

2016 - 2020 KIŞ (°C)				
	ARMUTLU	GEMLİK	OSMANGAZİ	MUDANYA
Mera	0,52	0,54	-2,38	-0,78
Orman	-1,87	-1,24	0,03	-2,41
Su	-1,25	9,88	5,33	12,09
Tarım	-1,13	-2,46	-6,70	-2,81
Yerleşim	-0,73	-5,79	-5,24	-2,63
Zeytin	-1,79	-4,86	-3,29	-3,06
2016 - 2020 BAHAR (°C)				
Mera	-11,93	-9,38	-8,83	-8,20
Orman	-6,87	-7,15	-7,31	-9,28
Su	-	-	-13,05	21,31
Tarım	-8,61	-5,38	-5,38	-14,54
Yerleşim	-9,10	-9,08	-6,49	-15,49
Zeytin	-10,03	-9,32	-8,41	-9,59
2016 - 2020 YAZ (°C)				
Mera	-3,86	-5,39	4,48	3,28
Orman	-3,66	-0,85	1,34	0,32
Su	-	-	-	-
Tarım	-5,06	-0,87	2,47	-1,45
Yerleşim	-5,63	0,88	0,01	-1,56
Zeytin	-1,82	-2,42	2,17	0,24

Tablo 18
2016 - 2020 yıllarındaki sınıflara göre alan değişimi (% bazında)

2016 – 2020 KIŞ (ALAN) (%)				
	ARMUTLU	GEMLİK	OSMANGAZİ	MUDANYA
Mera	23,08	68,58	69,88	-6,82
Orman	-19,03	-14,21	5,89	-18,26
Su	-50	0,1	0,2	0,3
Tarım	87,79	-23,96	-56,31	86,07
Yerleşim	30,47	-3,6	-14,38	-0,74
Zeytin	1,63	-9,8	1,13	-10,53
2016 – 2020 BAHAR (ALAN) (%)				
Mera	-95,24	-57,81	-54,11	-11,11
Orman	-12,06	-21,45	8,88	29,02
Su	0,2	-	-75	-
Tarım	5,83	9,6	72	48,84
Yerleşim	29,03	34,81	76,13	-12,69
Zeytin	25,4	16,55	-10,72	10,25
2016 – 2020 YAZ (ALAN) (%)				
Mera	80	61,68	21,25	120
Orman	7,26	22,4	2,4	25,17
Su	-	-	-	-
Tarım	-56,07	-73,98	-30,52	-50,06
Yerleşim	6,55	28,86	79,81	39,94
Zeytin	2,55	16,1	1,28	-0,88

BEŞİNCİ BÖLÜM BÖLÜM

SONUÇ VE ÖNERİLER

Arazi kullanımının sonucunda arazideki değişimler, nüfus artışıdaki düzensiz ivme, ekonomik dalgalanmalar ve vejetasyondaki dengesiz dağılımdan kaynaklı süreçlerde gerçekleşmektedir. Ekolojik çevrenin etkisinin yanısıra antropojenik etkilerin artışta olması ile tarımsal ve orman alanlarındaki değişim kentsel alanlarda kayıplar şeklinde yaşanmaktadır. Kentsel alanlardaki artışın kıyı bölgelerine de baskı oluşturduğu ve biyolojik etkiler yarattığı anlaşılmaktadır. Yaşanan tüm bu dönüşümler arazinin yüzeyinde belirgin sıcaklık değişimlerinin olmasına neden olmaktadır. Bu nedenle kıyı bölgelerindeki arazinin tarımsal ve kentsel metriklerinin değişiminin negatif ve pozitif yönde incelenmesi çevresel politikaların müdahalelerine izin verecek bilinçli kararlar alınmasını teşkil eder.

Bu çalışma Güney-Doğu Marmara bölgesindeki iki kentin sahil bandı ve çevresinde gerçekleşen AKBÖ değişiminin belirgin sonuçlarını sosyoekonomik nedenlerle araştırmak ve sıcaklık değişimlerinin ilişkisini irdelemek için UA ve CBS ile geçerli bir yanıt aramıştır. Literatürde mevcutta ve güncel olarak AKBÖ değişimi, YYS sıcaklığı ve sınıflandırma tekniklerine yönelik çok sayıda araştırma bulunmaktadır. Fakat bu araştırmaların konuyu açıklama gücü çalışma alanının ele alınmaması, farklı indeksler ve teknikler kullanılarak analiz yapılmaması ve sosyoekonomik nedenler-AKBÖ-YYS ilişkisinin irdelenmemesinden dolayı eksik kalmaktadır ve literatür çoklu dinamiklerin incelenmesini göz ardı etmektedir. İlgili açığı kapatmak amacıyla, bu çalışma RO ve NTS sınıflandırma tekniklerini ve YYS_{ArcGIS} ve YYS_{GEE} sıcaklık arasındaki ilişkiyi farklı dinamiklerde kullanarak literatürdeki hakim yaklaşımlardan farklı bir argüman ortaya koymaktadır. Bu bağlamda 2016 ve 2020 yıllarında 3 sezon periyodundaki değişimler ilçe bazında uydu görüntülerinden yararlanılarak incelenmiş ve sınıflandırma doğruluğu Google Earth Pro programı ile sağlanmıştır. İki ayrı yıldaki 3 sezonun birleşimi ile oluşturulan ABA işleminin görüntüde bant kombinasyonlarındaki benzer verileri ayıklayarak anlamlılık düzeyi sağlamış olması ile en yüksek doğruluk sonucuna ulaştığı görülmüştür. Uydu görüntülerinde orjinal bantlardaki 2 adet sınıflandırma, 21 adet indeks ile sınıflandırma ve 410 homojen yer örnek noktasıyla yapılan doğruluk analizi sonucunda en yüksek sıcaklık ve en düşük sıcaklık sırasıyla;

- Kış sezonu 2016 yılı için O_{I2} (yüksek) ve O_{NTS} (düşük) sınıflandırma sonuçlarına ulaşılmıştır. 12.bandın etki ettiği tarihte çalışma bölgesindeki tahılların ilk

gelişme döneminde içeriğinde nem oranı fazla olduğundan ve kullanılan indeksin matematiğindeki B12'nin nem içeriğini ölçme (toprak ve bitki örtüsü için) ve B8'in bitki örtüsü tespitinde kullanılması gibi spesifik özellikleri ön plana çıkarmasından dolayı yüksek çıkmıştır. O_{NTS} sınıflandırmasında ise, belirlenen tarihte vejetasyonun nesne tanıtımında eksik kalması ile NTS tekniğinde segmentasyonun tam gerçekleşmediği anlaşılmıştır.

- Bahar sezonu 2016 yılı için O_{RO} sınıflandırması, orjinal on bandın içeriğinin ve kombinasyonunun değiştirilmemesi ve incelenen tarihteki arazi vejetasyonunun toprak yüzeyini %70-80 olana kadar örtmüş olması sebebiyle hem kentsel hem tarımsal alanlar için daha rahat ayırt edicilik sağladığı anlaşılmıştır. Yine aynı sezonda O_{I11}BO₇ sınıflandırmasının düşük orana sahip olması, incelenen tarihteki vejetasyonun (geneli ilk gelişme) B5 ve B7'nin orjinal bant kombinasyonundan çıkarılması sebebiyle algılanmasının zayıflamasına ve B11'in geniş bant aralığına sahip olmasından kaynaklı olarak algılamada güçlük çekmesinden dolayı olduğu görülmüştür.

- Yaz sezonunda 2016 yılı yine O_{RO} sınıflandırması bahar sezonundaki nedenlerle daha yüksek sonuç vermiştir. Fakat O_{I8a} indeksinin düşük doğruluğa sahip olması çalışma alanındaki bitki örtüsünün örtü derecesinin az olmasından kaynaklı tarımsal alanların sınıflandırma işleminde seçilememesinden dolayı olacağı düşünülmüştür.

- Kış sezonu 2020 yılı O_{I5} sınıflandırması, tarımsal alanların incelenen tarihte araziye etki etmemesi fakat kentsel ve diğer alanların sınıflandırmada belirgin özellikler göstermesi ve orjinal on bant üzerinde matematiksel işlemler ile etkileşimi olmaması sebebiyle daha yüksek sonuç vermiştir. O_{I11}BO₇ indeksinin içeriğindeki bantlar sebebiyle nem oranı ve bitki örtüsü içeriğinin ölçülebilirliği tarımsal alanlar ile eşleşme sağlamadığı görülmüştür.

- Bahar sezonu için 2020 yılında O_{RO} indeksinin etkisinin fazla olması, 2016 bahar sezonu ile aynı etkiden kaynaklandığı anlaşılmıştır. Bunun yanısıra O_{I12}BO₇ indeksinin düşük sonuçlanması, bitki örtüsü incelemesi için gerekli olan B5 ve B7'nin orjinal bantlardan çıkarılmış olması ve B12 ile oluşan kombinasyonda algılama zayıflığı ile açıklanmaktadır.

- Yaz sezonu için 2020 yılındaki sınıflandırmada O_{I6} indeksi ve orjinal bantların bitki örtüsü ayırıcılığı için kırmızı kenar bant ile etkileşim sağlamış olması ve dolayısıyla istenilen mevsimde ön plana çıkarıcılığın artması ile daha uygun olduğu

anlaşılmasıdır. O₁₁BO₇ için ise, arazideki vejetasyonda nem oranının ölçülerek etki edeceği ürünler olmadığından ve yine orjinal bantlardan B5 ve B7'nin eksiltilmesinin olumsuz etkilediği anlaşılmıştır.

En yüksek doğruluğun ortaya çıktığı kombinasyonun araştırıldığı bu çalışmada, 2016 ve 2020 yıllarındaki ortaya çıkan değişimlerin çeşitli sosyoekonomik ve teknik sebeplerden kaynaklandığı anlaşılmaktadır. Buna bağlı olarak;

- Kış görüntülerinde 2016 ve 2020 yıllarında en yüksek doğruluk çıkan kombinasyonlara göre elde edilen değişimlerde, yol kenarındaki zeytin alanlarının istimlakı sonucu yapay yeşil alanlar oluştuğu ve bu nedenle Z sınıfından T sınıfına dönüşüm yaşandığı, Gemlik-Bursa Kuzey Kavşağı'nın yapım aşaması devam etmesi sebebiyle uydu verisinin sınıflamasındaki teknik hatalar Y alanlarının M sınıfı ile karıştırıldığını göstermiştir.
- Bahar görüntülerinden elde edilen gözlemlere bakıldığında, O alanlarından T alanlarına dönüşüm yaşandığı, tarım alanlarının yanında kırsal yerleşimlerin oluşması ile Y ve Z sınıflarının artış yaşadığı düşünülmektedir. Aynı zamanda 12 Mart 2017 tarihinde hizmete giren Gemlik-Bursa Kuzey Kavşağı'nın da Y alanlarının değişimini etkilediği görülmüştür.
- Yaz mevsimi bazında M sınıfındaki vejetasyonun büyüyen bitki boyutuyla birlikte O sınıfı ile karıştığı sonucu elde edilmiştir.

YYs hesaplamasında kullanılan iki farklı yöntem ile kodların kullanıldığı sıcaklık değerlerinin manuel olarak ortaya çıkan değerlerden kısmi daha düşük (~0.90 °C) seviyede olduğu görülmüştür. Bu sıcaklık farkının, GEE platformunda yazılım algoritmasına göre yapılan işlemlerde, kodlardaki ifadelerin birbiriyle etkileşime girmesiyle gerçekleştiği anlaşılmıştır. YYs hesaplamak için belirlenen meteoroloji istasyonlarının konumları ve çevresinde oluşturulan tampon bölgede oluşan AKBÖ değişiklikleri ve sıcaklık arasındaki ilişki değişkenliklerle ortaya çıkmıştır. 2016 yılında gerçekleşen iklim olayları neticesinde ortalama sıcaklıklar çalışma alanında artışlara sebep olmuştur ve mevsim normallerinin üstünde seyreden bir hava sıcaklığı görülmüştür. Bunun yanısıra 2016 ve 2020 yılları arasında çalışma alanında 2 defa sıcak hava dalgası görülmüştür.

Sıcaklıklar ile AKBÖ ilişkisinde, 2016 ve 2020 yılları kış sezonunda;

- Armutlu bölgesinde kıyı şeridinde daha yakın olan T ve Z alanlarında yüksek sıcaklık görüldüğü, O piksellerinden Y piksellerine bir dönüşümün olduğu ve yeni oluşan Y piksellerinin sıcaklığının arttığı görülmüştür,
- Gemlik bölgesinde mevsim normallerinden kaynaklı en düşük ve en yüksek sıcaklıklar sırasıyla O ve Y alanlarında görülmüştür,
- Osmangazi bölgesinde T alanlarından O alanlarına değişim görülmüş ve piksel bazındaki değişimden kaynaklı en düşük sıcaklığın O ve en yüksek sıcaklığın Y alanlarında olduğu anlaşılmıştır,
- Mudanya bölgesinde M ve Y alanları düşük ve yüksek olarak elde edilmiş, 2016 kış sezonunda ülkede gelişen göç anlaşmasının, sonraki yıllarda Y alanında sıcaklık değerlerini artırdığı düşünülmektedir.

Bahar sezonunda 2016-2020 en düşük ve en yüksek sıcaklıklar sırasıyla,

- Armutlu bölgesinde M ve Y sınıflarında olduğu, kıyı şeridinde T ve Z sınıflarının Y sınıfları üzerinde güçlü bir baskı kurarak sıcaklığı azalttığı anlaşılmıştır,
- Gemlik bölgesinde en düşük sıcaklık M ve en yüksek sıcaklık Y sınıflarında olduğu, Armutlu bölgesi ile aynı sıcaklık tepkilerini verdiği görülmüştür,
- Osmangazi bölgesinde en düşük sıcaklığın S ve en yüksek sıcaklığın geçirimsiz yapılarla içiçe olmasından kaynaklı Z sınıfında olduğu düşünülmektedir,
- Mudanya bölgesinde düşük ve yüksek sıcaklıkların sırasıyla O ve Y sınıflarında olduğu görülmüştür. T ve Z alanlarının artmasıyla bitki örtüsü etkisinden O sınıfındaki sıcaklıkların azaldığı anlaşılmıştır. Bahar sezonu için kıyı bölgelerindeki Y alanlarındaki sıcaklık artışının, pandemiden kaynaklı bölgesel taşınmazların artışı olduğu düşünülmektedir.

Yaz sezonunda 2016-2020 en düşük ve en yüksek sıcaklıklar sırasıyla,

- Armutlu bölgesinde mevsim normallerinde O ve Y sınıflarında olduğu, T alanlarından Y alanına dönüşün olduğu düşünülmektedir,
- Gemlik bölgesinde düşük ve yüksek sıcaklıkların sırasıyla O ve Y sınıflarında olduğu, T sınıflarındaki piksellerin Y sınıflarına dönüşmesiyle sıcaklığın arttığı düşünülmekte ve Armutlu bölgesiyle aynı tepkiyi verdiği görülmektedir,
- Osmangazi bölgesinde en düşük sıcaklığın O ve en yüksek sıcaklığın Z sınıflarında olduğu görülmüştür, zeytin sınıfının yüksek sıcaklıkta seyrediyor olmasının geçirimsiz yapılar ile içiçe olduğundan kaynaklandığı düşünülmektedir,
- Mudanya bölgesinde düşük sıcaklığın O ve yüksek sıcaklığın Y sınıfında görüldüğü, T alanlarından Y alanlarına değişim olduğu anlaşılmıştır. Hem Gemlik – Bursa Kuzey Kavşağı hem TOGG fabrikasının inşaatının başlamasıyla geçirimsiz yüzeylerin arttığı ve bu bağlamda sıcaklıkta Y alanlarında artış görüldüğü düşünülmektedir.

Alanda Gemlik-Bursa Kuzey Kavşağı ve TOGG gibi yatırım kararları ve uygulamaları ile beraber yapılaşmaların hızlanması sonucu geçirimsiz yüzeyler ve buna bağlı olarak nüfus değerleri artmıştır. Ayrıca Dünya'yı etkisi altına alan pandemi sonrasında iki ayrı yılda gerçekleşen kur değişimleri ile TL değerindeki iniş-çıkış formu birçok alanı etkilemiştir. Doların artmasından dolayı inşaat ve gayrimenkul sektörü ülke bazında düşüşe girmiş olsa bile, pandemiden ve büyük yatırımlardan kaynaklı kıyı bölgelerinde inşaat ve gayrimenkul sektöründe gelişimin arttığı anlaşılmıştır.

Ülke genelinde GSYH içinde inşaat ve gayrimenkul sektörü kurdaki artışa bağlı düşüşe geçerken, tarım/ormancılık/balıkçılık alanı GSYH içinde artışta görünmekte ve bu alanların sınıflandırmasındaki kısmi dönüşümün sebebinin de o alanlara maddi yatırım yapılmış olduğu düşünülmüştür. 2020 yılında oluşan pandemi sürecinin olumsuz etkilerinin azaltılması için, sağlık alanının GSYH içindeki payı artırılmış, genişletilen geçirimsiz yüzeylerdeki değişim çalışma alanındaki geçirimsiz yüzeyleri az da olsa etkilemiştir. GSYH

verilerinin doğrudan çalışma alanı ile ilgisi olmamakla birlikte, dolaylı yoldan bir etkisinin olduğu düşünülmektedir.

Bu çalışma ile Güney-Doğu Marmara'da bulunan zeytin ve yerleşim alanlarının yıllar içindeki değişiminin nüfus artışı ve çeşitli yatırım kararları ile oluştuğu sonucuna varılmıştır. Alansal değişimlerin doğruluk analizi işlemlerinin sonucunda oluşan çıktılara bakıldığında, doğrudan orjinal bantlardan oluşturulan kompozitlerde, Bant 12 ve Bant 5 ile oluşturulan indekslerde Rastgele Orman sınıflandırma tekniğinin daha doğru sonuçlar verdiği fakat fazla verilerden ayıklanmış Ana Bileşenler Analizi görüntüsünün tüm sınıflandırmalara oranla daha doğru olduğu anlaşılmıştır. AKBÖ değişimlerinin YYS_{ArcGIS} ile ilişkisinde, tüm mevsimlerde bitki örtüsünün varlığının sıcaklığı düşürdüğü, bazı alanlarda Y sınıfındaki sıcaklık düşüşünün kıyı bölgelerinde bitki örtüsü ile bir arada bulunmasından kaynaklandığı anlaşılmıştır.

Bu değişimlerin ve dağılımın belirlenmesinde uydu görüntüleri, nüfus ve meteoroloji verileri kullanılarak kentsel planlamaların dikkate alınması, sanayi bölgelerinin planlanması açısından oluşan ve oluşacak durumların tespiti için yapılacak çalışmaların kolay ve ekonomik olarak oluşturulması için altlık olacaktır. Söz konusu çalışmaların daha yüksek çözünürlüklü uydu görüntüleri ve detaylı demografik verilerle birlikte kullanılması ile daha detaylı bilgilere ulaşılması mümkündür.

KAYNAKÇA

- Abbas, Z., & Jaber, D. H. S. (2020). Accuracy Assessment Of Supervised Classification Methods For Extraction Land Use Maps Using Remote Sensing And GIS Techniques. *The Fourth Postgraduate Engineering Conference*. <https://iopscience.iop.org/article/10.1088/1757-899X/745/1/012166/pdf>
- Abdu, H. A. (2019). Classification Accuracy and Trend Assessments of Land Cover-Land Use Changes from Principal Components of Land Satellite Images. *International Journal of Remote Sensing*, 40, 1275–1300. <https://doi.org/10.1080/01431161.2018.1524587>
- Adam, E., Mutanga, O., Odindi, J., & Abdel-Rahman, E. M. (2014). Land-Use/Cover Classification in a Heterogeneous Coastal Landscape Using Rapideye Imagery: Evaluating The Performance of Random Forest and Support Vector Machines Classifiers. *International Journal of Remote Sensing*, 35(10). <https://doi.org/10.1080/01431161.2014.903435>
- Aggarwal, S. (2004). Principles of Remote Sensing. *Satellite Remote Sensing and GIS Applications in Agricultural Meteorology*, 23(2), 23–38.
- Agugliaro, F. M., Xin, J., Yang, J., Sun, D., Han, T., Song, C., & Shi, Z. (2022). Seasonal Differences in Land Surface Temperature under Different Land Use/Land Cover Types from the Perspective of Different Climate Zones. *Land*, 11(1122), 1–17. <https://doi.org/10.3390/land11081122>
- Ahamed, T., Tian, L., Zhang, Y., & Ting, K. C. (2011). A Review of Remote Sensing Methods for Biomass Feedstock Production. In *Biomass and Bioenergy* (Vol. 35, Issue 7). <https://doi.org/10.1016/j.biombioe.2011.02.028>
- Alshari, E. A., & Gawali, B. W. (2021). Development of Classification System for LULC Using Remote Sensing And GIS. *Global Transitions Proceedings*, 2(1), 8–17. <https://doi.org/10.1016/J.GLTP.2021.01.002>
- Anand, V., & Oinam, B. (2020). Future Land Use Land Cover Prediction with Special Emphasis on Urbanization and Wetlands. *Remote Sensing Letters*, 11(3). <https://doi.org/10.1080/2150704X.2019.1704304>

- Asci, E., Inalpulat, M., & Genc, L. (2021). Identification of Residential Development Impacts on Agricultural Lands Using Landsat Imageries: Case Study Of Bursa, Nilufer (1990-2020) . *III. Balkan Agricultural Congress (AGRIBALKAN)*, 19. https://www.researchgate.net/publication/356987240_Identification_of_Residential_Development_Impacts_on_Agricultural_Lands_Using_Landsat_Imageries_Case_Study_Of_Bursa_Nilufer_1990-2020
- Baeza, S., & Paruelo, J. M. (2020). Land Use/Land Cover Change (2000-2014) in The Rio De La Plata Grasslands: An Analysis Based on MODIS NDVI Time Series. *Remote Sensing*, 12(3). <https://doi.org/10.3390/rs12030381>
- Barnes, E. M., Clarke, T. R., Richards, S. E., Colaizzi, P. D., Haberland, J., Kostrzewski, M., Waller, P., Choi C., R. E., Thompson, T., Lascano, R. J., Li, H., & Moran, M. S. (2000). Coincident Detection of Crop Water Stress, Nitrogen Status and Canopy Density Using Ground Based Multispectral Data. *Proc. 5th Int. Conf. Precis Agric.*
- Batunacun, Nendel, C., Hu, Y., & Lakes, T. (2018). Land-Use Changea and Land Degradation on The Mongolian Plateau from 1975 To 2015—A Case Study From Xilingol, China. *Land Degradation and Development*, 29(6), 1595–1606. <https://doi.org/10.1002/LDR.2948>
- Baysal, D. (2006). *Eskişehir Kentsel Yerleşim Alanının Farklı Yıllara Ait Fiziksel Değişiminin Uzaktan Algılama Yöntemi İle Değerlendirilmesi*. Anadolu Üniversitesi.
- Blaschke, T. (2010a). ISPRS Journal of Photogrammetry and Remote Sensing Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1). <https://doi.org/10.1016/j.isprsjprs.2009.06.004>
- Blaschke, T. (2010b). Object Based Image Analysis for Remote Sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*. <https://doi.org/10.1016/j.isprsjprs.2009.06.004>
- Breiman, L. (2001). Random Forests. *Machine Learning*. <https://doi.org/10.1023/A:1010933404324>
- Cavur, M., Duzgun, H. S., Kemec, S., & Demirkan, D. C. (2019). Land Use and Land Cover Classification of Sentinel 2-A: St Petersburg Case Study. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS*

Archives, 42(1/W2). <https://doi.org/10.5194/isprs-archives-XLII-1-W2-13-2019>

- Chan, J. C. W., & Paelinckx, D. (2008). Evaluation of Random Forest and Adaboost tree-based ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery. *Remote Sensing of Environment*, 112(6), 2999–3011. <https://doi.org/10.1016/J.RSE.2008.02.011>
- Chandra Pandey, P., Koutsias, N., Petropoulos, G. P., Srivastava, P. K., & Ben Dor, E. (2019). Land Use/Land Cover in View of Earth Observation: Data Sources, Input Dimensions, and Classifiers-A Review of The State of The Art. *Geocarto International*, 36, 957–988. <https://doi.org/10.1080/10106049.2019.1629647>
- Chaudhry, S., Attri, P., & Sharma, S. (2015). Approaches for LULC Change Detection-A Review. *International Journal of Current Engineering and Technology*, 5(5), 12. <http://inpressco.com/category/ijcet>
- Chehata, N., Guo, L., & Forests, R. (2009). Airborne Lidar Feature Selection for Urban Classification Using Random Forests. *Lazer Scanning*, XXXVIII(3/W8).
- Colkesen, I., Yusuf Ozturk, M., Kavzoglu, T., & Gunes Sefercik, U. (2021). *Determination Of Sea Surface Mucilage Formations Using Multitemporal Sentinel-2 Imagery* <https://www.researchgate.net/publication/356634268>
- Dang, A. T. N., Kumar, L., Reid, M., & Nguyen, H. (2021). Remote Sensing Approach for Monitoring Coastal Wetland in the Mekong Delta, Vietnam: Change Trends and Their Driving Forces. *Remote Sensing*, 13(3359). <https://doi.org/10.3390/rs13173359>
- Dekolo, S., Oduwaye, L., & Nwokoro, I. (2015). Urban Sprawl and Loss of Agricultural Land in Peri-Urban Areas of Lagos. *Regional Statistics*. <https://doi.org/10.15196/RS05202>
- Dengiz, O., & Demirağ Turan, İ. (2014). Uzaktan Algılama ve Coğrafi Bilgi Sistem Teknikleri Kullanılarak Arazi Örtüsü / Arazi Kullanımı Zamansal Değişimin Belirlenmesi: Samsun Merkez Gölçesi Örneği (1984-2011). *Türkiye Tarımsal Araştırmalar Dergisi*, 1(1), 78–90. <http://dergi.siirt.edu.tr/index.php/ziraat>
- Dewidar, K. M. (2010). Detection of Land Use/Land Cover Changes for The Northern Part of The Nile Delta (Burullus Region), Egypt. *International Journal of Remote*

Sensing, 25(20), 4079–4089. <https://doi.org/10.1080/01431160410001688312>

- Dharani, M., & Sreenivasulu, G. (2021). Land Use and Land Cover Change Detection by Using Principal Component Analysis and Morphological Operations in Remote Sensing Applications. *International Journal of Computers and Applications*, 43(5). <https://doi.org/10.1080/1206212X.2019.1578068>
- Di Zhang, Hao Wang, Xu Wang, & Zhi Lü. (2019). Accuracy Assessment of The Global Forest Watch Tree Cover 2000 in China. *Int J Appl Earth Obs Geoinformation*. <https://reader.elsevier.com/reader/sd/pii/S0303243419306452?token=4D6ACD39DC5A2CFE278AA34409D3EFB7A69BBA7ABE6AC65CC52ACC731EB37C5A0B41EE079125265C385D17EC9449CB08&originRegion=eu-west-1&originCreation=20210518211007>
- Du, C., Ren, H., Qin, Q., Meng, J., Zhao, S., Li, Z.-L., Sobrino, J. A., Song, X., & Thenkabail, P. S. (2015). A Practical Split-Window Algorithm for Estimating Land Surface Temperature from Landsat 8 Data. *Remote Sensing*, 7, 647–665. <https://doi.org/10.3390/rs70100647>
- Feng, Q., Liu, J., Gong, J., Zarco-Tejada, P. J., Lucieer, A., Nichol, J., & Thenkabail, P. S. (2015). UAV Remote Sensing for Urban Vegetation Mapping Using Random Forest and Texture Analysis. *Remote Sensing*, 7, 1074–1094. <https://doi.org/10.3390/rs70101074>
- Foody, G. M. (2009). Sample Size Determination for Image Classification Accuracy Assessment and Comparison. *International Journal of Remote Sensing*, 30, 5273–5291. <https://doi.org/10.1080/01431160903130937>
- Genc, L., İnalpulat, M., & Ascı, E. (2021). Investigating Spectral Characteristics of Mucilage through Hyperspectral Remote Sensing Methods. *III. International Agricultural, Biological & Life Science Conference*, 394–399. https://www.researchgate.net/profile/Mohamed-Milad-7/publication/364316523_Transfer_learning_based_deep_networks_for_the_covid-19_diagnosis/links/6356a50c8d4484154a2d484f/Transfer-learning-based-deep-networks-for-the-covid-19-diagnosis.pdf#page=396
- Genc, L., & Smith, S. (2005). Assessment Of Principal Component Analysis (Pca) for

- Moderate and High Resolution Satellite Data. *Resources And Conservation*, 6(2).
- Ghimire, B., Rogan, J., & Miller, J. (2010). Contextual Land-Cover Classification: Incorporating Spatial Dependence in Land-Cover Classification Models Using Random Forests and The Getis Statistic. *Remote Sensing Letters*, 1(1), 45–54. <https://doi.org/10.1080/01431160903252327>
- Gitelson, A. A., Kaufman, Y. J., Stark, R., & Rundquist, D. (2002). Novel Algorithms For Remote Estimation Of Vegetation Fraction. *Remote Sensing of Environment*, 80(1). [https://doi.org/10.1016/S0034-4257\(01\)00289-9](https://doi.org/10.1016/S0034-4257(01)00289-9)
- Goodin, D. G., Anibas, K. L., & Bezymennyi, M. (2015). Mapping Land Cover and Land Use from Object-Based Classification: An Example From A Complex Agricultural Landscape. *International Journal of Remote Sensing*, 36(18), 4702–4723. <https://doi.org/10.1080/01431161.2015.1088674>
- Guan, H., Yu, J., Li, J., & Luo, L. (2012). Random Forests-Based Feature Selection for Land-Use Classification Using Lidar Data and Orthoimagery. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XXXIX-B7. <https://doi.org/10.5194/isprsarchives-xxxix-b7-203-2012>
- Hasan, S., Shi, W., Zhu, X., & Abbas, S. (2019). Monitoring of Land Use/Land Cover and Socioeconomic Changes in South China over the Last Three Decades Using Landsat and Nighttime Light Data. *Remote Sensing*, 11(1658). <https://doi.org/10.3390/rs11141658>
- Herrmann, I., Pimstein, A., Karnieli, A., Cohen, Y., Alchanatis, V., & Bonfil, D. J. (2011). LAI Assessment of Wheat and Potato Crops by Venus and Sentinel-2 Bands. *Remote Sensing of Environment*, 115(8). <https://doi.org/10.1016/j.rse.2011.04.018>
- Htitiou, A., Boudhar, A., Lebrini, Y., Hadria, R., Lionboui, H., Elmansouri, L., Tychon, B., & Benabdelouahab, T. (1976). The Performance of Random Forest Classification Based on Phenological Metrics Derived from Sentinel-2 and Landsat 8 to Map Crop Cover in an Irrigated Semi-arid Region. *Remote Sensing in Earth Systems Sciences*, 2, 208–224. <https://doi.org/10.1007/s41976-019-00023-9>
- Hu, B., Xu, Y., Huang, X., Cheng, Q., Ding, Q., Bai, L., Li, Y., & Chowdhury, P. K. R. (2021). Improving Urban Land Cover Classification with Combined Use of Sentinel-

2 and Sentinel-1 Imagery Academic Editors: Tilottama Ghosh. *ISPRS Int. J. Geo-Inf*, 10, 533. <https://doi.org/10.3390/ijgi10080533>

Hussein, K., Alkaabi, K., Ghebreyesus, D., Liaqat, M. U., & Sharif, H. O. (2020). Land Use/Land Cover Change Along the Eastern Coast of the UAE and Its Impact on Flooding Risk. *Geomatics, Natural Hazards and Risk*, 11(1). <https://doi.org/10.1080/19475705.2019.1707718>

Inalpulat, M., & Genc, L. (2021). Quantification of LULC Changes and Urbanization Effects on Agriculture Using Historical Landsat Data in North-West Anatolia, Turkey. *Polish Journal of Environmental Studies*. <https://doi.org/10.15244/pjoes/130953>

Jamali, A., & Abdul Rahman, A. (2019). Evaluation Of Advanced Data Mining Algorithms in Land Use/Land Cover Mapping. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 42(4/W16). <https://doi.org/10.5194/isprs-archives-XLII-4-W16-283-2019>

Jiménez-Muñoz, J. C., Sobrino, J. A., Gillespie, A., Sabol, D., & Gustafson, W. T. (2006). Improved Land Surface Emissivities Over Agricultural Areas Using ASTER NDVI. *Remote Sensing of Environment*, 103(4), 474–487. <https://doi.org/10.1016/J.RSE.2006.04.012>

Jiménez-Muñoz, J. C., Sobrino, J. A., Plaza, A., Guanter, L., Moreno, J., & Martínez, P. (2009). Comparison Between Fractional Vegetation Cover Retrievals from Vegetation Indices and Spectral Mixture Analysis: Case Study of PROBA/CHRIS Data Over an Agricultural Area. *Sensors*, 9, 768–793. <https://doi.org/10.3390/s90200768>

Jog, S., & Dixit, M. (2016). Supervised Classification Of Satellite Images. *Conference on Advances in Signal Processing, CASP 2016*. <https://doi.org/10.1109/CASP.2016.7746144>

Johnsson, K. (1994). Segment-Based Land-Use Classification from SPOT Satellite Data. *Photogrammetric Engineering and Remote Sensing*.

Joshi, R. R., Warthe, M., Dwivedi, S., Vijay, R., & Chakrabarti, T. (2011). Monitoring Changes in Land Use Land Cover Of Yamuna Riverbed in Delhi: A Multi-Temporal Analysis. *International Journal of Remote Sensing*, 32(24), 9547–9558.

<https://doi.org/10.1080/01431161.2011.565377>

- Kavzoglu, T., Yilmaz, E. O., Colkesen, I., Gunes Sefercik, U., & Gazioglu, C. (2023). Detection And Monitoring Of Mucilage Formations Using Pixel-Based Convolutional Neural Networks: The Case Study Of Izmit Gulf, Turkey. *Istanbul University Press* (p. 233). Istanbul University Press. <https://doi.org/10.26650/B/LS32.2023.003.11>
- Kindu, M., Schneider, T., Teketay, D., & Knoke, T. (2013). Land Use/Land Cover Change Analysis Using Object-Based Classification Approach in Munessa-Shashemene Landscape Of The Ethiopian Highlands. *Remote Sensing*, 5(5), 2411–2435. <https://doi.org/10.3390/rs5052411>
- Kupidura, P. (2019). The Comparison of Different Methods of Texture Analysis for Their Efficacy for Land Use Classification in Satellite Imagery. *Remote Sensing*. <https://doi.org/10.3390/rs11101233>
- Latif, M. S. (2014). Land Surface Temperature Retrieval of Landsat-8 Data Using Split Window Algorithm- A Case Study of Ranchi District. *Internal Journal of Engineering Development and Research*, 2(4).
- Lawrence, R. L., Wood, S. D., & Sheley, R. L. (2006). Mapping Invasive Plants Using Hyperspectral Imagery and Breiman Cutler Classifications. *Remote Sensing of Environment*, 100(3), 356–362. <https://doi.org/10.1016/J.RSE.2005.10.014>
- Le Maire, G., François, C., & Dufrêne, E. (2004). Towards Universal Broad Leaf Chlorophyll Indices Using PROSPECT Simulated Database and Hyperspectral Reflectance Measurements. *Remote Sensing of Environment*, 89(1). <https://doi.org/10.1016/j.rse.2003.09.004>
- Li, Q., Wang, C., Zhang, B., & Lu, L. (2015). Object-Based Crop Classification with Landsat-MODIS Enhanced Time-Series Data. *Remote Sensing*, 7(12), 16091–16107. <https://doi.org/10.3390/rs71215820>
- Li, X., Wang, Y., Li, J., & Lei, B. (2016). Physical and Socioeconomic Driving Forces of Land-Use and Land-Cover Changes: A Case Study of Wuhan City, China. *Discrete Dynamics in Nature and Society*. <https://doi.org/10.1155/2016/8061069>
- Lin, Y., & Jeon, Y. (2006). Random Forests and Adaptive Nearest Neighbors. *Journal of the*

- American Statistical Association*, 101(474).
<https://doi.org/10.1198/016214505000001230>
- Liu, D., & Xia, F. (2010a). Assessing Object-Based Classification: Advantages and Limitations. *Remote Sensing Letters*, 1(4), 187–194.
<https://doi.org/10.1080/01431161003743173>
- Liu, D., & Xia, F. (2010b). Assessing Object-Based Classification: Advantages and Limitations. *Remote Sensing Letters*, 1(4), 187–194.
<https://doi.org/10.1080/01431161003743173>
- Liu, Y., & Chen, Y. (2021). Study On the Impact of Coastal Land Use Change on Environment Based on Remote Sensing Data. *E3S Web of Conferences*.
<https://doi.org/10.1051/e3sconf/202126701061>
- Lourenço, P., Teodoro, A. C., Gonçalves, J. A., Honrado, J. P., Cunha, M., & Sillero, N. (2021). Assessing The Performance Of Different OBIA Software Approaches For Mapping Invasive Alien Plants Along Roads with Remote Sensing Data. *International Journal of Applied Earth Observation and Geoinformation*, 95, 102263. <https://doi.org/10.1016/j.jag.2020.102263>
- Magidi, J., Nhamo, L., Mpandeli, S., & Mabhaudhi, T. (2021). Application Of The Random Forest Classifier to Map Irrigated Areas Using Google Earth Engine. *Remote Sensing*. <https://doi.org/10.3390/rs13050876>
- Main, R., Cho, M. A., Mathieu, R., O’Kennedy, M. M., Ramoelo, A., & Koch, S. (2011). An Investigation Into Robust Spectral Indices For Leaf Chlorophyll Estimation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(6).
<https://doi.org/10.1016/j.isprsjprs.2011.08.001>
- Mallupattu, P. K., & Sreenivasula Reddy, J. R. (2013). Analysis of Land Use/Land Cover Changes Using Remote Sensing Data and GIS at an Urban Area, Tirupati, India. *The Scientific World Journal*. <https://doi.org/10.1155/2013/268623>
- Manisha B. Patil, Chitra G. Desai, & Bhavana N. Umrikar. (2012). Image Classification Tool for Land Use / Land Cover Analysis: A Comparative Study Of Maximum Likelihood and Minimum Distance Method. *International Journal of Geology, Earth*

and *Environmental Sciences*.
https://www.researchgate.net/publication/281118125_IMAGE_CLASSIFICATION_TOOL_FOR_LAND_USE_LAND_COVER_ANALYSIS_A_COMPARATIVE_STUDY_OF_MAXIMUM_LIKELIHOOD_AND_MINIMUM_DISTANCE_METHOD

- Meinel, G., & Neubert, M. (2004). A Comparison of Segmentation Programs for High Resolution Remote Sensing Data. *XXth ISPRS Congress Technical Commission IV*, 6. www.dpi.com.
- Mishra, P. K., Rai, A., & Rai, S. C. (2020). Land Use and Land Cover Change Detection Using Geospatial Techniques in The Sikkim Himalaya, India. *Egyptian Journal of Remote Sensing and Space Science*, 23(2). <https://doi.org/10.1016/j.ejrs.2019.02.001>
- Munyati, C. (2004). Use of Principal Component Analysis (PCA) of Remote Sensing Images in Wetland Change Detection on The Kafue Flats, Zambia. *Geocarto International*, 19(3). <https://doi.org/10.1080/10106040408542313>
- Nguyen, L. H., Joshi, D. R., Clay, D. E., & Henebry, G. M. (2020). Characterizing Land Cover/Land Use From Multiple Years of Landsat and MODIS Time Series: A Novel Approach Using Land Surface Phenology Modeling and Random Forest Classifier. *Remote Sensing of Environment*, 238. <https://doi.org/10.1016/J.RSE.2018.12.016>
- Njoku, E. A., & Tenenbaum, D. E. (2022). Quantitative Assessment of the Relationship Between Land Use/Land Cover (LULC), Topographic Elevation and Land Surface Temperature (LST) in Ilorin, Nigeria. *Remote Sensing Applications: Society and Environment*, 27(100780). <https://doi.org/10.1016/J.RSASE.2022.100780>
- Norman, M., Mohd Shahar, H., Mohamad, Z., Rahim, A., Amri Mohd, F., & Zulhaidi Mohd Shafri, H. (2021). Urban Building Detection Using Object-Based Image Analysis (OBIA) and Machine Learning (ML) Algorithms. *IOP Conference Series: Earth and Environmental Science*, 620, 012010. <https://doi.org/10.1088/1755-1315/620/1/012010>
- Ok, A. O., Akar, O., & Gungor, O. (2017). European Journal of Remote Sensing Evaluation of Random Forest Method for Agricultural Crop Classification. *European Journal of Remote Sensing*, 45(1), 421–432. <https://doi.org/10.5721/EuJRS20124535>

- Ouyang, Z. (2015). *Object-Based Classification & eCognition*.
- Pal, M. (2005). Random Forest Classifier for Remote Sensing Classification. *International Journal of Remote Sensing*, 26(1), 217–222. <https://doi.org/10.1080/01431160412331269698>
- Panigrahy, R. K., Panigrahy, S., & Ray, S. S. (2009). Study on the Utility of IRS-P6 AWiFS SWIR Band for Crop Discrimination and Classification. In *J. Indian Soc. Remote Sens* (Vol. 37).
- Penuelas, J., Pinol, J., Ogaya, R., Filella, I., Peña Uelas, J., Pin, J., & Ol, Ä. (1997). Estimation of Plant Water Concentration By the Reflectance Water Index WI (R900/R970). *International Journal of Remote Sensing*, 18(13), 2869–2875. <https://doi.org/10.1080/014311697217396>
- Perumal, K., & Bhaskaran, R. (2010). Supervised Classification Performance of Multispectral Images. *Journal of Computing*, 2(2).
- Petropoulos, G. P., Vadrevu, K. P., & Kalaitzidis, C. (2013). Spectral Angle Mapper And Object-Based Classification Combined with Hyperspectral Remote Sensing Imagery for Obtaining Land Use/Cover Mapping in a Mediterranean Region. *Geocarto International*. <https://doi.org/10.1080/10106049.2012.668950>
- Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V. R., Murayama, Y., & Ranagalage, M. (2020). Sentinel-2 Data for Land Cover/Use Mapping: A Review. *Remote Sensing*, 12(2291). <https://doi.org/10.3390/rs12142291>
- Qu, A., Chen, Z., Li, M., Zhi, J., Wang, H., & Mutanga, O. (2021). Accuracy Improvements to Pixel-Based and Object-Based LULC Classification with Auxiliary Datasets from Google Earth Engine. *Remote Sensing*, 13, 453. <https://doi.org/10.3390/rs13030453>
- Radoux, J., Bogaert, P., Fasbender, D., & Defourny, P. (2010). Thematic Accuracy Assessment of Geographic Object-Based Image Classification. *International Journal of Geographical Information Science*, 25(6), 895–911. <https://doi.org/10.1080/13658816.2010.498378>
- Richards, J. A., & Jia, X. (2006). Remote sensing digital image analysis: An introduction. In *Remote Sensing Digital Image Analysis: An Introduction*. Springer Berlin Heidelberg. <https://doi.org/10.1007/3-540-29711-1>

- Rodriguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M., & Rigol-Sanchez, J. P. (2012). An Assessment of the Effectiveness of A Random Forest Classifier for Land-Cover Classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67(1), 93–104. <https://doi.org/10.1016/J.ISPRSJPRS.2011.11.002>
- Rwanga, S. S., & Ndambuki, J. M. (2017). Accuracy Assessment of Land Use/Land Cover Classification Using Remote Sensing and GIS. *International Journal of Geosciences*, 08(04), 611–622. <https://doi.org/10.4236/ijg.2017.84033>
- Scornet, E. (2015). Random Forests And Kernel Methods. *IEEE Transactions on Information Theory*, 62(3).
- Sekertekin, A., Abdikan, S., & Murat Marangoz, A. (2018). The Acquisition of Impervious Surface Area from LANDSAT 8 Satellite Sensor Data Using Urban Indices: A Comparative Analysis. *Environmental Monitoring and Assessment*, 190, 381. <https://doi.org/10.1007/s10661-018-6767-3>
- Sobrino, J. A., & Raissouni, N. (2000). Toward Remote Sensing Methods for Land Cover Dynamic Monitoring: Application to Morocco. *International Journal of Remote Sensing*, 21(2), 353–366. <https://doi.org/10.1080/014311600210876>
- Stumpf, A., & Kerle, N. (2011). Object-Oriented Mapping of Landslides Using Random Forests. *Remote Sensing of Environment*, 115(10). <https://doi.org/10.1016/j.rse.2011.05.013>
- Sundarakumar, K., Harika, M., Aspiya Begum, S. K., Yamini, S., & Balakrishna, K. (2012). Land Use and Land Cover Change Detection and Urban Sprawl Analysis of Vijayawada City Using Multitemporal Landsat Data. *International Journal of Engineering Science and Technology*, 4(01).
- Tadese, M., Kumar, L., Koech, R., & Kogo, B. K. (2020). Mapping Of Land-Use/Land-Cover Changes and Its Dynamics in Awash River Basin Using Remote Sensing and GIS. *Remote Sensing Applications: Society and Environment*, 19. <https://doi.org/10.1016/j.rsase.2020.100352>
- Tesfaye, A. A., Berhan, •, & Awoke, G. (n.d.). Evaluation of the Saturation Property of Vegetation Indices Derived from Sentinel-2 In Mixed Crop-Forest Ecosystem. *Spatial Information Research*, 29. <https://doi.org/10.1007/s41324-020-00339-5>

- The European Space Agency. (t.y.). Sentinel-2, https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-2
- The European Space Agency. (t.y.). Sentinel-2 Mission Guide, <https://sentinel.esa.int/web/sentinel/missions/sentinel-2>
- Thonfeld, F., Steinbach, S., Muro, J., & Kirimi, F. (2020). Long-Term Land Use/Land Cover Change Assessment of The Kilombero Catchment in Tanzania Using Random Forest Classification and Robust Change Vector Analysis. *Remote Sensing*, 12(7). <https://doi.org/10.3390/rs12071057>
- Trimble. (2007). Ecognition® Developer 7 Reference Book. *Definiens AG, München*.
- Tucker, C. J. (1979). Red and Photographic Infrared Linear Combinations for Monitoring Vegetation. *REMOTE SENSING OF ENVIRONMENT*, 8, 127–150.
- Tucker, C. J. (1980). Remote Sensing of Leaf Water Content in the Near Infrared. *Remote Sensing of Environment*, 10(1), 23–32. [https://doi.org/10.1016/0034-4257\(80\)90096-6](https://doi.org/10.1016/0034-4257(80)90096-6)
- United States Geological Survey (USGS). (t.y.). Landsat - 8, <https://www.usgs.gov/landsat-missions/landsat-8>
- Venkata Dasu, M., Reddy, P. V. N., & Chandra Mohan Reddy, S. (2019). Classification Of Landsat-8 Imagery Based on PCA and NDVI Methods. *International Journal of Innovative Technology and Exploring Engineering*, 8(10). <https://doi.org/10.35940/ijitee.J9843.0881019>
- Wang, L., Sousa, W. P., & Gong, P. (2004). Integration of Object-Based And Pixel-Based Classification for Mapping Mangroves With Ikonos Imagery. *International Journal Of Remote Sensing*, 25(24). <https://doi.org/10.1080/014311602331291215>
- Welch, R., Francis, A., Nugraha, A. S., & Atmaja, D. M. (2021). Split-Windows Algorithm (Swa) Methods Using Fractional Vegetation Cover (Fvc) on Landsat 8 OLI/TIRS. *Earth and Environmental Science*, 683. <https://doi.org/10.1088/1755-1315/683/1/012107>
- Wong, M. S., Zhu, X., Abbas, S., Kwok, C. Y. T., & Wang, M. (2021). Optical Remote Sensing. In *Optical Remote Sensing* (pp. 315–344). <https://doi.org/10.1007/978-981->

- Wu, C., Niu, Z., Tang, Q., & Huang, W. (2008). Estimating Chlorophyll Content from Hyperspectral Vegetation Indices: Modeling and Validation. *Agricultural and Forest Meteorology*, 148(8–9). <https://doi.org/10.1016/j.agrformet.2008.03.005>
- Wu, K. Y., Ye, X. Y., Qi, Z. F., & Zhang, H. (2013). Impacts of Land Use/Land Cover Change and Socioeconomic Development on Regional Ecosystem Services: the Case of Fast-Growing Hangzhou Metropolitan Area, China. *Cities*, 31, 276–284. <https://doi.org/10.1016/J.CITIES.2012.08.003>
- Wu, Q., Li, H. qing, Wang, R. song, Paulussen, J., He, Y., Wang, M., Wang, B. hui, & Wang, Z. (2006). Monitoring and Predicting Land Use Change in Beijing Using Remote Sensing and GIS. *Landscape and Urban Planning*, 78(4). <https://doi.org/10.1016/j.landurbplan.2005.10.002>
- Wu, T., Luo, J., Gao, L., Sun, Y., Dong, W., Zhou, N., Liu, W., Hu, X., Xi, J., Wang, C., & Yang, Y. (2021). Geo-Object-Based Vegetation Mapping via Machine Learning Methods with an Intelligent Sample Collection Scheme: A Case Study of Taibai Mountain, China. *Remote Sensing*. <https://doi.org/10.3390/rs13020249>
- Xianju, L., Gang, C., Jingyi, L., Weitao, C., Xinwen, C., & Yiwei, L. (2017). Effects of RapidEye Imagery's Red-edge Band and Vegetation Indices on Land Cover Classification in an Arid Region. *Chinese Geographical Science*, 27(5), 827–835. <https://doi.org/10.1007/s11769-017-0894-6>
- Xiuwan, C. (2002). Using Remote Sensing and GIS to Analyse Land Cover Change and Its Impacts on Regional Sustainable Development. *International Journal of Remote Sensing*, 23(1), 107–124. <https://doi.org/10.1080/01431160010007051>
- Ye, S., Pontius, R. G., & Rakshit, R. (2018). A Review of Accuracy Assessment for Object-Based Image Analysis: From Per-Pixel to Per-Polygon Approaches. *ISPRS Journal of Photogrammetry and Remote Sensing*. <https://doi.org/10.1016/j.isprsjprs.2018.04.002>
- Yiğit, A. Y., Şenol, H. İ., & Kaya, Y. (2022). Çok Zamanlı Multispektral Uydu Verilerinin Marmara Gölü Kıyı Değişimi Analizinde Kullanılması. *Geomatik*, 7(3), 253–260. <https://doi.org/10.29128/GEOMATIK.1017376>

- Yu, Q., Gong, P., Clinton, N., Biging, G., Kelly, M., & Schirokauer, D. (2006). Object-Based Detailed Vegetation Classification with Airborne High Spatial Resolution Remote Sensing Imagery. *Photogrammetric Engineering and Remote Sensing*, 72(7), 799–811. <https://doi.org/10.14358/PERS.72.7.799>
- Yulianti, E. (2019). Multi-Temporal Sentinel-2 Images for Classification Accuracy. *Journal of Computer Science*, 15, 258–268. <https://doi.org/10.3844/jcssp.2019.258.268>
- Zafari, A., Zurita-Milla, R., & Izquierdo-Verdiguier, E. (2019). Evaluating the Performance of a Random Forest Kernel for Land Cover Classification. *Remote Sensing*, 11(5), 575. <https://doi.org/10.3390/rs11050575>
- Zarco-Tejada, P. J., Miller, J. R., Noland, T. L., Mohammed, G. H., & Sampson, P. H. (2001). Scaling-Up and Model Inversion Methods with Narrowband Optical Indices for Chlorophyll Content Estimation In Closed Forest Canopies with Hyperspectral Data. *IEEE Transactions on Geoscience and Remote Sensing*, 39(7). <https://doi.org/10.1109/36.934080>
- Zhang, T., Su, J., Liu, C., Chen, W.-H., Liu, H., & Liu, G. (n.d.). *Band Selection in Sentinel-2 Satellite for Agriculture Applications*. <https://scihub.copernicus.eu/>
- Zhang, T., Su, J., Xu, Z., Luo, Y., & Li, J. (2021). Sentinel-2 Satellite Imagery for Urban Land Cover Classification by Optimized Random Forest Classifier. *Applied Sciences (Switzerland)*, 11, 543. <https://doi.org/10.3390/app11020543>
- Zhou, W., Troy, A., & Grove, M. (2008). Object-Based Land Cover Classification and Change Analysis in the Baltimore Metropolitan Area Using Multitemporal High Resolution Remote Sensing Data. *Sensors*. <https://doi.org/10.3390/s8031613>