

**T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**DESTEK VEKTÖR MAKİNELERİ YÖNTEMİ İLE ARAZİ KULLANIMI
SINIFLANDIRILMASINDA
KERNEL FONKSİYONLARINA AİT KARŞILAŞTIRMALI PARAMETRE
DUYARLIK ANALİZİ: RAPİDEYE VE SPOT ÖRNEĞİ**

MUSTAFA ÜSTÜNER

**YÜKSEK LİSANS TEZİ
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI
UZAKTAN ALGILAMA VE CBS PROGRAMI**

**DANIŞMAN
DOÇ. DR. FÜSUN BALIK ŞANLI**

İSTANBUL, 2013

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**DESTEK VEKTÖR MAKİNELERİ YÖNTEMİ İLE ARAZİ KULLANIMI
SINIFLANDIRILMASINDA KERNEL FONKSİYONLARINA AİT
KARŞILAŞTIRMALI PARAMETRE DUYARLIK ANALİZİ: RAPİDEYE VE SPOT
ÖRNEĞİ**

Mustafa ÜSTÜNER tarafından hazırlanan tez çalışması 24.12.2013 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalı'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Doç. Dr. Füsun BALIK ŞANLI
Yıldız Teknik Üniversitesi

Jüri Üyeleri

Doç. Dr. Füsun BALIK ŞANLI
Yıldız Teknik Üniversitesi

Doç. Dr. Çiğdem GÖKSEL
İstanbul Teknik Üniversitesi

Doç. Dr. Bülent BAYRAM
Yıldız Teknik Üniversitesi

ÖNSÖZ

“DVM Yöntemi ile Arazi Kullanımı Sınıflandırılmasında Kernel Fonksiyonlarına ait Karşılaştırmalı Parametre Duyarlık Analizi: RapidEye ve SPOT Örneği ” isimli bu çalışma, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim Dalında yüksek lisans tezi olarak hazırlanmıştır.

Tez çalışması süresince bilgi ve tecrübelerinden faydalandığım, tezimin her aşamasında yardımını ve desteğini esirgemeyen, üst görüşü ve önerileri ile yol gösteren, tez danışmanım ve değerli hocam sayın Doç. Dr. Füsün BALIK ŞANLI’ ya teşekkürlerimi sunarım.

Çalışma alanı ile ilgili arazi çalışması verileri ile uydu görüntüsünün sağlanması ve değerlendirilmesi aşamasında görüş, öneri ve birikimlerinden yararlandığım değerli hocalarım sayın Prof. Dr. Yusuf KURUCU ve Dr. Müh. Mustafa Tolga ESETLİLİ’ ye teşekkürlerimi sunarım.

Tez çalışmam süresinde çalışma fırsatı bulduğum ABD Güney Florida Üniversitesi Geospatial Analytics Laboratuvarı’nda bana çalışma fırsatı sunan, değerli görüş ve önerilerinden faydalandığım hocam sayın Doç. Dr. Barnali Dixon’a teşekkürlerimi sunarım. Ayrıca burslu araştırmacı olarak destek aldığım YÖK’e teşekkür ederim.

Çalışmam sırasında bilgi ve deneyimlerini benimle paylaşan ve yardımını esirgemeyen Dr. Müh. Saygın ABDİKAN’a teşekkürlerimi sunarım.

Tez çalışmamda kullandığım SPOT uydusu veri temini için İTÜ UHUZAM’a teşekkürlerimi sunarım.

Aralık, 2013

Mustafa ÜSTÜNER

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ	vi
KISALTMA LİSTESİ	vii
ŞEKİL LİSTESİ.....	viii
ÇİZELGE LİSTESİ	ix
ÖZET	x
ABSTRACT	xii
BÖLÜM 1	
GİRİŞ	1
1.1 Literatür Özeti	1
1.2 Tezin Amacı	4
1.3 Hipotez	4
BÖLÜM 2	
UZAKTAN ALGILAMADA GÖRÜNTÜ SINIFLANDIRMA	5
2.1 Görüntü Önışleme Adımları	5
2.2 Sınıflandırma Yöntemleri	6
2.2.1 Destek Vektör Makineleri	8
2.2.2 En Çok Benzerlik Yöntemi	13
BÖLÜM 3	
UYGULAMA	14
3.1 Çalışma Alanı	14
3.2 Arazi Çalışması ve Eğitim Verisi	15
3.3 Materyal ve Yöntem	21
3.3.1 Kullanılan Veriler	21
3.3.1.1 RapidEye	21

3.3.1.2 SPOT.....	24
3.3.2 Yöntem.....	26
3.3.2.1 Görüntülerin Çakıştırılması.....	26
3.3.2.2 Uydu Görüntülerinin Sınıflandırılması.....	27
3.4 Kernel Fonksiyonlarının Konfigürasyonu ve Model Tasarımı.....	27
3.5 Doğruluk Analizi.....	35
BÖLÜM 4	
BULGULAR VE TARTIŞMA.....	41
BÖLÜM 5	
SONUÇ VE ÖNERİLER.....	54
KAYNAKLAR.....	57
ÖZGEÇMİŞ.....	61

SİMGE LİSTESİ

a_b	Aday pikselin b sınıfına ait olma yüzdesi
b	Bias (eğilim değeri)
C	Düzenleme (penaltı) parametresi
Cov_b	b sınıfının kovaryans matrisi
d	Polinom derecesi
D	Olasılık değeri
$f(x)$	x bilinmeyenli fonksiyon
$f(x) = \text{sign}$	Karar fonksiyonu
$K(x, x_i)$	Kernel Fonksiyonu
M_b	b örnek sınıfının ortalama vektörü
γ	Gama
ξ_i	Yapay değişken
λ_i	Lagrange çarpanları
x_i	Hiperdüzlem üzerindeki nokta
w	Hiperdüzlemi normali
y_i	Sınıf etiketleri

KISALTMA LİSTESİ

ASTER	Advanced Spaceborn Thermal Emission and Reflection Radiometer
ATM	Airborne Thematic Mapper
CBS	Coğrafi Bilgi Sistemleri
CLC	CORINE Land Cover
CORINE	Coordination of Information on the Environment
DA	Diskriminant Analizi
DLR	Deutsches Zentrum für Luft-und Raumfahrt e.V.
DVM	Destek Vektör Makineleri
EÇB	En Çok Benzerlik
EKU	En Kısa Uzaklık
ETM+	Enhanced Thematic Mapper Plus
KA	Karar Ağaçları
KÖ	Kızılötesi
LULC	Land Use Land Cover
MLC	Maximum Likelihood Classification
MS	Multispektral
NDVI	Normalized Difference Vegetation Index
Pan	Pankromatik
RMSE	Root Mean Square Error
RO	Rastgele Orman
SVM	Support Vector Machine
UTM	Universal Transverse Mercator
YKN	Yer Kontrol Noktası
YSA	Yapay Sinir Ağları

ŞEKİL LİSTESİ

	Sayfa
Şekil 2. 1 Sınıflandırma Yöntemleri	7
Şekil 2. 2 Doğrusal olarak ayrılabilen iki sınıflı DVM ve optimum hiperdüzlem	9
Şekil 2. 3 Doğrusal olarak ayrılamayan iki sınıflı DVM ve optimum hiperdüzlem.....	11
Şekil 3. 1 Çalışma Alanı	15
Şekil 3. 2 Çalışma alanında ürün desenine ait örnekler	16
Şekil 3. 3 RapidEye eğitim verisi	17
Şekil 3. 4 SPOT5 eğitim verisi	18
Şekil 3. 5 Çalışma alanı RapidEye uydu görüntüsü	23
Şekil 3. 6 Çalışma alanı SPOT5 uydu görüntüsü	26
Şekil 3. 7 İş Akış Şeması	31
Şekil 4. 1 Rapideye görüntüsü için polinom derecesine göre doğruluklar.....	41
Şekil 4. 2 SPOT5 görüntüsü için polinom derecesine göre doğruluklar	42
Şekil 4. 3 RapidEye görüntüsü için polinom kernelinde biasa göre doğruluklar.....	43
Şekil 4. 4 RapidEye görüntüsü için sigmoid kernelinde biasa göre doğruluklar	43
Şekil 4. 5 SPOT5 görüntüsü için polinom kernelinde biasa göre doğruluklar	44
Şekil 4. 6 SPOT5 görüntüsü için sigmoid kernelinde biasa göre doğruluklar	44
Şekil 4. 7 RapidEye için kernel türünde en yüksek sınıflandırma doğrulukları	47
Şekil 4. 8 SPOT5 için kernel türünde en yüksek sınıflandırma doğrulukları.....	47
Şekil 4. 9 EÇB1 tematik haritası	48
Şekil 4. 10 ML11 tematik haritası	48
Şekil 4. 11 MP9 tematik haritası.....	49
Şekil 4. 12 MR5 tematik haritası.....	49
Şekil 4. 13 MS9 tematik haritası	50
Şekil 4. 14 EÇB2 tematik haritası	51
Şekil 4. 15 ML7 SPOT tematik haritası.....	51
Şekil 4. 16 MP34 tematik haritası.....	52
Şekil 4. 17 MS29 tematik haritası	52
Şekil 4. 18 MR26 tematik haritası.....	52

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 2. 1	Kernel türleri ve matematiksel ifadeleri 12
Çizelge 2. 2	Kernel türleri ve parametreler 12
Çizelge 3. 1	Eğitim veri seti 17
Çizelge 3. 2	RapidEye eğitim verisi istatistiksel bilgiler 18
Çizelge 3. 3	SPOT5 eğitim verisi istatistiksel bilgiler 20
Çizelge 3. 4	RapidEye uydusu teknik özellikleri 21
Çizelge 3. 5	RapidEye veri işleme seviyeleri 22
Çizelge 3. 6	Kullanılan RapidEye görüntüsünün özellikleri 23
Çizelge 3. 7	SPOT5 uydusunun teknik özellikleri 24
Çizelge 3. 8	SPOT5 veri işleme seviyeleri 25
Çizelge 3. 9	RapidEye için polinom derecesinin aranması I 28
Çizelge 3. 10	RapidEye için polinom derecesinin aranması II 28
Çizelge 3. 11	RapidEye için bias parametresinin aranması II 29
Çizelge 3. 12	RapidEye için bias parametresinin aranması II 29
Çizelge 3. 13	RapidEye için düzenleme parametresinin aranması 30
Çizelge 3. 14	Model Tablosu 32
Çizelge 3. 15	RapidEye görüntüsüne ait sınıflandırma doğrulukları 35
Çizelge 3. 16	SPOT5 görüntüsüne ait sınıflandırma doğrulukları 38
Çizelge 3. 17	EÇB yöntemine ait sınıflandırma doğrulukları 40
Çizelge 4. 1	RapidEye C parametresi göre kernel türünde sınıflandırma sonuçları .. 45
Çizelge 4. 2	SPOT-5 C parametresi göre kernel türünde sınıflandırma sonuçları 45
Çizelge 4. 3	RapidEye için kernel bazından en yüksek sınıflandırma sonuçları 46
Çizelge 4. 4	SPOT-5 için kernel bazından en yüksek sınıflandırma sonuçları 46

**DESTEK VEKTÖR MAKİNELERİ YÖNTEMİ İLE ARAZİ KULLANIMI
SINIFLANDIRILMASINDA KERNEL FONKSİYONLARINA AİT
KARŞILAŞTIRMALI PARAMETRE DUYARLIK ANALİZİ: RAPİDEYE VE SPOT
ÖRNEĞİ**

Mustafa ÜSTÜNER

Harita Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Tez Danışmanı: Doç. Dr. Füsün BALIK ŞANLI

Ülkelerin gelişmişlik düzeyi ve toplumların refah seviyesi yüksek bir şekilde yaşayabilmesi o ülkedeki sosyal, kültürel ve ekonomik kaynakların etkin kullanımı ve sürdürülebilir yönetimine bağlıdır. 2006 CORINE (Coordination of Information on the Environment) arazi örtüsü verisine göre ülkemiz topraklarının %42.35'i tarım alanlarından, %54.04'ü ise ormanlık ve yarı-doğal bitki örtüsünden oluşmaktadır. Ülke topraklarının stratejik planlaması ve doğal kaynakların sürdürülebilir yönetimi için arazi örtüsü/kullanımına ilişkin detaylı ve güvenilir bilgiler yerel otoriteler ve karar vericiler için önem arz etmektedir.

Uzaktan algılama teknolojisi doğal kaynakların (orman, tarım alanı, bitki örtüsü vb.) etkin, doğru planlanması ve yönetiminde önemli bir role sahiptir. Çok bantlı yüksek çözünürlüklü uydu görüntüleri arazi örtüsü ve kullanımına ilişkin tematik haritaların üretilmesinde sağladığı spektral, mekânsal ve zamansal zenginlik nedeniyle tercih edilmekte ve yaygın olarak kullanılmaktadır. Uydu görüntülerinden tematik bilgi elde etmek amacıyla kullanılan en yaygın yöntem uydu görüntülerinin sınıflandırılmasıdır. Elde edilecek tematik bilginin doğruluğu ve kalitesi, kullanılan uydu görüntüsü ve bant kombinasyonunun seçiminin yanı sıra sınıflandırmada kullanılacak algoritmaya da bağlıdır. Bu çalışmada, uydu görüntülerinin sınıflandırılması işleminde son zamanlarda yüksek sınıflandırma kabiliyeti nedeniyle tercih edilen makine öğrenme

algoritmalarından birisi olan Destek Vektör Makineleri (DVM) ile geleneksel sınıflandırma yöntemlerinden birisi olan ve literatürde geçerliliği kabul edilmiş En Çok Benzerlik (EÇB) yöntemi tercih edilmiştir.

Çalışmada son yıllarda tarım, bitki örtüsü, orman ve sulak alanları haritalanması ve bu alanlara ilişkin bilgi elde etmek amacıyla yaygın olarak kullanılan ve başarılı sonuçlar veren RapidEye ve SPOT çok bantlı yüksek çözünürlüklü uydu görüntüleri kullanılmıştır. Seçilen uydu görüntüleri yüksek çözünürlüklerinin yanı sıra içerdikleri bantlar nedeniyle tercih edilmiştir.

Çalışma alanı Aydın ili sınırları içindedir. Tarım arazileri ile kaplı alanda mısır (I,II ve III evre), pamuk (iyi, orta, zayıf), toprak (ıslak, nemli, kuru), çayır ve mera alanı, yerleşim alanı ve su yüzeyi olmak üzere oniki farklı sınıf belirlenmiştir. Çalışmaya ilişkin arazi çalışması görüntü alımı ile eş zamanlı olarak Ege Üniversitesi Ziraat Fakültesi Toprak Bilimi ve Bitki Besleme bölümü tarafından gerçekleştirilmiştir.

DVM sınıflandırma işleminde dört farklı kernel ve birbirinden farklı yüzotuzdokuz model kullanılmıştır. Bu modeller kullanılarak DVM sınıflandırma işleminde kernel tipi ve bu kernellere ait parametre seçiminin sınıflandırma doğruluğu üzerindeki etkisi incelenmiş ve en yüksek sınıflandırma doğruluğu veren model (en uygun parametre seti) bulunmuştur. Ayrıca hem sınıflandırma yöntemlerinin hem de uydu görüntülerinin tarımsal amaçlı uygulamalarda kullanılabilirliği ve başarısı da test edilmiştir.

DVM yöntemi kullanılarak elde edilen sınıflandırma sonuçları seçilen modele bağlı olarak çoğunlukla EÇB yöntemi kullanılarak elde edilen sonuçlardan yüksek olsa da birkaç modelde ise düşüktür. İki görüntü türü içinde en yüksek sınıflandırma doğruluğunu veren kernel polinom kernelidir ve sınıflandırma doğruluğu RapidEye için %85.6 iken SPOT için %73.3 tür. Üretilen tematik haritaların sınıflandırma doğrulukları kappa katsayısı ve hata matrislerinden (toplam doğruluk) yararlanılarak elde edilmiştir.

Anahtar Kelimeler: Destek vektör makineleri, kernel fonksiyonları, karşılaştırmalı duyarlık analizi, RapidEye, SPOT

ABSTRACT

COMPARATIVE SENSITIVITY ANALYSIS OF KERNEL PARAMETERS FOR SUPPORT VECTOR MACHINES ON LAND USE CLASSIFICATION: A CASE STUDY OF RAPIDEYE AND SPOT

Mustafa ÜSTÜNER

Department of Geomatic Engineering

MSc. Thesis

Advisor: Assoc. Prof. Dr. Füsün BALIK ŞANLI

The development level of countries and living of societies in a high welfare level are based on efficient use and sustainable management of their social, cultural and economical resources. Based on CLC 2006 data, the land in Turkey consists of 42.35% agricultural areas and 54.04% forest and semi natural vegetation. Therefore, reliable and detailed information regarding LULC are critical important for environmental decision makers and local authorities on strategic planning and sustainable resource management of country's land.

Remote sensing technology has an important role in efficient and proper planning and management of natural resources. Multispectral high resolution images are preferred and commonly used since providing the spectral, spatial and temporal information while producing thematic maps. Image classification is the most common way to gather thematic information, among the all collateral methods. The quality and accuracy of the thematic information are based on algorithm used as well as satellite image and its band combination. One of the machine learning algorithms SVMs which are commonly used in recently since its high classification capability and one of the conventional classification algorithms MLC whose validity has been accepted in literature are preferred in this study.

Multispectral high resolution RapidEye and SPOT images are used in this study since they have been effectively used for vegetation, forest and wetland mapping and gave successful results. These images has been preferred since their band features obtained besides their high resolution

The study area is located Aydin province and covered by agricultural lands. Study area has 12 land use classes as they are corn (I.crop, II.crop, III.crop), cotton (well-developed, moderate-developed, weak-developed), soil (wet, moist, dry), pasture and brush land mixed area, settlement area and water body. In-situ data was collected at the acquisition date of satellite images by experts from Department of Soil Science and Plant Nutrition in Ege University, İzmir.

Four different types of kernel and 139 different models have been used for SVM classification. The effects on choice of kernel and its internal parameters have been investigated and optimum parameters having highest classification accuracy have been determined. Moreover, the success and efficient use of satellite images and classification algorithms on agricultural lands have been examined.

SVM classification results based on selected various model have superior performance than MLC in most cases, however MLC is better than SVM rarely in a few cases. For both type of satellite images, the polynomial kernel had the highest classification accuracies which are 85.6% and 73.3% for RapidEye and SPOT, respectively.

Keywords: Support vector machines, kernel functions, comparative sensitivity analysis, RapidEye, SPOT

1.1 Literatür Özeti

Arazi kullanım bilgisi, ekonomiye dayalı politikaların ve çevresel konuların ele alınmasında önemli bir bileşendir. Ulusal ve küresel anlamda, tarım alanlarının sürekli ve hızlı bir şekilde izlenebilmesi ve sürdürülebilir tarım politikalarının oluşturulabilmesi amacıyla uzaktan algılama tekniği son 30 yıldır işlerle birlikte kullanılmaktadır. Uydu görüntülerinin sınıflandırılması ve analizi, uzaktan algılamada bilgi çıkarımı amacıyla kullanılan en yaygın yöntemlerden birisidir. Özellikle son 10 yıldır çoğalan yüksek çözünürlüklü uydu verileri ve gelişmiş sınıflandırma algoritmalarının da kullanılması ile elde edilen bilgilerin doğruluğu ve güvenilirliği giderek artmaktadır.

Literatür incelediğinde uzaktan algılama çalışmalarında en sık kullanılan sınıflandırma yöntemleri olarak En Çok Benzerlik (EÇB), Yapay Sinir Ağları (YSA), Karar ağaçları (KA), Destek Vektör Makineleri (DVM) ve nesne tabanlı sınıflandırma yöntemlerinin kullanıldığı görülmektedir. En yaygın çalışmalar ise multispektral veya hiperspektral uydu görüntüleri kullanılarak arazi örtüsü/kullanımı haritası üretmek amacıyla mevcut ya da yeni sınıflandırma algoritmalarının performanslarının karşılaştırmalı analizinin yapılmasıdır. Sınıflandırma algoritmalarının performansı, kullanılan uydu görüntüsü, uydu görüntüsünün bant kombinasyonu, sınıflandırma işleminde kullanılan eğitim verisi, algoritmaya bağlı kullanılan parametrelerin uygun seçimi vb. etkenlere bağlı olarak değişmektedir.

Bu amaçla yapılan çalışmaların bazılarında bahsetmek gerekirse;

Kavzoğlu ve Çölkesen (2009), çalışmalarında arazi örtüsü sınıflandırması amacıyla Destek Vektör Makineleri (DVM) ve En Çok Benzerlik (EÇB) sınıflandırma yöntemlerini

Landsat ETM+ (Landsat Enhanced Thematic Mapper Plus) ve Terra ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer) görüntüleri üzerinde test etmişlerdir[1]. Dixon ve Candede (2008), arazi kullanımı sınıflandırması amacıyla Yapay Sinir Ağları (YSA), DVM ve EÇB sınıflandırma yöntemlerini Landsat TM görüntüsü üzerinde kullanmışlardır [2]. Srivastava vd. (2012), arazi kullanımı/örtüsü sınıflandırması amacıyla DVM, YSA ve EÇB sınıflandırma yöntemlerini Landsat TM ve ETM+ görüntüleri üzerinde test ederek karşılaştırmalı analizler yapmışlardır. Çalışmada, lineer kernel en başarılı kernel olarak bulunmuştur [3]. Petropoulos vd. (2012), çalışmalarında arazi örtüsü/kullanımı sınıflandırması amacıyla DVM ve YSA sınıflandırma yöntemlerini Hyperion hiperspektral görüntüsü üzerinde test ederek karşılaştırmalı analizler yapmışlardır [4]. Watanachaturaporn vd. (2008) arazi örtüsü sınıflandırmasında NDVI (Normalized Difference Vegetation Index- Normalize edilmiş fark bitki örtüsü indeksi) ve Sayısal Yükseklik Modeli (SYM) verilerinin sınıflandırmaya olan etkilerini Karar ağaçları (KA), DVM ve YSA yöntemlerini kullanarak araştırmışlardır. Bu çalışmada, polinom kerneli en yüksek sınıflandırma doğruluğunu vermiştir [5]. Gong vd. (2013) çok sayıda Landsat TM ve ETM+ görüntülerinden yararlanarak küresel ölçekte arazi örtüsü haritası oluşturmak amacıyla Rastgele Orman (RO), DVM, KA ve EÇB sınıflandırma yöntemlerinin karşılaştırmalı analizini yapmıştır [6]. Huang vd. (2002), çalışmalarında arazi örtüsü sınıflandırması amacıyla DVM, YSA, KA ve EÇB sınıflandırma yöntemlerini Landsat TM uydu görüntüsü üzerinde test ederek karşılaştırmalı analizler yapmışlardır [7]. Pal ve Mather (2005), arazi örtüsü sınıflandırması amacıyla DVM, YSA ve EÇB sınıflandırma yöntemlerinin performanslarını Landsat ETM+ ve DAIS hiperspektral uydu görüntülerini kullanarak test etmişlerdir [8].

Yukarıda sözedilen bilimsel çalışmaların hepsinde uygun parametre seti ve kernel türünün seçildiği takdirde DVM sınıflandırma yönteminin üstün sonuçlar vereceği görülmüştür. Ancak KA ve RO algoritmalarının DVM' den başarılı olduğu çalışmalar da mevcuttur [9], [10].

DVM sınıflandırma yöntemi arazi örtüsü/kullanımı sınıflandırmasında yüksek sınıflandırma doğruluğuna sahip sonuçlar vermesinin yanı sıra, tarım alanları ile ilgili uygulamalarda da etkin bir biçimde kullanılmakta ve yüksek doğruluklu sonuçlar elde edilmektedir. Fakat, DVM sınıflandırma yöntemi ile gerçekleştirilen tarım alanları ile

ilgili uygulamaların sayısı, uzmanlık gerektiren bir arazi çalışmasına ihtiyaç duyduğu için arazi örtüsü/kullanımı sınıflandırmasına nazaran azdır.

Foody ve Mathur (2004), tarımsal ürünlerin sınıflandırılması amacıyla Diskriminant analizi (DA), DVM, KA ve EÇB sınıflandırma yöntemlerini ATM (Airborne Thematic Mapper) görüntüsü üzerinde deneyerek başarılı sonuçlar elde etmişlerdir [11]. Mathur ve Foody (2008), tarım alanlarının sınıflandırılmasında DVM yönteminin fazla eğitim verisi gerektirmeden başarılı sonuçlar verebileceğini göstermişlerdir [12].

Bu çalışmada kullanılan RapidEye uydu görüntüsü kırmızı-kenar ve SPOT uydu görüntüsü de yakın kızılötesi bant içermeleri ve ayrıca yüksek çözünürlüklü olmaları nedeniyle, tarım, bitki örtüsü, orman ve sulak alanları haritalanmasında tercih edilmekte ve başarılı sonuçlar vermektedir. Literatür incelediğinde, DVM sınıflandırma yönteminin tarım alanı ile ilgili uygulamalarda, özellikle RapidEye ile SPOT uydu görüntülerinin kullanıldığı çalışmalar, diğer tarım alanı ile ilgili uygulamalara nazaran daha az sayıdadır. Ancak, bu tür çalışmaların sayısı giderek artmaktadır.

Schuster vd. (2012), çalışmalarında arazi kullanımı sınıflandırması amacıyla DVM sınıflandırma yöntemini kullanarak RapidEye uydu görüntüsüne ait kırmızı-kenar (red-edge) bandının sınıflandırmaya olan katkısını araştırmıştır [13]. Eitel vd. (2011), çalışmalarında kozalaklı ağaçlarda erken stresin tespit edilmesinde RapidEye uydu görüntüsüne ait kırmızı-kenar bandının katkısını araştırmıştır [14]. Tigges vd. (2013) kentsel yeşil alanların sınıflandırılmasında çok zamanlı RapidEye uydu görüntülerinin kullanılmasının katkılarını DVM sınıflandırma yöntemini kullanarak test etmişlerdir [15]. Löw vd. (2013), RapidEye uydu görüntüsünün DVM ve RO sınıflandırma algoritmaları kullanılarak tarımsal alanların sınıflandırılmasındaki uygulanabilirliği ve başarısını test etmişlerdir [16]. Yang vd. (2011), çalışmalarında yöntemlerden ikisi EÇB ve DVM olan beş farklı kontrollü sınıflandırma yöntemini kullanarak SPOT 5 uydu görüntüsünün ürün deseni belirlemede ki kullanılabilirliği ve başarısını test etmişlerdir [17]. Türker ve Yazıcı (2011), çalışmalarında ürün deseni belirlenmesi amacıyla EÇB sınıflandırma yöntemini kullanarak SPOT 4-5, IKONOS ve QuickBird uydu görüntülerinin sınıflandırma sonuçlarını karşılaştırmış ve bu uydu görüntülerinin tarım alanı ile ilgili uygulamalarda kullanılabilirliğini test etmişlerdir [18]. Duro vd. (2012), KA, RO, DVM ve nesne tabanlı sınıflandırma yöntemlerini kullanarak SPOT-5 uydu görüntüsünün tarım alanı ile ilgili uygulamalarda kullanılabilirliğini karşılaştırmalı analiz yaparak test etmişlerdir [19].

DVM sınıflandırma yöntemi parametrelerine ait duyarlılık analizi ile ilgili yapılmış çalışmalar sınırlı sayıdadır ve genelde Landsat uydu görüntüsü ya da hiperspektral uydu görüntüleri ile yapılmıştır [7], [20], [21], [22].

1.2 Tezin Amacı

Bu tez çalışmasının birincil amacı RapidEye ve SPOT uydu görüntülerinin DVM sınıflandırma yöntemi ile sınıflandırılmasında parametrelere ait duyarlılık analizinin yapılması başka bir ifade ile her bir parametre türünün sınıflandırma doğruluğu üzerindeki etkisinin incelenmesi ve karşılaştırmalı analiz edilmesidir. İkincil amacı; tarım alanları ile ilgili uygulamalarda RapidEye ve SPOT uydu görüntülerinin az sayıda eğitim verisi kullanarak DVM sınıflandırma yöntemi ile başarılı sonuçlar elde edilebileceğinin ve uygulanabilirliğinin test edilmesidir. Üçüncü amacı ise DVM sınıflandırma yönteminin seçilen parametre setine bağlı olarak EÇB yöntemine göre başarılı sonuçlar verip vermeyeceğinin araştırılmasıdır.

1.3 Hipotez

Bu çalışmada hipotez aşağıdaki gibi kurulmuştur;

- RapidEye ve SPOT uydu görüntüleri DVM sınıflandırma yöntemi kullanılarak tarım alanları ile ilgili uygulamalarda, özellikle ürün deseninin tespitinde kullanılabilir ve tatminkâr sonuçlar sunabilir.
- Literatürde, diğer kernellere kıyasla üstün sınıflandırma yeteneğine sahip olduğu birkaç çalışma ile ispatlanan radyal tabanlı kernelin aksine, uygun parametre seti seçildiği takdirde polinom kerneli daha başarılı sonuçlar verebilir.
- Çoğu bilimsel çalışmada, DVM yönteminin EÇB yönteminden daha yüksek sınıflandırma doğruluğu verdiği ispatlanmış olsa da, en uygun kernel ve parametre seti seçilmediği takdirde EÇB yöntemi daha başarılı sonuçlar verebilir.

UZAKTAN ALGILAMADA GÖRÜNTÜ SINIFLANDIRMA

Uzaktan algılama, bilgisayar ve uydu-uzay teknolojilerindeki son gelişmeler ile birlikte, uydu görüntülerinin elde edilebilirliği ve kullanım alanı artmıştır. Bu gelişmeler ile birlikte yeryüzü hakkında bilgi edinmemiz kolaylaşmıştır [23], [24], [25], [26]. Uydu görüntüleri arazi örtüsü ve kullanımına ilişkin sağladığı spektral, mekânsal ve zamansal zenginlik nedeniyle tercih edilmekte ve yaygın olarak kullanılmaktadır. Uydu görüntülerinden bilgi elde etmek amacıyla kullanılan en yaygın yöntem uydu görüntülerinin sınıflandırılmasıdır [27].

Görüntü sınıflandırma, piksellerin temsil ettiği arazi örtüsü/kullanımı sınıflarına otomatik atanması işlemi olarak tanımlanmaktadır [28]. Uydu görüntülerinden güvenilir bilginin elde edilebilmesi, kullanılacak olan sınıflandırma yönteminin kalitesi ve doğruluğuna bağlıdır [29]. Bu nedenle uzaktan algılamada görüntü sınıflandırma algoritmaları üzerine yapılan çalışmalar artmakta ve önem kazanmaktadır. Bugüne kadar çeşitli sınıflandırma yöntemleri geliştirilmiş, farklı veriler kullanılarak farklı amaçlara yönelik yapılan çalışmaların başarıları test edilmiştir. Ayrıca yeni yöntemlerin bulunması amacıyla da çalışmalar hala devam etmektedir. Özellikle son 10 yıldır çoğalan yüksek çözünürlüklü uydu verileri ve gelişmiş sınıflandırma algoritmalarının da kullanılması ile elde edilen bilgilerin doğruluğu ve güvenilirliği giderek artmaktadır.

2.1 Görüntü Ön işleme Adımları

Uydular veya uçaklarda takılı algılayıcılar tarafından görüntüler kaydedilirken, geometrilerinde bazı distorsiyonlar içerebilirler ve bu nedenle bilgi elde etmek amacıyla kullanılamazlar [30].


Ham görüntü olarak ifade edebileceğimiz bu görüntüleri kullanmadan önce görüntü geometrisinde ve gri (parlaklık) değerlerinde düzeltmeler yapmak gerekir [25], [30]. Bu düzeltmeler görüntü önışleme olarak adlandırılmaktadır [28].

Bazen görüntü önışleme adımlarına ek olarak görüntünün algılanabilirliğı ve yorumlanabilirliğini artırmak amacıyla görüntü zenginleştirme tekniklerine başvurulur. Görüntü önışleme ve görüntü zenginleştirme tekniklerinden yararlanılarak geometrik ve radyometrik düzeltmeleri yapılmış olan görüntüler bilgi elde etmek amacıyla kullanılabilir hale gelmiştir [31].

2.2 Sınıflandırma Yöntemleri

Sınıflandırma işlemi temel olarak kontrollü ve kontrolsüz sınıflandırma olmak üzere ikiye ayrılmaktadır (Şekil 2.1). Kontrollü sınıflandırma yönteminde, arazi örtüsü/kullanımı sınıflarına ilişkin öncül tematik bilgiler mevcuttur. Bu öncül bilgilere dayalı olarak, eğitim verisi oluşturulur. Bu eğitim verileri yardımıyla kontrollü sınıflandırma gerçekleştirilmektedir. Kontrolsüz sınıflandırma da ise sınıflara ait herhangi bir öncül bilgi yoktur. Kontrolsüz sınıflandırma yönteminde piksellerin hangi sınıfa atanacağı çeşitli algoritmalar yardımıyla bulunmaktadır ve bu algoritmalar yaygın olarak kümeleme algoritmaları olarak adlandırılmaktadır [32].

Kontrollü sınıflandırma, uydu görüntülerinin sınıflandırılması işleminde kontrolsüz sınıflandırmaya kıyasla daha yüksek sınıflandırma doğruluğına sahip olması ve güvenilirliğı nedeniyle daha çok tercih edilmektedir. Kontrollü sınıflandırma yöntemleri, eğitim verisinin istatistiksel dağılımını kabul durumuna göre parametrik ve parametrik olmayan yöntemler olmak üzere ikiye ayrılmaktadır (Şekil 2.1). Parametrik sınıflandırma yöntemlerinin eğitim verisinin istatistiksel dağılımı üzerine bir kabulü vardır ve bu istatistiksel dağılım genellikle Normal (Gauss) dağılımdır. Parametrik olmayan yöntemlerde ise verinin dağılımına ait herhangi bir kabul yapılmaz [32], [31].



Şekil 2.1 Sınıflandırma Yöntemleri

Parametrik sınıflandırma yöntemlerine En Kısa Uzaklık (EKU) ve En Çok Benzerlik (EÇB) yöntemleri, parametrik olmayan yöntemlere ise KA, DVM, YSA, RO algoritmaları örnek olarak verilebilir. Literatüre bakıldığında en çok kullanılan sınıflandırma teknikleri arasında En Çok Benzerlik (EÇB) , Yapay Sinir Ağları (YSA) ve Karar Ağaçları (KA) yöntemlerinin kullanıldığı görülmektedir [7]. En yaygın şekilde kullanılan teknik ise kolay uygulanabilmesi ve birçok ticari ve akademik yazılımlarda bulunabilmesi nedeniyle tercih edilen, parametrik bir yöntem olan En Çok Benzerlik yöntemidir [33], [34]. Yapay sinir ağları parametrik olmayan yapısı ile en çok benzerlik yöntemine ait problemlerin üstesinden gelebilmektedir [35], [36]. Verinin istatistiksel dağılımı üzerine bir varsayım yapmaması nedeniyle EÇB yönteminden daha iyi sonuçlar verdiği görülmektedir [37]. Ancak yapay sinir ağlarının başarısı, ağın ve uygulama algoritmalarının seçimine oldukça fazla bağımlı olması bu yöntemin en büyük kısıtlayıcılarından [35]. Diğer bir parametrik olmayan sınıflandırma tekniği ise karar ağaçları yöntemidir. Karar ağaçları sınıflandırma yöntemi, sınıflandırma işlemini basit karar verme işlemlerinden oluşan çoklu adımlara bölmektedir [38]. Daha sonrada, her bir aşamada değişken sayısına bağlı olarak belirlenen tek değişkenli ve çok değişkenli karar ağacı kullanarak çözmektedir [39], [40].

DVM ve RO algoritmaları uzaktan algılama da EÇB ve YSA yöntemlerine göre kısmen yeni sayılmakta, son yıllarda bu yöntemler üzerine yapılan çalışmalar giderek artmakta ve başarılı sonuçlar elde edilmektedir [41]. İstatistiksel öğrenme teorisine dayanan

Destek Vektör Makineleri yüksek sınıflandırma kabiliyetine sahip olması ve az sayıda eğitim verisi kullanması ile diğer yöntemlere üstünlük sağlamaktadır ve özellikle son yıllarda sıklıkla tercih edilmektedir [12].

2.2.1 Destek Vektör Makineleri

1970'li yılların sonlarına doğru Rus Bilim adamı Vladimir Vapnik ve arkadaşları tarafından geliştirilen destek vektör makinelerinin uzaktan algılama alanındaki ilk uygulamaları 1990'lı yılların sonlarında görülmektedir [41]. Uzaktan algılama alanında DVM ile yapılan ilk bilimsel içerikli çalışmada hiperspektral uydu görüntüleri sınıflandırılmıştır. Daha sonraları da çalışmalar çok bantlı uydu görüntülerinin sınıflandırması ile devam etmiştir [42], [7].

Destek vektör makineleri (DVM) istatistiksel öğrenme teorisine dayalı parametrik olmayan bir sınıflandırma yöntemidir [43]. DVM, ikili sınıflandırmalar için geliştirilmiş olup az sayıda örnekleme verisi ile doğru sınıflandırma sonuçları elde etmeye olanak sağlamaktadır [44]. Başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması için tasarlanmış olan yöntem, daha sonra çok sınıflı ve doğrusal olmayan verilerin sınıflandırılması için geliştirilmiştir. Destek vektör makineleri, Yapısal Risk Azalımı (YRA) prensibine dayanmaktadır. Bu prensip, iki hiperdüzlem arasındaki sınır mesafesini maksimum hale getirmektedir [43].

Örneğin iki sınıflı, r sayıda örnekten oluşan ve birbirinden ayrılabilir $(x_1, y_1), \dots, (x_r, y_r)$ şeklinde tanımlanan bir eğitim verisi verilsin; burada $x \in \mathbb{R}^N$ olup N boyutlu bir uzayı, $y \in \{+1, -1\}$ olup sınıf etiketlerini temsil etmektedir ve bu iki sınıf çeşitli $N-1$ boyutlu hiperdüzlemler tarafından ayrılabilir. Bu iki sınıfı birbirinden ayırabilen, iki sınıf türü için de kendisine en yakın noktalar arasındaki uzaklığı maksimuma çıkarabilen tek bir hiperdüzlem vardır [7], [45].

Bu hiperdüzlem optimum hiperdüzlem olarak adlandırılır (Şekil 2.2).

Bir hiperdüzlem

$$w \cdot x_i + b = 0 \quad (2.1)$$

olarak tanımlanır.

Burada x_i hiperdüzlem üzerindeki noktayı, w hiperdüzlemin normalini ve b ise hiperdüzlemin orijinden olan uzaklığı olarak ifade edilen biası (eğilim değeri) temsil

etmektedir (Şekil 2.2). İki sınıflı doğrusal olarak ayrılabilen veriler için, ayırım yapan hiperdüzlem

$$w.x_i + b \geq +1, \text{ her } y = +1 \text{ için} \quad (2.2)$$


$$w.x_i + b \leq -1, \text{ her } y = -1 \text{ için} \quad (2.3)$$

olarak tanımlanabilir.

Yukarıdaki iki eşitsizlik tek bir eşitsizlik haline getirilirse

$$y_i (w.x_i + b) - 1 \geq 0, y_i \in \{1, -1\} \quad (2.4)$$

şeklini alır



Şekil 2.2 Doğrusal olarak ayrılabilen iki sınıflı DVM ve optimum hiperdüzlem

Optimum hiperdüzleme paralel ve

$$w.x_i + b = \pm 1 \quad (2.5)$$

eşitliği ile tanımlanan ayırım yapabilen iki hiperdüzlem üzerinde bulunan ve sınır genişliğini belirleyen noktalar destek vektörleri olarak adlandırılır [1], [12], [45]. Bu iki hiperdüzlem arasındaki sınır genişliği (marjin) $2/||w||$ dir. İki sınıflı maksimum sınır

genişliği ile ayıran optimum hiperdüzlem, $\|w\|^2$ ifadesinin (2.4) deki sınırlamalara bağlı olarak minimum hale getirilmesi ile bulunabilir [7],[45].

$$\min \left[\frac{1}{2} \|w\|^2 \right]$$

(2.6)

Bu problem Lagrange denklemleri kullanılarak çözülebilecek bir optimizasyon problemidir ve çözüm için karar fonksiyonu


$$f(x) = \text{sign} \left(\sum_{i=1}^r \lambda_i \cdot y_i (x \cdot x_i) + b \right) \quad (2.7)$$

şeklinde olur.

Burada λ_i , $i=1, 2, \dots, r$ Lagrange çarpanlarını temsil etmektedir.

Eğer sınıflar doğrusal olarak ayıramıyorsa (Şekil 2.3), (2.6) ifadesi ve ona ait sınırlamalar ayırım yapılabilmesi için yetersiz kalmaktadır. Problem ξ_i yapay değişkeninin tanımlanması ve (2.4)'e eklenmesi ile çözülebilmektedir. ξ_i yapay değişkeni pozitif değerler almaktadır ve sınıflandırma hatalarını ifade etmektedir [44], [1], [7].

$$y_i(w \cdot x_i + b) - 1 + \xi_i \geq 0 \quad (2.8)$$



Şekil 2.3 Doğrusal olarak ayrılamayan iki sınıflı DVM ve optimum hiperdüzlem

Optimum hiperdüzlem aşağıdaki optimizasyon probleminin çözümü ile bulunabilir:

$$\min \left[\frac{\|w\|^2}{2} + C \sum_{i=1}^r \xi_i \right] \quad (2.9)$$

Hiperdüzlemin (yada karar yüzeyinin) doğrusal eşitlikler yardımıyla belirlenememesi durumunda, bu problem kernel (çekirdek) fonksiyonları yardımıyla çözülebilir. Girdi uzayında doğrusal olarak ayrılamayan verinin, kernel fonksiyonları aracılığı ile yüksek boyutlu uzay(özellik uzayı) da görüntülenerek doğrusal olarak ayrımı sağlanır.[46], [1], [7].

Kernel fonksiyonları genel ifadesi aşağıdaki gibidir.

$$K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) \quad (2.10)$$

Bu durumda karar fonksiyonu;

$$f(x) = \text{sign} \left(\sum_{i=1}^r \lambda_i \cdot y_i \cdot K(x, x_i) + b \right) \quad (2.11)$$

şeklinde olur.

Burada λ_i , $i=1,2, \dots ,r$ Lagrange çarpanlarını , $K(x, x_i)$ kernel fonksiyonunu temsil etmektedir.

Destek vektör makinelerinde yaygın olarak kullanılan kernel fonksiyonları genel olarak lineer(doğrusal), polinom, radyal tabanlı ve sigmoid kernelleri olmak üzere 4 gruba ayrılmaktadır (Çizelge 2.1) [20], [7],[45].

Çizelge 2.1 Kernel Türleri ve Matematiksel İfadeleri

Kernel Türü	Matematiksel
Lineer (Doğrusal) Kerneli	$K(x_i, x_j) = x_i \cdot x_j$
Polinom Kerneli	$K(x_i, x_j) = (\gamma(x_i \cdot x_j) + b)^d, \gamma > 0, \delta > 0$
Radyal Tabanlı Fonksiyon	$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2), \gamma > 0$
Sigmoid Kerneli	$K(x_i, x_j) = \tanh(\gamma(x_i \cdot x_j) - b), \gamma > 0, \delta > 0$

Çizelge 2.1’ de görülen matematiksel ifadelerde;

$K(x, x_i)$ kernel fonksiyonunu, d polinom derecesini, b bias parametresini, γ gamma parametresini ve C düzenleme (penaltı) parametresi temsil etmektedir [7],[45].

Çizelge 2.2 Kernel ve sahip olunan parametreler

Parametre Türü	Kernel Türü
Polinom derecesi (d)	Polinom
Bias (b)	Polinom, Sigmoid
Gama (γ)	Polinom, Radyal Tabanlı, Sigmoid
Düzenleme(Hata)Parametresi(C)	Lineer, Polinom, Radyal Tabanlı, Sigmoid

Çizelge 2.2’de kernel türlerine ait parametreler ve her bir parametre türünün hangi kernel türünde bulunduğu görülmektedir.

Başlangıçta iki sınıflı verilerin sınıflandırılması amacıyla tasarlanmış olan destek vektör makineleri, çeşitli yöntemler aracılığıyla çok sınıflı verilerin sınıflandırılması işleminde de başarıyla kullanılmaktadır. Bu yöntemlerden en yaygın iki tanesi “Bire karşı bir (one against one- Pairwise classification strategy)” ve “Bire karşı hepsi (one against all)”

yaklaşımlardır. Bu iki yöntemde de temel mantık çok sınıflı verilerin sınıflandırılması problemini, iki sınıflı verilerin sınıflandırılması problemine dönüştürerek temel DVM yaklaşımının kullanılmasını sağlamaktır [12], [20], [47].

N sayıda sınıftan oluşan bir eğitim verisinde herhangi bir sınıf türü için, bire karşı hepsi yaklaşımında diğer tüm sınıf türleri tek bir sınıf (küme) gibi ele alınıp bir adet ikili sınıflandırıcı yardımıyla sınıflandırma işlemi gerçekleştirilirken, bire karşı bir yaklaşımında diğer her bir sınıf türü ayrı ayrı ele alınarak her bir sınıf çifti için bir adet ikili sınıflandırıcı kullanılarak bu işlem gerçekleştirilir [47], [48], [49] .

2.2.2 En Çok Benzerlik Yöntemi/Maksimum Olabilirlik

En Çok Benzerlik yöntemi, uzaktan algılanmış verilerin sınıflandırılması işleminde kullanılan kontrollü sınıflandırma yöntemlerinden en yaygın olanıdır [28]. Bu yöntemde normal dağılım modeli kullanılır ve her bir sınıf için eğitim verisinin normal dağılımda olduğu kabul edilir. Bu kabul ile birlikte bir sınıf, piksellere ait gri (parlaklık) değerlerinin yanı sıra o sınıfa ait ortalama vektörü ve kovaryans matrisi yardımıyla ayırt edilebilir [28], [32].

EÇB sınıflandırma yöntemi Bayes Teorisine dayalıdır ve bu yöntemde piksel, herhangi bir sınıfa ait olma olasılık değerlerinden en yüksek olan sınıfa atanır[31], [32].

Pikselin herhangi bir sınıfa ait olma olasılığı aşağıdaki eşitlik ile hesaplanabilir.

$$D = \ln(a_b) - \left[0.5 \ln(|Cov_b|) \right] - \left[0.5 \cdot (X - M_b)^T \cdot (Cov_b^{-1}) \cdot (X - M_b) \right] \quad (2.12)$$

Yukarıdaki eşitlikte; D olasılık değerini, b örnek bir sınıfı, X aday pikselin ölçüm vektörünü, M_b b örnek sınıfının ortalama vektörünü, a_b aday pikselin b sınıfına ait olma yüzdesini, Cov_b b sınıfının kovaryans matrisini göstermektedir [1],[2].


UYGULAMA

Bu çalışma ile Destek Vektör Makineleri sınıflandırma yönteminin arazi kullanım haritası oluşturmada ve tarımsal ürünlerin sınıflandırılmasında uygulanabilirliği ve başarısı test edilmiştir. Dört farklı kernel türü ve bu kernellere ait parametrelerin permütasyon ve kombinasyonlarından oluşan birbirinden farklı toplam 139 farklı model kullanılarak DVM mimarisi üzerinde duyarlık analizi yapılmış, başka bir deyişle DVM kernel fonksiyonlarına ait parametre seçiminin sınıflandırma doğruluğu üzerindeki etkisi incelenmiştir (Çizelge 3.12 ve Şekil 3.5). Çalışmada Aydın iline ait, yüksek çözünürlüklü RapidEye ve SPOT uydu görüntüleri kullanılmıştır. Destek vektör makineleri sınıflandırma sonuçları geleneksel sınıflandırma yöntemlerinden biri olan ve artık literatürde geçerliliği kabul edilmiş En Çok Benzerlik sınıflandırma yöntemi ile karşılaştırılmıştır. Arazi örtüsü/ kullanımı sınıfları, Anderson (2001) sınıflandırma sistemine göre belirlenmiştir. Bu bölümde çalışma alanına ait arazi çalışması ve yersel veriler, kullanılan veri ve yazılım, sınıflandırma işlemi ve kernel fonksiyonlarının konfigürasyonu, model tasarımı ve ayrıca sınıflandırılmış görüntülerin doğruluk analizi anlatılmıştır.

3.1 Çalışma Alanı

İlk çağlardan beri, ticaret yolları üzerinde bulunması, verimli topraklara sahip olması ve tarıma uygun iklimi nedeniyle Aydın ili önemli bir yerleşim merkezi haline getirmiştir. Coğrafi konumu itibarıyla 37°-44' ve 38°-08' kuzey enlemleri ile 27°-23' ve 28°-52' doğu boylamları arasında bulunan Aydın ili Ege bölgesinin güneybatı kısmında yer almaktadır. Kuzeyinde İzmir ve Manisa, doğusunda Denizli ve güneyinde Muğla illeri yer almaktadır (Şekil 3.1).

İlin orta ve batı kesimi verimli ovalarla, kuzeyi ve güneyi ise dağlarla çevrilidir. Sahip olduğu uygun iklimi ve her türlü bitkisel üretimin yapılmasına olanak sağlayan verimli toprak yapısı ile Aydın ili önemli bir tarım potansiyeline sahiptir ve Türkiye'nin polikültürel tarım alanlarından birisidir. Tarım ilde önemli bir geçim kaynağıdır ve toplam nüfusun yaklaşık %55 i geçimini tarımdan sağlamaktadır. Tarımın hemen her dalında faaliyet gösterilmektedir. Sanayi bitkilerinin yanı sıra tarla, bağ ve bahçe ürünleri yetiştiren işletmeler fazladır. İlin en çok katma değer yaratan bitkisel ürünleri ise pamuk, zeytin, incir ve kestanedir. Aydın, zeytin, incir, kestanede Türkiye genelinde birinci sırada, pamuk üretiminde ise ikinci sırada yer almaktadır [50].




Şekil 3.1 Çalışma alanı

3.2 Arazi Çalışması ve Kullanılan Eğitim Verisi

Çalışma alanında uydu görüntülerinin elde edilme tarihi ile eş zamanlı olarak arazi çalışması gerçekleştirilmiştir. Bir el-GPS cihazı ile Anderson sınıflandırma sistemine bağlı olarak belirlenen arazi örtüsü/kullanımı sınıflarına ait konum bilgileri toplanmıştır. Toplam 70 adet örnek alınmış olup koordinat ve arazi örtüsü/kullanım şekli bilgileri kaydedilmiştir. Bu arazi çalışması Ege Üniversitesi Ziraat Fakültesi Toprak Bilimi ve Bitki Besleme Bölümü tarafından gerçekleştirilmiştir. Şekil 3.2 çalışma alanındaki sınıflara ait birer adet örnek içermektedir.

Bir sonraki adım olarak, sınıflandırma için gerekli eğitim verisi ve arazi çalışması sonucu kaydedilmiş verilerden faydalanarak doğruluk analizinde kullanılacak referans (test) verileri için bir veri tabanı oluşturulmuştur. Çalışma alanına ait arazi örtüsü/kullanımı sınıflarının eğitim ve referans (test) verilerinin oluşturulması aşaması arazi çalışmasını gerçekleştiren uzman ekibin görüş ve önerilerine dayanılarak tamamlanmıştır.

RapidEye görüntüsünün sınıflandırılmasında kullanılan eğitim verisi 11585 pikselden oluşmaktadır. Bu da toplam görüntü pikselinin yaklaşık %0,3'ü ne denk gelmektedir. SPOT görüntüsünün sınıflandırılmasında kullanılan eğitim verisi 1287 pikselden oluşmaktadır. Bu da toplam görüntü pikselinin yaklaşık %0,1'i ne denk gelmektedir. Çalışmada kullanılan RapidEye ve SPOT uydu görüntülerine ait eğitim veri seti ve arazi kullanımı sınıf türleri Çizelge 3.1' de görüldüğü gibi belirlenmiştir.




Şekil 3.2 Çalışma alanında ürün desenine ait örnekler

Çizelge 3.1 Eğitim Veri Seti


Sınıf	Eğitim Veri Seti	
	RapidEye	SPOT
Birinci evre Mısır	1022	119
İkinci evre Mısır	1033	100
Üçüncü evre Mısır	445	53
İyi pamuk	1121	112
Orta Pamuk	1251	117
Zayıf Pamuk	1049	90
Islak toprak	1300	136
Nemli toprak	1000	119
Kuru toprak	800	126
Su yüzeyi	501	114
Yerleşim Alanı/Kent	1450	68
Çayır ve mera alanı	613	133
Toplam	11585	1287

Çalışmada kullanılan eğitim verilerine ait görseller Şekil 3.3 ve Şekil 3.4'te görülmektedir.



Şekil 3.3 RapidEye Eğitim Verisi

Eğitim Verisi (SPOT5)



Şekil 3.4 SPOT5 Eğitim Verisi

Bu çalışmada kullanılan eğitim verilerine ait istatistiksel bilgiler Çizelge 3.2 ve Çizelge 3.3'te görülmektedir.

Çizelge 3.2 RapidEye Eğitim Veri Seti İstatistiksel Bilgiler

Sınıf Türü	Bant Türü	Piksel Gri değerleri			
	Band	En az	En Çok	Ort. Değer	Standart sapma
1.evre mısır	Band 1	4945	6144	5550.426	200.77
	Band 2	3962	5480	4641.605	281.81
	Band 3	2348	3723	2860.705	247.16
	Band 4	3067	4973	3938.992	353.92
	Band 5	6647	9942	8534.003	892.41
2.evre mısır	Band 1	4852	5825	5408.556	138.41
	Band 2	3931	4903	4432.118	145.02
	Band 3	2224	2858	2509.336	89.83
	Band 4	3342	4268	3829.989	153.16
	Band 5	9177	12327	10811.15	951.28
3.evre mısır	Band 1	5895	7051	6419.178	215.58
	Band 2	5436	6734	6160.708	234.87
	Band 3	3474	5684	4426.573	346.69
	Band 4	5216	6768	6066.065	282.16
	Band 5	8497	10859	9570.798	445.42

Çizelge 3.2 RapidEye Eğitim Veri Seti İstatistiksel Bilgiler (devam)

Sınıf Türü	Bant Türü	Piksel Gri değerleri			
		En az	En Çok	Ort. Değer	Standartsapma
İyi Pamuk	Band 1	5241	6223	5741.468	164.30
	Band 2	4476	5853	5070.779	219.59
	Band 3	2369	3276	2794.376	167.05
	Band 4	5043	6696	5687.915	313.67
	Band 5	14021	16989	15423.12	572.41
Orta Pamuk	Band 1	5429	6441	5901.741	185.25
	Band 2	4553	6246	5418.098	336.96
	Band 3	2600	3518	3101.369	174.43
	Band 4	4703	7298	6088.02	558.90
	Band 5	9403	14685	12770.39	977.44
Zayıf Pamuk	Band 1	5423	7225	6291.521	331.65
	Band 2	5004	7524	6275.636	593.47
	Band 3	3021	5812	4189.230	747.04
	Band 4	5309	7423	6604.981	378.62
	Band 5	8182	12635	10502.70	1003.27
Islak Toprak	Band 1	5411	7083	6024.158	197.39
	Band 2	4866	6176	5593.232	224.82
	Band 3	3348	5754	4210.182	457.20
	Band 4	4652	6300	5260.197	325.59
	Band 5	5618	9071	7501.165	538.54
Nemli Toprak	Band 1	7673	10748	9125.913	688.10
	Band 2	7939	11831	9663.230	920.69
	Band 3	8355	13138	10049.53	1036.87
	Band 4	7282	11683	8849.208	901.89
	Band 5	7122	12274	8904.926	1195.34
Kuru Toprak	Band 1	5475	8009	6457.711	583.70
	Band 2	4862	7664	5963.311	803.92
	Band 3	4150	8294	5880.056	1198.67
	Band 4	4667	7302	5840.718	767.54
	Band 5	5411	7619	6682.148	562.76
Su Yüzeyi	Band 1	4917	6999	5985.234	633.14
	Band 2	3292	6297	5002.259	1063.03
	Band 3	1715	4783	3404.281	1143.73
	Band 4	1797	3783	2810.337	626.87
	Band 5	1124	3914	1733.623	323.16
Kent	Band 1	5945	14194	9268.468	1153.06
	Band 2	5102	13955	9140.069	1306.49
	Band 3	3835	13833	8821.459	1501.00
	Band 4	4530	11033	7923.962	968.67
	Band 5	5153	11804	8318.985	847.42
Çayır ve Mera Alanı	Band 1	5848	9784	7573.879	1089.77
	Band 2	5246	10149	7150.178	1461.01
	Band 3	4253	10471	6899.703	1756.12
	Band 4	4574	9312	6475.292	1361.62
	Band 5	5341	9144	6919.235	1052.53

Çizelge 3.3 SPOT5 Eğitim Veri Seti İstatistiksel Bilgiler

Sınıf Türü	Band Türü	Piksel Gri değerleri			
		En az	En Çok	Ort. Değer	Standart sapma
1.evre mısır	Band 1	131	176	150.983	14.85
	Band 2	45	52	48.076	1.84
	Band 3	58	63	60.555	1.33
	Band 4	51	61	55.588	2.63
2.evre mısır	Band 1	117	162	139.45	13.87
	Band 2	46	55	50.020	2.28
	Band 3	61	67	63.780	1.36
	Band 4	47	61	53.850	4.96
3.evre mısır	Band 1	137	168	156.132	7.46
	Band 2	58	67	63.0189	2.56
	Band 3	72	80	76.811	2.01
	Band 4	53	62	58.453	2.23
İyi Pamuk	Band 1	212	255	232.705	9.18
	Band 2	46	55	50.286	2.06
	Band 3	65	72	68.786	1.66
	Band 4	64	69	65.938	1.26
Orta Pamuk	Band 1	185	224	201.966	10.62
	Band 2	49	57	53.564	2.03
	Band 3	66	74	71.282	2.25
	Band 4	59	65	62.658	1.52
Zayıf Pamuk	Band 1	148	181	167.633	8.28
	Band 2	53	67	56.4333	3.90
	Band 3	70	81	73.422	3.09
	Band 4	56	71	60.722	4.06
Islak Toprak	Band 1	95	156	132.074	19.53
	Band 2	51	74	58.721	6.39
	Band 3	65	80	69.603	3.79
	Band 4	53	76	62.772	6.15
Nemli Toprak	Band 1	110	135	125.219	5.66
	Band 2	119	170	157.135	9.02
	Band 3	105	129	123.202	3.48
	Band 4	88	112	106.084	5.26
Kuru Toprak	Band 1	134	150	142.905	4.50
	Band 2	50	58	54.151	1.86
	Band 3	62	71	66.444	2.57
	Band 4	53	61	57.659	2.17
Su yüzeyi	Band 1	32	58	41.509	5.98
	Band 2	38	91	69.684	22.58
	Band 3	52	91	75.263	15.37
	Band 4	16	36	23.307	5.21
Kent	Band 1	79	130	107.824	9.64
	Band 2	76	150	117.662	16.66
	Band 3	78	141	104.441	12.49
	Band 4	78	103	89.250	5.98
Çayır ve Mera Alanı	Band 1	74	91	81.173	3.07
	Band 2	68	97	82.188	4.47
	Band 3	68	85	75.391	2.81
	Band 4	61	100	77.0451	7.29

3.3 Materyal ve Yöntem

3.3.1 Kullanılan Veriler

Bu çalışmada yüksek çözünürlüklü uydu görüntülerinden 23 Ağustos 2012 tarihli RapidEye, 5 Ağustos 2012 tarihli SPOT uydu görüntüleri ve arazi çalışmaları sonucu elde edilen yer gerçeği verisi kullanılmıştır.

3.3.1.1 RapidEye

RapidEye, merkezi Kanada’da bulunan MDA (MacDonald, Dettwiler and Associates) şirketi tarafından Alman RapidEye A.Ş için tasarlanan ve 29 Ağustos 2008 tarihinde Kazakistan Baykonur uzay üssünden uzaya fırlatılan ticari amaçlı bir uydudur. RapidEye uydusu öncelikli olarak hassas tarım çalışmaları ve araştırmaları yapan uluslararası şirketler ve enstitülere ve ayrıca askeri/ticari amaçlı güncel uydu haritası üretimi yapımına veri sağlamak amacıyla uzaya gönderilmiştir [52].

RapidEye uydusu, birbirine kalibre ve aynı yörüngede hareket eden aynı algılayıcıları içeren 5 adet mini uydudan oluşmaktadır. Bu uydular takım halinde çalışmaktadır ve günde 4 milyon km²’nin üzerinde bir alanı 5m’lik çözünürlüğe sahip 5 farklı spektral bantta kaydetme özelliğine sahiptir [52].

Uydunun teknik özellikleri Çizelge 3.4’ de görülmektedir.

Çizelge 3.4 RapidEye Uydusu Teknik Özellikleri

Uydu Sayısı	5	
Tahmini Ömür	7 sene	
Yörünge Yüksekliği	630 km. Güneşe eşzamanlı	
Ekvator Geçiş Zamanı	11:00 (tahmini)	
Spektral Bantlar (nm)	<u>Bant Türü</u>	<u>Spektral Aralık(nm)</u>
	Mavi	440 – 510
	Yeşil	520 – 590
	Kırmızı	630 - 685
	Kırmızı Kenar	690 – 730
	Yakın Kızılötesi	760 – 850
Yersel Örnekleme Aralığı (nadir)	6.5 m	

Çizelge 3.4 RapidEye Uydu Teknik Özellikleri (devam)

Piksel Boyutu (ortorektifiye edilmiş)	5 m
Çerçeve Genişliği	77 km
Uydu Üzerindeki Veri Saklama Kapasitesi	Her yörünge geçişi için 1500km’lik veri toplama kapasitesi
Yeniden Geçiş Zamanı	5.5 gün (nadir)
Görüntü Çekme Kapasitesi	4 milyon km ² / gün
Dinamik Aralığı	12 bit

RapidEye uydu görüntüsünü diğer çok bantlı uydu görüntülerinden ayıran en önemli özelliği standart bantların yanı sıra klorofil içeriğine duyarlı olan, elektromanyetik spektrumun 690-730 nm aralığında algılama yapan kırmızı kenar (redegde) bandına sahip ilk yüksek çözünürlüklü uydu görüntüsü olmasıdır [52].

RapidEye firması müşterilerine, isteklerine bağlı olarak veri işleme seviyesine göre iki farklı seviyede veri sunmaktadır (Çizelge 3.5).

Çizelge 3.5 RapidEye veri işleme seviyeleri


Veri İşleme Seviyesi (Seviye)	Teknik Özellikleri
1B	RapidEye Temel Ürün Radyometrik ve algılayıcı düzeltmeleri veriye uygulanmıştır. Geometrik düzeltme uygulanmamış, kullanıcının kendisinin yapması tercih edilmiştir.
3A	RapidEye Orto Ürün Geometrik, radyometrik ve algılayıcı düzeltmeleri veriye uygulanmıştır. Geometrik düzeltme işleminde SYM (30-90m) ve YKN’ler kullanılmıştır.

Bu çalışmada RapidEye ortogörüntüsü kullanılmıştır (Şekil 3.5). Kullanılan uydu görüntüsüne ait detaylar Çizelge 3.6’de görülmektedir.

Çizelge 3.6 Kullanılan Uydu Görüntüsünün Özellikleri

Görüntü Özellikleri	Tanımı
Format	GeoTIFF
Piksel Boyutu	5 m
Radyometrik Çözünürlük	16 bit unsigned
Görüntünün Boyutu (megabayt)	250
Geometrik Düzeltme	YKN ve SYM
Datum	WGS84
Harita Projeksiyonu	UTM

RapidEye uydu görüntüsünün başlıca kullanım alanları; tarım, ormancılık, çevre, enerji ve altyapı sistemleri, harita üretimi, güvenlik ve acil hizmetlerdir.



Şekil 3.5 Çalışma Alanı RapidEye uydu görüntüsü

3.3.1.2 SPOT

SPOT (Système Pour l'Observation de la Terre/ Yer Gözlem Sistemi) yüksek çözünürlüklü yer gözlem uydusu, Belçika ve İsveç'in de ortaklığında 1978 yılında Fransız SPOT Image firması tarafından yeryüzüne ilişkin doğal kaynakların izlenmesi ve yönetimi üzerine bilgi elde etmek ve yeryüzü kaynaklarının yönetimini geliştirmek amacıyla tasarlanmıştır. İlk SPOT uydusu olan SPOT-1 uydusu 22 Şubat 1986 yılında fırlatılmıştır. SPOT uydusu bugüne kadar 6 seri halinde farklı tarihlerde ve özelliklerde uzaya gönderilmiştir. En son gönderilen SPOT uydusu, 9 Eylül tarihinde Hindistan'dan gönderilen SPOT-6 uydusudur. SPOT-7 uydusunun da 2014 yılında gönderilmesi planlanmaktadır. SPOT 6 ve 7 uyduları Alman Uzay ve Havacılık Ajansı'nın (DLR) uyduları olan TerraSAR-X ve TanDEM-X radar uyduları ile etkileşimli olarak işleyecektir. Çalışmada SPOT-5 uydu görüntüsü kullanılmıştır. SPOT-5 uydusunun teknik özellikleri Çizelge 3.7' de görülmektedir.

Çizelge 3.7 SPOT-5 uydusunun teknik özellikleri


Yörünge	Güneş Senkronize - Yakın Kutupsal
Yörünge Yüksekliği	822 km (Ekvatorda)
Yörünge Periyodu	101,4 dakika
Yörünge Döngüsü	26 gün
Tekrarlı Geçiş Süresi	2-3 gün, enleme göre değişken
Tarama Alanı	60 Km x 60 Km - 80 Km nadirde
Metrik Doğruluk	30 m yatay konum doğruluğu (CE90%)
Radyometrik Çözünürlük	8 bit
Mekansal Çözünürlük	Pan: 2.5m (2 adet 5m çözünürlüklü çerçeveden üretim) Pan: 5m (nadir) MS: 10m (nadir) KISADALGA KÖ: 20m (nadir)
Spektral Bantlar	Pan: 480-710 nm Yeşil: 500-590 nm Kırmızı: 610-680 nm Yakın KÖ: 780-890 nm Kısadalga KÖ: 1,580-1,750 nm
Algılama açısı	±31.060

SPOT Image firması, SPOT-5 uydu görüntüsü için müşterilerine değişen isteklerine bağlı olarak veri işleme derecesine göre beş farklı seviyede veri sunmaktadır (Çizelge 3.8).

Çizelge 3.8 SPOT Veri İşleme Seviyeleri

Ürün Tipi	Açıklamalar
Seviye 1A	Ham veri ürünü
Seviye 1B	Sistem düzeltmesi getirilmiş veri ürünü
Seviye 2A	Yer kontrol noktası olmaksızın koordinatlandırılmış ürün
Seviye 2B	Yer kontrol noktası ile koordinatlandırılmış ürün
Seviye 3	Ortorektifiye ürünler

Çalışmada Level 2A verisi kullanılmıştır. Level 2A olarak işlenmiş görüntü ürünü; standart bir projeksiyonda (UTM) tanımlanmış koordinat bilgisine (WGS84) sahiptir.



Şekil 3.6 Çalışma Alanı SPOT 5 uydu görüntüsü

Orjinalinde 20 metre mekansal çözünürlüğe sahip olan kırsal kızıltötesi (SWIR) bandı, 10 metreye örneklenerek kullanıcıya sunulmaktadır. Çalışma alanına ait 1,2,3 bant sıralamasındaki SPOT-5 uydu görüntüsü Şekil 3.6’ da görüldüğü gibidir.

3.3.2 Yöntem

Öncelikle RapidEye ve SPOT görüntülerini birbirine karşılaştırılmış daha sonra sınıflandırma işlemlerini gerçekleştirmek üzere kernel fonksiyonlarının konfigürasyonu ve model tasarımı yapılmıştır.

3.3.2.1 Görüntülerin Çakıştırılması

Sınıflandırma işleminden önce, aynı yer örnekleri kullanılarak sınıflandırma yapılacağı ve karşılaştırmalı analiz gerçekleştirileceği için uydu görüntülerinin Erdas Imagine programı yardımıyla karesel ortalama hatanın (RMSE) 0,5 pixelden küçük olmasına dikkat edilerek çakıştırılması (görüntünün görüntüye register edilmesi) işlemi gerçekleştirilmiştir.

3.3.2.2 Uydu Görüntülerinin Sınıflandırılması

Uydu görüntülerinin sınıflandırılması aşaması ENVI uzaktan algılama ve görüntü işleme yazılımının En Çok Benzerlik ve Destek Vektör Makinaları algoritmaları kullanılarak gerçekleştirilmiştir. EÇB sınıflandırma işlemi, ENVI yazılımının sınıflandırma modülü kullanılarak gerçekleştirilmiştir. EÇB yöntemi literatürde kabul görmüş bir yöntemdir ve farklı sınıflandırma yöntemlerinin başarısı EÇB yöntemi ile kıyaslanarak gösterilmektedir. Destek Vektör Makineleri sınıflandırma yöntemi ise son yıllarda uydu görüntülerinin sınıflandırılması işleminde sıklıkla kullanılmakta ve başarılı sonuçlar vermektedir. Özellikle sınıflandırma işleminde EÇB yöntemine kıyasla uygun parametre kombinasyonu kullanılmak şartıyla daha yüksek doğruluğa sahip olduğu birçok bilimsel çalışma ile kanıtlanmıştır. Sınıflandırma işleminde dört farklı kernel (lineer, polinom, radyal tabanlı fonksiyon, sigmoid) ile 139 farklı model oluşturulmuş ve bu 139 model sırasıyla RapidEye ve SPOT görüntüleri üzerinde test edilmiştir (Çizelge 3.12).

3.4 Kernel Fonksiyonlarının Konfigürasyonu ve Model Tasarımı

DVM sınıflandırma işleminde dört farklı kernel fonksiyonu ve bu fonksiyonlara ait parametrelerin farklı kombinasyonlarından meydana gelen toplam 139 adet farklı model kullanılmıştır. Sınıflandırma işleminin gerçekleşmesi için her bir kernel fonksiyonun kullanıcı tarafından tanımlanması gereken ve sınıflandırma performansını etkileyen parametreleri vardır. Hangi modelin (parametre setinin) en uygun (optimum)

olduğu (en yüksek sınıflandırma sonucu vereceği) önceden bilinmemektedir. En uygun parametre seti grid arama (grid search) metodu ile bulunmuştur.

En yüksek doğruluğa erişmek için her bir parametrenin optimum değerinde olduğu parametre setinin kullanılması gerekmektedir. Düzenleme parametresi (C) 0-1000 aralığında, polinom derecesi (d) 1-6 aralığında, bias (b) parametresi 0-7 aralığında, gama (γ) parametresi ise 0,1-0,5 aralığında alınmıştır.

Öncelikle tek parametreye sahip olduğu için lineer kernelinin sınıflandırma işlemi gerçekleştirilmiştir. Daha sonra sırası ile polinom, radyal tabanlı fonksiyon ve sigmoid kernellerinin sınıflandırma işlemi gerçekleştirilmiştir.

γ parametresi sınıflandırma işleminin başında Envi yazılımına ait kullanıcı kılavuzundaki önerilere göre bant sayısının tersi ($1/\text{bant sayısı}$) olarak belirlenmiştir. Dolayısı ile 5 bantlı RapidEye görüntüsü için 0,2, 4 bantlı SPOT görüntüsü için 0,25 alınmıştır. En uygun parametre setinin aranması işlemi her bir kernel için benzer adımlar içermektedir. Polinom kernelin sınıflandırma işlemine öncelikle en uygun d parametresinin aranması ile başlanmıştır. Bu parametre belirlenirken polinom fonksiyondaki diğer parametreler sabit tutularak d parametresi 1-6 aralığında alınmış ve elde edilen sınıflandırma doğrulukları karşılaştırılmıştır. (Çizelge 3.9 ve Çizelge 3.10). Sabit tutulan parametreler farklı kombinasyonlarda alınarak d parametresine göre tekrar sınıflandırma işlemleri yapılmış ve sınıflandırma doğrulukları karşılaştırılmıştır. Aşağıdaki çizelgelerden de görüleceği üzere birkaç deneme yapılmıştır ve en uygun polinom derecesi bulunmuştur. Çizelge 3.9 ve Çizelge 3.10'de RapidEye uydu görüntüsüne ait yapılan denemelerden, diğerlerine göre daha yüksek sınıflandırma sonuçlarına sahip olan iki farklı düzenleme (C) parametresine ait arama görülmektedir.

Çizelge 3.9 RapidEye uydu görüntüsü için Polinom derecesinin aranması işlemi I

Deneme No	d	b	γ	C	Doğruluk
D.1	1	5	0.2	800	%83.8164
D.2	2	5	0.2	800	%84.1787
D.3	3	5	0.2	800	%84.0580
D.4	4	5	0.2	800	%84.7826
D.5	5	5	0.2	800	%85,1449
D.6	6	5	0.2	800	%85,6280

Çizelge 3.10 RapidEye uydu görüntüsü için Polinom derecesinin aranması işlemi II

No	d	b	γ	C	Doğruluk
D.7	1	5	0.2	600	%82.9710
D.8	2	5	0.2	600	%83.9372
D.9	3	5	0.2	600	%84.0580
D.10	4	5	0.2	600	%85.0242
D.11	5	5	0.2	600	%85,0242
D.12	6	5	0.2	600	%84,6618

Her iki çizelgedeki sonuçlar karşılaştırıldığında C parametresinin 800 olarak tanımlandığı Çizelge 3.9’ da sunulan sınıflandırma doğrulukları daha yüksek olduğundan d değeri 6 olarak alınmıştır. C, b ve γ parametreleri en yüksek sınıflandırma doğruluğunu vermesi beklenerek tahmini olarak seçilmiştir.

Daha sonra en uygun b parametresinin aranması işlemine geçilmiştir. Bu süreçte d parametresi 6 alınarak sabitlenmiş, γ ve C parametreleri yine sabit değerde alınarak b parametresi ise 0-7 aralığında değişen değerlerde alınarak sınıflandırma işlemi yapılmıştır. Sabit tutulan parametreler farklı kombinasyonlarda alınarak değişen b parametresine göre sınıflandırma işlemine devam edilmiştir ve elde edilen sınıflandırma sonuçları karşılaştırılmıştır. Çizelge 3.11 ve Çizelge 3.12’da RapidEye uydu görüntüsüne ait yapılan denemelerden ,diğerlerine göre daha yüksek sınıflandırma sonuçlarına sahip olan iki farklı düzenleme (C) parametresine ait arama görülmektedir.

Çizelge 3.11 RapidEye uydu görüntüsü için Bias parametresinin aranması işlemi I

No	d	b	γ	C	Doğruluk
D.13	6	0	0.2	800	gerçekleşmedi
D.14	6	1	0.2	800	%84.1787
D.15	6	2	0.2	800	%84.7826
D.16	6	3	0.2	800	%85.2657
D.17	6	4	0.2	800	%85,0242
D.18	6	5	0.2	800	%85,6280
D.19	6	6	0.2	800	%84,9034
D.20	6	7	0.2	800	%84,6618

Çizelge 3.12 RapidEye uydu görüntüsü için Bias parametresinin aranması işlemi II

No	d	b	γ	C	Doğruluk
D.21	6	0	0.2	600	%44,3237
D.22	6	1	0.2	600	%84.2995
D.23	6	2	0.2	600	%84.0242
D.24	6	3	0.2	600	%85.1449
D.25	6	4	0.2	600	%85,6280
D.26	6	5	0.2	600	%84,6618
D.27	6	6	0.2	600	%84,2995
D.28	6	7	0.2	600	%84,9034


Denemeler sonucunda en uygun b parametresi 5 olarak bulunmuştur. Daha sonra bu en uygun d parametresini veren parametre kombinasyonunda (modellerde) b parametresinin 5 olup olmadığı kontrol edilmiştir. Bias (b) parametresi 5 olduğu için C parametresinin bulunması işlemine geçilmiştir. Bias parametresi 5 değerinde olmaması durumunda ise tüm işlemler baştan itibaren tekrar yapılacaktır.

En uygun C parametresinin aranması işleminde; d parametresi 6, b parametresi 5 ve γ parametresi 0.2 olarak alınmış, C parametresi ise 0-1000 aralığında 100'er aralıklarla alınarak sınıflandırma işlemi gerçekleştirilmiştir ve elde edilen sınıflandırma sonuçları karşılaştırılmıştır (Çizelge 3.13).

Çizelge 3.13 RapidEye uydu görüntüsü için Düzenleme Parametresinin aranması işlemi

No	d	b	γ	C	Doğruluk
D.29	6	5	0,2	0	%82,8502
D.30	6	5	0,2	100	%84,9034
D.31	6	5	0,2	200	%85,5072
D.32	6	5	0,2	300	%84,9034
D.33	6	5	0,2	400	%84,6618
D.34	6	5	0,2	500	%85,1449
D.35	6	5	0,2	600	%84,6618
D.36	6	5	0,2	700	%85,0242
D.37	6	5	0,2	800	%85,6280
D.38	6	5	0,2	900	%85,1449
D.39	6	5	0,2	1000	%84,9034

En uygun C parametresi 800 olarak bulunmuştur. Eğer önceki parametrelerin en uygun değerlerinin aranması işlemlerinde C parametresi 800 olarak alınmış ise en uygun parametre setinin aranması işlemi polinom fonksiyon için sonra ermiştir, değil ise tüm işlemler baştan itibaren yapılacaktır. Daha sonra bulunan bu üç parametrenin en uygun değerleri alınarak 0,1-0,5 aralığında değişen değerlerle γ parametresinin en uygun değeri aranmış ve γ parametresinin bir etkisi olmadığı gözlenmiştir. Böylece RapidEye uydu görüntüsü için polinom kerneline ait en uygun parametre seti $(d,b,\gamma,C)=(6,5,0.2,800)$ olarak bulunmuştur. Polinom fonksiyonda gerçekleştirilen en uygun parametre arama adımları diğer kernel fonksiyonları için de değişen parametre setlerine bağlı olarak aynı şekilde gerçekleştirilmiştir. RapidEye görüntüsü için gerçekleştirilen bu adımlar, değişen parametreler ve modellere bağlı olarak SPOT uydu görüntüsü için de gerçekleştirilmiştir. Genel iş akış şeması Şekil 3.7 'de görülmektedir. Sonuçta 139 adet farklı model ortaya çıkmıştır (Çizelge 3.14).



Şekil 3.7 İş Akış Şeması

Çizelge 3.14 Model Tablosu

K.Türü (Görüntü)	Model No	d	b	γ	C
LINEER (RapidEye ve SPOT)	ML1	X	x	x	0
	ML2	x	x	x	100
	ML3	x	x	x	200
	ML4	x	x	x	300
	ML5	x	x	x	400
	ML6	x	x	x	500
	ML7	x	x	x	600
	ML8	x	x	x	700
	ML9	x	x	x	800
	ML10	x	x	x	900
	ML11	x	x	x	1000
Polinom (RapidEye)	MP1	6	5	0,2	0
	MP2	6	5	0,2	100
	MP3	6	5	0,2	200
	MP4	6	5	0,2	300
	MP5	6	5	0,2	400
	MP6	6	5	0,2	500
	MP7	6	5	0,2	600
	MP8	6	5	0,2	700
	MP9	6	5	0,2	800
	MP10	6	5	0,2	900
	MP11	6	5	0,2	1000
	MP12	6	0	0,2	800
	MP13	6	1	0,2	800
	MP14	6	2	0,2	800
	MP15	6	3	0,2	800
	MP16	6	4	0,2	800
	MP17	6	6	0,2	800
	MP18	6	7	0,2	800
	MP19	1	5	0,2	800
	MP20	2	5	0,2	800
	MP21	3	5	0,2	800
	MP22	4	5	0,2	800
	MP23	5	5	0,2	800
	MP24	6	5	0,1	800
	MP25	6	5	0,3	800
	MP26	6	5	0,4	800
	MP27	6	5	0,5	800
Polinom (SPOT)	MP28	3	6	0,25	0
	MP29	3	6	0,25	100
	MP30	3	6	0,25	200
	MP31	3	6	0,25	300

Çizelge 3.14 Model Tablosu (devam)

K. Türü (Görüntü)	Model No	d	b	γ	C
Polinom (SPOT)	MP32	3	6	0,25	400
	MP33	3	6	0,25	500
	MP34	3	6	0,25	600
	MP35	3	6	0,25	700
	MP36	3	6	0,25	800
	MP37	3	6	0,25	900
	MP38	3	6	0,25	1000
	MP39	3	0	0,25	600
	MP40	3	1	0,25	600
	MP41	3	2	0,25	600
	MP42	3	3	0,25	600
	MP43	3	4	0,25	600
	MP44	3	5	0,25	600
	MP45	3	7	0,25	600
	MP46	1	6	0,25	600
	MP47	2	6	0,25	600
	MP48	4	6	0,25	600
	MP49	5	6	0,25	600
	MP50	6	6	0,25	600
	MP51	3	6	0,1	600
	MP52	3	6	0,3	600
	MP53	3	6	0,4	600
	MP54	3	6	0,5	600
Radyal Tabanlı (RapidEye)	MR1	x	x	0,2	0
	MR2	x	x	0,2	100
	MR3	x	x	0,2	200
	MR4	x	x	0,2	300
	MR5	x	x	0,2	400
	MR6	x	x	0,2	500
	MR7	x	x	0,2	600
	MR8	x	x	0,2	700
	MR9	x	x	0,2	800
	MR10	x	x	0,2	900
	MR11	x	x	0,2	1000
	MR12	x	x	0,1	800
	MR13	x	x	0,3	800
	MR14	x	x	0,4	800
	MR15	x	x	0,5	800
Radyal Tabanlı (SPOT)	MR16	x	x	0,25	0
	MR17	x	x	0,25	100
	MR18	x	x	0,25	200
	MR19	x	x	0,25	300

Çizelge 3.14 Model Tablosu (devam)

K.Türü (Görüntü)	Model No	d	b	γ	C
Radyal Tabanlı (SPOT)	MR20	x	x	0,25	400
	MR21	x	x	0,25	500
	MR22	x	x	0,25	600
	MR23	x	x	0,25	700
	MR24	x	x	0,25	800
	MR25	x	x	0,25	900
	MR26	x	x	0,25	1000
	MR27	x	x	0,1	1000
	MR28	x	x	0,3	1000
	MR29	x	x	0,4	1000
	MR30	x	x	0,5	1000
Sigmoid(RapidEye)	MS1	x	0	0,2	0
	MS2	x	0	0,2	100
	MS3	x	0	0,2	200
	MS4	x	0	0,2	300
	MS5	x	0	0,2	400
	MS6	x	0	0,2	500
	MS7	x	0	0,2	600
	MS8	x	0	0,2	700
	MS9	x	0	0,2	800
	MS10	x	0	0,2	900
	MS11	x	0	0,2	1000
	MS12	x	1	0,2	800
	MS13	x	2	0,2	800
	MS14	x	3	0,2	800
	MS15	x	4	0,2	800
	MS16	x	5	0,2	800
	MS17	x	6	0,2	800
	MS18	x	7	0,2	800
	MS19	x	0	0,1	800
	MS20	x	0	0,3	800
	MS21	x	0	0,4	800
	MS22	x	0	0,5	800
Sigmoid (SPOT)	MS23	x	0	0,25	0
	MS24	x	0	0,25	100
	MS25	x	0	0,25	200
	MS26	x	0	0,25	300
	MS27	x	0	0,25	400
	MS28	x	0	0,25	500
	MS29	x	0	0,25	600
	MS30	x	0	0,25	700
	MS31	x	0	0,25	800

Çizelge 3.14 Model Tablosu (devam)

K.Türü (Görüntü)	Model No	d	b	γ	C
Sigmoid (SPOT)	MS32	x	0	0,25	900
	MS33	x	0	0,25	1000
	MS34	x	1	0,25	600
	MS35	x	2	0,25	600
	MS36	x	3	0,25	600
	MS37	x	4	0,25	600
	MS38	x	5	0,25	600
	MS39	x	6	0,25	600
	MS40	x	7	0,25	600
	MS41	x	0	0,1	600
	MS42	x	0	0,3	600
	MS43	x	0	0,4	600
	MS44	x	0	0,5	600

3.5 Doğruluk Analizi

Sınıflandırılmış görüntülerin doğruluk analizi, hata matrisleri ve kappa katsayısı yardımıyla yapılmıştır. Kappa, yer gerçeklik verisine dayalı olarak sınıflandırılmış görüntünün karşılaştırılarak sınıflandırma doğruluğunun elde edilmesinde sıklıkla kullanılan bir indekstir [51].

Doğruluk analizi için kullanılacak referans (test) verileri, araziye ait örneklem kümesi kullanılarak görsel yorumlamaya dayalı sınıfların kapladığı alan bazında oluşturulmuştur (yardımcı veri). Örneğin birinci evre mısır sınıfına ait alan görsel olarak yorumlandığında diğer sınıflara oranla fazla olduğundan o sınıfa ait doğruluk analizinde kullanılmak üzere daha fazla nokta üretilmiştir.

RapidEye ve SPOT uydu görüntüleri için sınıflandırma doğrulukları Çizelge 3.15, Çizelge 3.16 ve Çizelge 3.17’de görüldüğü gibi elde edilmiştir.

Çizelge 3.15 RapidEye görüntüsüne ait sınıflandırma doğrulukları

Model No	Doğruluk	Kappa
ML1	%74,2754	0,7157
ML2	%83,0918	0,8128
ML3	%83,8164	0,8209
ML4	%83,5749	0,8182
ML5	%83,5749	0,8183

Çizelge 3.15 RapidEye görüntüsüne ait sınıflandırma doğrulukları (devam)

Model No	Doğruluk	Kappa
ML6	%83,4541	0,8170
ML7	%83,3333	0,8156
ML8	%83,4541	0,8169
ML9	%83,8164	0,8209
ML10	%83,5749	0,8183
ML11	%83,9372	0,8223
MP1	%82,8502	0,8101
MP2	%84,9034	0,8330
MP3	%85,5072	0,8397
MP4	%84,9034	0,8331
MP5	%84,6618	0,8304
MP6	%85,1449	0,8357
MP7	%84,6618	0,8304
MP8	%85,0242	0,8344
MP9	%85,6280	0,8411
MP10	%85,1449	0,8357
MP11	%84,9034	0,8330
MP12	gerçekleşmedi	
MP13	%84,1787	0,8249
MP14	%84,7826	0,8317
MP15	%85,2657	0,8370
MP16	%85,0242	0,8344
MP17	%84,9034	0,8330
MP18	%84,6618	0,8304
MP19	%83,8164	0,8209
MP20	%84,1787	0,8250
MP21	%84,0580	0,8237
MP22	%84,7826	0,8317
MP23	%85,1449	0,8357
MP24	%85,6280	0,8411
MP25	%85,6280	0,8411

Çizelge 3.15 RapidEye görüntüsüne ait sınıflandırma doğrulukları (devam)

Model No	Doğruluk	Kappa
MP26	%85,6280	0,8411
MP27	%85,6280	0,8411
MR1	%72,1014	0,6907
MR2	%83,0918	0,8128
MR3	%83,3333	0,8155
MR4	%83,5749	0,8182
MR5	%83,9372	0,8222
MR6	%83,9372	0,8222
MR7	%83,8164	0,8209
MR8	%83,8164	0,8209
MR9	%83,6957	0,8196
MR10	%83,8164	0,8209
MR11	%83,8164	0,8209
MR12	%83,6957	0,8196
MR13	%83,6957	0,8196
MR14	%83,6957	0,8196
MR15	%83,6957	0,8196
MS1	%72,1014	0,6906
MS2	%82,2464	0,8034
MS3	%83,2126	0,8142
MS4	%83,0918	0,8128
MS5	%83,0918	0,8128
MS6	%83,0918	0,8128
MS7	%82,9710	0,8115
MS8	%83,3333	0,8155
MS9	%83,8164	0,8209
MS10	%83,8164	0,8209
MS11	%83,8164	0,8209
MS12	%82,9710	0,8115
MS13	%81,8841	0,7994
MS14	%78,2609	0,7594

Çizelge 3.15 RapidEye görüntüsüne ait sınıflandırma doğrulukları (devam)

Model No	Doğruluk	Kappa
MS15	%75,8454	0,7327
MS16	%73,9130	0,7118
MS17	%69,8068	0,6664
MS18	%59,4203	0,5483
MS19	%83,8164	0,8209
MS20	%83,8164	0,8209
MS21	%83,8164	0,8209
MS22	%83,8164	0,8209

Çizelge 3.16 SPOT görüntüsüne ait sınıflandırma doğrulukları

Model No	Doğruluk	Kappa
ML1	%46,8085	0,4214
ML2	%67,6123	0,6461
ML3	%68,3215	0,6539
ML4	%68,3215	0,6537
ML5	%68,3215	0,6537
ML6	%69,0307	0,6614
ML7	%69,5035	0,6665
ML8	%69,5035	0,6665
ML9	%68,7943	0,6588
ML10	%69,2671	0,6639
ML11	%69,2671	0,6640
MP28	%53,6643	0,4953
MP29	%70,6856	0,6795
MP30	%71,1584	0,6846
MP31	%71,6312	0,6898
MP32	%72,3404	0,6976
MP33	%73,0496	0,7053
MP34	%73,2861	0,7078
MP35	%72,8132	0,7027

Çizelge 3.16 SPOT görüntüsüne ait sınıflandırma doğrulukları (devam)

Model No	Doğruluk	Kappa
MP36	%72,8132	0,7027
MP37	%73,0496	0,7052
MP38	%72,8132	0,7026
MP39	%63,1206	0,5971
MP40	%69,5035	0,6666
MP41	%70,9220	0,6821
MP42	%71,3948	0,6873
MP43	%72,1040	0,6950
MP44	%72,5768	0,7001
MP45	%72,8132	0,7027
MP46	%68,7943	0,6591
MP47	%69,7400	0,6692
MP48	%72,8132	0,7028
MP49	%68,7943	0,6593
MP50	%66,9031	0,6388
MP51	%73,2861	0,7078
MP52	%73,2861	0,7078
MP53	%73,2861	0,7078
MP54	%73,2861	0,7078
MR16	%45,8629	0,4108
MR17	%66,4303	0,6322
MR18	%68,5579	0,6564
MR19	%69,0307	0,6616
MR20	%69,0307	0,6616
MR21	%69,0307	0,6616
MR22	%69,2671	0,6640
MR23	%69,2671	0,6640
MR24	%69,9764	0,6718
MR25	%70,6856	0,6795

Çizelge 3.16 SPOT görüntüsüne ait sınıflandırma doğrulukları (devam)

Model No	Doğruluk	Kappa
MR26	%70,9220	0,6821
MR27	%70,9220	0,6821
MR28	%70,9220	0,6821
MR29	%70,9220	0,6821
MR30	%70,9220	0,6821
MS23	%46,3357	0,4156
MS24	%66,1939	0,6306
MS25	%66,4303	0,6333
MS26	%67,8487	0,6487
MS27	%68,3215	0,6538
MS28	%68,3215	0,6539
MS29	%69,2671	0,6643
MS30	%68,0851	0,6513
MS31	%68,3215	0,6539
MS32	%68,3215	0,6539
MS33	%68,3215	0,6539
MS34	%66,1939	0,6307
MS35	%65,2482	0,6205
MS36	%62,4113	0,5893
MS37	%58,8652	0,5495
MS38	%58,8652	0,5495
MS39	%45,6265	0,4081
MS40	%41,8440	0,3666
MS41	%69,2671	0,6643
MS42	%69,2671	0,6643
MS43	%69,2671	0,6643
MS44	%69,2671	0,6643

En çok benzerlik (EÇB) yöntemine göre sonuçlar aşağıdaki tabloda görülmektedir.


Çizelge 3.17 EÇB yöntemine ait sınıflandırma doğrulukları

Uydu Görüntüsü	Yöntem	Doğruluk	Kappa
RapidEye	EÇB Yöntemi	%81,6425	0,7968
SPOT	EÇB Yöntemi	%63,8298	0,6057


BULGULAR VE TARTIŞMA

Bu bölümde DVM duyarlık analizi yani DVM kernellerinin ve bu kernellere ait parametre seçiminin sınıflandırma doğruluğu üzerindeki etkisinin incelenmesi ve sınıflandırma sonuçlarının karşılaştırmalı analizi yapılacaktır. Gamma (γ) parametresinin sınıflandırma sonuçları üzerinde herhangi bir etkisi olmadığı gözlenmiştir. Bu nedenle gamma parametresi duyarlık analizi işlemine katılmamıştır. Diğer parametre türlerinin (d, b, C) model ve parametre bazında sınıflandırma sonuçları (kappa değerleri) verilerek değişen parametrelere ve modellere göre karşılaştırmalı analiz yapılmıştır. Bu karşılaştırma, kullanılan iki görüntü için de sırası ile polinom derecesi (d), bias (b), ve düzenleme parametresi (C) parametrelerine göre gerçekleştirilmiştir.

Şekil 4.1 ve Şekil 4.2’de sırasıyla RapidEye ve SPOT uydu görüntülerinin değişen model ve polinom derecesine göre sınıflandırma sonuçları (kappa değerleri) verilmiştir. En yüksek sınıflandırma sonucu RapidEye uydu görüntüsünde MP9 modelinde, SPOT uydu görüntüsünde ise MP34 modelinde elde edilmiştir (Şekil 4.1 ve Şekil 4.2).



Şekil 4.1 RapidEye görüntüsü için kullanılan Polinom derecesine göre doğruluklar




Şekil 4.2 SPOT görüntüsü için kullanılan Polinom derecesine göre doğruluklar


Şekil 4.1’ de ki sınıflandırma sonuçları incelendiğinde model MP21 hariç polinom derecesi arttıkça sınıflandırma doğruluğu da artmaktadır. Polinom derecesi 1 değerini aldığı anda (Model MP19) diğer modellere göre (Model MP20, 21, 22, 23, 9) daha düşük sınıflandırma sonucu vermektedir. Polinom derecesi 6 olan model MP9, diğer polinom derecelerinden (Model MP 19, 20, 21, 22, 23) daha yüksek sınıflandırma sonucu vermiştir.

Şekil 4.2’de ki sınıflandırma sonuçları incelendiğinde polinom derecesi 3 olan model MP34 ‘e kadar sınıflandırma sonuçları artan bir eğilim gösterirken polinom derecesi 3 den daha büyük modellerde (Model MP48,49,50) azalan bir eğilim göstermektedir. Polinom derecesi 3 olan MP34 modeli, diğer polinom derecelerine sahip olan modellerden (Model MP 46, 47, 48, 49, 50) daha yüksek sınıflandırma sonucu vermiştir. RapidEye görüntüsünden elde edilen sonucun tersine, SPOT görüntüsünde ise en yüksek polinom derecesi en düşük sınıflandırma sonucunu vermiştir.

Aşağıdaki şekillerde RapidEye ve SPOT uydu görüntülerinin değişen model ve bias değerlerine göre polinom ve sigmoid kernelleri için sınıflandırma sonuçları (kappa değerleri) verilmiştir (Şekil 4.3, Şekil 4.4, Şekil 4.5, Şekil 4.6).




Şekil 4.3 RapidEye görüntüsü için kullanılan Polinom Kernelinde Biasa göre doğruluklar




Şekil 4.4 RapidEye görüntüsü için kullanılan Sigmoid Kernelinde Biasa göre doğruluklar

RapidEye görüntüsünün sınıflandırma işleminde polinom kernelinde bias değeri sıfır olduğunda sınıflandırma işlemi gerçekleşmemiştir (Şekil 4.3). Polinom kernelinde Model MP16 hariç sınıflandırma doğruluğu bias parametresi 5 değerine ulaşana dek artan bir eğilim gösterirken, 5'ten daha büyük bias değerlerinde (model MP17, MP18) sınıflandırma doğruluğu azalan bir eğilim göstermektedir. Bias değeri 5 olan model MP9, diğer bias derecelerinden (model MP 13, 14, 15, 16, 17, 18) daha yüksek sınıflandırma sonucu vermiştir (Şekil 4.3). Şekil 4.3'te de görüleceği üzere bias parametresi polinom kerneli üzerinde farklı etkilere sahiptir. RapidEye görüntüsünde bias değeri arttıkça sigmoid kerneli için sınıflandırma doğruluğu azalmaktadır (Şekil 4.4). Özellikle biasın 5 ten büyük değerleri için (Model MS 17, MS 18) sınıflandırma doğruluğundaki düşüş miktarı artmaktadır. Bias'ın 0 değerine sahip model MS9, diğer bias derecelerinden (Model MS12, MS13, MS14, MS15, MS16, MS17, MS18) daha yüksek sınıflandırma sonucu vermiştir (Şekil 4.4). Şekil 4.4'te de görüleceği üzere bias

parametresi RapidEye uydu görüntüsü için sigmoid kerneli üzerinde sınıflandırma doğruluğu ile ters bir orantıya sahiptir. Bias değeri arttıkça sınıflandırma doğruluğu düşmektedir(Şekil 4.4).



Şekil 4.5 SPOT görüntüsü için kullanılan Polinom Kernelinde Biasa göre doğruluklar



Şekil 4.6 SPOT görüntüsü için kullanılan Sigmoid Kernelinde Biasa göre doğruluklar

Şekil 4.5 ve Şekil 4.6 daki grafiklerden de görüleceği üzere, SPOT uydu görüntüsünde bias değeri arttıkça (Model MP45 hariç) polinom kerneli için sınıflandırma doğruluğu artarken, sigmoid kerneli için sınıflandırma doğruluğu azalmaktadır. Sigmoid kerneli için en düşük bias değerine sahip model MS29 en yüksek sınıflandırma doğruluğunu verirken, en yüksek bias değerine sahip model MS40 en düşük sınıflandırma doğruluğunu vermektedir(Şekil 4.6). Polinom kerneli için model MP34 en yüksek sınıflandırma doğruluğunu verirken, model MP39 en düşük sınıflandırma doğruluğu sonucunu vermektedir. SPOT uydu görüntüsü için polinom kerneli, bias parametresinin 6'dan büyük olduğu durumda (model MP45) sınıflandırma

doğruluğunda düşüş göstermektedir. Şekil 4.5 ve Şekil 4.6 da ki grafiklerden de görüleceği üzere bias parametresinin değerindeki artış SPOT uydu görüntüsünde polinom kerneli için genel olarak sınıflandırma doğruluğunda artış gösterirken, sigmoid kerneli üzerinde azalış göstermektedir.

Çizelge 4.1 ve Çizelge 4.2 de RapidEye ve SPOT uydu görüntülerinin değişen model ve düzenleme parametresine (penaltı parametresi) göre dört kernel türü için de sınıflandırma sonuçları (kappa değerleri) verilmiştir.

Çizelge 4.1 RapidEye uydu görüntüsünün değişen C parametresine göre dört kernel türünde sınıflandırma sonuçları

Lineer		Polinom		Radyal Tabanlı		Sigmoid	
C/Model	Kappa	C/Model	Kappa	C/Model	Kappa	C/Model	Kappa
0/ML1	0.7157	0/MP1	0.8101	0/MR1	0.6907	0/MS1	0.6906
100/ML2	0.8128	100/MP2	0.8330	100/MR2	0.8128	100/MS2	0.8034
200/ML3	0.8209	200/MP3	0.8397	200/MR3	0.8155	200/MS3	0.8142
300/ML4	0.8182	300/MP4	0.8331	300/MR4	0.8182	300/MS4	0.8128
400/ML5	0.8183	400/MP5	0.8304	400/MR5	0.8222	400/MS5	0.8128
500/ML6	0.8170	500/MP6	0.8357	500/MR6	0.8222	500/MS6	0.8128
600/ML7	0.8156	600/MP7	0.8304	600/MR7	0.8209	600/MS7	0.8115
700/ML8	0.8169	700/MP8	0.8344	700/MR8	0.8209	700/MS8	0.8155
800/ML9	0.8209	800/MP9	0.8411	800/MR9	0.8196	800/MS9	0.8209
900/ML10	0.8183	900/MP10	0.8357	900/MR10	0.8209	900/MS10	0.8209
1000/ML11	0.8223	1000/MP11	0.8330	1000/MR11	0.8209	1000/MS11	0.8209

Çizelge 4.2 SPOT uydu görüntüsünün değişen C parametresine göre dört kernel türünde sınıflandırma sonuçları

Lineer		Polinom		Radyal Tabanlı		Sigmoid	
C/Model	Kappa	C/Model	Kappa	C/Model	Kappa	C/Model	Kappa
0/ML1	0.4214	0/MP28	0.4953	0/MR16	0.4108	0/MS23	0.4156
100/ML2	0.6461	100/MP29	0.6795	100/MR17	0.6322	100/MS24	0.6306
200/ML3	0.6539	200/MP30	0.6846	200/MR18	0.6564	200/MS25	0.6333
300/ML4	0.6537	300/MP31	0.6898	300/MR19	0.6616	300/MS26	0.6487
400/ML5	0.6537	400/MP32	0.6976	400/MR20	0.6616	400/MS27	0.6538
500/ML6	0.6614	500/MP33	0.7053	500/MR21	0.6616	500/MS28	0.6539
600/ML7	0.6665	600/MP34	0.7078	600/MR22	0.6640	600/MS29	0.6643
700/ML8	0.6665	700/MP35	0.7027	700/MR23	0.6640	700/MS30	0.6513
800/ML9	0.6588	800/MP36	0.7027	800/MR24	0.6718	800/MS31	0.6539
900/ML10	0.6639	900/MP37	0.7052	900/MR25	0.6795	900/MS32	0.6539
1000/ML11	0.6640	1000/MP38	0.7026	1000/MR26	0.6821	1000/MS33	0.6539

Çizelge 4.1 ve 4.2 de görüldüğü üzere her iki görüntüde de C parametresi tüm kernellerde 0 değerinde en düşük sınıflandırma sonucunu vermektedir. Her iki görüntü için de polinom kerneli (Model MP9 ve Model MP34) diğer kernellerden daha yüksek sınıflandırma doğruluğuna sahiptir (Çizelge 4.1 ve Çizelge 4.2). Optimum parametre seti kullanılan uydu görüntüsü ve kernel tipine göre değişiklik göstermektedir. Her bir kernel türü (lineer, polinom, radyal tabanlı, sigmoid) düzenleme parametresine değişen uydu görüntüsünün türüne bağlı olarak farklı duyarlılık göstermektedir (Çizelge 4.1 ve Çizelge 4.2).


Çizelge 4.3 ve Çizelge 4.4'te her iki uydu görüntüsü için dört farklı kernel türünde en yüksek sınıflandırma doğruluğunu veren modeller ve EÇB yönteminin sınıflandırma sonuçları verilmiştir.

Çizelge 4.3 RapidEye uydu görüntüsü için kernel bazında en yüksek sınıflandırma doğrulukları


Model Ismi	Kappa	Genel Doğruluk
MP9	0.8411	%85.63
ML11	0.8223	%83.94
MR5	0.8222	%83.94
MS9	0.8209	%83.82
EÇB1	0.7968	%81.64

Çizelge 4.4 SPOT uydu görüntüsü için kernel bazında en yüksek sınıflandırma doğrulukları

Model Ismi	Kappa	Genel Doğruluk
MP34	0.7078	%73,29
ML7	0.6665	%69,50
MR26	0.6821	%70,92
MS29	0.6643	%69,27
EÇB2	0.6097	%63,83




Şekil 4.7 RapidEye uydu görüntüsü için kernel bazında en yüksek sınıflandırma doğrulukları




Şekil 4.8 SPOT uydu görüntüsü için kernel bazında en yüksek sınıflandırma doğrulukları


Şekil 4.9 da EÇB yöntemi kullanılarak oluşturulmuş RapidEye uydu görüntüsüne ait tematik harita görülmektedir. Takip eden 4 tematik harita ise, RapidEye uydu görüntüsü için her bir kernel türünde en yüksek sınıflandırma doğruluğuna sahip modeller ile oluşturulmuş tematik haritalardır (Şekil 4.10, Şekil 4.11, Şekil 4.12, Şekil 4.13).




Şekil 4.9 EÇB1 Tematik haritası




Şekil 4.10 ML11 Tematik haritası



Şekil 4.11 MP9 Tematik haritası




Şekil 4.12 MR5 Tematik haritası




Şekil 4.13 MS9 Tematik haritası


Şekil 4.14 de EÇB yöntemi kullanılarak oluşturulmuş SPOT uydu görüntüsüne ait tematik harita görülmektedir. Takip eden 4 tematik harita ise, SPOT uydu görüntüsü için her bir kernel türünde en yüksek sınıflandırma doğruluğuna sahip modeller ile oluşturulmuş tematik haritalardır (Şekil 4.15, Şekil 4.16, Şekil 4.17, Şekil 4.18).




Şekil 4.14 EÇB2 Tematik haritası




Şekil 4.15 ML7(SPOT) Tematik haritası



Şekil 4.16 MP34 Tematik haritası



Şekil 4.17 MS29 Tematik haritası



Şekil 4.18 MR26 Tematik haritası

SONUÇLAR VE ÖNERİLER

Uzaktan algılama teknolojisi, bilgisayar ve uydu sistemlerindeki teknolojik gelişmelerle birlikte, yeryüzüne ilişkin küresel ve yerel ölçekte güncel, düşük maliyetli ve hızlı veri sağlayabilme olanağına sahiptir. Uzaktan algılanmış verilerin (uydu görüntülerinin) sınıflandırılması, tematik bilgi üretilmesinde kullanılan en yaygın yöntemdir. Sınıflandırılmış uydu görüntüleri başta CBS olmak üzere yeryüzüne ilişkin birçok problemin çözümünde önemli bir veri kaynağı olarak kullanılmaktadır. Uydu görüntülerinin sınıflandırılması sonucu elde edilmiş tematik haritaların güvenilirliği ve doğruluğu, kullanılacak sınıflandırma yöntemine ve uydu görüntüsünün türüne göre değişmekte olup sınıflandırma doğruluğu ile ilişkilidir. O nedenle uydu görüntülerinin sınıflandırılması amacıyla günümüze kadar çeşitli sınıflandırma yöntemleri geliştirilmiş, başarıyla uygulanmış ve hala da geliştirilmeye devam edilmektedir.

Bu çalışma ile toplam 139 farklı model (4 farklı kernel) kullanılarak DVM için kernel fonksiyonlarının ve bu kernellere ait parametre seçiminin sınıflandırma doğruluğu üzerindeki etkisi (duyarlık analizi) ve DVM sınıflandırma yönteminin ürün deseni belirlemedeki uygulanabilirliği/işlerliği incelenmiştir. DVM yöntemi ile elde edilen sınıflandırma sonuçları hem birbirleri ile hemde geleneksel sınıflandırma yöntemlerinden biri olan EÇB yöntemi ile karşılaştırılmıştır. Literatürde, sınıflandırma yöntemlerinin kıyaslanmasında, EÇB yöntemi referans sınıflandırma yöntemi olarak kabul edilmekte olup, sınıflandırma yönteminin başarısı EÇB yöntemine göre belirlenmektedir. Çalışmada yüksek çözünürlüklü uydu görüntülerinden RapidEye ve SPOT görüntüleri kullanılarak Aydın iline ait tarım alanları sınıflandırılmış ve tematik haritalar üretilmiştir.

Çalışmada kullanılan RapidEye uydu görüntüsü, kırmızı-kenar (red-edge) bandına sahip olması nedeniyle bitki örtüsü ve tarım ile ilgili uygulamalarda özellikle tercih sebebidir. Kırmızı-kenar bandı, klorofile duyarlı olması sebebiyle arazi kullanımı ve örtüsüne ait sınıfların ayırt edilebilirliğini kolaylaştırmakta dolayısıyla sınıflandırma doğruluğunun artmasına katkı sağlamaktadır. Bu çalışmada RapidEye uydu görüntüsünün sınıflandırma sonuçları, SPOT uydu görüntüsünün sınıflandırma sonuçlarından ortalama %14 daha yüksek sınıflandırma doğruluğuna sahiptir. Bunun ana nedeni de kırmızı-kenar bandına sahip olması ve mekansal çözünürlüğünün daha yüksek olmasıdır.

Destek vektör makineleri, üstün sınıflandırma kabiliyetine sahip olması nedeniyle uzaktan algılama uygulamalarında özellikle son yıllarda sıklıkla kullanılan ve tatminkar sonuçlar veren bir yöntemdir. DVM sınıflandırma yönteminin başarısı, kullanıcı tarafından belirlenen en uygun (optimum) parametre setinin ve uygun kernel türünün seçimine bağlıdır. En uygun parametre seti/uygun kernel türü görüntüden görüntüye ve kullanılacak eğitim verisine göre değişiklik göstermekte ve sınıflandırma öncesinde bilinmemektedir. O nedenle en uygun parametre seti ve kernel türü aranmalıdır. Uydu görüntülerinin sınıflandırması işleminde en uygun parametre seti ve uygun kernel türünün seçimi ile DVM sınıflandırma yönteminin, EÇB yöntemine kıyasla daha yüksek sınıflandırma doğruluğuna sahip olduğu literatürde birçok çalışma ile ispatlanmıştır. Bu tez çalışmamızda uygun kernel türü ve en uygun parametre setinin belirlenmesi ile, kullanılan her iki uydu görüntüsü için de DVM sınıflandırma yöntemi sonucu elde edilen görüntülerin sınıflandırma doğruluğu (MP9, ML11, MR5, MS9; MP34, ML7, MR26, MS29 modellerine ait sınıflandırma doğruluğu) EÇB sınıflandırma yöntemi sonucu elde edilen görüntülerin (EÇB1,EÇB2) sınıflandırma doğruluğundan daha yüksektir. RapidEye ve SPOT5 uydu görüntüleri için en yüksek doğruluğa sahip modeller MP9 ve MP34, EÇB1 ve EÇB2 modellerine kıyasla yaklaşık %4 ve %10 daha yüksek sınıflandırma doğrulukları vermiştir (Çizelge 4.3 ve Çizelge 4.4).

Parametre seti ve kernel türünün seçimine bağlı olarak bazen EÇB yönteminin (EÇB1,EÇB2), DVM yönteminden (MS18,MS40 modellerinden) daha yüksek sınıflandırma doğruluğu verdiği de çalışmamızda tespit edilmiştir.

SPOT5 uydu görüntüsünün sınıflandırma işleminde eğitim verisi her bir sınıf için azaltılarak, az eğitim verisi ile DVM sınıflandırma yönteminin yüksek sınıflandırma

doğruluğuna sahip sonuçlar vereceği de kanıtlanmıştır. SPOT5 görüntüsünün sınıflandırılmasında kullanılan eğitim verisinin RapidEye görüntüsünün sınıflandırma işleminde kullanılan eğitim verisinden az olmasının başka bir sebebi de çözünürlüğünün RapidEye görüntüsüne kıyasla düşük olması, aynı alan için daha az sayıda piksele sahip olmasıdır.

DVM sınıflandırma işleminde kernellere ait parametreler, sınıflandırma doğruluğu üzerinde değişik etkilere sahiptirler. Örneğin; RapidEye uydu görüntüsünde en yüksek polinom derecesi en yüksek sınıflandırma doğruluğunu verirken(model MP9), SPOT5 görüntüsünde en düşük sınıflandırma sonucunu(model MP50) vermiştir (Şekil 4.1 ve Şekil 4.2). Ayrıca parametrelerin her bir kernel türü üzerindeki etkisi de kernelden kernele değişiklik göstermektedir. Örneğin; Bias parametresi sıfır değerinde sigmoid kerneline ait sınıflandırma sonuçlarında en yüksek sınıflandırma sonucunu (MS9,MS29 modelleri) verirken, polinom kernelinde en düşük sınıflandırma sonucunu (model MP39) vermekte yada sınıflandırma işlemi (model MP12) gerçekleşmemektedir (Şekil4.4. ve Şekil 4.6). Özet olarak, kernel türü ve parametre seti seçiminin sınıflandırma performansına olan etkisi ve en uygun parametre seti, kullanılan uydu görüntüsü ve sınıflandırma işleminde kullanılan eğitim/test verisine göre değişiklik göstermektedir.

Destek vektör makineleri sınıflandırma yöntemi, EÇB yöntemine göre performans olarak üstün olmasına rağmen, karmaşık matematiksel yapısı nedeniyle sınıflandırma işlemi zamansal olarak EÇB yöntemine göre uzun sürmektedir. Çalışmamızda polinom kerneli, sınıflandırma işleminde zamansal olarak en uzun süren kernel türüdür. Bias parametresinin veya düzenleme parametresinin sıfır değerini aldığı modeller, zamansal olarak sınıflandırma işleminin en uzun olduğu modeller olarak karşımıza çıkmıştır.

Sonuç olarak, DVM sınıflandırma işleminin optimum parametre seti ve uygun kernelin seçimine bağlı olarak RapidEye ve SPOT görüntüleri üzerinde tarım alanlarının sınıflandırılmasındaki uygulanabilirliği ve işlevliliği test edilmiş, EÇB yöntemine kıyasla daha yüksek sınıflandırma doğruluğuna sahip sonuçlar verdiği gözlenmiştir. Ayrıca DVM mimarisi üzerinde duyarlılık analizi yapılarak, her bir parametre türünün sınıflandırma doğruluğu üzerinde ne tür etkilere sahip olduğu incelenmiş ve ayrıca en uygun parametre çifti ve uygun kernel türünün aranması işlem adımları anlatılmıştır.

KAYNAKLAR

- [1] Kavzoglu, T. ve Colkesen, I. (2009). "A kernel functions analysis for support vector machines for land cover classification." *International Journal of Applied Earth Observation and Geoinformation* 11(5): 352-359.
- [2] Dixon, B. ve Candade N. (2008). "Multispectral landuse classification using neural networks and support vector machines: one or the other, or both?" *International Journal of Remote Sensing* 29(4): 1185-1206.
- [3] Srivastava, P. K., Han, D. vd. (2012). "Selection of classification techniques for land use/land cover change investigation." *Advances in Space Research* 50(9): 1250-1265.
- [4] Petropoulos, G. P., Arvanitis K., vd. (2012). "Hyperion hyperspectral imagery analysis combined with machine learning classifiers for land use/cover mapping." *Expert Syst. Appl.* 39(3): 3800-3809.
- [5] Watanachaturaporn, P., Arora M. K., ve Varshney P. K. (2008). "Multisource Classification Using Support Vector Machines: An Empirical Comparison with Decision Tree and Neural Network Classifiers." *Photogrammetric Engineering and Remote Sensing* 74(2): 239-246
- [6] Gong, P, Wang J., vd. (2013). "Finer resolution observation and monitoring of global land cover: first mapping results with Landsat TM and ETM+ data." *International Journal of Remote Sensing* 34(7): 2607-2654.
- [7] Huang, C., Davis L. S., vd. (2002). "An assessment of support vector machines for land cover classification." *International Journal of Remote Sensing* 23(4): 725-749.
- [8] Pal, M. ve Mather P. M. (2005). "Support vector machines for classification in remote sensing." *International Journal of Remote Sensing* 26(5): 1007-1011.
- [9] Gislason, P. O, Benediktsson J. A., vd. (2006). "Random Forests for land cover classification." *Pattern Recognition Letters* 27(4): 294-300.
- [10] Otukey, J. R. ve Blaschke T. (2010). "Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms." *International Journal of Applied Earth Observation and Geoinformation* 12, Ek 1(0): 27-31.
- [11] Foody, G. M. ve Ajay M. (2004). "A relative evaluation of multiclass image classification by support vector machines." *Geoscience and Remote Sensing, IEEE Transactions on* 42(6): 1335-1343.

- [12] Mathur, A. ve Foody G. M. (2008). "Crop classification by support vector machine with intelligently selected training data for an operational application." *International Journal of Remote Sensing* 29(8): 2227-2240.
- [13] Schuster, C., Förster M., vd. (2012). "Testing the red edge channel for improving land-use classifications based on high-resolution multi-spectral satellite data." *International Journal of Remote Sensing* 33(17): 5583-5599.
- [14] Eitel, J. U. H, Vierling L. A., vd. (2011). "Broadband, red-edge information from satellites improves early stress detection in a New Mexico conifer woodland." *Remote Sensing of Environment* 115(12): 3640-3646
- [15] Tigges, J., Lakes T., vd. (2013). "Urban vegetation classification: Benefits of multitemporal RapidEye satellite data." *Remote Sensing of Environment* 136(0): 66-75.
- [16] Löw, F., Michel U., vd. (2013). "Impact of feature selection on the accuracy and spatial uncertainty of per-field crop classification using Support Vector Machines." *ISPRS Journal of Photogrammetry and Remote Sensing* 85(0): 102-119.
- [17] Yang, C., Everitt J. H., vd. (2011). "Evaluating high resolution SPOT 5 satellite imagery for crop identification." *Computers and Electronics in Agriculture* 75(2): 347-354.
- [18] Turker, M. ve Ozdarici A. (2011). "Field-based crop classification using SPOT4, SPOT5, IKONOS and QuickBird imagery for agricultural areas: a comparison study." *International Journal of Remote Sensing* 32(24): 9735-9768.
- [19] Duro, D. C., Franklin S. E., vd. (2012). "A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery." *Remote Sensing of Environment* 118(0): 259-272.
- [20] Yang, X. (2011). "Parameterizing support vector machines for land cover classification". *Photogrammetric Engineering and Remote Sensing*, 77(1), 27–37.
- [21] Waske, B., Van der Linden S., vd. (2010). "Sensitivity of Support Vector Machines to Random Feature Selection in Classification of Hyperspectral Data." *Geoscience and Remote Sensing, IEEE Transactions on* 48(7): 2880-2889.
- [22] Melgani, F. ve Bruzzone L. (2004). "Classification of hyperspectral remote sensing images with support vector machines." *Geoscience and Remote Sensing, IEEE Transactions on* 42(8): 1778-1790.
- [23] Benediktsson, J.A., Swain, P.H. ve Ersoy O.K. (1990) "Neural Networks approaches versus statistical methods in classification of multisource remote sensing data", *IEEE Transactions on Geoscience and Remote Sensing* (28) 540–552.
- [24] Benediktsson, J.A., Swain, P.H. (1992). "Consensus theoretic classification methods", *IEEE Transactions on Systems, Man and Cybernetics* (22) 688–704.
- [25] Richards, J.A (1993) *Remote Sensing Digital Image Analysis*, second ed., Springer-Verlag, New York.
- [26] Bruzzone, L., Prieto, D. F. ve Serpico, S.B. (1999). "A neural statistical approach to multitemporal and multisource remote sensing image classification", *IEEE Transactions on Geoscience and Remote Sensing* (37) 1350–1359.

- [27] Foody, G. M. (2002). "Status of land cover classification accuracy assessment." *Remote Sensing of Environment* 80(1): 185-201.
- [28] Lin, S.-K ,vd (2011). *Introduction to Remote Sensing*. Fifth Edition, The Guilford Press
- [29] Otukey, J. R. ve Blaschke T. (2010). "Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms." *International Journal of Applied Earth Observation and Geoinformation* 12, Ek 1(0): 27-S31.
- [30] Sunar, F. ve Kaya S. (1997). "Technical note: An assessment of the geometric accuracy of remotely-sensed images." *International Journal of Remote Sensing* 18(14): 3069-3074.
- [31] Sunar, F. *Uzaktan Algılama*, T.C. Anadolu Üniversitesi Yayını, Eskişehir, 2010.
- [32] Mather, P.M. ve Koch, M (2011). *Computer Processing of Remotely-Sensed Images: An. Introduction*, Fourth Edition, Wiley-Blackwell
- [33] Wang, F., (1990). "Fuzzy supervised classification of remote sensing images". *IEEE Transactions on Geoscience and Remote Sensing*, (28):194–201.
- [34] Hansen, M., Dubayah, R., ve DeFries, R., (1996). "Classification trees: an alternative to traditional land cover classifiers". *International Journal of Remote Sensing*, (17): 1075–1081.
- [35] Kavzoglu, T. ve Mather, P.M., (2003). "The use of backpropagating artificial neural networks in land cover classification." *International Journal of Remote Sensing*, (24): 4907–4938
- [36] Zhang, Y., Gao, J. ve Wang, J., (2007). "Detailed mapping of a salt farm from Landsat TM imagery using neural network and maximum likelihood classifiers: a comparison". *International Journal of Remote Sensing*, (28):2077–2089.
- [37] Paola, J.D. ve Schowengerdt, R.A., (1995). "A detailed comparison of backpropagation neural-network and maximum-likelihood classifiers for urban land-use classification". *IEEE Transactions on Geoscience and Remote Sensing*, (33):981–996.
- [38] Safavian, S. R., ve Landgrebe, D., (1991). "A survey of decision tree classifier methodology". *IEEE Transactions on Systems, Man, and Cybernetics*, (21):660–674.
- [39] Hansen, M., DeFries, R. S., Townshend, J. R. G., ve Sohlberg, R., (2000). "Global land cover classification at 1 km spatial resolution using a classification tree approach." *International Journal of Remote Sensing*, (21):1331–1364.
- [40] Brodley, C. E., ve Utgoff, P. E., (1995). *Multivariate decision trees*. *Machine Learning*, (19):45–77.
- [41] Shao, Y. ve Lunetta R. S. (2012). "Comparison of support vector machine, neural network, and CART algorithms for the land-cover classification using limited training data points." *Isprs Journal of Photogrammetry and Remote Sensing* (70): 78-87.
- [42] Gualtieri, J. A. ve Crompton, R. F. (1998) "Support vector machines for hyperspectral remote sensing classification". *Proceedings SPIE*, (3584):221-232
- [43] Vapnik, V.N., (1995). *The Nature of Statistical Learning Theory*. New York: Springer-Verlag.

- [44] Foody, G.M. ve Mathur, A. (2004). "Toward intelligent training of supervised image classifications: directing training data acquisition for SVM classification." *Remote Sensing of Environment*, (93):107–117.
- [45] Song, X., Duan Z., vd. (2011). "Comparison of artificial neural networks and support vector machine classifiers for land cover classification in Northern China using a SPOT-5 HRG image." *International Journal of Remote Sensing* 33(10): 3301-3320.
- [46] Mathur, A., Foody, G.M. (2008). "Multiclass and binary SVM classification: Implications for training and classification users." *IEEE Geoscience and Remote Sensing Letters* (5):241–245.
- [47] Çölkesen, İ. (2009) *Uzaktan Algılamada İleri Sınıflandırma Tekniklerinin Karşılaştırılması ve Analizi*. GYTE, Yüksek Lisans Tezi.
- [48] Akar, Ö ve Güngör, O (2013). "Classification of multispectral images using Random Forest algorithm". *Journal of Geodesy and Geoinformation*. 1(2), 106-112
- [49] Aisen, B. (2006) , A Comparison of Multiclass SVM Methods, <http://courses.media.mit.edu/2006fall/mas622i/Projects/aisen-project/>, 22/12/2013
- [50] Ege Ekonomiyi Geliştirme Vakfı, Aydın ili raporu, <http://www.egev.org/ilraporlari/aydin.pdf>, 22/12/2013
- [51] Congalton, R. G. (1991). "A review of assessing the accuracy of classifications of remotely sensed data". *Remote Sensing of Environment* (37): 35– 46.
- [52] Tyc, G., Tulip J., vd. (2005). "The RapidEye mission design." *ActaAstronautica* 56(1–2): 213-219.
- [53] SPOT uyduları hakkında teknik bilgiler, SPOT5 uydusu, <http://www.astrium-geo.com/en/191-spot-technical-information>, 22/12/2013

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Mustafa ÜSTÜNER
Doğum Tarihi ve Yeri : 1989, Samsun
Yabancı Dili : İngilizce
E-posta : mustuner@yildiz.edu.tr

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Lisans	Harita Mühendisliği	KTÜ	2010
Lise	Fen	Milli Piyango Anadolu Lisesi	2006

YAYINLARI

Bildiri

1. M. Ustuner , F. Balık Sanli, F. Bektas Balcik, M.T. Esetlili “Destek Vektör Makineleri Teknigi ile Siniflandirma: RapidEye Ornegi", Türkiye Ulusal Fotogrametri ve Uzaktan Algilama Birliği VII. Teknik Sempozyumu (TUFUAB’2013), 23-25 Mayıs 2013, KTÜ, Trabzon
2. Ustuner,M., Sanli,F,B.” Comparison of Neural Network and ISODATA Classifiers for Land Cover Assessment Using Optical Data” 2012 FIG 3.Komisyon Çalıştayı, 10-14 Aralık 2012, Atina, Yunanistan
3. Acar, U., Bayram, B., Balık Şanlı, F., Abdikan, S., Üstüner , M., Maktav, D., Sunar, F., SAR Görüntülerinden Kıyı Şeridi Belirleme Algoritması, UZAL-CBS 2012 IV. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu, pp. 122, (2012)