



**T.C.
SIVAS CUMHURİYET ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**KENTSEL DOKUNUN, DESTEK VEKTÖR MAKİNELERİ
YÖNTEMİ İLE SINIFLANDIRILMASI: İSTANBUL ÖRNEĞİ**

YÜKSEK LİSANS TEZİ

**Osman DOĞAN
(20169249005)**

**Geomatik Mühendisliği Ana Bilim Dalı
Tez Danışmanı: Dr. Öğr. Üyesi Çağdaş KUŞÇU ŞİMŞEK**

**SIVAS
HAZİRAN 2019**

Osman DOĐAN'ın hazırladığı ve “**KENTSEL DOKUNUN, DESTEK VEKTÖR MAKİNELERİ YÖNTEMİ İLE SINIFLANDIRILMASI: İSTANBUL ÖRNEĐİ**” adlı bu çalışma ařađıdaki jüri tarafından **GEOMATİK MÜHENDİSLİĐİ ANA BİLİM DALI**'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danıřmanı **Dr. Öğr. Üyesi Çađdař KUŐCU ŐİMŐEK**

Sivas Cumhuriyet Üniversitesi

Jüri Üyesi **Dr. Öğr. Üyesi Önder GÜR SOY**

Sivas Cumhuriyet Üniversitesi

Jüri Üyesi **Doç. Dr. Tekin SUSAM**

Tokat Gaziosmanpařa Üniversitesi

Bu tez, Sivas Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü tarafından **YÜKSEK LİSANS TEZİ** olarak onaylanmıştır.

Prof. Dr. İsmail ÇELİK

FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRÜ

Bu tez, Sivas Cumhuriyet Üniversitesi Senatosu'nun 20.08.2014 tarihli ve 7 sayılı kararı ile kabul edilen Fen Bilimleri Enstitüsü Lisansüstü Tez Yazım Kılavuzu (Yönerge)'nda belirtilen kurallara uygun olarak hazırlanmıştır.



Bütün hakları saklıdır.
Kaynak göstermek koşuluyla alıntı ve gönderme yapılabilir.

© Osman DOĞAN, 2019



Kızım Ayşe Gökçen'e...

ETİK

Sivas Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü, Tez Yazım Kılavuzu (Yönerge)'nda belirtilen kurallara uygun olarak hazırladığım bu tez çalışmada;

- ✓ Bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- ✓ Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- ✓ Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere, bilimsel normlara uygun olarak atıfta bulunduğumu ve atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- ✓ Bütün bilgilerin doğru ve tam olduğunu, kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- ✓ Tezin herhangi bir bölümünü, Cumhuriyet Üniversitesi veya bir başka üniversitede, bir başka tez çalışması olarak sunmadığımı; beyan ederim.

26.06.2019

Osman DOĞAN

KATKI BELİRTME VE TEŞEKKÜR

Bilgi ve deneyimlerinden sürekli yararlandığım, tezin her aşamasında yardımlarını esirgemeyen danışman hocam Dr. Öğr. Üyesi Çağdaş Kuşçu Şimşek'e çok teşekkür ederim.

Ayrıca bu çalışma boyunca sürekli destek olan Ar. Gör. Rutkay Atun'a, Halime Ödül'e, eşim Merve Doğan'a, tüm aile fertlerime ve mesai arkadaşlarıma teşekkürü bir borç bilirim.



ÖZET

KENTSEL DOKUNUN, DESTEK VEKTÖR MAKİNELERİ YÖNTEMİ İLE SINIFLANDIRILMASI: İSTANBUL ÖRNEĞİ

Osman DOĞAN

Yüksek Lisans Tezi

Geomatik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Çağdaş KUŞÇU ŞİMŞEK

2019, 66 + xvii sayfa

Kentsel alanın modellenerek takip edilmesi, planlama çalışmalarına altlık olması açısından önem taşımaktadır. Günümüz teknolojisinin sağlamış olduğu olanaklar, geniş ve karmaşık olan kentsel alanların izlenmesini de kolaylaştırmaktadır. Bunu sağlayan yöntemlerden birisi de, uzaktan algılama teknikleridir.

Uzaktan algılama teknikleri, kentsel çevrenin mekânsal ve spektral çeşitliliğinin karmaşıklığına rağmen, farklı çözünürlükte farklı kentsel ortamları tanımlamak, değerlendirmek ve sınıflandırmak için kullanılabilir. Özellikle zamansal seri uydu görüntüleri, kentsel dinamiklerin karmaşıklığına rağmen, kent genişlemesinin daha doğru takibine ve anlaşılmasına olanak tanınması nedeniyle gün geçtikçe zorunluluk haline gelmektedir.

Bu çalışmada, heterojen sınıflar olan kentsel doku tiplerinin ayırt edilebilmesinde kullanılacak en uygun yöntemin tespitine çalışılmıştır. Uygulama alanı olarak, farklı kentsel doku tiplerinin bulunduğu İstanbul'un kentleşmiş alanı seçilmiştir. Destek Vektör Makineleri (DVM) ve En Çok Olabilirlik (EÇO) Yöntemlerinin kullanıldığı çalışmada, görüntü olarak Landsat-8 ve Sentinel-2A orta çözünürlüklü uydu görüntüleri kullanılmıştır. DVM yöntemi polinom, lineer, sigmoid ve radyal tabanlı fonksiyon kernelleri için ayrı ayrı uygulanmıştır. Sınıflandırma doğruluğunun karşılaştırılması amacı ile alternatif yöntem olarak En Çok Olabilirlik yöntemi seçilmiştir. Sınıflandırma doğrulukları, kentsel doku matrisinden faydalanılarak, CBS

ortamında elde edilmiş olan kentsel doku verisi ile karşılaştırılarak yapılmıştır. Kullanılmış olan doku matrisi, grid alanı içerisinde kalan bina yüzeylerinin alan kaplama ve serpilme farklılıklarını ortaya koyarak kent dokularını ayırtmaktadır. Sınıflandırma doğruluğunun bu veriler ile karşılaştırılmasının temel nedeni kentin yüzey özellikleri ve kent morfolojisini en doğru şekilde temsil eden bir model üzerinden değerlendirmelerin yapılabilmesidir. Son aşamada elde edilmiş tüm sınıflandırma sonuçları SPSS programında karşılaştırılarak, doku sınıflandırması için en uygun yöntem tespit edilmiştir.

Bu çalışma sonucunda DVM ve EÇO yöntemleri, avantaj ve dezavantajları ile anlatılmıştır. Ayrıca, Sentinel-2A ve Landsat-8 görüntüleri kentsel doku sınıflandırılmasında verimlilik açısından karşılaştırılmıştır. Elde edilen sonuçların, uzaktan algılama tekniklerinin, ayırt edilmesi zor olan ve heterojen sınıflara sahip olan kentsel doku değişikliklerinin izlenmesinde etkin kullanımı için önemli bir girdi sağlayacağı düşünülmektedir.

Anahtar kelimeler: Destek Vektör Makineleri, Kentsel Doku, Sınıflandırma, Uzaktan Algılama, Kentsel Planlama

ABSTRACT

THE CLASSIFICATION OF URBAN PATTERN BY THE SUPPORT VECTOR MACHINES METHOD: A CASE STUDY IN ISTANBUL CITY

Osman DOĞAN

M. Sc. Thesis

Department of Geomatics Engineering

Supervisor: Asst. Prof. Dr. Çağdaş KUŞÇU ŞİMŞEK

2019, 66 + xvii page

Monitoring and the modelling of the urban area is important in terms of being a base data for planning studies. The opportunities provided by today's technology also facilitate the monitoring of large and complex urban areas. One of the methods that provides this is remote sensing techniques.

Despite the complexity of the spatial and spectral diversity of the urban environment, remote sensing techniques can be used to evaluate, define and classify different urban environments at different resolutions. In particular, use of time series satellite images which become more and more imperative due to the complexity of urban dynamics is allowing for more accurate monitoring and understanding of urban expansion.

The main aim of the study is that to determine the suitable method to distinguish the urban pattern types which are heterogeneous classes. The urban area of Istanbul, which has different urban pattern types, has been chosen as the study area. Landsat-8 and Sentinel-2A medium resolution satellite images were used as images in the study where Support Vector Machines (SVM) and Maximum Likelihood (ML) classification methods were used. SVM method was applied separately for all kernel types as polynomial, linear, sigmoid and radial basis. In order to compare the accuracy of the classifications, the Maximum Likelihood method was chosen as an alternative method. Classification accuracy was calculated by comparing with urban pattern type's data obtained by urban pattern matrix in GIS. The urban pattern matrix separates the urban patterns according to the covering area of the building surfaces in a grid area and differentiation of distribution of buildings within the grid area. The main reason why classification accuracy is compared with these data is that evaluations can be made on

a model that accurately represents urban surface characteristics and urban morphology. All the results obtained in the last stage were compared in SPSS program and the most suitable method for urban pattern classification was determined.

As a result of this study, SVM and ML methods are presented with their advantages and disadvantages. In addition, Sentinel-2A and Landsat-8 images were compared in terms of productivity in urban pattern classification. It is thought that the obtained results will provide an important input for the efficient use of the remote sensing techniques in monitoring the urban pattern changes that has heterogeneous classes which are difficult to distinguish.

Keywords: Support Vector Machines, Urban Pattern, Classification, Remote Sensing, Urban Planning

İÇİNDEKİLER

KATKI BELİRTME VE TEŞEKKÜR	vii
ÖZET	viii
ABSTRACT	x
ŞEKİLLER DİZİNİ	xiii
ÇİZELGELER DİZİNİ	xv
KISALTMALAR DİZİNİ	xvii
1. GİRİŞ	1
1.1 Çalışmada Kullanılan Sınıflandırma Yöntemleri	4
1.1.1 Destek Vektör Makineleri.....	4
1.1.2 En Çok Olabilirlik Yöntemi	7
1.2 Literatür Araştırması	8
2. MATERİYAL ve YÖNTEM	14
2.1 Çalışmanın Amacı	14
2.2 Çalışma Alanı	14
2.3 Çalışma Verileri.....	15
2.4 Yöntem	17
2.5 Bulgular	45
3. SONUÇ ve ÖNERİLER	50
KAYNAKLAR	52
EKLER	54
EK-1 EÇO Sınıflandırması ve Genelleştirme Görüntüsü	55
EK-2 Lineer Kerneli ile DVM Sınıflandırması ve Genelleştirme Görüntüsü.....	56
EK-3 Radyal Tabanlı Fonksiyon Kerneli ile DVM Sınıflandırması ve Genelleştirme Görüntüsü.....	57
EK-4 Sigmoid Kerneli ile DVM Sınıflandırması ve Genelleştirme Görüntüsü.....	58
EK-5 Polinom Kerneli ile DVM Sınıflandırması ve Genelleştirme Görüntüsü.....	59
EK-6 Kente Ait CBS ile Elde Edilmiş Dokuların Gösterimi (Tam Sayfa)	60
EK-7 En Yüksek Doğruluğa Sahip Sınıflandırma Görüntüsü (Landsat-8) (Tam Sayfa)	61
EK-8 En Yüksek Doğruluğa Sahip Genelleştirme Görüntüsü (Landsat-8) (Tam Sayfa)	62
EK-9 En Yüksek Doğruluğa Sahip Sınıflandırma Görüntüsü (Sentinel-2a) (Tam Sayfa)	63
EK-10 En Yüksek Doğruluğa Sahip Genelleştirme Görüntüsü (Sentinel-2a) (Tam Sayfa)	64
ÖZGEÇMİŞ	65

ŞEKİLLER DİZİNİ

Şekil 1.1 Optimum Hiper-Düzlem.....	5
Şekil 1.2 Lineer (doğrusal) ayırlamayan veri seti.....	6
Şekil 1.3 İki boyutlu özellik uzayı (solda), üç boyutlu özellik uzayı (sağda).	6
Şekil 2.1 Çalışma alanının konumu.....	14
Şekil 2.2 Landsat-8 uydu görüntüsünün 4-3-2 bant kombinasyonu.....	16
Şekil 2.3 Sentinel-2A uydu görüntüsünün 4-3-2 bant kombinasyonu.....	17
Şekil 2.4 İş akış şeması.....	18
Şekil 2.5 İstanbul kentleşme alanı.....	19
Şekil 2.6 Doku farklılığı matrisi temel kabulü.....	19
Şekil 2.7 Kente ait CBS ile elde edilmiş dokuların gösterimi	20
Şekil 2.8 Doku gruplarının gerçek görüntü üzerinde gösterimi.....	21
Şekil 2.9 Doku gruplarının bantlardaki yansıtımı.....	22
Şekil 2.10 Landsat-8 bantlarının yansımaya grafikleri.....	24
Şekil 2.11 Sentinel-2A bantlarının yansımaya grafikleri.....	25
Şekil 2.12 Toplanan imzaların noktasal dağılımı.....	26
Şekil 2.13 En yüksek doğruluğa sahip sınıflandırma görüntüsü (Üsküdar) (Landsat-8).....	39
Şekil 2.14 En yüksek doğruluğa sahip genelleştirme görüntüsü (Üsküdar) (Landsat-8).....	40
Şekil 2.15 En yüksek doğruluğa sahip sınıflandırma görüntüsü (Esenler- Davutpaşa ve Bayrampaşa) (Landsat-8).....	40
Şekil 2.16 En yüksek doğruluğa sahip genelleştirme görüntüsü (Esenler- Davutpaşa ve Bayrampaşa) (Landsat-8).....	41
Şekil 2.17 En yüksek doğruluğa sahip sınıflandırma görüntüsü (Küçükçekmece-Bakırköy) (Landsat-8).....	41
Şekil 2.18 En yüksek doğruluğa sahip genelleştirme görüntüsü (Küçükçekmece-Bakırköy) (Landsat-8).....	42
Şekil 2.19 En yüksek doğruluğa sahip sınıflandırma görüntüsü (Bahçelievler-Güngören) (Landsat-8).....	42
Şekil 2.20 En yüksek doğruluğa sahip genelleştirme görüntüsü (Bahçelievler-Güngören) (Landsat-8).....	43
Şekil 2.21 En yüksek doğruluğa sahip sınıflandırma görüntüsü (Landsat-8)...	43
Şekil 2.22 En yüksek doğruluğa sahip genelleştirme görüntüsü (Landsat-8)...	44
Şekil 2.23 En yüksek doğruluğa sahip sınıflandırma görüntüsü (Sentinel-2A)	44
Şekil 2.24 En yüksek doğruluğa sahip genelleştirme görüntüsü (Sentinel- 2A).....	45
Şekil 2.25 Görüntüye göre EÇO ve DVM kernellerinin doğrulukları.....	46
Şekil 2.26 Görüntüye göre C parametresinin doğruluğa etkisi.....	46
Şekil 2.27 Görüntüye göre polinom derecesinin doğruluğa etkisi.....	47
Şekil 2.28 Görüntüye göre bias parametresinin doğruluğa etkisi.....	47

Şekil 2.29 Sınıflandırmaya ve genelleştirmeye göre EÇO ve DVM kernellerinin doğruluğa etkisi..... 48



ÇİZELGELER DİZİNİ

Çizelge 1.1 Elektromanyetik Spektrum (EMS)'un dalga boyu aralıkları.....	1
Çizelge 1.2 Sınıflandırma çeşitleri.....	3
Çizelge 1.3 Kernel fonksiyonları.....	7
Çizelge 1.4 Çalışmalar matrisi.....	13
Çizelge 2.1 Landsat-8 uydusunun bant özellikleri.....	15
Çizelge 2.2 Sentinel-2A uydusunun bant özellikleri.....	16
Çizelge 2.3 Doku oluşturma matrisi.....	20
Çizelge 2.4 En Çok Olabilirlik Yöntemi 'ne ait sınıflandırma doğrulukları (Landsat-8).....	26
Çizelge 2.5 Lineer Kerneli 'ne ait sınıflandırma doğrulukları (Landsat-8).....	27
Çizelge 2.6 Radyal Tabanlı Fonksiyon Kerneli 'ne ait sınıflandırma doğrulukları (Landsat-8).....	27
Çizelge 2.7 Sigmoid Kerneli 'ne ait sınıflandırma doğrulukları (C=1000) (Landsat-8).....	27
Çizelge 2.8 Sigmoid Kerneli 'ne ait sınıflandırma doğrulukları (C=600) (Landsat-8).....	28
Çizelge 2.9 Polinom Kerneli 'ne ait sınıflandırma doğrulukları (C=600) (Landsat-8).....	28
Çizelge 2.10 En Çok Olabilirlik Yöntemi 'ne ait sınıflandırma doğrulukları (Sentinel-2A).....	30
Çizelge 2.11 Lineer Kerneli 'ne ait sınıflandırma doğrulukları (Sentinel-2A).....	30
Çizelge 2.12 Radyal Tabanlı Fonksiyon Kerneli 'ne ait sınıflandırma doğrulukları (Sentinel-2A).....	31
Çizelge 2.13 Sigmoid Kerneli 'ne ait sınıflandırma doğrulukları (C=1000) (Sentinel-2A).....	31
Çizelge 2.14 Polinom Kerneli 'ne ait sınıflandırma doğrulukları (C=1000) (Sentinel-2A).....	31
Çizelge 2.15 En Çok Olabilirlik Yöntemi 'ne ait geliştirme doğrulukları (Landsat-8).....	33
Çizelge 2.16 Lineer Kerneli 'ne ait geliştirme doğrulukları (Landsat-8)....	33
Çizelge 2.17 Radyal Tabanlı Fonksiyon Kerneli 'ne ait geliştirme doğrulukları (Landsat-8).....	34
Çizelge 2.18 Sigmoid Kerneli 'ne ait geliştirme doğrulukları (C=1000) (Landsat-8).....	34
Çizelge 2.19 Sigmoid Kerneli 'ne ait geliştirme doğrulukları (C=600) (Landsat-8).....	34
Çizelge 2.20 Polinom Kerneli 'ne ait geliştirme doğrulukları (C=600) (Landsat-8).....	35
Çizelge 2.21 En Çok Olabilirlik Yöntemi 'ne ait geliştirme doğrulukları (Sentinel-2A).....	36
Çizelge 2.22 Lineer Kerneli 'ne ait geliştirme doğrulukları (Sentinel-2A).....	36
Çizelge 2.23 Radyal Tabanlı Fonksiyon Kerneli 'ne ait geliştirme doğrulukları (Sentinel-2A).....	37

Çizelge 2.24 Sigmoid Kerneli 'ne ait genelleştirme doğrulukları (C=1000) (Sentinel-2A).....	37
Çizelge 2.25 Polinom Kerneli 'ne ait genelleştirme doğrulukları (C=1000) (Sentinel-2A).....	37
Çizelge 2.26 EÇO yöntemi ve en yüksek doğruluğa sahip kernel sınıflandırmalarının korelasyonları.....	49
Çizelge 3.1 DVM ve EÇO sınıflandırmalarının avantajları-dezavantajları....	51



KISALTMALAR DİZİNİ

ASTER	: Advanced Spaceborn Thermal Emission and Reflection
CART	: Classification and Regression Trees
CASI	: Compact Airborne Spectrographic Imager
CBERS-2	: China-Brazil Earth Resources Satellite-2
CBS	: Coğrafi Bilgi Sistemleri
CORINE	: Coordination of Information on the Environment
DVM (SVM)	: Destek Vektör Makineleri (Support Vector Machines)
EMS	: Electromagnetic Spectrum
ETM	: Enhanced Thematic Mapper
EYKAA	: En Yakın Komşu Ayrışım Analizi
ISODATA	: The Iterative Self – Organizing Data Analysis Technique
EÇO (ML)	: En Çok Olabilirlik (Maximum Likelihood)
LAND	: Landsat-8
LIN	: Lineer
µm	: Micrometer
Narrow-NIR	: Narrow-Near Infrared
NIR	: Near Infrared
POL	: Polinom
QGIS	: Quantum Geographic Information System
RF	: Random Forest
RGB	: Red-Green-Blue
RBF	: Radial Based Function
SENT	: Sentinel-2A
SIG	: Sigmoid
SPSS	: Statistical Package for the Social Sciences
SWIR	: Short-Wave Infrared
TIRS	: Thermal Infrared Sensor
TM	: Thematic Mapper
USGS	: United States Geological Survey
UTM	: Universal Transverse Mercator
UV	: Ultraviolet
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Uzaktan Algılama, nesnelere doğrudan fiziksel bir temas kurmadan, farklı algılama yöntemleri kullanılarak bilgi edinme bilimidir. Farklı bir ifade ile uzaktan algılama, elektromanyetik spektrumun bir bölgesinde nesneden kaynaklanan yansıtım, saçılım değerlerinin algılanması, depolanması, bunun sonrasında nesnelerin tanımlanması ve sınıflandırılabilmesi için bu değerlerin kullanılması olarak tanımlanmaktadır. Uzaktan algılama verileri, dünyaya yakın balon, uçak vs. araçlarla toplanıyor olsa da, genellikle uydulardan elde edilen verilerin ifadesinde kullanılmaktadır (Uça Avcı vd. 2015). Bu yöntemler ile elektromanyetik spektrumun (EMS) çeşitli dalga boyu bölgesinde yeryüzünün görüntülerinin alınması sağlanmaktadır. Bu bölgeler aşağıda tablo halinde gösterilmiştir (Çizelge 1.1);

Çizelge 1.1 Elektromanyetik Spektrum (EMS)'un dalga boyu aralıkları

<u>Dalga boyu</u>	<u>Açıklama</u>
Gama Işınları	Gama Işınları
X-ray Işınları	X-ray Işınları
Ultraviyole (UV) Bölgesi 0.30 μm -0.38 μm (1 μm = 10^{-6} m)	Bu bölge görünür dalga boyunun mor kısmının ötesini temsil etmektedir. Yeryüzündeki kayalar ve mineraller UV radyasyonu yayar. Bununla birlikte, UV radyasyonu büyük ölçüde yeryüzü atmosferi tarafından yayılmaktadır ve bu nedenle uzaktan algılama alanında kullanılmamaktadır.
Görünür spektrum 0.4 μm -0.7 μm	Gözlerin algılayabildiği aralıktır. Bu aralık spektrumun renk ile ilişkilendirilebildiği tek kısımdır. Mavi, yeşil ve kırmızı görünür bölgenin üç ana rengini oluşturur.
Mor 0.4 μm -0.446 μm	
Mavi 0.446 μm -0.5 μm	
Yeşil 0.5 μm -0.578 μm	Burada tek renk diğer iki renk olmadan görüntülerde anlam ifade etmez ancak üç renkten çeşitli oranlarda karıştırıldığında
Sarı 0.578 μm -0.592 μm	
Turuncu 0.592 μm -0.62 μm	

Kırmızı 0.62 μm -0.7 μm	diğer renkler bulunabilir. Bir nesnenin rengi, yansıttığı ışığın rengiyle tanımlanır.
Kızılötesi (IR) spektrum 0.7 μm -100 μm	Görünür spektrumun kırmızı kısmından daha uzun dalga boyları kızılötesi tayf olarak adlandırılır. Bu bölge 1800 yılında İngiliz Astronom William Herschel tarafından bulunmuştur. Kızılötesi bölge radyasyon özelliklerine göre ikiye ayrılabilir; Yansıtılan IR (0.7 μm -3.0 μm) uzaktan algılama için kullanılır. Termal IR (3.0 μm -35 μm), dünya yüzeyinden yayılan ve uzaktan algılama için kullanılan radyasyondur.
Mikrodalga bölgesi 1 mm-1 m	Uzaktan algılamada kullanılan en uzun dalga boyudur. Bu aralıktaki en kısa dalga boyları termal kızılötesindeki dalga boylarına benzer özelliktedir.
Radyo dalgaları > 1 m	Genelde ticari yayın ve meteoroloji için kullanılan spektrumun en uzun kısmıdır.

Tabloda gösterilen dalga boylarından bir kısmı atmosferik pencereleden enerji olarak iletilmektedir. Bu pencereler görünür bölge ve kızılötesi bölgede bulunmaktadır (Aggarwal, 2003).

Uzaktan algılama haritacılık alanında; baraj seviyesi, su debisi belirlemek amacıyla subilimi alanında; ürün verimliliği tahmini için tarım alanında; kayaç tiplerinin belirlenmesi için jeoloji alanında; arazideki maden çeşitliliğinin ortaya çıkarılabilmesi için maden alanında; bitki türlerinin sınıflandırılabilmesi ve bitki stresi ölçümleri için ormancılık alanında; ayrıca kent dokusunun belirlenmesi, kentsel gelişimde çarpık yapılaşmanın önüne geçilebilmesi amacıyla çevre ve şehircilik faaliyetlerinde uygulanabilmektedir (Kavzoğlu vd., 2011).

Yeryüzündeki her bir cisim farklı spektral yansıtıma sahiptir, bu cisimlerin tanıma işlemi ise sınıflandırma yöntemleri yolu ile gerçekleştirilmektedir. Geniş anlamda

görüntü sınıflandırması, arazideki sınıflara ait piksellerin kategorize edilmesi olarak da tanımlanmaktadır.

Sınıflandırma işlemi için;

- Öncelikle kentsel alan, orman, tarım vs. sınıflar tanımlanarak şema oluşturulur, saha çalışmaları yapılır, çalışma alanı hakkında bilgi toplanır.
- Görüntülere gerekli radyometrik, atmosferik, geometrik ve topografik düzeltmelerle görüntü ön işleme adımı izlenir.
- Bunun sonrasında eğitim verileri (spektral imzalar) toplanır.
- Görüntü sınıflandırma algoritması çalıştırılır.
- Doğruluk analizi yapılarak arazi sınıflandırma sonuçları ile saha çalışma verileri karşılaştırılır.

Arazi sınıfı haritalarını oluşturmak için farklı sınıflandırma yöntemleri kullanılmaktadır. Kontrollü- kontrolsüz, parametrik-parametrik olmayan-metrik olmayan, zor-kolay sınıflandırma, piksel başına sınıflandırma-alt piksel sınıflandırması vb. mantığına göre sınıflandırma çeşitleri, aşağıdaki tabloda açıklamalarıyla birlikte verilmiştir (Çizelge 1.2).

Çizelge 1.2 Sınıflandırma çeşitleri

<u>Yöntem</u>	<u>Örnekler</u>	<u>Özellikler</u>
Parametrik	En Çok Olabilirlik Sınıflandırması ve Kontrolsüz Sınıflandırma vb.	Varsayım: Veri alanı normal olarak dağıtılır.
Parametrik Olmayan	En Yakın Komşuluk Sınıflandırması, Kolay Sınıflandırma, Yapay Sinir Ağları ve Destek Vektör Makineleri vb.	Önceden varsayım yapılmaz.
Metrik Olmayan	Kural-tabanlı Karar Ağacı Sınıflandırması	Hem gerçek veriler hem de nominal ölçeklendirilmiş veriler üzerinde istatistiksel analiz yapılabilir.

Kontrollü	En Çok Olabilirlik, En Yakın Mesafe ve Paralelkenar Sınıflandırma vb.	Analizdeki sınıflarda temsil edilecek eğitim verilerini tanımlar ve her piksel istatistiksel analize göre sınıflandırılır.
Kontrolsüz	ISODATA ve K-ortalamlar vb.	Eğitim verisi yok. Benzer spektral özelliklere sahip pikseller, belirli kriterlere göre gruplandırılır.
Zor (Parametrik)	Kontrollü ve Kontrolsüz Sınıflandırmalar	Farklı sınıflar kullanılan sınıflandırmalardır.
Kolay (Parametrik Olmayan)	Bulanık Küme Sınıflandırma Mantığı	Gerçek dünyanın heterojen yapısını göz önünde bulundurur. Her piksele, piksel içinde bulunan arazi kullanım sınıfının bir miktarı atanır.
Ön-piksel		Piksel-piksel görüntü sınıflandırmasıdır.
Nesne-tabanlı		Her nesne ve piksel üzerinde yapılan sınıflandırmadır.
Hibrit Yaklaşımlar		Uzman sistemler ve yapay zekâ içerir.

Çalışmada kullanılmak üzere iki yöntem seçilmiştir; bunlardan En Çok Olabilirlik Yöntemi parametrik, Destek Vektör Makineleri Yöntemi ise parametrik olmayan sınıflandırma grubuna girmektedir (Al-doski vd., 2013).


1.1 Çalışmada Kullanılan Sınıflandırma Yöntemleri

1.1.1 Destek Vektör Makineleri

Destek vektör makineleri, sınıflandırma problemlerinin çözümü için 1965 yılında Rus bilim insanı Vladimir Vapnik tarafından geliştirilmiştir (Cortes vd., 1995). Bu yöntemle ilk olarak uzaktan algılama verileri sınıflandırılmıştır. İkili sınıflandırmalar

için geliştirilmiş bu yöntem, az eğitim verisi ile yüksek doğrulukta sınıflandırma sonuçları elde etmeye imkân sağlamaktadır. Başlangıçta doğrusal verilerin sınıflandırmaları için kullanılan bu yöntem, daha sonraları çok sınıflı ve doğrusal olmayan verilerin sınıflandırmaları için kullanılmıştır (Üstüner, 2013).


Genel olarak ifade edilirse, karmaşık ve gürültülü verilerden iyi bir sınıflandırma sonucu veren, istatistiksel öğrenme teorisinden türetilmiş kontrollü bir sınıflandırma yöntemidir. Sınıflar arasındaki sınırı, maksimize eden bir hiper-düzlem ile ayırarak sınıfları ayırmaktadır. Ayıran yüzeye en uygun hiper-düzlem, hiper-düzleme en yakın verilere destek vektörleri denilmektedir (Şekil 1.1).



Şekil 1.1 Optimum Hiper-Düzlem


Yukarıdaki XY düzleminde, soldaki gri nesnelere bir sınıfı, sağdaki beyaz nesnelere diğer bir sınıfı temsil etmektedir. Bu iki sınıfın birbirine en yakın olduğu noktalardan iki doğru çizilir ve bu doğrular üzerinde yer alan nesnelere destek vektörleri denilmektedir; bu iki sınıfı eşit mesafede ayıran düzleme ise optimum hiper-düzlem (ağırlık vektörü) denilmektedir; burada b vektörün eğilimini ifade etmektedir. Bu düzlem lineer sınıflandırmalar için geçerlidir.

Şekil 1.2'deki gibi ayrılması zor, lineer olmayan veri setlerinde ise DVM kernelleri kullanılmaktadır.



Şekil 1.2 Lineer (doğrusal) ayrılamayan veri seti

Bu kerneller; lineer, polinom, radyal tabanlı fonksiyon ve sigmoid olarak tanımlanmaktadır. Bu yöntemde, kerneller yardımıyla karmaşık veri setleri farklı bir özellik uzayına taşınmaktadır. Örneğin, şekil 1.3'te verilmiş olan soldaki veri kümesi iki boyutlu uzaya sahipken, sağdaki veri kümesinde kerneller yardımıyla bu veriler üç boyutlu uzaya taşınmıştır.



Şekil 1.3 İki boyutlu özellik uzayı (solda), üç boyutlu özellik uzayı (sağda)

Kerneller birer fonksiyondur ve bu fonksiyonlarda kullanılan deęişkenler ařaęıdaki çizelgede gösterilmiřtir (Çizelge 1.3).

Çizelge 1.3 Kernel fonksiyonları

<u>Kernel Tipi</u>	<u>Fonksiyon</u>
Lineer	$K(x_i, x_j) = x_i^T x_j$
Polinom	$K(x_i, x_j) = (g x_i^T x_j + b)^d, g > 0$
Radyal Tabanlı Fonksiyon	$K(x_i, x_j) = \exp(-g \ x_i - x_j\ ^2), g > 0$
Sigmoid	$K(x_i, x_j) = \tanh(g x_i^T x_j + b)$

Sadece polinom fonksiyonlarında kullanılan d (derece), polinom derecesini ifade etmekte ve 1 ile 6 aralıęında deęer almaktadır. Lineer hariç dięer kernellerde kullanılan g (gama) deęeri sınıflandırmaya giren bant sayısının tersini göstermekte, b (bias) deęeri ise polinom ve sigmoid fonksiyonlarında kullanılan normalleřtirme derecesi olarak ifade edilmektedir. Son olarak her kernelde kullanılan c deęeri (ceza parametresi), ayırlamaz veri setlerinde, yanlış sınıflamaya verilen izin derecesini ifade etmektedir. (<https://www.harrisgeospatial.com/docs/SupportVectorMachine.html>).

1.1.2 En Çok Olabilirlik Yöntemi

En çok olabilirlik yöntemi, her bir sınıfın istatistiklerinin normal olarak daęıtıldıęı ve belirli bir pikselin belirli bir sınıfa ait olma olasılıęını varsaymaktadır. Bu yöntemde her piksel, en yüksek olasılıęa sahip olan sınıfa atanmaktadır. Ařaęıdaki fonksiyona göre;

$$g_i(x) = \frac{1}{n} \ln p(w_i) - 0.5 * \ln |\sum_i| - 0.5 * (x - m_i)^T (\sum_i)^{-1} (x - m_i)$$

i = sınıf,

x = n boyutlu veriler (n. bant sayısı),

p(w_i) = w_i sınıfının görüntüde ortaya çıkma olasılıęı ve tüm sınıflar için aynı olduęu varsayılması olasılıęı,

|\sum_i| = w_i sınıfındaki erinin kovaryans matrisinin determinantı,

(\sum_i)⁻¹ = ters matris,

m_i = ortalama vektörü ifade etmektedir.

1.2 Literatür Araştırması

Literatürde multispektral görüntülerin sınıflandırılması hakkında çeşitli araştırmalar yapılmış, farklı yöntemlerle çözümler aranmış ve bu çözümlerin sonuçları irdelenmiştir. Bu çalışma kapsamında Destek Vektör Makinelerinin görüntü sınıflandırmaya sağladığı katkı araştırılmış ve kentsel doku, arazi kullanımı, orman, tarım ve yangın alanlarında yapılan çalışmalar aşağıda incelenmiştir.

Kentsel doku üzerine yapılan çalışmalar;

Colaninno vd. (2011), yaptıkları çalışmanın amacını Barcelona şehrinin morfolojik homojen yapılarını tanımlama ve otomatik olarak sınıflandırma şeklinde belirtmiştir. Şehrin 7 kentsel dokuda (Eski Kasaba, Genişleme, XX. Yüzyıl Şehri, Parçalanmış Şehir, Yetmişlerin Şehri, Kenar Mahalle, Endüstriyel-Ticari ve Özel Binalar) sınıflandırıldığı çalışmada, binaların biçimsel ve ilişkisel karakterlerine bağlı olarak kentin morfolojisini ölçmek için indeksler belirlenmiştir. İndeksler oluşturulurken binalar arası mesafe, bina boyu, bölgenin yoğunluğu vs. etkenlerden yararlanılmıştır. Çalışmada, kentler araştırılırken sadece tasarım, ekonomi veya insan göçlerinden ibaret olmadığı kanısına varılmış, gerçek kentin karmaşıklığını yani kentin morfolojisini araştırmak için bir yöntem sunulmuştur.

Giannini vd. (2012), yüksek çözünürlüklü multispektral bantlara sahip QuickBird uydu görüntüsü kullanarak, Destek Vektör Makineleri Yöntemi ile kentsel dokuyu bina, yol ve bitki örtüsü olarak üç grupta sınıflandırmıştır. Çalışma İtalya'nın Napoli kentini kapsamaktadır. Çalışma sonucunda doğruluk, binalar için %95.43, yollar için %92 ve bitki örtüsü için %88.57 olarak bulunmuştur. Kullanılan bu yöntemin sadece kent dokusu için değil, arazi sınıflandırması için de kullanılabileceği kanısına varılmıştır.

Ober vd. (1997), yaptıkları doku çalışmasında, kentsel morfolojiyi karakterize etmek için kullanılan uzaktan algılanmış bir görüntünün, farklı yansıtım değerlerindeki değişimin mekânsal dağılımla ilişkisini araştırmışlardır. Çalışmada 30m. çözünürlüklü Landsat-TM ve maskeleyme işlemi için 10m. çözünürlüklü Spot uydu görüntüleri kullanılmıştır. Envi programında ISODATA Yöntemi ile sınıflandırılan görüntüler 3 gruba ayrılmıştır. Birinci sınıf, dar sokaklar ve kapalı binalarla sınırlandırılmış kentsel

bölgeler, ikinci sınıf; geniş caddeler ve çok büyük bloklu yapılar, üçüncü sınıf; küçük binalar ve büyük caddelerin bulunduğu alanlar tespit edilmiştir.

Amorim vd. (2009), farklı yaşanabilir koşullara sahip kentsel alanlarda morfolojik dokuları ayırt etmişlerdir. Çalışma sonucunda, doku analizinin, kent yapısına, biçimine, büyüklüğüne ve arazi kullanımına göre farklı kalıplar ortaya koyduğunu tespit etmişlerdir. Ayrıca doku analizinin kentin morfolojik yapısıyla sosyal-kültürel yapısı arasındaki ilişkinin anlaşılabilmesi için umut verici bir çalışma olduğu vurgulanmıştır. Ikonos, QuickBird ve CBERS-2 uydu görüntülerinin kullanıldığı çalışmada, gecekondulu mahallesi ve lüks mahalle tipleri arasında sınıflandırma yapma ve şehirleşme seviyeleri ile mahalleler arasında ayırım yapma kabiliyeti ortaya konulmuştur.

Colaninno vd. (2012), uydu görüntüsü ve uzaktan algılama teknikleri kullanılarak İspanya'nın Akdeniz kıyılarındaki arazi örtüsünü sınıflandırmışlardır. Fiziksel özelliklere bağlı olarak kentsel yerleşim yerlerinin büyüklüğü, şekli, yoğunluğu ve parçalanması gibi bir dizi göstergelere dayanarak farklı kentsel doku tiplerinin otomatik sınıflandırılması için bir yöntem geliştirilmiştir. Çalışma Envi programında, En Yakın Mesafe Yöntemi ile yapılmış olup, yöntem olarak bitki ve kent indekslerinden yararlanılmıştır ve görüntü olarak Landsat 4-5 TM kullanılmıştır. Sonuç olarak kentin morfolojik yapısı; sürekli, süreksiz ve dağınık olarak üç sınıfta gruplandırılmıştır. Çalışmanın doğruluğu yaklaşık %63 olarak hesaplanmıştır.

Bekkari vd. (2012), çalışmalarında yüksek çözünürlüklü uydu görüntüleri kullanarak, DVM ve Harlick özelliklerini kentsel alanlara uygulamışlardır. Mekânsal DVM, Uzamsal DVM, Mekânsal ve Uzamsal DVM olarak 3 sınıflandırma yapılan çalışmada, Mekânsal ve Uzamsal DVM'nin bir arada kullanıldığı sınıflandırma yüksek doğruluğu vermiştir.

Suralkar vd. (2012), çalışmalarında doku verilerini kullanarak DVM sınıflandırmasını lineer, polinom, RBF ve sigmoid kernelleri ile test etmişlerdir. Sonuçta RBF kerneli ile elde edilen doku sınıflandırmalarının, diğer kernellerle yapılan sınıflandırmalara kıyasla daha üstün olduğu tespit edilmiştir.

Arazi kullanımı üzerine yapılan çalışmalar;

Atasever (2011) ise çalışmasında Yapay Sinir Ağları ile Destek Vektör Makineleri (DVM), Boosting (Hızlandırma), Sınıflandırma ve Regresyon Ağaçları (CART), Rastgele Orman (RF) yöntemlerini ASTER ve Landsat bantları üzerinde uygulayarak arazi sınıflandırmıştır. Aster görüntüsü ile yapılan sınıflandırma işleminde, CART yönteminin en yüksek doğruluğu, RF yönteminin en düşük doğruluğu verdiğini gözlemlemiş, Landsat görüntüsünün sınıflandırılmasında ise DVM-Lineer ve En Çok Olabilirlik yöntemlerinin en düşük doğruluğu, DVM-Polinom ile DVM-RTK (Radyal Tabanlı Kernel) yöntemlerinin yüksek doğruluğu verdiği tespit edilmiştir.

Tarım alanında yapılan çalışmalar;

Rende (2009), tez çalışmasında Destek Vektör Makinelerini AVIRIS hiperspektral görüntülerinin sınıflandırılması amacıyla kullanmış, kullandığı diğer iki yöntemle göre (En Yakın Komşu Ayrışım Analizi ve Öğrenme++ Aşamalı Öğrenme Algoritması) DVM'nin üstünlüğünü ortaya koymuştur ve az eğitim verisiyle tarım alanlarında yüksek başarı sağlayan bir yöntem olduğunu belirtmiştir.

Üstüner (2013), Aydın ili tarım alanlarını kapsayan RapidEye (5m.) ve SPOT5 (10m.) uydu görüntülerine DVM ve EÇO yöntemlerini uygulayarak, hangi yöntemle az eğitim verisi kullanılarak başarılı sonuçlar elde edebileceğinin testini uygulamıştır. En yüksek doğruluğa sahip modeller DVM sınıflandırmalarıyla elde edilmiş olup, en çok olabilirlik modellerine kıyasla yaklaşık %4 ile %10 daha yüksek sınıflandırma doğrulukları vermiştir.

Gualtieri vd. (1998) AVIRIS (17*17) görüntüsü üzerinde, DVM, bLOOC+DAFE+ECHO ve Euclidean yöntemlerini kullanarak mısır, soya fasulyesi, soya fıstığı ve otlak-ağaçlık alanların sınıflandırılmasını amaçlamışlardır. Sınıflandırma sonucunda sırasıyla %96,3, %93,5 ve %66,7 doğruluk elde etmişlerdir.

Karimi vd. (2008), bir mısır tarlası üzerinde alınan hiperspektral gözlemlerin analizinde DVM yönteminin uygulanabilirliğini incelemiş, CASI (20m.) uydu görüntüsüne DVM ve Kademeli Regresyon Yöntemi uygulamışlardır. DVM sonuçları, kademeli regresyon yöntemi ile elde edilenlerle karşılaştırılmış ve DVM ile elde edilen sonuçların daha başarılı olduğu tespit edilmiştir.

Ormanlık alanlarda yapılan çalışmalar;

Knorn vd. (2009)'nin Landsat ve Quickbird görüntülerine DVM ile Zincir DVM'yi kullandığı çalışmada ormanlık olan-olmayan alanları araştırmışlardır. DVM yöntemi uygulandığında 8 görüntü için %92.1 ile %98.9 arasında doğruluk elde edilmiş, zincir DVM kullanıldığında ortalama %98.1 doğruluk elde edilmiş, zincir sınıflamanın üstünlüğü geniş arazi yüzeylerinde kullanım için önerilmiştir.

Dalponte vd. (2009), ASIA Eagle Sensor (0.62m.) görüntüsüne DVM, En Çok Olabilirlik ve Lineer Diskriminant Analiz yöntemlerini uygulayarak orman alanlarının sınıflandırılmasına yönelik bir çalışma yapmışlardır. Sonuç olarak; DVM'nin her zaman en yüksek doğrulukları sağladığı ve ek olarak maksimum spektral çözünürlüğü ile en iyi performansı sergilediği ortaya koyulmuştur.

Liu vd. (2006) Kaliforniya'daki ani meşe ölümlerini izlemek için ADAR 5500 (1m.) görüntüsüne DVM ve EÇO yöntemleri uygulamıştır. Sonuç olarak piksel tabanlı tekli tarih yaklaşımlarına (2000 yılı: Kappa = 0.67; Yıl 2001: Kappa = 0.66) kıyasla çok daha iyi sonuçlar elde ettiğini göstermiştir (Yıl 2000: Kappa = 0.92; Yıl 2001: Kappa = 0.91).

Yangın alanlarında yapılan çalışmalar;

Cao vd. (2009) Çin ile Moğolistan sınırında bir bölgedeki, yanmış çayırılık alanı MODIS (500m.) ve Landsat TM (30m.) görüntülerini kullanarak araştırmışlardır. Çalışma sonucunda yanmış alanların sınıflandırmasında genel doğruluk %96,8, Kappa değeri %93,3 olarak bulmuştur.

Petropoulos vd. (2009), yangın yaşanmış bir bölgede vaka sonrası değerlendirme yapmak için ASTER uydu görüntülerine DVM uygulanmasının sonuç verip-vermeyeceğini araştırmışlardır. Elde edilen yangın öncesi ve yangın sonrasındaki iki farklı ASTER uydu görüntüsüne algoritma uygulanmış ve CORINE 2000 arazi kullanımı verisiyle karşılaştırılma yapılmıştır. Sonuç olarak %94,6'lık bir genel doğruluk ve %93 'lük bir Kappa değeri elde edilmiştir. Ayrıca sınıflandırma sonucunda 5 farklı arazi sınıfı elde edilmiştir (sınıflanmayan alanlar, orman, tarım alanları, çalılık arazi, kentsel alanlar).

Yapılan alıřmalarda kullanılan DVM ve DVM'ye alternatif yntemler, uydu grntleri ve yazılımlar bir izelgede gsterilmiřtir (izelge 1.4). izelge 1.4'ten faydalanılarak bu alıřmada; Landsat-8 ve Sentinel-2A grntleri zerinden, DVM sınıflandırma yntemleri ve EO sınıflandırma yntemi karřılařtırılarak, kentsel doku sınıflandırmasında en bařarılı yntemin ve parametrelerin belirlenmesine karar verilmiřtir.



Çizelge 1.4 Çalışmalar matrisi

<u>Çalışma</u> No	<u>Yöntemler</u>			<u>Uydu Görüntüleri</u>											<u>Yazılımlar</u>	
				RapidEye (5)	Spot (10)	Aster (30)	Landsat (30)	ASIA (0.62)	Sentinel (10)	AVIRIS (17-20)	Q.Bird (0.61)	MODIS (500)	ADAR5500 (1)	CASI (20)	Envi	Matlab
1	DVM	EYKAA	Öğrenme ++							X						X
2	YSA	EÇO	Boosting			X	X									
	CART	DVM	RF													X
3	DVM	EÇO		X	X										X	
4	DVM	bLOOC+ DAFE+ ECHO	Euclidean							X						
5	DVM(Zincir)						X				X					
6	DVM	EÇO	Lineer Disk.					X								X
7	DVM						X					X				
8	DVM	EÇO											X			
9	DVM					X									X	
10	DVM	Kademeli Regresyon												X	X	
Bu tez çalışması	DVM	EÇO					X		X						X	

- 1-10 arasındaki çalışmalar literatür kısmında verilmiştir.
- Uydu görüntülerinin çözünürlükleri, görüntü isimleri ile birlikte parantez içerisinde verilmiştir.


2. MATERYAL ve YÖNTEM

2.1 Çalışmanın Amacı

Bu tez çalışmasında; iki konu araştırılmıştır. Destek Vektör Makineleri ve En Çok Olabilirlik yöntemlerinin sınıflandırma doğruluklarına bakılarak üstün olan yöntemin belirlenmesi, ikincisi de sınıflandırma ile tespit edilmesi zor olan heterojen yapıdaki kentsel dokunun tespit edilmesidir.

2.2 Çalışma Alanı

Kuzeyde İstanbul çevre yolu, batıda Büyükçekmece Gölü, doğuda İstanbul-Kocaeli il sınırı ve güneyde deniz kıyısına kadar olan kent dokusunun yoğun olduğu alan, çalışma alanı olarak seçilmiştir. Alan $40^{\circ}50'00''$ kuzey enlemi ve $28^{\circ}30'00''$ doğu boylamı arasında kalmaktadır (Şekil 2.1).



2.3 Çalışma Verileri


Çalışmada uydu görüntüsü olarak Landsat-8 ve Sentinel-2A, vektör veri olarak İstanbul yapı verisi ve Corine-2012 arazi kullanım verisi kullanılmıştır. Verilerin özellikleri aşağıdaki şekilde tanımlanmıştır;

1972’de başlayan Landsat serisinin son ve tek çalışan uydusu olma özelliğine sahip Landsat-8, 2013 yılının Şubat ayında fırlatılmıştır. 16 günde bir görüntüleme yapmakta ve 185 km*185 km’lik bir alan taramaktadır. Görüntülerin radyometrik çözünürlüğü 12 bittir. Uydunun bantlarına ait dalga boyu aralıkları ile çözünürlükleri bir tablo halinde verilmiştir (Çizelge 2.1).

Çizelge 2.1 Landsat-8 uydusunun bant özellikleri

<u>Landsat-8 Bantları</u>	<u>Dalga boyu Aralıkları(μm)</u>	<u>Çözünürlük (m)</u>
Bant 1 – Coastal aerosol	0,443-0,453	30
Bant 2 – Blue	0,450-0,515	30
Bant 3 – Green	0,525-0,600	30
Bant 4 – Red	0,630-0,680	30
Bant 5 – NIR	0,845-0,885	30
Bant 6 – SWIR1	1,560-1,660	30
Bant 7 – SWIR2	2,100-2,300	30
Bant 8 – Pan	0,500-0,680	15
Bant 9 – Cirrus	1,360-1,390	30
Bant 10 – TIRS 1	10,300-11,300	100
Bant 11 – TIRS 2	11,500-12,500	100

Çalışmada 06.11.2014 tarihli Landsat-8 uydu görüntüsü kullanılmıştır (Şekil 2.2).



Şekil 2.2 Landsat-8 uydu görüntüsünün 4-3-2 bant kombinasyonu


Sentinel-2A uydusu 2015 yılının Haziran ayında fırlatılmış olup, 10 günde bir görüntüleme yapmakta ve 290km genişliğinde bir alan taramaktadır. Görüntülerin radyometrik çözünürlüğü 12 bittir. Uydunun bantlarına ait dalga boyu aralıkları ile çözünürlükleri bir tablo halinde verilmiştir (Çizelge 2.2).

Çizelge 2.2 Sentinel-2A uydusunun bant özellikleri

<u>Sentinel-2A Bantları</u>	<u>Dalga boyu aralıkları (μm)</u>	<u>Çözünürlük (m)</u>
Bant 1 – Coastal aerosol	0,443	60
Bant 2 – Blue	0,490	10
Bant 3 – Green	0,560	10
Bant 4 – Red	0,665	10
Bant 5 – Vegetation Red Edge	0,705	20
Bant 6 – Vegetation Red Edge	0,740	20
Bant 7 – Vegetation Red Edge	0,783	20
Bant 8 – NIR	0,842	10
Bant 8A – Narrow NIR	0,865	20
Bant 9 – Water Vapour	0,945	60
Bant 10 – SWIR – Cirrus	1,375	60

Bant 11 – SWIR	1,610	20
Bant 12 – SWIR	2,190	20

Çalışmada 30.07.2015 tarihli Sentinel-2A uydu görüntüsü kullanılmıştır (Şekil 2.3).




Şekil 2.3 Sentinel-2A uydu görüntüsünün 4-3-2 bant kombinasyonu

Birbirine en yakın tarihli bu iki uydu görüntüsü, temiz olmaları ve elde edilen yapı verilerinin tarihleri ile uyumlu olmaları sebebiyle seçilmiştir. Bundan dolayı aradaki 8 aylık fark göz ardı edilmiştir.

İstanbul ilçe belediyelerinden temin edilen vektör veri formatındaki bilgiler, kentin doku sınıflarını oluşturmak için doku hesabı kısmında kullanılmıştır. Çalışma alanının sınırları belirlenirken, Corine verileri ve yapı verilerinden faydalanılarak, yalnızca kentleşmiş alanları ifade eden ve farklı doku tipleri barındıran bölge çalışma alanı olarak belirlenmiştir.


2.4 Yöntem

Çalışmada piksel tabanlı sınıflandırma tekniği kullanılarak Destek Vektör Makineleri ve En Çok Olabilirlik yöntemleri, farklı çözünürlükteki iki uydu görüntüsüne uygulanmıştır. Çalışmanın iş akış şeması aşağıda verilmiştir (Şekil 2.4).




Şekil 2.4 İş akış şeması

Sınıflandırma çalışmalarına başlamadan önce ön işlemler gerçekleştirilmiştir. Öncelikle 28 ilçeden temin edilen yapı verilerinin projeksiyonları UTM seçilmiş ve koordinat sistemleri WGS_1984_UTM_zone_35N olarak tanımlanmıştır. Daha sonra tüm ilçe verileri birleştirilip tek vektör veri haline getirilmiştir. Bu veride teras gibi yeryüzünde karşılığı bulunmayan öznelikler silinmiş, sadece ID (identification) kodları tanımlanmış olan yapı verileri kullanılmıştır. Corine-2012 arazi kullanım verilerinden yararlanılarak, güneyde Marmara Denizi'ne, batıda Büyükçekmece Gölü'ne, doğuda İstanbul-Kocaeli sınırına ve kuzeyde İstanbul Çevre Yolu'na kadar olan bölge çalışma alanı olarak belirlenmiştir. Daha sonra ArcMap ortamında 150m.*150m. grid ağı oluşturulup, yapı verileri ile ilişkilendirilmiştir (Şekil 2.5).




Şekil 2.5 İstanbul kentleşme alanı

Kuşçu Şimşek (2013)'in, geliştirdiği doku matrisi yöntemine göre, kentsel doku CBS ortamında elde edilmiştir. Matrisin oluşturulmasındaki temel amaç, yapıların bulunduğu alandaki kaplama ve serpilme farkının ortaya konulmasıdır (Şekil 2.6).



$$\text{Toplam Taban Alanı} = a + a + a + 3a + 4a = 10a$$

$$\text{Ortalama Taban Alanı} = (a + a + a + 3a + 4a) / 5 = 2a$$



$$\text{Toplam Taban Alanı} = 10a$$

$$\text{Ortalama Taban Alanı} = 10a$$


Şekil 2.6 Doku farklılığı matrisi temel kabulü

Buna göre her grid içindeki yapıların toplam taban alanları ve ortalama taban alanları hesaplanmıştır. Toplam taban alanları kaplamayı, ortalama taban alanları serpilmeyi göstermektedir (Çizelge 2.3).

Çizelge 2.3 Doku oluşturma matrisi (Kuşçu Şimşek, 2013)

		Toplam Taban Alanı (m ²) →		
		≤ 3750	3750<...≤7500	>7500
Ortalama Taban Alanı (m ²) ↑	...≤300	1	3	5
	>300	2	4	6


Bu tabloya göre yapılan hesapla Şekil 2.7’de verilmiş olan kent dokusu oluşturulmuş, İstanbul İli 6 doku sınıfıyla tanımlanmaya çalışılmıştır.



Şekil 2.7 Kente ait CBS ile elde edilmiş dokuların gösterimi


Buna göre 1 numaralı dokuyu seyrek, az katlı, ayrık nizam ve gecekonduların oluşturduğu yapılar ile boğazın sahil kesiminde yer alan yapılar oluşturmaktadır. 2 numaralı dokuyu ise Ataköy, Ataşehir, Ayazağa Oyak sitesi gibi yeşil alanlarla bütünleşmiş konutların toplu bulunduğu yapılar oluşturmaktadır. 3 numaralı dokuyu çoğunlukla 5-6 katlı ve farklı yükseklikteki binaların oluşturduğu ayrık yapılar oluşturmaktadır ve Kadıköy, Bakırköy, Levent ilçelerinde görülmektedir. 5 numaralı dokuyu 4-7 katlı sıkışık yapılar oluşturmaktadır.

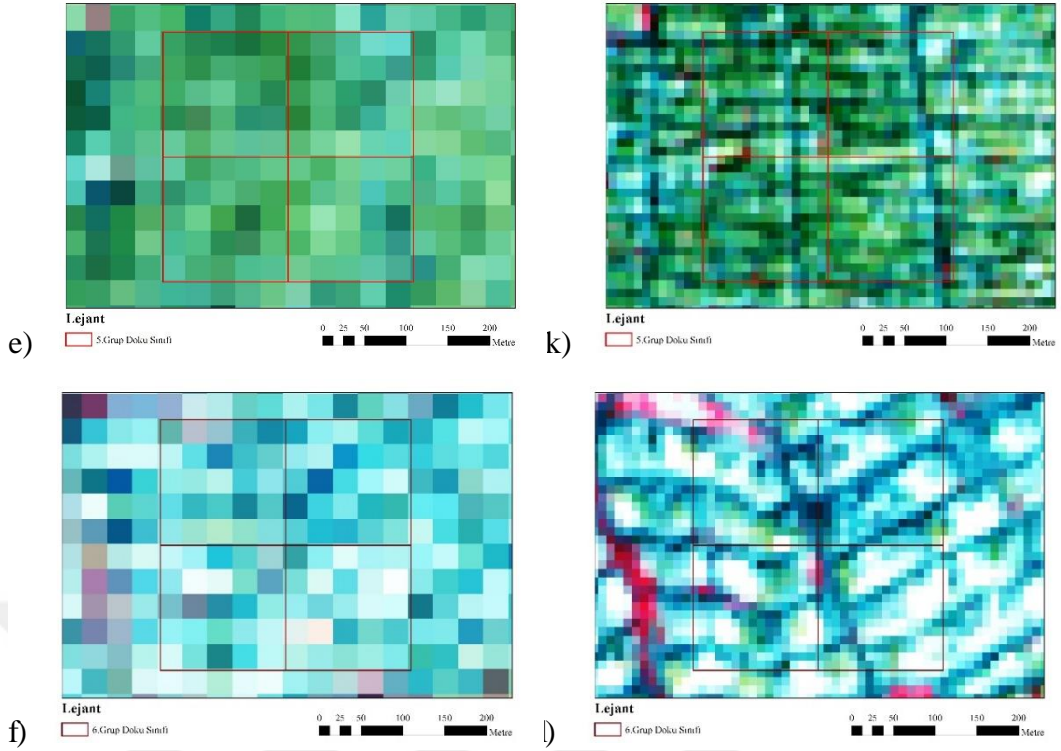
yapılar ve E5 yolu üzerinde bahçesi yok denecek kadar az olan bitişik nizam yapılar oluşturmaktadır. Bu yapılar Fatih, Eminönü, tarihi yarımada ve Beyoğlu gibi kent merkezlerinde görülmektedir. Son olarak 6 numaralı dokuyu da büyük sanayi binalarının bulunduğu Güngören, Zeytinburnu, Bayrampaşa vs. ilçelerin sanayileri oluşturmaktadır.



Şekil 2.8 Doku gruplarının gerçek görüntü üzerinde gösterimi (a) Doku Grubu "1", b) Doku Grubu "2", c) Doku Grubu "3", d) Doku Grubu "4", e) Doku Grubu "5", f) Doku Grubu "6")

Dokuların Landsat-8 ve Sentinel-2A görüntülerindeki yansıtımı aşağıda gösterilmiştir.






Şekil 2.9 Doku gruplarının bantlardaki yansıtımı (Soldaki görüntüler Landsat-8 olmak üzere: a) Doku Grubu “1”, b) Doku Grubu “2”, c) Doku Grubu “3”, d) Doku Grubu “4”, e) Doku Grubu “5”, f) Doku Grubu “6”) (Sağdaki görüntüler Sentinel-2A olmak üzere: g) Doku Grubu “1”, h) Doku Grubu “2”, i) Doku Grubu “3”, j) Doku Grubu “4”, k) Doku Grubu “5”, l) Doku Grubu “6”)


Doku tiplerindeki yapılar karşılaştırıldığında 4 numaralı dokunun diğer doku grupları içinde dağıldığı ve sayıca çok az olduğu tespit edildiği için kullanılmamasına karar verilmiştir. Kalan bilgiler analizde kullanılmak üzere veri tabanına aktarılmıştır. Çalışmanın CBS kısmı tamamlandıktan sonra Uzaktan Algılama kısmına geçilmiş, Landsat-8 ve Sentinel-2A bantlarına açık kaynak kodlu QGIS programında, “Semi-Automatic Classification Plugin” eklentisi ile meta veriler okutulmuş ve atmosferik düzeltmeler otomatik olarak yapılmıştır. Atmosferik düzeltmeler yapıldıktan sonra kompozit görüntü oluşturularak veri hazır hale getirilmiştir.

Dokuların, farklı bantlarda yaptığı yansıtımı ölçmek ve çalışmada kullanılacak bant kombinasyonunu belirlemek amacı ile SPSS programında aşağıdaki grafikler oluşturulmuştur. Bu işlem için bir dokuya ait olan gridler seçilmiş, aynı grid içlerindeki piksellerin ortalama değerleri alınarak o dokuya ait yansıtımlar Landsat-8 ve Sentinel-2A verilerinin her bir bandında incelenmiştir. Dokuların görüntü üzerindeki gözle

ayrımı da dikkate alınarak her bir dokunun kendisi için en uygun bant kombinasyonu kullanılmıştır.




Şekil 2.10 Landsat-8 bantlarının yansma grafikleri (a) Doku Grubu "1", b) Doku Grubu "2", c) Doku Grubu "3", d) Doku Grubu "4", e) Doku Grubu "5", f) Doku Grubu "6")



Şekil 2.11 Sentinel-2A bantlarının yansımaları grafikleri (a) Doku Grubu "1", b) Doku Grubu "2", c) Doku Grubu "3", d) Doku Grubu "4", e) Doku Grubu "5", f) Doku Grubu "6")

Sınıflandırma işlemi için hazır hale gelen veriler Envi programında açılmış ve eğitim verisi 5 doku grubu için oluşturulmuştur. Doku gruplarından 1.sınıf için 711, 2.sınıf için 378, 3.sınıf için 765, 5.sınıf için 657 ve 6.sınıf için 270 piksel doku matrisi üzerinden toplanmıştır (Şekil 2.12).



Şekil 2.12 Toplanan imzaların noktasal dağılımı

Toplanan imzalarla Landsat-8 görüntüsüne En Çok Olabilirlik yöntemi sınıflandırması uygulanmış, aşağıdaki doğruluklar elde edilmiştir (Çizelge 2.4). Doğruluklar, CBS ile oluşturulan doku haritası ve Basemap kullanılarak, sınıflandırma sonucunun doğru – yanlış olması durumuna göre değerlendirilmiştir.

Çizelge 2.4 En Çok Olabilirlik Yöntemi 'ne ait sınıflandırma doğrulukları (Landsat-8)

<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
50.4203	0.3304	50.2	16.41	51.65	56.57	44.07

DVM sınıflandırmasında kullanılan kerneller ve bu kernellere ait parametrelerin değiştirilmesiyle farklı doğruluğa sahip sınıflandırılmış veriler elde edilmektedir. Ancak bu verilerin hangisinin daha yüksek doğruluğa sahip olduğu önceden bilinmemektedir. En uygun parametre seti grid arama (grid search) yöntemi ile bulunmaktadır (Üstüner, 2013). Bunun için öncelikle görüntüye DVM sınıflandırmasının Lineer Kerneli uygulanmış, bu kernelde kullanılan C parametresine 100 ile 1000 değeri arasında sayılar verilerek en yüksek doğruluk seçilmiştir (Çizelge 2.5).

Çizelge 2.5 Lineer Kerneli'ne ait sınıflandırma doğrulukları (Landsat-8)

<u>C</u>	<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
100	55.7717	0.3836	64.38	2.01	50.27	63.83	40
200	55.8784	0.3854	64.36	2.46	50.36	64.04	40.02
400	55.9415	0.3869	64.81	3.34	50.18	63.81	39.83
600	55.9909	0.3875	64.95	3.11	50.23	63.7	40.52
800	56.0762	0.3883	65.3	2.86	50.28	63.61	40.5
1000	56.1183	0.3888	65.37	2.84	50.33	63.62	40.59

Bu işlem sonrasında Radyal Tabanlı Fonksiyon Kerneli'nin C ve γ parametreleri girilmiş ve sınıflandırma gerçekleştirilmiştir. Burada C parametresi Lineer Kerneli gibi 100-1000 aralığında değişkenlik göstermektedir, ancak γ parametresi görüntüdeki bant sayısının ters orantısı olduğu için sabittir (Çizelge 2.6).

Çizelge 2.6 Radyal Tabanlı Fonksiyon Kerneli'ne ait sınıflandırma doğrulukları (Landsat-8)

<u>C</u>	<u>γ</u>	<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
100	0.167	55.3857	0.3786	64.14	2.36	49.77	63.19	40.13
200	0.167	55.5877	0.3824	64.55	3.43	49.52	63.47	40.36
400	0.167	55.6648	0.3847	64.67	4.48	49.43	63.46	40.58
600	0.167	55.7202	0.386	64.82	4.86	49.13	63.68	41.1
800	0.167	55.6004	0.3853	64.5	5.68	49.43	63.13	41.18
1000	0.167	55.4503	0.3843	64.04	6.62	49.32	63.08	41.12

Lineer ve Radyal Tabanlı Fonksiyon kernellerinde en yüksek doğruluğun yakalandığı sınıflandırmalara bakılmış, Lineer Kerneli'nde C=1000 ve Radyal Tabanlı Fonksiyon Kerneli'nde C=600 olduğu sınıflandırmalar seçilmiştir. Sigmoid kerneli sınıflandırmasında en yüksek doğruluğa sahip olan modellerin C ve γ değerleri girilmiş, her b=0,1...6,7 değeri için sınıflandırma gerçekleştirilmiştir (Çizelge 2.7).

Çizelge 2.7 Sigmoid Kerneli'ne ait sınıflandırma doğrulukları (C=1000) (Landsat-8)

<u>C</u>	<u>γ</u>	<u>b</u>	<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
1000	0.167	0	55.718	0.3839	63.55	3.09	50.76	63.93	39.51
1000	0.167	1	55.75	0.3813	64.7	0.82	50.02	64.04	38.69

1000	0.167	2	55.167	0.3737	64.15	0.02	49.48	63.1	40.41
1000	0.167	3	53.363	0.353	61.18	1.14	45.19	64.56	40.12
1000	0.167	4			İşlem	Hata	Verdi!		
1000	0.167	5			İşlem	Hata	Verdi!		
1000	0.167	6	50.546	0.3264	50.44	8.21	40.92	70.6	37.15
1000	0.167	7	44.371	0.2192	43.01	-	26.42	77.12	15.77

C=600 için doğruluklar aşağıdaki tabloda gösterilmiştir (Çizelge2.8).

Çizelge 2.8 Sigmoid Kerneli'ne ait sınıflandırma doğrulukları (C=600) (Landsat-8)

C	γ	b	<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
600	0.167	0	55.7776	0.3835	64.48	1.96	50.24	63.79	39.82
600	0.167	1	55.6206	0.3795	64.71	0.11	50.04	63.52	40
600	0.167	2	54.8388	0.3703	63.19	0.12	49.47	63.02	40.61
600	0.167	3	53.0582	0.3489	60.61	1.89	43.39	66.2	37.97
600	0.167	4			İşlem	Hata	Verdi		
600	0.167	5			İşlem	Hata	Verdi		
600	0.167	6	51.0784	0.3302	51.94	5.94	42.21	69.79	37.27
600	0.167	7	41.619	0.1767	35.48	-	19	85.54	3.88

Son olarak Polinom Kerneli'nin uygulanması için C parametresinin 600 ve 1000 verildiği modellere bakılmış olup, C'nin 600 olduğu modellerde daha yüksek olduğu gözlemlenmiştir. Buna göre C=600, b (Bias)=0,1...6,7 ve d (Derece)=1,2...5,6 kombinasyonları ile modeller oluşturulmuş ve doğruluklar aşağıda gösterilmiştir (Çizelge 2.9).

Çizelge 2.9 Polinom Kerneli'ne ait sınıflandırma doğrulukları (C=600) (Landsat-8)

C	γ	d	b	<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
600	0.167	1	0	55.7709	0.3836	64.38	2.02	50.26	63.84	40
600	0.167	2	0	54.0021	0.3573	59.28	1.13	51.94	62.3	36.08
600	0.167	3	0	46.1079	0.2457	38.95	1.23	60.38	49.79	28.2
600	0.167	4	0	43.3115	0.1989	41.5	1.97	65	33.43	17.7
600	0.167	5	0	39.6228	0.1445	50.16	0.01	68.76	8.45	18.33
600	0.167	6	0	22.9493	0.0326	10.15	-	-	-	99.19

600	0.167	1	1	55.7761	0.3836	64.42	2.03	50.24	63.82	39.99
600	0.167	2	1	56.0242	0.3877	65.45	2.98	49.58	64.01	40.23
600	0.167	3	1	55.8616	0.3876	65.29	4.85	49.77	62.96	41.06
600	0.167	4	1	55.531	0.3854	64.57	6.78	49.17	62.84	41.53
600	0.167	5	1	55.3815	0.3843	64.29	7.61	49.17	62.43	41.94
600	0.167	6	1	55.4258	0.3846	64.88	7.47	48.96	62.17	41.86
600	0.167	1	2	55.7716	0.3836	64.38	2	50.24	63.86	39.99
600	0.167	2	2	56.1999	0.3897	66.14	2.92	49.63	63.78	40.25
600	0.167	3	2	55.6531	0.3868	65.17	6.64	48.84	62.88	42.11
600	0.167	4	2	55.2395	0.3832	64.44	8.67	48.8	61.92	42.11
600	0.167	5	2	55.1944	0.3823	64.99	8.39	49.93	59.84	43.15
600	0.167	6	2	54.9224	0.3794	64.97	8.96	49.75	58.93	43.5
600	0.167	1	3	55.7712	0.3836	64.37	2	50.25	63.86	40
600	0.167	2	3	56.2375	0.3903	66.39	2.95	49.57	63.61	40.86
600	0.167	3	3	55.5039	0.3856	64.84	7.54	48.93	62.46	42.17
600	0.167	4	3	55.2277	0.3829	64.93	8.47	49.77	60.24	42.69
600	0.167	5	3	54.9343	0.3796	65.14	9.2	49.57	59.03	42.8
600	0.167	6	3	54.8005	0.3784	65.17	9.52	49.37	58.53	43.83
600	0.167	1	4	55.7716	0.3836	64.37	2	50.23	63.88	40.02
600	0.167	2	4	56.2355	0.3906	66.36	3.26	49.65	63.47	41.04
600	0.167	3	4	55.5219	0.3857	64.77	7.61	49.24	62.29	41.88
600	0.167	4	4	54.8996	0.3802	64.3	9.84	49.29	60.01	43.08
600	0.167	5	4	54.3666	0.3753	63.03	11.44	49.69	58.8	43.64
600	0.167	6	4	53.8381	0.3688	62.81	12.48	49.96	56.83	42.58
600	0.167	1	5	55.7711	0.3836	64.37	2	50.23	63.88	40.03
600	0.167	2	5	56.2587	0.3908	66.5	3.14	49.54	63.54	41.03
600	0.167	3	5	55.2753	0.3834	64.56	8.37	48.85	61.9	42.2
600	0.167	4	5	54.9348	0.3801	64.67	9.51	49.3	59.84	42.49
600	0.167	5	5	54.1485	0.373	63	11.84	47.83	60.05	42.96
600	0.167	6	5	53.892	0.3686	61.4	13.28	50.34	58.5	39.48
600	0.167	1	6	55.7723	0.3836	64.37	2	50.23	63.88	40.03
600	0.167	2	6	56.2042	0.3904	66.25	3.45	49.55	63.53	41.17
600	0.167	3	6	55.2633	0.3835	64.49	8.25	49.01	61.68	42.96

600	0.167	4	6	54.8151	0.3792	64.77	10.15	48.51	59.99	42.73
600	0.167	5	6	53.8518	0.3696	61.89	12.11	49.94	58.05	42.45
600	0.167	6	6	54.0239	0.3694	62.68	11.03	51.28	56.37	43.61
600	0.167	1	7	55.7712	0.3836	64.37	2	50.24	63.87	40.02
600	0.167	2	7	56.189	0.3903	66.07	3.54	49.84	63.4	40.97
600	0.167	3	7	55.0211	0.3813	63.48	9.38	48.34	62.63	42.01
600	0.167	4	7	54.6275	0.3775	63.53	11.04	50.12	58.95	42.22
600	0.167	5	7	54.5289	0.3764	63.25	11.55	48.7	60.37	41.93
600	0.167	6	7	54.4334	0.3754	64.93	10.72	48.2	58.76	42.15

Doğruluk analizlerine bakıldığında, birçok modelin EÇO sınıflandırmasından üstün olduğu gözlemlenmiştir. Polinom Kerneli'nde $C=600$, $\gamma=0.167$, $d=2$ ve $b=5$ değerleri ile oluşturulan modelin en yüksek doğruluğa sahip görüntü olduğu tespit edilmiştir. Landsat-8 görüntüsü için kernellerin doğruluk analizleri yapıldıktan sonra aynı algoritma Sentinel-2A görüntüsü için de uygulanmış ve aşağıdaki doğruluklar elde edilmiştir.

Çizelge 2.10 En Çok Olabilirlik Yöntemi 'ne ait sınıflandırma doğrulukları (Sentinel-2A)

<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
30.1442	0.088	34.7	9.4	53	0.03	64.2

Çizelge 2.11 Linear Kerneli'ne ait sınıflandırma doğrulukları (Sentinel-2A)

<u>C</u>	<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
100	41.5725	0.1923	39.3	4.31	35.54	58.58	34.1
200	41.9371	0.1958	40.7	3.1	35.37	58.59	34.58
400	41.6464	0.195	38.65	5.22	36.03	58.9	34.13
600	42.3584	0.1988	42.14	1.52	35.58	58.54	34.25
800	42.1654	0.1981	41.39	2.94	35.61	58.45	34.13
1000	42.5736	0.1995	44.19	0.43	34.39	58.42	34.23

Çizelge 2.12 Radyal Tabanlı Fonksiyon Kerneli'ne ait sınıflandırma doğrulukları (Sentinel-2A)

<u>C</u>	<u>γ</u>	<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
100	0.143	41.5464	0.1875	39.58	0.36	36.15	58.22	34.38
200	0.143	41.8189	0.1914	40.68	0.91	35.73	58.24	34.52
400	0.143	42.0738	0.1951	41.76	1.2	35.32	58.2	35.07
600	0.143	42.173	0.1971	42.24	1.48	35.08	58.15	35.5
800	0.143	42.141	0.1972	41.78	1.93	35.69	57.84	35.43
1000	0.143	42.2055	0.1978	41.94	1.74	35.75	57.86	35.37

Çizelge 2.13 Sigmoid Kerneli'ne ait sınıflandırma doğrulukları (C=1000) (Sentinel-2A)

<u>C</u>	<u>γ</u>	<u>b</u>	<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
1000	0.143	0	42.1655	0.1947	41.94	0.43	36.15	58.51	34.53
1000	0.143	1	41.8373	0.1918	39.86	0.85	35.73	58.31	34.35
1000	0.143	2	-	-	İşlem	Hata	Verdi!	-	-
1000	0.143	3	-	-	İşlem	Hata	Verdi!	-	-
1000	0.143	4	-	-	İşlem	Hata	Verdi!	-	-
1000	0.143	5	-	-	İşlem	Hata	Verdi!	-	-
1000	0.143	6	-	-	İşlem	Hata	Verdi!	-	-
1000	0.143	7	-	-	İşlem	Hata	Verdi!	-	-

Çizelge 2.14 Polinom Kerneli'ne ait sınıflandırma doğrulukları (C=1000) (Sentinel-2A)

<u>C</u>	<u>γ</u>	<u>d</u>	<u>b</u>	<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
1000	0.143	1	0	42.2323	0.196	42.5	0.8	34.9	58.5	34.6
1000	0.143	2	0	39.2773	0.161	28.8	1	34.1	65.4	29
1000	0.143	3	0	37.1178	0.128	10.4	-	53.5	59.1	23.2
1000	0.143	4	0	31.3294	0.027	16	-	84.5	0.01	16.7
1000	0.143	5	0	16.4542	0.001	-	-	-	71.4	30.9
1000	0.143	6	0	16.6282	4E-04	-	-	-	100	0.2
1000	0.143	1	1	41.8844	0.196	41.3	3.5	34.5	58.6	34.4
1000	0.143	2	1	42.2165	0.198	42.4	2.1	34.7	58.5	34.5

1000	0.143	3	1	42.2866	0.199	42.5	1.6	35.1	58.3	35.5
1000	0.143	4	1	42.3947	0.2	42.7	1.2	35.6	57.9	36.3
1000	0.143	5	1	<u>42.4581</u>	0.201	42.7	0.8	35.8	57.8	36.8
1000	0.143	6	1	42.4424	0.201	42.1	0.7	36.8	57.4	37.3
1000	0.143	1	2	41.8814	0.196	41.3	3.5	34.6	58.6	34.5
1000	0.143	2	2	42.2214	0.199	42.3	2.9	34.7	58.5	34.8
1000	0.143	3	2	<u>42.2715</u>	0.201	42.1	2.6	35.5	57.9	36.4
1000	0.143	4	2	42.2021	0.201	41.8	2.9	36.3	57	37.5
1000	0.143	5	2	42.0212	0.199	41.2	3	37.2	56	37.4
1000	0.143	6	2	41.7816	0.197	39.8	3.7	39.6	54	38.3
1000	0.143	1	3	41.8928	0.196	41.4	3.5	34.5	58.6	34.5
1000	0.143	2	3	42.1694	0.199	42.1	3.3	34.7	58.5	34.6
1000	0.143	3	3	<u>42.2229</u>	0.201	42	3.1	35.3	57.8	36.7
1000	0.143	4	3	42.0812	0.199	41.7	2.6	36.6	56.4	37.4
1000	0.143	5	3	41.8655	0.198	41.8	3.3	37.9	53.9	38.8
1000	0.143	6	3	41.5856	0.196	41.7	5.4	35.8	54.8	38.2
1000	0.143	1	4	41.8262	0.195	40.8	3.8	35	58.4	34.6
1000	0.143	2	4	42.0466	0.198	41.6	3.9	34.7	58.5	34.7
1000	0.143	3	4	<u>42.2508</u>	0.201	43.1	2.5	35.3	56.8	37.6
1000	0.143	4	4	41.7962	0.195	41.4	2.2	37.5	54.9	37.3
1000	0.143	5	4	41.327	0.192	36.3	3	41	54.8	39.3
1000	0.143	6	4	41.2497	0.194	35.7	2.9	39.1	57	42
1000	0.143	1	5	41.945	0.196	41.4	2.9	34.8	58.4	34.8
1000	0.143	2	5	<u>42.2926</u>	0.2	42.8	2.9	34.7	58.2	34.3
1000	0.143	3	5	42.2323	0.202	42.4	2.7	35.4	57.4	37.6
1000	0.143	4	5	41.985	0.198	40	2.2	38.6	56	37.2
1000	0.143	5	5	41.8619	0.199	41.3	2.7	35.2	57.2	40.2
1000	0.143	6	5	41.2561	0.196	39	5.5	34.7	57.4	42.2
1000	0.143	1	6	41.8271	0.195	40.8	3.7	34.9	58.5	34.6
1000	0.143	2	6	42.1745	0.199	42.2	3.3	34.9	58.1	35
1000	0.143	3	6	<u>42.1757</u>	0.201	42.9	2.6	35.3	56.8	37.6
1000	0.143	4	6	41.9522	0.2	40	2.7	35.9	58.5	38.3
1000	0.143	5	6	41.527	0.193	37	2.5	39.5	56.7	38

1000	0.143	6	6	41.235	0.193	38.4	2.7	39.7	53.2	42.9
1000	0.143	1	7	41.8649	0.196	41	3.5	34.9	58.4	34.6
1000	0.143	2	7	42.1121	0.199	42.1	3.9	34.4	58.5	34.9
1000	0.143	3	7	41.9448	0.198	40.6	2.4	36.7	57	38.6
1000	0.143	4	7	42.3987	0.203	44.4	1.3	34.2	57.1	38.2
1000	0.143	5	7	41.9468	0.198	40	1.6	38.6	55.8	38.4
1000	0.143	6	7	41.0812	0.188	38.1	3.6	40.2	52.9	38.1

İki farklı uydu görüntüsüne En Çok Olabilirlik ve Destek Vektör Makineleri yöntemleri uygulandıktan sonra, her sonuç görüntüyle CBS ile elde edilmiş doku gridi verisi karşılaştırılmıştır. Her 150m.*150m. grid içine düşen sınıflanmış piksellerin sayıca çok olanı seçtilerip o gride yazdırılmış, böylelikle her görüntü için genelleştirme işlemi uygulanmıştır. Bu işlemin yapılma amacı; sınıflandırma doğruluğunun artırılması, dağılmış doku parçası sınıflarının giderilmesidir. Bu çalışma kapsamında sınıflandırılmış görüntülerin, görsel ve istatistiksel olarak doğruluklarının artışı genelleştirme yöntemi ile test edilmiştir. Sınıflandırma işlemi yapılan her modelin genelleştirmesi her iki yöntem ve uydu görüntüsü için aşağıda verilmiştir.

Çizelge 2.15 En Çok Olabilirlik Yöntemi 'ne ait genelleştirme doğrulukları (Landsat-8)

<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
64.089	0.5043	63.49	10.2	71.94	67.12	59.54

Çizelge 2.16 Lineer Kerneli'ne ait genelleştirme doğrulukları (Landsat-8)

<u>C</u>	<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
100	66.8477	0.533	76.91	-	63.18	73.97	49.06
200	67.0986	0.5365	77.1	-	63.43	74.33	49.37
400	67.3081	0.5394	78.13	0.15	63.27	73.93	50
600	67.4283	0.5411	78.41	0.07	63.39	73.79	51.05
800	67.471	0.5414	78.71	-	63.4	73.64	50.63
1000	67.5253	0.5421	78.89	0.07	63.46	73.53	50.73

Çizelge 2.17 Radyal Tabanlı Fonksiyon Kerneli'ne ait genelleştirme doğrulukları (Landsat-8)

<u>C</u>	<u>γ</u>	<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
100	0.167	66.6628	0.5308	77.11	-	62.65	73.56	49.69
200	0.167	66.88	0.5339	77.81	0.15	62.27	73.86	49.9
400	0.167	67.1322	0.5376	78.41	0.51	62.41	73.83	50
600	0.167	67.2744	0.5399	78.63	0.88	62.08	74.17	51.36
800	0.167	67.0921	0.5376	78.4	1.47	62.41	73.4	50.94
1000	0.167	67.0611	0.5377	77.98	1.54	62.6	73.46	51.68

Çizelge 2.18 Sigmoid Kerneli'ne ait genelleştirme doğrulukları (C=1000) (Landsat-8)

<u>C</u>	<u>γ</u>	<u>b</u>	<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
1000	0.167	0	66.8516	0.533	77.14	-	63.08	73.84	48.85
1000	0.167	1	66.602	0.5292	76.89	-	62.6	73.87	48.01
1000	0.167	2	66.4145	0.5276	75.89	-	62.69	73.91	50.63
1000	0.167	3	64.5318	0.502	73.82	0.15	53.49	79.8	47.69
1000	0.167	4			İşlem	Hata	Verdi!		
1000	0.167	5			İşlem	Hata	Verdi!		
1000	0.167	6	61.6378	0.4681	62.25	3.23	49.88	86.34	46.86
1000	0.167	7	41.5926	0.178	35.42	-	10.59	94.98	0.73

Çizelge 2.19 Sigmoid Kerneli'ne ait genelleştirme doğrulukları (C=600) (Landsat-8)

<u>C</u>	<u>γ</u>	<u>b</u>	<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
600	0.167	0	66.9783	0.535	76.26	0.22	64.19	74.15	48.43
600	0.167	1	66.9176	0.5329	77.32	-	62.7	74.57	46.44
600	0.167	2	66.4145	0.5276	75.89	-	62.69	73.91	50.63
600	0.167	3	65.2236	0.5122	74.36	0.07	57.13	77.38	50.63
600	0.167	4			İşlem	Hata	Verdi!		
600	0.167	5			İşlem	Hata	Verdi!		
600	0.167	6	61.6378	0.4681	62.25	3.23	49.88	86.34	46.86
600	0.167	7	47.6669	0.2624	47.97	-	20.92	89.73	9.96

Çizelge 2.20 Polinom Kerneli'ne ait genelleştirme doğrulukları (C=600) (Landsat-8)

<u>C</u>	<u>γ</u>	<u>d</u>	<u>b</u>	<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
600	0.167	1	0	<u>66.8594</u>	0.5332	76.91	-	63.18	74	49.16
600	0.167	2	0	65.5235	0.514	70.87	-	67.62	72.16	44.18
600	0.167	3	0	53.4098	0.3416	42.29	-	77.47	53.4	32.11
600	0.167	4	0	48.0002	0.257	45.03	0.07	82.72	27.28	18.49
600	0.167	5	0	42.6766	0.1799	53.76	-	82.14	1.33	14.97
600	0.167	6	0	37.0166	-	-	-	-	-	100
600	0.167	1	1	66.8632	0.5332	76.99	-	63.18	73.93	49.06
600	0.167	2	1	67.3391	0.5398	78.67	0.07	62.39	74.45	49.37
600	0.167	3	1	<u>67.3779</u>	0.541	79.24	0.51	62.8	73.16	51.26
600	0.167	4	1	67.2059	0.5395	78.75	1.61	62.35	73.27	52.2
600	0.167	5	1	67.1632	0.5395	78.26	1.91	62.92	72.9	53.14
600	0.167	6	1	67.2744	0.5408	78.97	1.91	62.75	72.61	53.35
600	0.167	1	2	66.84	0.5329	76.92	-	63.12	73.98	49.16
600	0.167	2	2	<u>67.4632</u>	0.5412	79.49	0.07	62.37	74	49.16
600	0.167	3	2	67.3753	0.5416	79.43	1.61	62.01	73.36	52.83
600	0.167	4	2	67.2628	0.541	78.87	2.2	62.68	72.61	54.09
600	0.167	5	2	67.3391	0.542	79.22	2.35	64.69	70.01	56.39
600	0.167	6	2	67.0443	0.5382	79.62	2.57	64.26	68.87	56.71
600	0.167	1	3	66.8477	0.5331	76.92	-	63.14	73.98	49.16
600	0.167	2	3	<u>67.568</u>	0.5426	79.98	0.07	62.1	73.86	50.84
600	0.167	3	3	67.3688	0.5419	79.12	1.91	62.46	73.05	53.67
600	0.167	4	3	67.3947	0.5428	79.25	2.35	64.44	70.5	55.77
600	0.167	5	3	67.2499	0.5411	79.97	2.57	64.26	69.24	56.29
600	0.167	6	3	67.0792	0.5387	80.38	2.86	64.07	68.23	56.92
600	0.167	1	4	66.8671	0.5333	76.94	-	63.1	74.06	49.16
600	0.167	2	4	<u>67.6068</u>	0.5432	79.95	0.07	62.43	73.64	51.15
600	0.167	3	4	67.4503	0.543	79.04	1.91	63.01	72.9	53.25
600	0.167	4	4	67.0999	0.5397	78.79	3.08	63.81	70.42	56.6
600	0.167	5	4	66.5606	0.5334	77.78	4.4	64.6	68.47	57.55
600	0.167	6	4	66.3007	0.5299	77.94	5.36	65.86	66.16	55.14

600	0.167	1	5	66.871	0.5334	76.95	-	63.09	74.06	49.27
600	0.167	2	5	67.6068	0.5432	80.02	0.07	62.2	73.79	51.26
600	0.167	3	5	67.3404	0.542	79.1	2.27	62.75	72.57	53.77
600	0.167	4	5	67.1542	0.5401	79.25	3.01	63.88	70.16	55.56
600	0.167	5	5	66.377	0.5317	77.98	5.28	62.05	70.41	55.56
600	0.167	6	5	66.046	0.5254	76.17	6.09	65.71	67.85	51.15
600	0.167	1	6	66.8749	0.5335	76.93	-	63.13	74.06	49.27
600	0.167	2	6	67.5913	0.5431	79.88	0.07	62.2	73.84	51.68
600	0.167	3	6	67.3869	0.5429	78.87	2.42	63.05	72.41	55.56
600	0.167	4	6	67.0701	0.5391	79.68	3.37	62.84	70.35	55.87
600	0.167	5	6	66.5115	0.5334	76.79	5.06	66.31	67.86	54.82
600	0.167	6	6	66.0925	0.5255	77.56	4.11	66.91	64.88	55.87
600	0.167	1	7	66.8671	0.5333	76.94	-	63.12	74.05	49.16
600	0.167	2	7	67.5835	0.543	79.71	0.07	62.64	73.53	51.78
600	0.167	3	7	67.0999	0.5394	77.95	3.01	62.15	73.46	54.51
600	0.167	4	7	67.0753	0.5402	78.42	5.06	65.46	68.76	55.66
600	0.167	5	7	67.0287	0.5398	78.24	4.99	63.44	71.08	54.82
600	0.167	6	7	66.8555	0.5361	80.37	3.37	62.83	69.09	53.77

Çizelge 2.21 En Çok Olabilirlik Yöntemi 'ne ait genelleştirme doğrulukları (Sentinel-2A)

<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
38.7691	0.1819	37.1	4.25	77.45	-	84.07

Çizelge 2.22 Lineer Kerneli 'ne ait genelleştirme doğrulukları (Sentinel-2A)

<u>C</u>	<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
100	51.6831	0.3237	47.62	0.51	43.86	75.83	40.46
200	52.6061	0.3362	50.47	-	43.6	76.03	41.51
400	52.4277	0.335	47.36	0.66	45.83	76.46	41.82
600	53.4399	0.3467	52.72	-	43.92	76.07	41.19
800	53.3002	0.3454	52.01	-	44.31	75.99	41.19
1000	53.6803	0.3489	56.42	-	40.4	76.51	40.25

Çizelge 2.23 Radyal Tabanlı Fonksiyon Kerneli'ne ait genelleştirme doğrulukları (Sentinel-2A)

<u>C</u>	<u>γ</u>	<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
100	0.143	50.8202	0.3104	46.14	-	44.09	74.55	38.89
200	0.143	51.563	0.3208	48.45	-	43.44	75	40.25
400	0.143	52.3695	0.3322	51.19	-	42.55	75.41	41.93
600	0.143	53.4399	0.3467	52.72	-	43.92	76.07	41.19
800	0.143	53.0831	0.3428	52.09	0.07	43.88	75.3	43.19
1000	0.143	53.2266	0.3447	52.3	0.07	44.14	75.33	42.87

Çizelge 2.24 Sigmoid Kerneli'ne ait genelleştirme doğrulukları (C=1000) (Sentinel-2A)

<u>C</u>	<u>γ</u>	<u>b</u>	<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
1000	0.143	0	52.4548	0.3326	51.11	0	42.68	75.83	40.78
1000	0.143	1	51.6638	0.3224	47.11	0	45.47	74.74	40.36
1000	0.143	2			İşlem	Hata	Verdi!		
1000	0.143	3			İşlem	Hata	Verdi!		
1000	0.143	4			İşlem	Hata	Verdi!		
1000	0.143	5			İşlem	Hata	Verdi!		
1000	0.143	6			İşlem	Hata	Verdi!		
1000	0.143	7			İşlem	Hata	Verdi!		

Çizelge 2.25 Polinom Kerneli'ne ait genelleştirme doğrulukları (C=1000) (Sentinel-2A)

<u>C</u>	<u>γ</u>	<u>d</u>	<u>b</u>	<u>Doğruluk</u>	<u>Kappa</u>	<u>Doku1</u>	<u>Doku2</u>	<u>Doku3</u>	<u>Doku5</u>	<u>Doku6</u>
1000	0.143	1	0	52.641	0.3353	52.39	-	41.74	75.98	40.99
1000	0.143	2	0	45.5321	0.2387	28.17	-	38.88	83.69	27.25
1000	0.143	3	0	41.6444	0.1844	2.42	-	65.66	71.88	22.01
1000	0.143	4	0	31.9629	0.0294	5.92	-	98.05	-	11.95
1000	0.143	5	0			İşlem	Hata	Verdi!		
1000	0.143	6	0			İşlem	Hata	Verdi!		
1000	0.143	1	1	52.4781	0.3342	52.22	-	40.94	76.39	41.4
1000	0.143	2	1	52.9202	0.3396	53.13	-	41.56	76.2	41.72

1000	0.143	3	1	53.2692	0.3451	53.43	0.07	42.46	75.99	42.66
1000	0.143	4	1	53.657	0.3512	53.44	0.07	43.88	75.61	44.44
1000	0.143	5	1	53.7889	0.3534	53.25	0.07	44.42	75.62	45.18
1000	0.143	6	1	53.785	0.3538	51.57	0.07	46.86	74.78	46.54
1000	0.143	1	2	52.5207	0.3348	52.22	-	41.08	76.36	41.61
1000	0.143	2	2	53.277	0.3451	54.09	-	41.29	76.51	42.66
1000	0.143	3	2	53.7462	0.3531	53.3	0.15	43.8	76.06	45.18
1000	0.143	4	2	54.1767	0.3606	53.05	0.15	46.2	74.89	48.43
1000	0.143	5	2	54.2736	0.3616	52.84	0.07	48.79	72.74	48.32
1000	0.143	6	2	54.3977	0.3643	50.28	0.37	55.22	68.95	50.63
1000	0.143	1	3	52.5518	0.3352	52.49	-	40.86	76.39	41.61
1000	0.143	2	3	53.2964	0.3455	53.87	0.07	41.53	76.62	42.24
1000	0.143	3	3	53.9401	0.3563	53.53	0.22	43.95	76.24	45.81
1000	0.143	4	3	54.3047	0.3618	53.19	0.07	47.56	73.8	48.01
1000	0.143	5	3	54.6149	0.3669	54.35	0.22	50.74	69.62	51.89
1000	0.143	6	3	54.8127	0.37	56.29	0.51	46.15	72.84	52.52
1000	0.143	1	4	52.4083	0.3336	51.31	0.07	42.04	75.96	41.82
1000	0.143	2	4	53.3856	0.3472	53.37	0.22	42.08	76.84	42.77
1000	0.143	3	4	54.3706	0.3625	55.86	0.07	43.74	75	48.11
1000	0.143	4	4	53.8664	0.3553	52.08	0	49.66	71.26	48.43
1000	0.143	5	4	53.4088	0.3524	42.02	0.15	59.46	70.3	52.52
1000	0.143	6	4	53.0365	0.3502	41.57	0.15	54.53	74.19	56.81
1000	0.143	1	5	52.4975	0.3345	52	-	41.65	75.92	41.72
1000	0.143	2	5	53.6493	0.3498	55.28	-	41.59	76.27	41.72
1000	0.143	3	5	54.1379	0.3596	54.43	0.07	44.04	75.48	48.43
1000	0.143	4	5	54.1922	0.3607	49.24	-	52.71	72.52	47.9
1000	0.143	5	5	54.4908	0.3665	53.89	0.07	44.36	76.39	53.14
1000	0.143	6	5	53.8393	0.3613	50.72	0.59	43.66	77.54	59.75
1000	0.143	1	6	52.3424	0.3327	51.25	0.07	41.87	75.99	41.72
1000	0.143	2	6	53.5407	0.3492	53.98	-	42.55	76.2	42.98
1000	0.143	3	6	54.3628	0.3624	55.55	0.07	43.91	75.15	48.11
1000	0.143	4	6	54.0487	0.3603	50.37	-	45.51	78.11	50
1000	0.143	5	6	53.2964	0.3499	43.29	-	55.28	73.32	49.37

1000	0.143	6	6	53.9479	0.3621	46.17	0.07	56.66	69.42	59.96
1000	0.143	1	7	52.4277	0.3338	51.59	-	41.79	75.98	41.82
1000	0.143	2	7	53.5097	0.3489	54.52	0.22	41.26	76.83	42.66
1000	0.143	3	7	53.8005	0.3561	50.08	-	47.98	74.93	50
1000	0.143	4	7	54.4171	0.3631	58.05	-	39.77	76.69	49.48
1000	0.143	5	7	54.006	0.3594	48.31	-	52.79	72.55	50.21
1000	0.143	6	7	52.9435	0.3448	45.28	0.15	57.27	67.45	50.63


Doğruluk çizelgelerine bakıldığında, genelleştirmenin sınıflandırma doğruluğunu artırdığı görülmektedir. Bu artırım, aşağıdaki doku örnek alanlarında incelenmiştir. Üsküdar-Karacaahmet Mezarlığı'nın kuzey kısmında yer alan, 3 ve 5 numaralı dokuların yoğun bulunduğu bölgede, sınıflandırma görüntüsü aşağıdaki gibidir (Şekil 2.13). Yuvarlak içine alınan bölgelere bakıldığında, genelleştirme işlemi sonrasında görüntünün yüksek doğrulukla sınıflandığı görülmektedir.





Şekil 2.14 En yüksek doğruluğa sahip genelleştirme görüntüsü (Üsküdar)(Landsat-8)

Şekil 2.15'te görülen Esenler İlçesi'nin YTÜ kampüsünün sağ tarafında bulunan Bayrampaşa Sanayi Sitesi'ne bakıldığında, sanayi dokusuyla 5 numaralı yoğun konut dokusu karışmış, genelleştirme işlemi ile bu karışma giderilmiştir (Şekil 2.16).




Şekil 2.15 En yüksek doğruluğa sahip sınıflandırma görüntüsü (Esenler-Davutpaşa ve Bayrampaşa) (Landsat-8)



Şekil 2.16 En yüksek doğruluğa sahip genelleştirme görüntüsü (Esenler-Davutpaşa ve Bayrampaşa) (Landsat-8)

Şekil 2.17'deki Atatürk Havaalanı'nın batısına düşen bölgede çoğunlukta bulunan 3 numaralı doku 5 dokusuyla karışmış, genelleştirme işlemi ile bu karışıklık giderilmiştir (Şekil 2.18).



Şekil 2.17 En yüksek doğruluğa sahip sınıflandırma görüntüsü (Küçükçekmece-Bakırköy) (Landsat-8)



Şekil 2.18 En yüksek doğruluğa sahip geliştirme görüntüsü (Küçükçekmece-Bakırköy) (Landsat-8)

Şekil 2.19'daki İSKİ Bahçelievler Şube Müdürlüğü'nün güneyinde bulunan bölgede yoğun bulunan 3 dokusu 5 dokusu ile karışma göstermiş, yapılan geliştirme işlemi ile karışıklık giderilmiştir (Şekil 2.20).




Şekil 2.19 En yüksek doğruluğa sahip sınıflandırma görüntüsü (Bahçelievler-Güngören) (Landsat-8)




Şekil 2.20 En yüksek doğruluğa sahip genelleştirme görüntüsü (Bahçelievler-Güngören) (Landsat-8)

Çalışma alanının tamamını gösteren, en yüksek sınıflandırma ve genelleştirme doğruluğuna ait Landsat-8 görüntüleri Şekil 2.21 ve Şekil 2.22’de gösterilmiştir.




Şekil 2.21 En yüksek doğruluğa sahip sınıflandırma görüntüsü (Landsat-8)




Şekil 2.22 En yüksek doğruluğa sahip geliştirme görüntüsü (Landsat-8)

Çalışma alanının tamamını gösteren, en yüksek sınıflandırma ve geliştirme doğruluğuna ait Sentinel-2A görüntüleri Şekil 2.23 ve Şekil 2.24’de gösterilmiştir.



Şekil 2.23 En yüksek doğruluğa sahip sınıflandırma görüntüsü (Sentinel-2A)



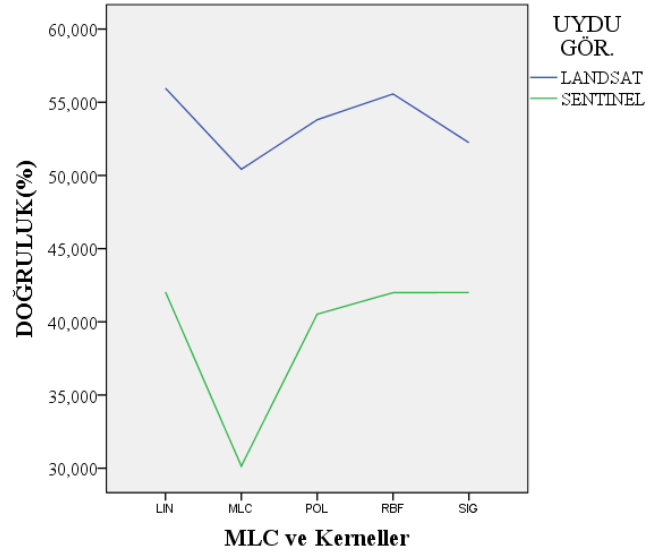
Şekil 2.24 En yüksek doğruluğa sahip genelleştirme görüntüsü (Sentinel-2A)

Son olarak elde edilen EÇO yöntemine ait sınıflandırma görüntüleri ile DVM kernellerinde en yüksek doğruluğa sahip sınıflandırma görüntüleri arasındaki korelasyonlar Bivariate korelasyon yöntemi incelenmiştir (Çizelge 2.26).

2.5 Bulgular

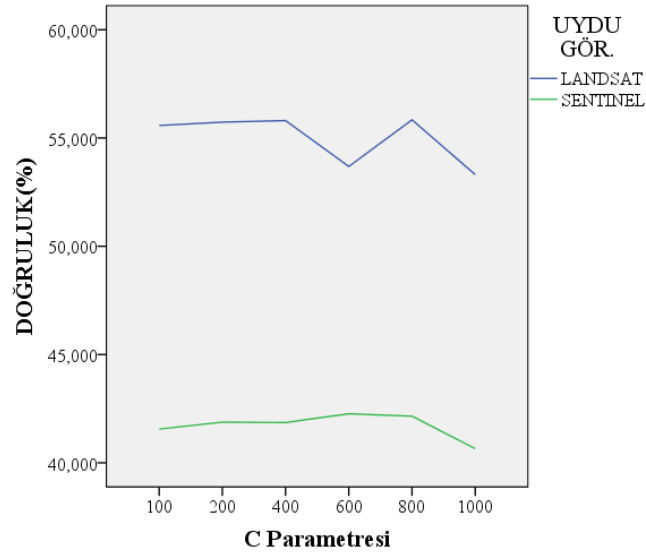
Sınıflandırma işlemleri yapıldıktan sonra elde edilen her sonuç SPSS programında değerlendirilmeye alınmıştır. Sonuçlar, sınıflandırma türüne göre (DVM, EÇO), işlem türüne göre (sınıflandırma, genelleştirme), parametre türüne göre (C, d, b), kernel tipine göre (linear, polinom, radyal tabanlı fonksiyon, sigmoid) ve uydu görüntüsüne göre (Landsat-8, Sentinel-2A) ayrı ayrı SPSS programında değerlendirilmiştir.

Öncelikle EÇO yöntemi ile DVM kernellerinin doğrulukları, uydu görüntüsünün türüne göre SPSS programında analizi yapılmıştır. Landsat-8 görüntüsü ile yapılan sınıflandırmalarda EÇO yöntemi %50 doğruluk verirken, DVM kernellerinde yaklaşık %54-55 doğruluk çıkmıştır. Aynı şekilde Sentinel-2A görüntüsü ile yapılan sınıflandırmalarda EÇO yöntemi %30 doğruluk verirken, DVM kernellerinde yaklaşık %41-42 doğruluk elde edilmiştir. Ayrıca iki uydu görüntüsü sonuçları karşılaştırıldığında, Landsat-8 ile yapılan sınıflandırmaların Sentinel-2A ile yapılan sınıflandırmalara göre %14 daha yüksek doğruluk verdiği görülmüştür (Şekil 2.25).



Şekil 2.25 Görüntüye göre EÇO ve DVM kernellerinin doğrulukları

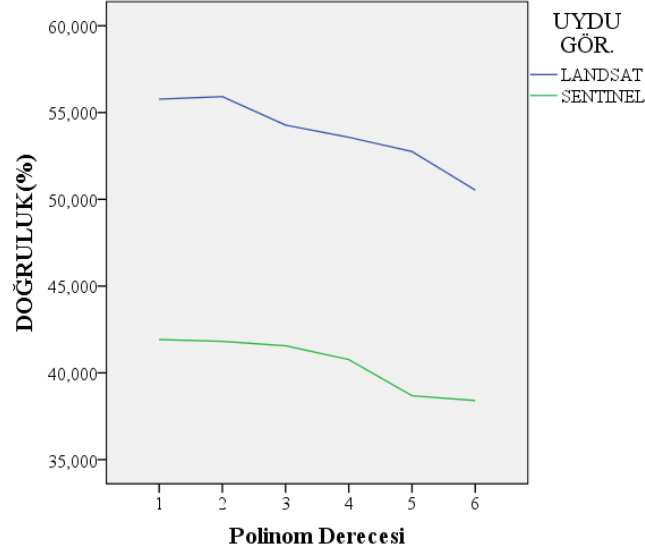
DVM yönteminin her kernelinde kullanılan C parametresinin görüntü türüne göre doğruluğa etkisi araştırılmıştır. Landsat-8 ile yapılan sınıflandırmaların yaklaşık %54-56 doğruluk verdiği, Sentinel-2A ile yapılan sınıflandırmaların yaklaşık %41-42 doğruluk verdiği gözlemlenmiştir. Ayrıca Landsat-8 ile yapılan DVM sınıflandırmaları, Sentinel-2A ile yapılan sınıflandırmalara göre %14-15 daha yüksek doğruluk verdiği grafik üzerinde görülmektedir (Şekil 2.26).



Şekil 2.26 Görüntüye göre C parametresinin doğruluğa etkisi

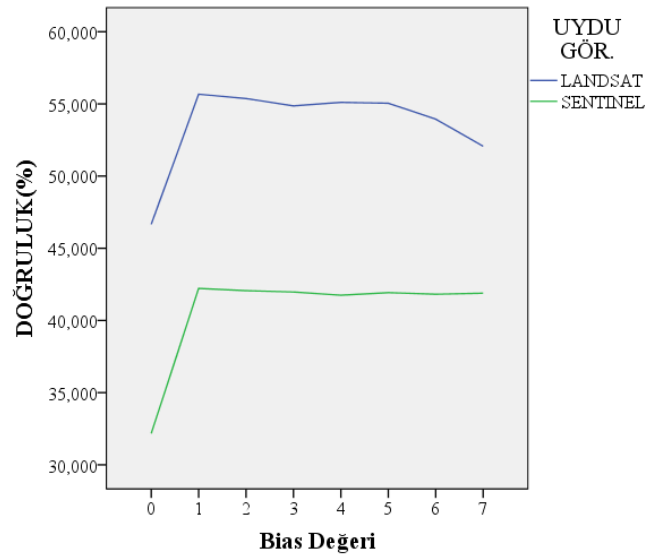
DVM yönteminin sadece polinom kernelinde kullanılan polinom derecesi 1 ile 6 arasında değer almaktadır. Bu değerın değışmesi ile elde edilen doğruluklar grafik

üzerinde incelendiğinde, Landsat-8 ile yapılan sınıflandırmalarda %51-56, Sentinel-2A ile yapılan sınıflandırmalarda %39-42 aralığında doğruluk verdiği görülmüştür. Ayrıca polinom derecesi yükseldikçe doğruluk değerleri düşmektedir (Şekil 2.27).



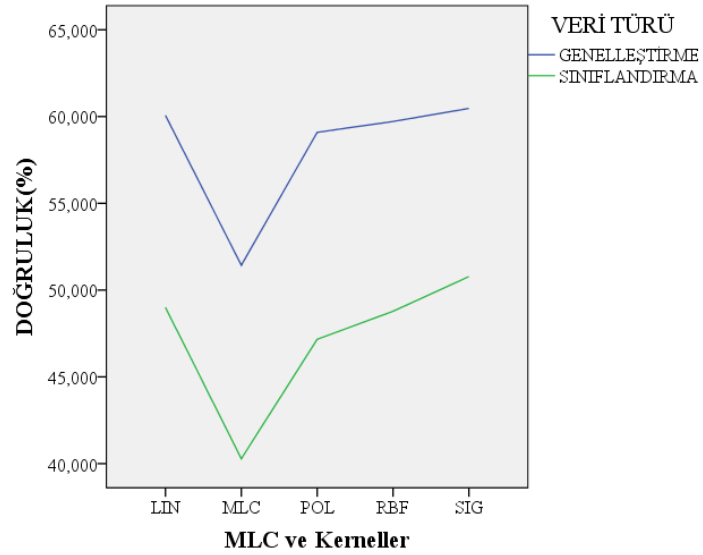
Şekil 2.27 Görüntüye göre polinom derecesinin doğruluğa etkisi

Polinom ve sigmoid kernellerinde kullanılan b (bias) değerinin doğruluğa etkisini araştırmak için bias değerleri ile doğruluklar SPSS grafiğinde incelenmiştir. Değerin 0 girildiği sınıflandırmalar oldukça düşük doğruluk vermiştir. Diğer değerlerde ise Landsat-8 ile yapılan sınıflandırmalar %52-56 aralığında, Sentinel-2A ile yapılan sınıflandırmalar %42 civarında doğruluk vermiştir (Şekil 2.28).



Şekil 2.28 Görüntüye göre bias parametresinin doğruluğa etkisi

Son olarak sınıflandırma ve genelleştirme görüntülerinin doğrulukları SPSS programında bir arada incelenmiştir. Grafikte EÇO yönteminin DVM kernellerine göre oldukça düşük doğruluk verdiği görülmektedir. DVM kernelleri ile elde edilen ve yaklaşık %50 doğruluk veren sınıflandırma görüntülerine genelleştirme işlemi uygulandığında, doğruluğun %60 civarında arttığı görülmektedir (Şekil 2.29).



Şekil 2.29 Sınıflandırmaya ve genelleştirmeye göre EÇO ve DVM kernellerinin doğruluğa etkisi

Son olarak EÇO yöntemi ile DVM'nin 4 kernelinde en yüksek doğruluğa sahip sınıflandırma görüntülerinin korelasyonları SPSS programında incelenmiştir. Öncelikle raster formattaki sınıflandırma görüntüleri nokta verisine çevrilmiş, daha sonra SPSS programının korelasyon analizi kısmında heterojen yapılar için 'iki değişkenli' olarak gerçekleştirilmiştir. EÇO yöntemi ile yapılan sınıflandırmalar iki uydu görüntüsünde 0.40 korelasyona sahip iken, DVM yönteminin 4 kernelinde bu korelasyon yaklaşık 0.62-0.63 civarındadır (Çizelge 2.26).

Çizelge 2.26 EÇÖ yöntemi ve en yüksek doğruluğa sahip DVM kernel sınıflandırmalarının korelasyonları

GÖR. ADI	SENT. ML	SENT. LIN.	SENT. RBF	SENT. SIG.	SENT. POL.
LAND. ML	,400** ,000 26875	,575** ,000 26875	,582** ,000 26875	,576** ,000 26875	,583** ,000 26875
LAND. LIN.	,356** ,000 26875	,635** ,000 26875	,621** ,000 26875	,622** ,000 26875	,627** ,000 26875
LAND. RBF	,374** ,000 26875	,644** ,000 26875	,632** ,000 26875	,632** ,000 26875	,638** ,000 26875
LAND. SIG.	,372** ,000 26875	,646** ,000 26875	,635** ,000 26875	,635** ,000 26875	,640** ,000 26875
LAND. POL.	,353** ,000 26875	,633** ,000 26875	,619** ,000 26875	,620** ,000 26875	,624** ,000 26875

** . Correlation is significant at the 0.01 level (2-tailed).

3. SONUÇ ve ÖNERİLER

Heterojen yapı sergileyen doku sınıflandırması, görsel olarak yapıldığı için yanılma payı yüksektir, bu nedenle manuel yapılması zor bir işlemdir. Birden fazla operatörle çalışılması gereken bu yöntemde, operatörün yorumuna bağlı olarak sınıfların karışması olasıdır. Bu karışımın önüne geçmek amacıyla CBS tekniklerinin doku sınıflandırılmasında kullanılmımı daha uygundur. Matematiksel analizlerle elde edilmiş doku sınıfları, en doğru ve güvenilir sonuçları vermektedir; ancak sürekli güncel yapı verisine ulaşmanın zor olması, yöntemin dezavantajıdır. Bu nedenle uydu görüntüleriyle sınıflandırma yöntemi alternatif olarak ön plana çıkmaktadır. Bu yöntem, özellikle maliyet ve zaman açısından büyük önem taşımaktadır. Programlar aracılığıyla otomatik yapıldığı için ekstra uğraş gerektirmeyen sınıflandırma işlemleri, özellikle homojen alanlarda çok yüksek doğruluklar verebilmektedir.

Bu tez ile benzer olan Colaninno vd.'nin (2011) yaptıkları çalışmada binaların biçimsel ve ilişkisel karakterlerine bağlı olarak kentin morfolojisi ortaya çıkarılmıştır. Yöntem olarak öncelikle farklı tipteki bina grupları tanımlanmış, bina şekillerinin geometrik özelliklerine dayanarak kentsel doku modelleri analiz edilmiş ve bina mesafelerine bakılarak indeksler oluşturulmuştur. Çalışma sonucunda kent 7 farklı dokuya ayrılmıştır. Bu tez çalışmasında da benzer olarak yapıların yoğunluklarına doku matrisleri ile bakılmış, İstanbul kenti 6 farklı kentsel dokuya ayrılmıştır.

Bu tez çalışmasıyla benzer olan Üstüner'in (2013) yapmış olduğu araştırmada DVM ile EÇO yöntemleri yüksek ve düşük çözünürlüklü iki uydu görüntüsüne uygulanmış, homojen tarım alanları sınıflandırılmıştır. Homojen alanda yapılan çalışmada yüksek çözünürlüklü uydu görüntülerinde %14 daha çok doğruluk elde edilirken, heterojen alana (kentsel alan) uygulanan bu çalışmada düşük çözünürlüklü uydu görüntüleri %14 daha yüksek doğruluk vermiştir.

Bu çalışma sonucunda elde edilmiş bulguların da gösterdiği üzere, yöntem seçiminin %6'ya kadar fark yaratabildiği tespit edilmiştir. Sınıflandırma çalışmalarında uydu görüntüsü seçimi kadar uydu görüntüsüne uygulanacak yöntem seçiminin de önemli olduğu ortaya çıkmıştır. Çalışma sonucunda elde edilmiş bulgulara göre, DVM yönteminin özellikleri ortaya konulacak olursa; yöntemin hem avantaj hem de dezavantajlarının bulunduğu görülmektedir (Çizelge 3.1).

Çizelge 3.1 DVM ve EÇO sınıflandırmalarının avantajları-dezavantajları

<u>DVM</u>	<u>EÇO</u>
Yüksek doğruluk	Düşük doğruluk
Parametre var	Parametre yok
Karmaşık verilerde başarılı	Karmaşık verilerde az başarılı
Daha az eğitim verisi	Daha çok eğitim verisi
Lineer ve lineer olmayan hiper-düzlemler ile veri atama işlemi gerçekleşir. Olasılığa göre atama yapılmaz.	Sınıflandırma verileri olasılığa göre atanır.
Sınıflandırma öncesinde ön bilgi varsayımı yoktur.	Sınıflandırma öncesinde ön bilgi varsayımı vardır.
Çok sayıda bağımsız değişkenle çalışabilme ve dışardan müdahale imkânı vardır.	Dışardan müdahale imkânı yoktur.
İşlemler girilen parametre setine göre çok uzun sürebilir.	Değişken bulunmadığı için işlemler daha kısa sürebilir.

Tabloda görülen avantajlar ile dezavantajlar bir arada değerlendirilirse, çalışmada öncelikle fazla parametre gerektirmeyen ve hızlı bir çözüm yöntemi olan EÇO sınıflandırması ön plana çıkmaktadır. Ancak hassas çalışmalarda DVM'nin kullanılması, doğruluk açısından avantaj yarattığı görülmektedir. Ayrıca, çalışma sonucundan elde edilmiş bulgulara göre kullanılmış olan genelleştirme yönteminin doğruluğu %11'e kadar artırmasından dolayı, özellikle heterojen sınıflandırmalar için kullanılması önerilmektedir. Bu çalışmada genelleştirme işleminin doğruluğu heterojen alanlarda test edilmiştir; ancak bu doğruluk, homojen alanlarda da test edilmelidir.

Yapılan bu çalışma kentsel gelişimin sağlıklı bir şekilde sürdürülmesi açısından önem taşımaktadır. Çağımızın bir sorunu olarak, hızla artan kentleşme sonucunda çevre kirliliği, düzensiz şehirleşme, tarım alanlarının azalması gibi sorunlar karşımıza çıkmaktadır. Bu nedenle, sürdürülebilir kentlerin sağlanabilmesi için, kentsel gelişimin kontrol altında bulunması gerekmektedir. Bunu sağlamanın en güvenilir yolu ise, uzaktan algılama ve CBS teknolojilerinin etkin kullanımından geçmektedir.

KAYNAKLAR


- Aggarwal S.** (2003). Principles of Remote Sensing. **Sivakumar, M.V.K. at all** (Eds.), *Satellite Remote Sensing and GIS Applications in Agricultural Meteorology*, 23-38, Dehra Dun.
- Al-doski, J., X., Mansori, S.B., Shafri, H.Z.M.** (2013). Image Classification in Remote Sensing. *Journal of Environment and Earth Science*, 3 (10), 141-147.
- Amorim, L., Barros Filho M.N., Cruz, D.** (2009). Urban texture and space configuration. *Proceedings of the 7th International Space Syntax Symposium*, Royal Technology Institute, 8-11 July, Stockholm.
- Atasever, Ü.E.** (2011). Uydu görüntülerinin sınıflandırılmasında hızlandırma (boosting), destek vektör makineleri, rastgele orman (random forest) ve regresyon ağaçlarını yöntemlerinin kullanılması. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü*, (Yüksek Lisans Tezi), 86s, Kayseri.
- Bekkari, A., Idbraim, S., Elhassouny, A., Mammass, D., Yassa, M.E., Ducrot, D.** (2012). SVM and Haralick Features for Classification of High Resolution Satellite Images from Urban Areas. **Elmoataz, A. at all** (Eds.), *Image and Signal Processing*, 17-26, Morocco.
- Cao, X., Chen, J., Matsushita, B., Imura, H., Wang, L.** (2009). An automatic method for burn scar mapping using support vector machines. *International Journal of Remote Sensing*, 30 (3), 577-594.
- Colaninno, N., Cladera, J.R., Pfeffer, K.** (2011). An automatic classification of urban texture: form and compactness of morphological homogeneous structures in Barcelona. *51st European Congress of the Regional Science Association International*, Technical University of Catalonia, 30 August-2 September, Barcelona.
- Colaninno, N., Roca, J., Alhaddad, B.** (2012). Defining densities for urban residential texture, through land use classification, from Landsat Tm imagery: case study of Spanish mediterranean coast. *22nd ISPRS Congress*, Melbourne Convention and Exhibition Centre, 25 August-1 September, Melbourne.
- Cortes, C., Vapnik, V.** (1995). Support-Vector Networks. *Kluwer Academic Publishers*, 20, 273-297.
- Dalponte, M., Bruzzone, L., Vescovo, L., Gianelle, D.** (2009). The role of spectral resolution and classifier complexity in the analysis of hyperspectral images of forest areas. *Remote Sensing of Environment*, 113, 2345-2355.
- Giannini, M.B., Merola, P., Allegrini, A.** (2012). Texture analysis for urban areas classification in high resolution satellite imagery. *Applied Remote Sensing Journal*, 2 (2), 65-71.
- Gualtieri, J.A., Crompt, R.F.** (1998). Support vector machines for hyperspectral remote sensing classification. *Applied Imagery Pattern Recognition Workshop*, 14-16 October, Washington D.C..

- Karimi, Y., Prasher, S.O., Madani, A., Kim, S.** (2008). Application of support vector machine technology for the estimation of crop biophysical parameters using aerial hyperspectral observations. *Canadian Biosystems Engineering*, 50, 7.13-7.20.
- Kavzođlu, T., ölkesen İ.** (2011). Uzaktan Algılama teknolojileri ve uygulama alanları. *Türkiye’de Sürdürülebilir Arazi alıřtayı*, Okan Üniversitesi, 26-27 Mayıs, İstanbul.
- Knorn, J., Rabe, A., Radeloff, V.C., Kuemmerle, T., Kozak, J., Hostert, P.** (2009). Land cover mapping of large areas using chain classification of neighboring Landsat satellite images. *Remote Sensing of Environment*, 113, 957-964.
- Kuşçu Şimşek, .** (2013). İstanbul’da kentsel iklim üzerine antropojenik etkiler; Kent ısı adalarının incelenmesi. *Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü*, (Doktora Tezi), 238s, İstanbul.
- Liu, D., Kelly, M., Gong, P.** (2006). A spatial-temporal approach to monitoring forest disease spread using multi-temporal high spatial resolution imagery. *Remote Sensing of Environment*, 101, 167-180.
- Ober, G., Tomasoni R., Cella, F.** (1997). Urban texture analysis. *Technical conference on application of digital image processing*, Program on Signal and Image Processing, 27 July-1 August, San Diego.
- Petropoulos, G.P., Knorr, W., Scholze, M., Boschetti, L., Karantounias, G.** (2010). Combining Aster multispectral imagery analysis and support vector machines for rapid and cost-effective post-fire assessment: A case study from the Greek wildland fires of 2007. *Natural Hazards and Earth System Sciences*, 10, 305-317.
- Rende, F.Ş.** (2009). Aşamalı öğrenmeli destek vektör makineleri ile hiperspektral görüntülerin sınıflandırılması. *Gebze Yüksek Teknoloji Enstitüsü Mühendislik ve Fen Bilimleri Enstitüsü*, (Yüksek Lisans Tezi), 96s, Gebze.
- Suralkar, S.R., Karode, A.H., Pawade, P.W.** (2012). Texture Image Classification Using Support Vector Machine. *International Journal of Computer Technology and Applications*, 3 (1), 71-75.
- Ua Avcı, Z.D., Ua Güneş, E.P., abuk, A.,** (2015). Uzaktan algılama ve cođrafi bilgi sistemleri eğitiminin uzaktan eğitimdeki yeri ve önemi. *Harita teknolojileri Elektronik Dergisi*, 7 (3), 53-68.
- Url-1** <<https://earthexplorer.usgs.gov/>>, alındığı tarih: 30.01.2019.
- Url-2** <<https://www.harrisgeospatial.com/>>, alındığı tarih: 30.05.2019.
- Url-3** <<https://eos.com/>>, alındığı tarih: 01.06.2019.
- Üstüner, M.** (2013). Destek vektör makineleri yöntemi ile arazi kullanımını sınıflandırmasında kernel fonksiyonlarına ait karşılaştırmalı parametre duyarlılık analizi: Rapideye ve Spot örneđi. *Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü*, (Yüksek Lisans Tezi), 74s, İstanbul.


EKLER

- EK-1** EÇO Sınıflandırması ve Genelleştirme Görüntüsü (a-Landsat-8 Sınıflandırma, b-Landsat-8 Genelleştirme, c-Sentinel-2A Sınıflandırma, d-Sentinel-2A Genelleştirme)
- EK-2** Lineer Kerneli ile DVM Sınıflandırması ve Genelleştirme Görüntüsü (a-Landsat-8 Sınıflandırma, b-Landsat-8 Genelleştirme, c-Sentinel-2A Sınıflandırma, d-Sentinel-2A Genelleştirme)
- EK-3** Radyal Tabanlı Fonksiyon Kerneli ile DVM Sınıflandırması ve Genelleştirme Görüntüsü (a-Landsat-8 Sınıflandırma, b-Landsat-8 Genelleştirme, c-Sentinel-2A Sınıflandırma, d-Sentinel-2A Genelleştirme)
- EK-4** Sigmoid Kerneli ile DVM Sınıflandırması ve Genelleştirme Görüntüsü (a-Landsat-8 Sınıflandırma, b-Landsat-8 Genelleştirme, c-Sentinel-2A Sınıflandırma, d-Sentinel-2A Genelleştirme)
- EK-5** Polinom Kerneli ile DVM Sınıflandırması ve Genelleştirme Görüntüsü (a-Landsat-8 Sınıflandırma, b-Landsat-8 Genelleştirme, c-Sentinel-2A Sınıflandırma, d-Sentinel-2A Genelleştirme)
- EK-6** Kente Ait CBS ile Elde Edilmiş Dokuların Gösterimi (Tam Sayfa)
- EK-7** En Yüksek Doğruluğa Sahip Sınıflandırma Görüntüsü (Landsat-8) (Tam Sayfa)
- EK-8** En Yüksek Doğruluğa Sahip Genelleştirme Görüntüsü (Landsat-8) (Tam Sayfa)
- EK-9** En Yüksek Doğruluğa Sahip Sınıflandırma Görüntüsü (Sentinel-2A) (Tam Sayfa)
- EK-10** En Yüksek Doğruluğa Sahip Genelleştirme Görüntüsü (Sentinel-2A) (Tam Sayfa)


EK-1 EÇO Sınıflandırması ve Genelleştirme Görüntüsü




a)



b)




c)




d)


EK-2 Linear Kernelli ile DVM Sınıflandırması ve Genelleştirme Görüntüsü




a)



c)




b)




d)


EK-3 Radyal Tabanlı Fonksiyon Kerneli ile DVM Sınıflandırması ve Genelleştirme Görüntüsü




a)



b)




c)




d)


EK-4 Sigmoid Kerneli ile DVM Sınıflandırması ve Genelleştirme Görüntüsü




a)



b)




c)




d)


EK-5 Polinom Kerneli ile DVM Sınıflandırması ve Genelleştirme Görüntüsü




a)



b)




c)




d)


EK-6 Kente Ait CBS ile Elde Edilmiş Dokuların Gösterimi (Tam Sayfa)




EK-7 En Yüksek Doğruluğa Sahip Sınıflandırma Görüntüsü (Landsat-8) (Tam Sayfa)




EK-8 En Yüksek Doğruluğa Sahip Genelleştirme Görüntüsü (Landsat-8) (Tam Sayfa)



EK-9 En Yüksek Doğruluğa Sahip Sınıflandırma Görüntüsü (Sentinel-2A) (Tam Sayfa)



EK-10 En Yüksek Doğruluğa Sahip Genelleştirme Görüntüsü (Sentinel-2A) (Tam Sayfa)



ÖZGEÇMİŞ



Kişisel bilgiler

Adı Soyadı	Osman DOĞAN
Doğum Yeri ve Tarihi	Sivas, 19.03.1990
Medeni Hali	Evli
Yabancı Dil	İngilizce
E-posta Adresi	osmandogan5858@gmail.com

Eğitim ve Akademik Durumu

Lise	Sivas Lisesi, 2009
Yüksekokul	Gaziosmanpaşa Üniversitesi, Harita ve Kadastro, 2011
Lisans	Anadolu Üniversitesi, İşletme, 2016
Lisans	Cumhuriyet Üniversitesi, Geomatik Mühendisliği, 2016
Yüksek Lisans	Cumhuriyet Üniversitesi, Geomatik Mühendisliği Anabilim Dalı, 2019

İş Tecrübesi

Alfa Planlama	Gayrimenkul Değerleme, 2012
Özbelsan A.Ş.	Harita ve Kadastro Teknikeri, 2012-2018
Özbelsan A.Ş.	Harita Mühendisi, 2018-Halen

Kongreler ve Bildiriler

Ulusal

1. ÇAĞDAŞ KUŞÇU ŞİMŞEK, OSMAN DOĞAN (2018). Investigation of Surface Temperature Differentiation of Fagus and Quercus Stands by Using Landsat Images. Cumhuriyet Science Journal, 40 (1), 265-274.,
Doi:10.17776/csj.440198.

