

**ÇANKIRI KARATEKİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**ILGAZ ORMAN İŞLETME MÜDÜRLÜĞÜ BÖLGESİNDE
KAR ÖRTÜSÜ HARİTALAMASI İÇİN
DESTEK VEKTÖR MAKİNELERİ TASARIMININ DEĞERLENDİRİLMESİ**

Bora Berkay ÇİFTÇİ

ORMAN MÜHENDİSLİĞİ ANABİLİM DALI

**ÇANKIRI
2017**

Her hakkı saklıdır

ÖZET

Yüksek Lisans Tezi

ILGAZ ORMAN İŞLETME MÜDÜRLÜĞÜ BÖLGESİNDE KAR HARİTALAMASI İÇİN DESTEK VEKTÖR MAKİNELERİ TASARIMININ DEĞERLENDİRİLMESİ

Bora Berkay ÇİFTÇİ

Çankırı Karatekin Üniversitesi
Fen Bilimleri Enstitüsü
Orman Mühendisliği Anabilim Dalı

Danışman: Yrd. Doç. Dr. Semih KUTER

Bu çalışma, Çankırı ve Kastamonu illeri sınırları içinde yer alan Ilgaz Orman İşletme Müdürlüğü bölgesinde, orta çözünürlüklü görüntüleme spektrometresi (MODIS) verisinden fraksiyonel kar örtüsü (FKÖ) haritalaması amacıyla destek vektör makineleri (DVM) tasarımının araştırılmasını amaçlamaktadır. Bu amaçla, Mart 2000 - Nisan 2016 tarihleri arasında edinilen on üç MODIS - Landsat 7/8 görüntü çifti kullanılmıştır. DVM modellerin eğitilmesinde MODIS 1-7 bantlarına ait atmosfer üstü reflektans değerleri, normalize fark kar indisi, normalize fark vejetasyon indisi ve arazi sınıfı prediktör değişkenler olarak kullanılmıştır. Referans FKÖ haritaları daha yüksek mekansal çözünürlüğe sahip Landsat ikili kar haritalarından üretilmiştir. DVM modellerinin eğitimi ve testi sırasında, eğitim verisi boyutunun ve örneklem türünün DVM modellerinin performansı üzerindeki etkileri araştırılmıştır. Kernel fonksiyonu seçiminin FKÖ haritalama performansına önemli bir katkısı olup olmadığını ortaya koymak için ek bir araştırma da yapılmıştır. Bağımsız test verisi üzerindeki sonuçlar, radyal taban fonksiyonu (RBF), doğrusal, 2. derece polinom, 3. derece polinom ve 4. derece polinom kernel kullanılarak elde edilen DVM modellerinin referans FKÖ verileriyle iyi bir uyum içinde olduğunu göstermektedir (ortalama $R \geq 0.91$). Buna karşın, standart MODIS kar fraksiyonu ürünü, yani MOD10A1, ortalama $R = 0.77$ ile biraz daha kötü performans sergilemektedir. RBF kernele sahip DVM modelleri, model eğitimi sırasında küçük, orta ve büyük ölçekli eğitim verileri için sırasıyla 279, 2,300 ve 8,457 saniye işlemci süresine sahip olup, model oluşturma sırasında hesaplamasal olarak daha verimlidir.

2017, 88 sayfa

Anahtar Kelimeler: Fraksiyonel Kar Örtüsü Haritalaması, MODIS, Landsat ETM+, Landsat 8, Destek Vektör Makineleri, Destek Vektör Regresyonu.

ABSTRACT

Master of Science Thesis

AN ASSESSMENT OF DESIGN OF SUPPORT VECTOR MACHINES FOR SNOW COVER MAPPING IN ILGAZ FOREST DISTRICT REGION

Bora Berkay ÇİFTÇİ

Cankiri Karatekin University
Graduate School of Natural and Applied Sciences
Department of Forest Engineering

Supervisor: Yrd. Doç. Dr. Semih KUTER

This study aims to investigate the design and assessment of support vector machines (SVM) for fractional snow cover (FSC) mapping from moderate resolution imaging spectroradiometer (MODIS) data in Ilgaz Forest District region lying within the borders of Çankırı and Kastamonu provinces. For this purpose, thirteen MODIS - Landsat 7/8 image pairs acquired between March 2000 and April 2016 are used. SVM models are trained by using MODIS top-of-atmospheric reflectance values of bands 1-7, normalized difference snow index, normalized difference vegetation index and land cover class as predictor variables. Reference FSC maps are generated from higher spatial resolution Landsat binary snow cover maps. During the training and the testing, the effects of the training data size and the sampling type on the predictive performance of SVM models are investigated. An additional search is also conducted to reveal whether the choice of kernel function has a significant contribution to the FSC mapping performance. The results on the independent test scenes indicate that the developed SVM models with radial basis function (RBF), linear, 2nd order polynomial, 3rd order polynomial and 4th order polynomial kernels are in good agreement with reference FSC data with average values of $R \geq 0.91$. In contrast, the standard MODIS snow fraction product, namely, MOD10 FSC, exhibits slightly poorer performance with average $R = 0.77$. The SVM models with RBF kernel is computationally more efficient in model building with average CPU times of 279, 2,300 and 8,457 seconds for small-, medium- and large-sized training data sets, respectively.

2017, 88 pages

Keywords: Fractional Snow Cover Mapping, MODIS, Landsat ETM+, Landsat 8, Support Vector Machines, Support Vector Regression.

ÖNSÖZ VE TEŞEKKÜR

“İlgaz Orman İşletme Müdürlüğü Bölgesinde Kar Örtüsü Haritalaması için Destek Vektör Makineleri Tasarımının Değerlendirilmesi” adlı bu çalışma 2014-2017 yılları arasında hazırlanarak Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsüne “Yüksek Lisans Tezi” olarak sunulmuştur. Bu araştırmanın amacı Çankırı ve Kastamonu illeri sınırları içinde yer alan Ilgaz Orman İşletme Müdürlüğü bölgesinde, orta çözünürlüklü görüntüleme spektrometresi (MODIS) verisinden fraksiyonel kar örtüsü (FKÖ) haritalaması amacıyla destek vektör makineleri (DVM) tasarımının araştırılmasını amaçlamaktadır. Bu amaçla, Mart 2000 - Nisan 2016 tarihleri arasında edinilen on üç MODIS - Landsat 7/8 görüntü çifti kullanılmıştır. Bu görüntülerden sekiz tanesi model eğitiminde kullanılmış, kalan beşi ise bağımsız test verisi seti olarak ayrılmıştır. DVM modellerinin eğitimi ve testi sırasında, eğitim verisi boyutunun ve örneklem türünün DVM modellerinin performansı üzerindeki etkileri araştırılmıştır.

Çalışmanın her safhasında yakın ilgi ve önerileri ile beni yönlendiren, her zaman destekleyen ve çalışmanın yönlendirilmesinde ve yürütülmesinde yol gösteren, kıymetli fikirlerini esirgemedi sunan, değerli danışman hocam Sayın Yrd. Doç. Dr. Semih Kuter’e sonsuz teşekkür ederim.

Bu tez çalışması Çankırı Karatekin Üniversitesi BAPK OF090316L04 nolu proje ile desteklenmiştir.

Tüm eğitim hayatım boyunca benden maddi ve manevi desteklerini esirgemeyen her zaman yanımda olan sevgili aileme teşekkürlerimi bir borç bilirim.

Bora Berkay ÇİFTÇİ
Çankırı, Kasım 2017

İÇİNDEKİLER

ÖZET.....	iv
ABSTRACT	v
ÖNSÖZ VE TEŞEKKÜR.....	vi
SİMGELER DİZİNİ.....	viii
ŞEKİLLER DİZİNİ.....	ix
ÇİZELGELER DİZİNİ.....	x
1. GİRİŞ	1
2. MATERYAL VE YÖNTEM	7
2.1. Çalışma Alanı	7
2.2. Veri Seti.....	8
2.2.1. MODIS.....	8
2.2.2. Landsat 7 ETM+ ve Landsat 8 OLI uyduları	10
2.3. Destek Vektör Makineleri (DVM).....	12
2.4. MODIS ürünleri.....	16
2.4.1. MODIS seviye 1B ürünü	18
2.4.2 MODIS kar algoritması ve seviye 3 günlük kar ürünü.....	21
2.5 Veri Seti İle İlgili Ön İşleme	24
2.5.1. MODIS verisinin ön işleme.....	26
2.5.2. Landsat 7 ETM+ ve Landsat 8 OLI referanslı FKÖ haritaları.....	28
2.6. Deneysel Tasarım	29
2.6.1. Örneklem boyutu ve örneklem türü	29
2.6.2. DVM modellerin eğitimi ve performans ölçütleri	30
3. BULGULAR VE TARTIŞMA.....	32
3.1. Eğitim Verisi Üzerinde DVM.....	32
3.2. Test Verisi Üzerinde DVM.....	33
4. SONUÇLAR.....	40
KAYNAKLAR.....	41
EKLER.....	49
EK 1 MATLAB Programında Uydu Görüntülerinden Eğitim ve Test Veri Setlerinin Oluşturulması İçin Kullanılan Fonksiyon.....	49
EK 2 MATLAB Programında DVM Kernel Fonksiyonlarından Doğrusal	54
EK 3 MATLAB Programında DVM Kernel Fonksiyonlarından RBF.....	63
EK 4 MATLAB Programında DVM Kernel Fonksiyonlarından Polinom	72
ÖZGEÇMİŞ	80

SİMGELER DİZİNİ

RANOVA	Repeated Measures ANOVA - Tekrarlanan Ölçümler ANOVA
DVM	Destek Vektör Makineleri
DN	Digital Number – Dijital Sayı
ETM+	The Enhanced Thematic Mapper Plus - Geliştirilmiş Tematik Haritalayıcı
EOS	Earth Observing System - Dünya Gözleme Sistemi
EOSDIS	Earth Observing System Data and Information System - Dünya Gözlem Sistemi Veri ve Bilgi Sistemi
FKÖ	Fraksiyonel Kar Örtüsü
HDF	Hierarchical Data Format - Hiyerarşik Veri Formatı
HDF - EOS	Hierarchical Data Format – Earth Observing System - Hiyerarşik Veri Formatı- Dünya Gözlem Sistemi
IGBP	The International Geosphere-Biosphere Programme - Uluslar arası Jeosfer-Biyosfer Programı
KKA	Karla Kaplı Alan
KSE	Kar Su Eşdeğeri
LSD	Least Significant Difference - En Az Anlamlı Fark
MODIS	Moderate Resolution Imaging Spectroradiometer - Orta Çözünürlüklü Görüntüleme Spektroradyometresi
NASA	National Aeronautics and Space Administration - Ulusal Havacılık ve Uzay Dairesi
NDSI	Normalized Difference Snow Index - Normalize Fark Kar İndisi
NDVI	Normalized Difference Vegetation - Normalize Fark Vegetasyon İndisi
NIR	Near Infrared - Yakın Kızılötesi
NOAA	National Oceanic and Atmospheric Administration - Ulusal Okyanus ve Atmosfer İdaresi
OLI	Operational Land Imager - Operasyonel Kara Görüntüleyici
R	Correlation Coefficient – Korelasyon Katsayısı
RBF	Radial Basis Function - Radyal Taban Fonksiyonu
RMSE	Root Mean Squared Error - Hataların Kareler Ort. Karekökü
SDS	Scientific Data Set - Bilimsel Veri Seti
SI	Scaled Integer – Ölçeklendirilmiş Tamsayı
SLC	Scan Line Corrector - Tarama Çizgi Düzelticisi
SWIR	Shortwave Infrared – Orta Kızılötesi
TIRS	Thermal Infrared Sensor - Termal Kızılötesi Sensör
TOA	Top of Atmospheric - Atmosferüstü
UA	Uzaktan Algılama
YA	Operational Research - Yöneylem Araştırmaları
Ha	Hektar
km ²	kilometrekare
m	metre
µm	Mikrometre
nm	Nanometre
°C	Santigrat Derece
γ	Standart Sapma

ŞEKİLLER DİZİNİ

Şekil 2.1	a) Çankırı – Kastamonu il sınırları ve Landsat 177/32'nin konumu, b) Ilgaz Orman İşletme Müdürlüğü sınırı ve Çalışma Alanı, c) Ilgaz Orman İşletme Müdürlüğüne bağlı İşletme Şeflik Sınırları	8
Şekil 2.2	MODIS'in gözlem alanı.....	10
Şekil 2.3	Destek vektörleri tarafından tanımlanan en uygun ayırıcı hiperdüzlem	13
Şekil 2.4	Doğrusal bir DVM için yumuşak marjin kayıp ayarının temel bir gösterimi	16
Şekil 2.5	MODIS sinüzodial grid şema.....	17
Şekil 2.6	Seviye 1B ürünündeki dn^b 'nin ölçekli tamsayı gösterim.....	20
Şekil 2.7	Landsat ETM+ görüntülerinden ikili kar haritası üretilmesi.....	25



ÇİZELGELER DİZİNİ

Çizelge 2.1 MODIS spektral bantlarının karşılığı	9
Çizelge 2.2 Landsat 7 ETM+ uydu görüntüsünün bantlarının geometrik ve spektral özellikleri (URL5).....	11
Çizelge 2.3 Landsat 8 OLI Bantları ve Özellikleri (URL5).....	12
Çizelge 2.4 Seviye 1B ürün özeti	19
Çizelge 2.5 Yansıtıcı solar bantların birimleri	21
Çizelge 2.6 MODIS'in kar verisi ürünleri.....	23
Çizelge 2.7 MOD/MYD10A1 günlük kar tipi özellikleri	24
Çizelge 2.8 DVM modellerinde kullanılan MODIS ve Landsat 7/8 verileri	26
Çizelge 2.9 DVM eğitilmesinde ve testinde kullanılan Landsat 7/8 ve MODIS çifti	26
Çizelge 2.10 Hata Matrisi Analizi (Arazi Kod Açıklamaları: 1: herdem yeşil ormanlar, 2: yaprak döken ormanlar 3: karışık ormanlar 4: çim ve çalılık alanlar 5: savanalar 6: karışık tarımsal alanlar 7: açık ve seyrek bitki örtüsü 8: daimi sulak alanlar).....	28
Çizelge 2.11 Örnekleme boyutuna ve örnekleme türüne göre eğitim piksellerinin sayısı (BR: Basit rastgele örnekleme, TR_FKÖ: Fraksiyonel kar örtüsü bakımından tabakalandırılmış rastgele örnekleme)	30
Çizelge 3.1 Her bir örnekleme türü ve örnek boyutu için modellerin eğitim sürecinde % 30'luk test verisi üzerinde en iyi R değerini veren seçilmiştir. Kalın yazılan R değerleri her bir tür için en iyi eğitim performansını göstermektedir	32
Çizelge 3.2 Kernel fonksiyonları için belirlenen optimal değerler	33
Çizelge 3.3 RBF, Doğrusal, 2. 3. ve 4. Derece Polinom kernel fonksiyonu kullanan DVM modellerinin beş bağımsız test görüntüsü ve toplamda 67.495 pikselden oluşan birleşik test veri seti üzerindeki performansı. Kalın harfle belirtilen satır, en iyi eğitim performansı bakımından ilgili modelin test sonuçlarını göstermektedir (K: küçük, O: orta, B: büyük).....	35
Çizelge 3.4 DVM modellerinin eğitimi boyunca saniye bazında geçirilen ortalama CPU zamanları.....	36
Çizelge 3.5 DVM ve MOD10A1'den elde edilen FKÖ değerleri için bağımsız test veri setlerine ait RMSE ve R değerleri.....	37
Çizelge 3.6 RMSE değerleri bakımından RANOVA test sonuçlarının kıyaslaması (*, ortalama farkın $\alpha = 0.05$ önem seviyesinde istatistiksel açıdan önemli olduğunu göstermektedir).....	38
Çizelge 3.7 R değerleri bakımından RANOVA test sonuçlarının kıyaslaması (*, ortalama farkın $\alpha = 0.05$ önem seviyesinde istatistiksel açıdan önemli olduğunu göstermektedir).....	39

1. GİRİŞ

Kar, dünya yüzeyinin önemli bir fiziki ögesi olup, mekânsal ve zamansal dağılımının sürekli gözlemlenmesi temel çevre araştırmaları açısından oldukça önemlidir. İklim bilimi açısından bakıldığında kar örtüsü, (i) elektromanyetik spektrumun görünür ve kızılötesine yakın bölgelerindeki yüksek albedosu (yüzeylerin ‘-ışığı-’ yayma gücü) sayesinde güneşten gelen ışığın büyük miktarını yansıttığı (Tekeli vd. 2005) ve (ii) zayıf ısı iletkenliği özelliğiyle bir yalıtkan madde gibi etki göstererek kış boyunca dünya yüzeyinden ısının serbest bırakılmasını engellediği için dünya ile atmosfer arasındaki enerji alışverişi süreci üzerinde doğrudan etkiye sahiptir (Zhang 2005). Kar aynı zamanda orta ve yüksek enlemlerdeki Alpin kuşağının yanı sıra dünyanın dağlık bölgelerinin hidrolojisinde de önemli bir rol oynamaktadır (Cline vd. 1998, Hartman vd. 1999, Lehning vd. 2006). Kar kütlelerinde biriken su, kış mevsimi boyunca potansiyel bir sel baskını riski taşıyan yüksek miktarda donmuş su rezervi olarak işlev görmekte olup, aynı zamanda enerji ve su tedariki açısından kıymetli bir kaynak teşkil etmektedir (Romanov vd. 2003, Akyurek vd. 2010).

Karın mekânsal dağılımı, önemli bir iklim değişkeni olarak kabul edilmektedir (Hüsler vd. 2012). Dolayısıyla Karla Kaplı Alan (KKA)’ın doğru bir şekilde modellenmesi, Kar Su Eşdeğeri (KSE)’nin daha iyi tahminlenmesi ve nihayetinde iklim değişikliği ve hidrolojik çalışmaların yanı sıra, atmosferik dolaşım ve hava tahmin modellerinin başarısı açısından da önemlidir (Dozier 1992, Foster vd. 1996, Brown vd. 2003, Hosaka vd. 2005, Clark vd. 2006). Saha ölçümlerine dayanan KKA analizleri (Brown ve Goodison 1996, Beniston 2003, Laternser ve Schneebeli 2003, Marty 2008) yüksek kaliteli uzun zaman serisi verisi sağlasa da saha ölçümleri yoluyla KKA haritalanması ekonomik ve lojistik açıdan pratik değildir (Gafurov ve Bárdossy 2009). Uzaktan Algılama (UA), ilk operasyonel kar haritalamasının Ulusal Okyanus ve Atmosfer İdaresi (National Oceanic and Atmospheric Administration - NOAA) tarafından yapıldığı 60’lı yılların ortalarından bu yana, çeşitli düşük ve orta mekansal çözünürlüğe sahip sensörlerce elde edilen zamanlı ve çok spektral verilerle kar örtüsünün istikrarlı bir şekilde izlenmesi için güçlü bir alternatif sunmaktadır (Hall ve Martinec 1985).

Güvenilir KKA tahminlemesi için metodolojiler geliştirilmesi uzun süredir UA'nın ilgi alanında yer almaktadır (Rango ve Martinec 1979, Malnes ve Guneriussen 2002, Metsämäki vd. 2002, Luoju vd. 2007, Siljamo ve Hyvärinen 2011).

Yüksek zamansal çözünürlüğü ve farklı mekansal çözünürlüklere sahip 0.4 μm 'dan 14.4 μm 'a kadar uzanan 36 spektral bantı ile (bant 1-2: 250 m, bant 3-7: 500 m, ve bant 8-36: 1000 m) Orta Çözünürlüklü Görüntüleme Spektrometresi (Moderate Resolution Imaging Spectroradiometer - MODIS), hem bölgesel hem de küresel ölçekte kar örtüsü haritalaması en fazla kullanılan araçtır (Hall vd. 2002, Rodell ve Houser 2004, Poon ve Valeo 2006, Shamir ve Georgakakos 2006, Parajka ve Blöschl 2008, Wang vd. 2008).

Kar haritalamasındaki problemlilerden biri, uydu görüntülerinin zamansal ve mekansal çözünürlükleri arasındaki ödünleşmedir. Çünkü yüksek mekansal çözünürlük zamansal çözünürlüğü azaltmaktadır, bu durum sonuçta kar örtüsündeki değişikliklerin algılanmasını sınırlandırmaktadır. Diğer taraftan yüksek zamansal çözünürlük bilgisi de düşük mekansal çözünürlükten dolayı kar örtüsü haritalarındaki doğruluğu azaltmaktadır.

Bu problemlerin üstesinden gelmek için, spektral ayırma (Painter vd. 2003) ve Normalize Fark Kar İndisi (Normalized Difference Snow Index - NDSI) (Salomonson ve Appel 2004) yöntemlerine dayalı Fraksiyonel Kar Örtüsü (FKÖ) haritalama yaklaşımları, düşük veya orta çözünürlüklü görüntüler için tasarlanmış ve uygulanmıştır. FKÖ haritalanmasında, bir pikselin kar veya kar değil olarak etiketlendiği ikili sınıflandırma yaklaşımının aksine, her bir orta/düşük mekansal çözünürlüğe sahip pikseldeki arazi sınıflarının mekansal dağılımları tam olarak bilinmese de, her bir sınıfın piksel içindeki yüzdesel olarak oransal dağılımı kestirilebilmektedir (Verbeiren vd. 2008).

Kar örtüsünü haritalama teknikleri iki ana kategoride gruplandırılabilir: (i) ikili, ve (ii) piksel altı sınıflandırma. Geleneksel ikili yaklaşımda her bir piksel ya kar ya da kar değil olarak belirtilmektedir. Hall vd. (1995) tarafından geliştirilen ilk MODIS ikili kar örtüsü algoritması, elektromanyetik spektrumun görünür bölgelerinde (0.4 - 0.7 μm) karın yüksek reflektans özelliğini ve kısa ve orta düzeyli kızıl ötesi bölgelerinde ise düşük reflektans özelliğini (1 - 4 μm) kullanan NDSI'nin üzerine kuruludur. MODIS

bant 4 (0.545-0.565 μm) ve bant 6 (1.628-1.652 μm) NDSI'yi hesaplamada kullanılmaktadır:

$$\text{NDSI} = \frac{\text{bant4}_{\text{MODIS}} - \text{bant6}_{\text{MODIS}}}{\text{bant4}_{\text{MODIS}} + \text{bant6}_{\text{MODIS}}}. \quad (1.1)$$

Bu orantı karı bulutlardan ve aynı zamanda karla kaplı olmayan yüzeylerden ayırt etmeye yaramaktadır. Algoritmanın ilk sürümünde orman bakımından yoğun olmayan bir alanda kar haritalama yapılması için gereken koşullara göre; $\text{NDSI} \geq 0.4$ ve bant 2 reflektansı $> \%11$ (karın sudan ayrılması için) ve bant 4 reflektansı ise $\geq \%10$ (yüksek NDSI değerlerine rağmen karanlık hedeflerin yanlışlıkla kar olarak sınıflandırılmasını önlemek için) olmalıdır (Klein ve Barnett 2003). Algoritmanın ikinci ve güncellenen versiyonları, (i) yoğun ormanlık olması durumunda kar örtüsünün haritalamasını geliştirmek için MODIS bant 1'i (0.620 - 0.670 μm) ve bant 2'yi (0.841 - 0.876 μm) kullanarak Normalize Fark Vejetasyon İndisi (Normalized Difference Vegetation Index - NDVI) ile NDSI'nin kombinasyonunu (Klein vd. 1998) ve (ii) önceki MODIS kar haritalarında yerkürenin birçok kısmında bulunan yanlışlıkla sınıflandırılan kar örtüsünün çoğunu bertaraf etmek için MODIS kızıl ötesi bantlarını, yani bant 31 (10.78 - 11.28 μm) ve bant 32'yi (11.77 - 12.27 μm) kullanarak bir termal maskenin uygulamaya geçirilmesini içermektedir (Hall vd. 2006). Bununla birlikte, ikili formattaki KKA verileri, iklim, hidrolojik ve sayısal hava örneklerine büyük belirsizlikler getirebilir, çünkü KKA'nın fraksiyonel özelliğinden yoksun olması, özellikle karın birikimi ve erime süresi boyunca KKA'nın mevsimsel dinamiklerini doğru bir şekilde tahmin edebilmeyi engellemektedir (Romanov vd. 2003, Dietz vd. 2012). Sonuç olarak dağılımlı fiziki modellerdeki kar karakteristiklerini kullanmak için piksel altı sınıflandırma yaklaşımı kullanılarak FKÖ haritaları üretilmek zorundadır (Painter vd. 2003, Dietz vd. 2012). Piksel altı sınıflandırma, arazi örtüsü sınıflarının muhtemel karışımını (örn; kar, toprak, kaya, bitki örtüsü, su vd.) ortaya çıkararak ve her bir örtü türünün alana ilişkin orantısını bir piksel içinde tanımlayarak düşük çözünürlüklü görüntülerde kalıtsal olarak görülen karışık piksel problemleriyle ilgili sınırlamaların ötesine geçmeye çalışmaktadır. Yine de her bir düşük çözünürlükteki pikseldeki sınıf orantılarının tam mekansal dağılımı hala bilinmezliğini korumaktadır (Verbeiren vd. 2008).

Spektral karışım analizi, FKÖ'yü tahmin etmede belki de en çok tercih edilen yöntemdir. Bir sensör tarafından ölçülen radyansın, tekli yüzeylerden yansıyan radyansların doğrusal bir birleşimi olduğu varsayımına dayanır, yani; spektral izleri/işaretleri benzersiz ve rastgele bir görüntü gürültü seviyesinin üstünde iyi ayrılmış olan uç üyelerdir (Xu vd. 2008). Rosenthal ve Dozier (1996) nihai üyelerin temel bileşen analizi yoluyla görüntü verilerinin alındığı denetimsiz doğrusal bir spektral karışım tekniği kullanarak Landsat ETM+ verilerinden FKÖ'yü tahmin etmiştir. Birçok çalışma MODIS verilerinden FKÖ'yü tahmin etmede bu yöntemi kullanmaktadır (Painter vd. 2003, Vikhamar ve Solberg 2003, Hongen ve Suhong 2004, Xu vd. 2008, Painter vd. 2009, Sirguyev vd. 2009, Zhu vd. 2012).

Terra ve Aqua MODIS görüntülerinden piksel altı fraksiyonel KKA haritalaması için bir başka yöntem ise; bir MODIS pikselinde daha yüksek çözünürlüklü Landsat kar haritalarının referans FKÖ olarak kullanılarak, NDSI ve FKÖ arasındaki istatistiksel doğrusal bir ilişki kurularak geliştirildi (Salomonson ve Appel 2004, 2006). Bu yöntem şu anda, Koleksiyon 5 ve 6'daki standart MODIS FKÖ ürünü oluşturmak için kullanılmaktadır (sırayla C5 ve C6 olan). Bununla beraber, C6'daki KKA FKÖ olarak verilmemiştir, onun yerine NDSI KKA açısından rapor edilmiştir. Sonuç olarak, FKÖ'yü hesaplamak için C6 NDSI KKA verilerine MODIS C5 FKÖ denklemi uygulanmalıdır (Riggs vd. 2016).

Veri madenciliği ve istatistiki öğrenme teorilerine dayanan “Destek Vektör Makineleri” (DVM) (Vapnik 1995) ileri düzey denetimli parametrik olmayan sınıflandırma ve regresyon aracıdır. Sismoloji (Fisher vd. 2017), enerji ve finans (Mustaffa vd. 2014, Yuan ve Lee 2015, Kumar vd. 2016), yüz tanıma, yazı sınıflandırma, biyobilgi ve veritabanlı pazarlama gibi birçok uygulamada başarılı bir şekilde kullanılmaktadır (Campbell ve Ying 2011). DVM'lerin arkasındaki temel mantık, sınıfların optimal ayrımını üreten karar sınırlarının yerinin belirlenmesidir (Vapnik 1995). Doğrusal karar sınırlarının sonsuz sayıları boyunca doğrusal olarak ayrılabilir ikili sınıflandırma probleminin varlığında DVM genelleme hatasını minimize eden seçer, bu da şu anlama gelir ki seçili karar sınırları iki sınıf arasındaki en büyük marjini bırakan olacaktır. Bu aşamada marjin, iki sınıfın en yakın noktalarından hiperdüzleme olan mesafelerin toplamı olarak tanımlanır (Pal ve Mather 2005).

DVM'ler ilk olarak örüntü tanımlama görevleri için geliştirilmiş olsalar da regresyon ve zaman serilerinin tahminlenmesine yönelik uygulamalarda da başarılı sonuçlar vermiştir (Drucker vd. 1997a, Müller vd. 1997, Mattera ve Haykin 1999). Genel manada DVM'lerin sunduğu faydalar, şu şekilde özetlenebilir Mountrakis vd. (2011): (a) UA uygulamaları için cazip olan uzaktan algılanan görüntülerinden edinilen verilerin çoğunlukla bilinmeyen dağılımları olduğu için sınıflandırılacak verinin bilinen istatistiki dağılımını DVM'ler varsaymazlar. (b) DVM'ler karesel (ya da ikinci dereceden) problemlerle ilgilendiğinden bu daima küresel minimuma gider ve bu da bunların yerel minimuma saplanmaya karşı dirençli olduklarını gösterir. (c) DVM'ler, sınırlı miktar ve/veya kaliteli eğitim verilerinden iyi bir şekilde yüksek genelleme yapma yeteneğine sahiptirler, çünkü "destek vektör" konsepti, sınıflandırıcının hiperdüzlemini belirlemek için sadece birkaç veri noktasına güvenir; bu da arazi doğrulama verilerinin temininin zorluğundan dolayı UA uygulamaları için çok kullanışlıdır. Yukarıda bahsedilen konular UA alanında çalışanların hemen dikkatini çekmiştir (Huang vd. 2002b, Foody ve Ajay 2004), DVM'ler görüntü sınıflandırma ve UA'deki regresyon (Bruzzone ve Melgani 2005, Kaheil vd. 2008, Zheng vd. 2008) görevlerinde başarılı uygulamalara sahiptirler ama henüz FKÖ tahminleri için kullanılmamaktadırlar.

DVM, UA'da gerek görüntü sınıflandırma (Huang vd. 2002a, Foody ve Ajay 2004), gerekse regresyon amacıyla (Bruzzone ve Melgani 2005, Kaheil vd. 2008, Zheng vd. 2008) yaygın bir şekilde uygulandığı bilinmekle birlikte, yapılan titiz literatür taraması sonucunda FKÖ alanında kullanıldığı bir çalışmaya rastlanmamıştır. Bilindiği üzere tüm parametrik olmayan sınıflandırma ve regresyon yöntemlerinde olduğu gibi, DVM'ler de modelin daha önce görmediği veriyi genelleme yeteneğini doğrudan etkileyen "model ayarlama" parametrelerine sahiptirler. Dolayısıyla bu çalışmanın birincil temel amacı UA'da FKÖ amacıyla DVM tasarımının detaylı olarak araştırılarak, en uygun DVM model ayarlama parametrelerinin seçilen çalışma sahası örneğinde ortaya konulmasıdır. Çalışmanın ikincil temel amacı ise, DVM modellerin eğitimi sırasında kullanılan eğitim veri setinin oluşturulmasında kullanılan örneklem tipinin ve örneklem boyutunun nihai DVM modellerinin genelleme ve tahmin becerisi üzerinde istatistiksel açıdan anlamlı bir etkisi olup olmadığının araştırılmasıdır.

Tezin kalan kısmı Őu Őekilde dŐzenlenmiŐtir:

- **Materyal ve YŐntem:** Tezin ikinci bŐlŐmŐnde seĀilen ĀalıŐma alanı kısaca tanıtılarak, MODIS, Landsat 7 ETM+ ve Landsat 8 OLI sensŐrleri ve analizlerde kullanılan bu sensŐrlere ait ŐrŐnler ile gŐrŐntŐlerin Őn iŐleme aŐamaları hakkında bilgiler verilmiŐtir. Daha sonra DVM'in matematik arka planı tanıtılarak, DVM modellerin eĀitilmesi ve bu sırada kullanılan deneysel tasarımı detaylarıyla aĀıklanmıŐtır.
- **Bulgular ve TartıŐma:** Tezin ŐçŐncŐ bŐlŐmŐnde eĀitim ve test verisi Őzerinde DVM modellerinin performansı deĀerlendirilmiŐtir. DVM modellerinin eĀitimi boyunca Őrneklem boyutlarına gŐre ortalama sŐreleri hakkında bilgi verilmiŐtir. DVM modellerinin ve MOD10A1 ŐrŐnŐnŐn performansları, test veri setleri kullanarak karŐılaŐtırılmıŐ, istatikselsel bakımdan Őnemli farklılıklar olup olmadıĀını belirlemek amacıyla tekrarlanan ŐlĀŐmler ANOVA (Repeated measures ANOVA - RANOVA) testi yapılmıŐtır.
- **SonuĀlar:** Tezin dŐrdŐncŐ ve son bŐlŐmŐnde, ĀalıŐmada elde edilen genel bulgular ve sonuĀlar kısaca Őzetlenerek, gelecekteki potansiyel ĀalıŐma konuları ile ilgili Őzet bilgiler verilmiŐtir.

2. MATERYAL VE YÖNTEM


2.1. Çalışma Alanı

Çalışma alanı Türkiye'nin Çankırı ve Kastamonu illerinin sınırları içinde bulunan Ilgaz Orman İşletme Müdürlüğü 1960 yılında kurulmuş olup, yaklaşık 7520 km²'lik bir alanı kapsamaktadır (Bakınız Şekil 2.1). Çankırı İlinin Ilgaz, Kurşunlu, Atkaracalar ve Bayramören ilçelerini kapsamaktadır. 205,258.4 Hektar (Ha) Sorumluluk alanına sahip, Orman İşletme Müdürlüğü %37.6 (77165.6 ha) ormanlık alan, %62.4 (128092.9 ha) açıklık alandan oluşmaktadır. Ormanlık alanın %59' u (45883.1 ha) normal koru %41 'i (31282.5 ha) bozuk koru niteliğindedir. Müdürlüğün bünyesinde 7 adet Orman İşletme Şefliği bulunmaktadır. İşletme Şeflikleri Ilgaz, Osmangözü, Devrez, Hızardere, Yenice Şefliklerinin kuruluş merkezi Ilgaz ilçesi, Kurşunlu Şefliğinin kuruluş merkezi Kurşunlu ilçesi, Bayramören şefliğinin kuruluş merkezi Bayramören ilçesidir. Yine bu orman işletme şefliklerine bağlı olarak ormanların korunmasına hizmet etmek amacıyla şeflik merkezlerinde kurulmuş olan 7 adet toplu koruma merkezi bulunmaktadır.

Ilgaz Orman İşletme Müdürlüğü orta Karadeniz bölümünün iç kısmında yer almaktadır. Doğudan Kastamonu Tosya, kuzeyden Kastamonu, Batıdan Bolu Devrez, Güneyden Çankırı İşletme Müdürlükleri ile komşudur. Ilgaz Orman İşletme Müdürlüğü 32 58' 45''- 33 51'32''doğu boylamları ile 40 55'32'' -41 04' 57'' kuzey enlemleriyle Ilgaz Orman İşletme Müdürlüğü sınırlarındaki ormanlar, genel olarak karadeniz ve karasal iklim kuşağı arasında kalmaktadır (URL1).

Çalışma alanının rakımı ortalama deniz seviyesinden 510-2540 m arasında değişen yüksekliktedir. Bitki örtüsü temel olarak orman, çalılık ve alp bitkilerinden müteşekkildir. Kuzey yamaçların düşük rakımlı yerleri genellikle meşe (*Quercus* spp.), karaçam (*Pinus nigra* ssp. *pallasiana*), Uludağ köknarı (*Abies nordmanniana* spp. *bornmulleriana*) ormanlarıyla kaplıdır. 1000-1300 m rakımlarda diğer çır ve kışın yaprak döken bitkilerle birlikte çoğunlukla gürgen (*Carpinus* spp.) ve kayın ağaçları (*Fagus orientalis* L.) gözlemlenir. 1500 m ve üzerinde ise saf veya karışık karaçam (*Pinus nigra* ssp. *pallasiana*) ve sarıçam (*Pinus sylvestris* L.) ormanları bulunur (Kuter 2008).

Bölgedeki yıllık ortalama sıcaklık 9.8 °C'dir. En soğuk ay -0.8 °C ortalama sıcaklıkla Ocak iken en sıcak ay 20 °C ile Temmuz'dur. Kastamonu Meteoroloji İstasyonu verilerine göre yıllık ortalama yağış miktarı 486 mm'dir. Dağ zirvelerinde yağış yaklaşık 1200 mm civarındadır. İç Anadolu ikliminin etkisiyle yamaçlarda 1 metreyi bulan kar tabakası, 6 ay boyunca kalmaktadır (Aydinozu vd. 2011, Kuter ve Kuter 2016).



Şekil 2.1 a) Çankırı – Kastamonu il sınırları ve Landsat 177/32'nin konumu, b) Ilgaz Orman İşletme Müdürlüğü sınırı ve Çalışma Alanı, c) Ilgaz Orman İşletme Müdürlüğüne bağlı İşletme Şeflik Sınırları

2.2. Veri Seti

2.2.1. MODIS

MODIS, Ulusal Havacılık ve Uzay Dairesi (National Aeronautics and Space Administration – NASA) tarafından işletilen iki çapraz iz tarayıcı radyometrik aracın ismidir: Bunlardan biri 1999 yılından beri Terra uydusunda, diğeri ise 2002 yılından bu yana Aqua uydusu üzerinde yer almaktadır (Qu vd. 2006). İlk aracın yerel

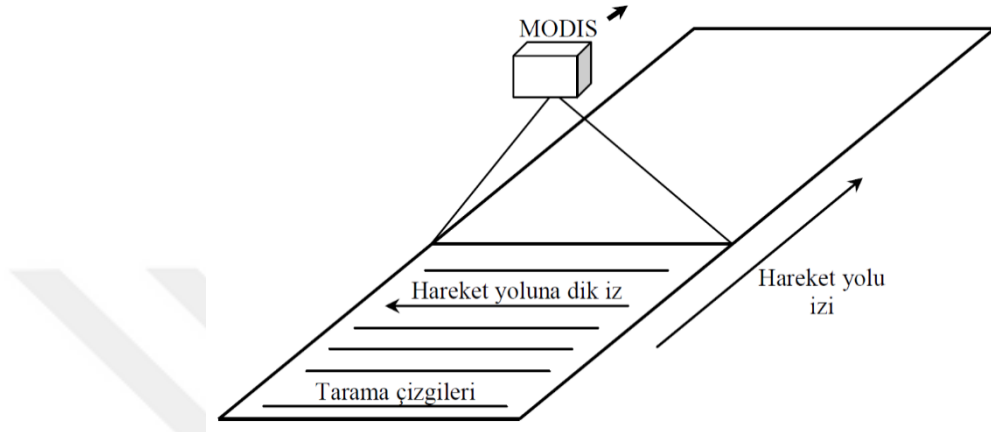
güneş zamanına göre 10:30 civarında ekvator üzerinde (güneye doğru) alçalan bir yörüngesi varken, ikincisinin yerel güneş zamanına göre 13:30 civarında ekvator üzerinde (kuzeye doğru) yükselen bir yörüngesi bulunmaktadır.

Çizelge 2.1 MODIS spektral bantlarının karşılığı

Bant	Aralık (µm)	Ortalama (µm)	Kullanma
250 m mekansal çözünürlükte yansıtıcı güneş bantları			
1	0.620-0.670	0.659	Aerosol, bulut, arazi
2	0.841-0.876	0.865	
500 m mekansal çözünürlükte yansıtıcı güneş bantları			
3	0.459-0.479	0.470	Aerosol and bulut optik kalınlığı, bulut fazı, bulut etkili yarı çapı, bulut maskesi, kar, arazi
4	0.545-0.565	0.555	
5	1.230-1.250	1.240	
6	1.628-1.652	1.640	
7	2.105-2.155	2.130	
1000 m mekansal çözünürlükte yansıtıcı güneş bantları			
8	0.405-0.420	0.412	Okyanus rengi, klorofil, fitoplankton, biyojeokimyası
9	0.438-0.448	0.443	
10	0.483-0.493	0.448	
11	0.526-0.536	0.531	
12	0.546-0.556	0.551	Tortular, atmosfer
13	0.662-0.672	0.667	
14	0.673-0.683	0.678	Floresan
15	0.743-0.753	0.748	Atmosfer, aerosol
16	0.862-0.877	0.869	
17	0.890-0.920	0.905	Atmosferik toplam çöktürülebilir su buharı, bulutlar
18	0.931-0.941	0.936	
19	0.915-0.965	0.940	
26	1.360-1.390	1.375	Sirüs bulutu
1000 m mekansal çözünürlükte termal emisyon bantları			
20	3.660-3.840	3.750	Bulut ve yüzey, sıcaklık, ateş ve volkan, deniz yüzeyindeki sıcaklık
21	3.929-3.989	3.960	
22	3.929-3.989	3.960	
23	4.020-4.080	4.050	
24	4.433-4.498	4.470	Atmosferdeki sıcaklık profili
25	4.482-4.549	4.520	
27	6.535-6.895	6.720	Troposferik su buharı
28	7.175-7.475	7.330	
29	8.400-8.700	8.550	Bulut parçacığı yarığı
30	9.580-9.880	9.730	Toplam ozon
31	10.780-11.280	11.030	Bulut, yüzey sıcaklığı, ateş
32	11.770-12.270	12.020	
33	13.185-13.485	13.340	Bulut üst yükseliği, sıcaklık, basınç, sıcaklık profili
34	13.485-13.785	13.640	
35	13.785-14.085	13.940	
36	14.085-14.385	14.240	

Her bir aracın şerit genişliği yaklaşık 2330 km'dir ve her biri 10 km'lik bir alanı taramaktadır (Bakınız Şekil 2.2). Bunlar dünyayı yeryüzünden 700 km'lik bir irtifadan $\pm 55^\circ$ 'lik bir görüş açısı ile görüntülemektedir ki bu da günlük bazda neredeyse tüm

yerkürenin gözlemlendiği anlamına gelmektedir (Qu vd. 2006). Her iki araç, radyasyon dengesi, bulut örtüsü ve atmosfer gibi dünyanın küresel dinamiklerini incelemek için değişkenlik gösteren mekansal çözünürlükte 0.4 μm 'dan 14.4 μm 'a kadar bir dalga boyu aralığındaki 36 spektral bantda veri elde etmektedir (Çizelge 2.1). (Salomonson vd. 1989).



Şekil 2.2 MODIS'in gözlem alanı (Toller vd. 2012)

2.2.2. Landsat 7 ETM+ ve Landsat 8 OLI uyduları

Geliştirilmiş tematik haritalayıcı (The Enhanced Thematic Mapper Plus - ETM+) aracını kullanan Landsat 7, NASA'nın küresel araştırma programının bir parçası olarak 15 Nisan 1999'da fırlatılmıştır. Bu uzun vadeli program, karaların, okyanusların, atmosferin, buz kütlelerinin yanı sıra yaşam formları da dahil olmak üzere Dünya'nın küresel çevrelerindeki değişimleri anlamayı amaçlamaktadır (Goward vd. 2001). Sensör, elektromanyetik spektrumun görünür, yakın kızılötesi ve kısa dalga kızılötesi bölgelerinde 6 spektral banta (30 m mekansal çözünürlük), bir termal kızılötesi banta (60 m ve 120 m mekansal çözünürlük) ve bir pankromatik banta (15 m mekansal çözünürlük) sahiptir (Karnieli vd. 2004). Landsat 7 ETM+ uydusunun bantları ve özellikleri Çizelge 2.2'de verilmiştir.

Çizelge 2.2 Landsat 7 ETM+ uydu görüntüsünün bantlarının geometrik ve spektral özellikleri (URL5)

Band	Dalgaboyu (μm)	Çözünürlük (m)
1	0.45-0.52	30
2	0.52-0.60	30
3	0.63-0.69	30
4	0.76-0.90	30
5	1.55-1.75	30
7	2.08-2.35	30
8	0.52-0.90	15

Landsat 8 uydusu 11 Şubat 2013'te Kaliforniya'da bulunan Vandenburg Hava Kuvvetleri Üssü'nden başarıyla fırlatılmıştır. Landsat 8 iki sensörüdür. İlki Operasyonel Kara Görüntüleyici (Operational Land Imager - OLI) ve ikincisi Termal Kızılötesi Sensör (Thermal Infrared Sensor - TIRS)'dür. ETM+ ile karşılaştırıldığında, OLI'nin iki ek yansıtıcı dalga boyu bandı vardır: kıyı sularında klorofil ve diğer asılı materyallere duyarlılığı artırmak için daha kısa dalga boylu mavi bant (0.43-0.45 μm) ve Sirkus bulutunu algılamak için yeni bir kısa dalga kızılötesi bant (1.36-1.39 μm) vardır. Diğer OLI bantları, çoğu durumda ETM+ bantlarından spektral olarak daha dardır. OLI'nin yakın kızılötesi (Near Infrared - NIR) bandı, MODIS NIR bandına daha yakın genişliktedir ve ETM+ NIR bandında meydana gelen 0.825 μm su buharı emilim özelliğini önler. TIRS, yüksek ve düşük kazançlı tek termal kızılötesi 60 m ETM+ bandına kıyasla, iki tane 100 m termal kızılötesi bantta yayılan radyasyonu algılar. İki termal TIRS bandı, termal dalga boyunda atmosferik düzeltmeyi, yüzey sıcaklığını ve yaymayı daha güvenilir bir şekilde elde etmeyi sağlar (Roy vd. 2014).

Çizelge 2.3 Landsat 8 OLI Bantları ve Özellikleri (URL5)

Bant	Dalga Boyu (mikrometre)	Çözünürlük (metre)
Bant-1 Coastal Aerosol (Kıyı Aerosol)	0.43-0.45	30
Bant-2 Mavi	0.45-0.51	30
Bant-3 Yeşil	0.53-0.59	30
Bant-4 Kırmızı	0.64-0.67	30
Bant-5 Yakın Kızılötesi (NIR)	0.85-0.88	30
Bant-6 Orta Kızılötesi (SWIR-1)	1.57-1.65	30
Bant-7 Orta Kızılötesi(SWIR-2)	2.11-2.29	30
Bant-8 Pankromatik	0.50-0.68	15
Bant-9 Sırrus	1.36-1.38	30
Bant-10 Termal Kızılötesi (TIRS-1)	10.60-11.19	100*30
Bant-11 Termal Kızılötesi (TIRS-2)	11.50-12.51	100*30

2.3. Destek Vektör Makineleri (DVM)

Bu alt bölümde Haykin (2009), Vapnik (1995), Mountrakis vd. (2011), Drucker vd. (1997b), Richards ve Jia (2006) ile Smola ve Schölkopf (2004)'e dayanılarak DVM ile ilgili genel bir özet sunulmaktadır.

En basit durum göz önüne alındığında, DVM doğrusal bir ikili sınıflandırıcıdır. Model eğitiminin ardından bir test örneği verildiğinde, DVM iki olası etiketten birini sınıf olarak atar. UA'daki bir sınıflandırma için, etiketlenecek test verileri, genellikle çok spektralli ya da hiper-spektralli görüntülerin her bir bandında bulunan her bir piksele ait sayısal değerdir (yani, reflektans, radyans ya da ham Dijital Sayı (Digital Number – DN)).


Eğitim verisi için, ilgili özelliklerle (yani, tahminleyici değişkenler) birlikte girdi vektörleri setinin \mathbf{x}_i tarafından verildiğini varsayalım. Her bir vektör $\mathbf{x} \in \mathbb{R}^N$ 'nin N -boyutlu uzay olduğu ve i 'nin mevcut örneklerin sayısı olduğu yerde, $(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_i, y_i)$ gibi y_i tarafından simgelenen ilgili etiketle (yani, sınıf) ilişkilendirilmektedir. En basit ikili sınıflandırma durumunda, y_i sadece iki muhtemel etiket alabilir, +1 ve -1. İkili sınıflandırıcı DVM'deki öğrenme görevinin temel amacı : (i) hiperdüzlemin bir tarafındaki veri noktalarının $y_i = + 1$, diğer tarafındakilerin ise $y_i = -1$ olarak etiketlendiği, ve (ii) hiperdüzlemin iki sınıfın etiketlenen noktalarına olan uzaklığının

maksimize edildiği bir hiperdüzleme karar vermektir. Yanlış sınıflandırmaları en aza indiren maksimum marjinli en uygun ayırıcı hiperdüzleminin konumu, iki sınıfa en yakın eğitim noktalarına komşu olan ayırıcı hiperdüzleme paralel olan iki hiperdüzlemce (yani, destek vektörler) tanımlanır (Bakınız Şekil 2.3). En uygun hiperdüzleme paralel iki hiperdüzlem şu şekilde ifade edilir:

$$\begin{aligned} \mathbf{w} \cdot \mathbf{x}_i + b &\geq +1, & y_i &= +1, \\ \mathbf{w} \cdot \mathbf{x}_i + b &\geq -1, & y_i &= -1, \end{aligned} \quad (2.1)$$

$(i = 1, 2, \dots, k),$

“.” nokta ya da skalar çarpımı, b hiperdüzlemin orijinden olan uzaklığını, \mathbf{x}_i tahminleyici değişkenler vektörünü, ve $\mathbf{w} = (w_1, \dots, w_N)^T$ en uygun ayırıcı hiperdüzlemin yönünü tayin eden N elemanın ağırlık vektörünü simgelemektedir.



Şekil 2.3 Destek vektörleri tarafından tanımlanan en uygun ayırıcı hiperdüzlem (Richards ve Jia 2006)

İfade (2.1)'deki iki eşitsizlik aşağıdaki tek eşitsizlik içinde yazılabilmektedir:

$$y_i [\mathbf{w} \cdot \mathbf{x}_i + b] \geq 1 \quad (i=1, 2, \dots, k). \quad (2.2)$$

Maksimum marjinli en uygun ayırıcı hiperdüzlem, İfade (2.2)'de verilen eşitsizlik kısıtlamasıyla birlikte aşağıdaki eşitlikte gösterildiği gibi \mathbf{w} 'nin normunun minimize edilmesiyle elde edilebilir:

$$F(\mathbf{w}) = \frac{1}{2}(\mathbf{w} \cdot \mathbf{w}). \quad (2.3)$$

Bu durum Denklem (2.3)'deki hedef fonksiyonunun Lagrange çarpanları kullanılmak suretiyle İfade (2.2)'deki kısıtlara tabi olarak minimize edildiği bir kısıtlı optimizasyon problemidir. Bazı yeniden düzenlemeler ve değişikliklerden sonra en uygun ayırıcı hiperdüzlemi tanımlayan karar kuralı şöyledir:

$$g(\mathbf{x}) = \text{sign} \left(\sum_i^r y_i \alpha_i^0 K(\mathbf{x}, \mathbf{x}_i) - b^0 \right), \quad (2.4)$$

Burada her bir r eğitim durumu için sınıf üyeliğinin tanımı olan y_i ile birlikte durumun tepkisini temsil eden bir \mathbf{x}_i vektörü var olup, $\alpha_i \geq 0$, ($i = 1, 2, \dots, r$) Lagrange çarpanlarını, $K(\mathbf{x}, \mathbf{x}_i)$ ise veri noktalarının doğrusal bir hiperdüzleme oturtulabileceği şekilde dağılımını sağlayan kernel fonksiyonunu simgelemektedir.

Doğrusal DVM uygulaması, girdi verisinin doğrusal olarak ayrılabilmesi varsayımına dayanmakta olup, bu koşul çok veya hiper spektral UA görüntülerinde nerdeyse hiç sağlanmamaktadır. Buna ek olarak UA görüntülerindeki sınıfların mekânsal ve spektral olarak çakışması doğrusal karar sınırlarının sınıfları yüksek doğrulukla ayırmasını zorlaştırmaktadır. Bu tür sıkıntıların üstesinden gelebilmek için yumuşak marjin ve kernel metodları geliştirilmiştir. Radyal taban fonksiyonu (Radial Basis Function – RBF), doğrusal, kuadratik ve polinom kerneller ham veriyi çok boyutlu özellik uzayına dönüştürmede sıklıkla kullanılmaktadır (Pal ve Mather 2005, Mountrakis vd. 2011).

Başlangıçta örüntü tanımlama görevleri için geliştirilmiş olsa da, DVM'ler regresyonda da oldukça iyi bir performans sergilemiştir. DVM regresyonunda ana hedef, tüm eğitim verileri için gerçekte elde edilen y_i hedef değerlerinden en çok ε kadar sapmaya sahip olan ve aynı zamanda da mümkün olduğunca düz olan bir $f(\mathbf{x})$ fonksiyonu bulmaktır. ε 'den daha az olan hatalar gözardı edilebilir olarak görülmekte olup, bundan büyük olan sapmalar ise kabul edilmemektedir. Bu durumda $f(\mathbf{x})$ aşağıdaki denkleme dönüşür:

$$f(\mathbf{x}) = \mathbf{w} \cdot \mathbf{x}_i + b, \quad \mathbf{w} \in \mathbb{X}, \quad b \in \mathbb{R}, \quad (2.5)$$

burada \mathbb{X} girdi deęişkenleri uzayını simgelemektedir. Denklem (2.5)'e göre, "düzlük" küçük \mathbf{w} cinsinden ifade edilebilmekte olup, bunu sağlamanın bir yolu ise bir konveks optimizasyon problemi olarak yeniden yazılabilecek olan $\|\mathbf{w}\|^2 = (\mathbf{w} \cdot \mathbf{w})$ 'yi minimize etmektir:

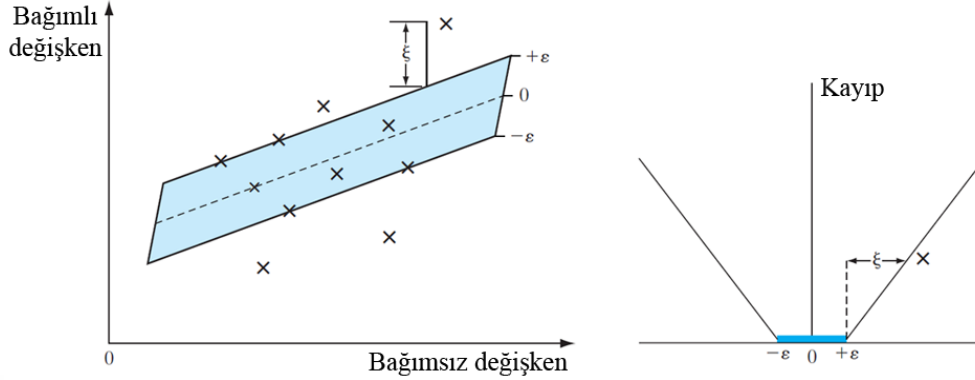
$$\begin{aligned} & \text{minimize } \frac{1}{2} \|\mathbf{w}\|^2, \\ & \text{kısıtlar } \begin{cases} y_i - \mathbf{w} \cdot \mathbf{x}_i - b \leq \varepsilon, \\ \mathbf{w} \cdot \mathbf{x}_i + b - y_i \leq \varepsilon, \end{cases} \\ & (i = 1, 2, \dots, N). \end{aligned} \quad (2.6)$$

Denklem (2.6), böyle bir $f(\mathbf{x})$ fonksiyonunun var olduğunu ve bu fonksiyonun bütün (\mathbf{x}_i, y_i) çiftlerini ε hassasiyetiyle tahminleyeceğini, yani bu konveks optimizasyon probleminin "uygulanabilir" olduğunu üstü kapalı olarak varsaymaktadır. Bazı hatalara müsaade edilebilen uygulanamaz senaryo durumunda yapay deęişkenler ξ_i, ξ_i^* , Denklem (2.6)'daki optimizasyon problemine ait dięer uygulanamaz kısıtlarla uğraşabilmek için kullanılabilmekte olup, bu yöntem aynı zamanda "yumuşak marjin" metodu olarak bilinmektedir. Sonuç olarak Vapnik (1995)'de verilen aşıęıdaki formül elde edilmektedir:

$$\begin{aligned} & \text{minimize } \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*), \\ & \text{kısıtlar } \begin{cases} y_i - \mathbf{w} \cdot \mathbf{x}_i - b \leq \varepsilon + \xi_i, \\ \mathbf{w} \cdot \mathbf{x}_i + b - y_i \leq \varepsilon + \xi_i^*, \\ \xi_i, \xi_i^* \geq 0. \end{cases} \end{aligned} \quad (2.7)$$

Sabit $C > 0$, $f(\mathbf{x})$ 'in düzlüğü ile ε , den daha büyük sapmaların tolere edilebileceęi deęer arasındaki ödünleşmeyi kontrol eder. Bu durum bizi, Şekil 2.4'de grafiksel olarak gösterilen ε 'den etkilenmeyen kayıp $|\xi|_\varepsilon$ fonksiyonuna götürmekte olup, şu şekilde ifade edilmektedir:

$$|\xi|_\varepsilon := \begin{cases} 0, & \text{eğer } |\xi| \leq \varepsilon, \\ |\xi| - \varepsilon, & \text{aksi halde.} \end{cases} \quad (2.8)$$



Şekil 2.4 Doğrusal bir DVM için yumuşak marjin kayıp ayarının temel bir gösterimi (Haykin 2009)


2.4. MODIS ürünleri

MODIS verileri farklı derleme ve işleme düzeylerinde bulunabileceğinden dolayı, kullanıcılar kullanmak istedikleri verilerin türünü ve kapsamını belirlemelidirler. MODIS verileri iki ana kategoride gruplandırılabilir; günlük görüntüler ve türetilmiş ürünler. Ürünler ayrıca Kalibrasyon, Atmosfer, Toprak, Kriyosfer ve Okyanus gruplarına ayrılır.

Çoğu uydu veri işleme sisteminde olduğu gibi, MODIS beş farklı işleme seviyesine sahiptir. (Vermote vd. 2011). Ham uydu yayınları seviye 0 verileri ile verilir. Seviye 1 verileri radyometrik olarak kalibre edilmiş verilerden oluşur. Seviye 2 verileri, seviye 1 verilerinin atmosferik olarak düzeltilmesi ile elde edilir ve yüzey reflektans değerlerini verir. Seviye 2 verileri bir harita projeksiyonuna gridlendiğinde ve geçici olarak bir araya getirildiğinde veya ortalaması alındığında seviye 3 verileri elde edilir. Seviye 4 verileri ise, ilave işleme tabi tutulan ürünlerdir.

Seviye 2'ye kadar olan MODIS verileri, gridlenmemiş yörüngesel şerit biçimi olarak mevcuttur; burada her bir şerit, işleme kolaylığı için tipik olarak küçük parçalara veya granüllere bölünmüştür. Daha yüksek seviyedeki veriler, Şekil 2.5'de gösterildiği gibi

tipik olarak bir dizi çakışmayan karolardaki coğrafi olarak konumlandırılmış ürünlerle birlikte, belirli bir harita projeksiyonuna coğrafi olarak yerleştirilir.



Şekil 2.5 MODIS sinüzoidal grid şema (Vermote vd. 2011)

MODIS veri dosyaları, Dünya Gözlem Sistemi Veri ve Bilgi Sistemi (Earth Observing System Data and Information - EOSDIS) tarafından seçilen standart veri depolama biçimi olan Hiyerarşik Veri Formatındadır (Hierarchical Data Format - HDF) (URL2). Bu veri dosyaları, EOSDIS tarafından Dünya Gözleme Sistemi (Earth Observing System - EOS) verilerine arama hizmetleri depolamak ve uygulamak için standartlar oluşturmak üzere tanımlanan HDF-EOS (Hierarchical Data Format – Earth Observing System - Hiyerarşik Veri Formatı - Dünya Gözlem Sistemi) uzantısını kullanmaktadır (URL3).

MODIS dosya adları, belirli ürünle ilişkili kısa ve kullanışlı bilgileri veren basit, ancak çok tanıtıcı bir standart kullanır. Spesifik bir örnek olarak,

“MOD09GA.A2006013.h18v04.005.2008059145954.hdf” dosya ismi aşağıdaki gibi açılır:

- MOD09GA – Ürünün kısa adı (MOD: Terra / MYD: Aqua),
- .A2006013 – Verinin ediminin Jül/ 4 rakamlı tarihi (A-YYYYDDD),
- .h18v04 – Karo (yatayXXdikeyYY),

- .005 – kolleksiyon versiyonu,
- .2008059145954 – Ürünün Jül / 4 rakamlı tarihi (YYYYDDDHHMMSS),
- .hdf – Veri formatı (HDF-EOS).

Bu çalışmada kullanılan MODIS ürün türleri aşağıdaki alt bölümlerde kısaca tanıtılmaktadır.

2.4.1. MODIS seviye 1B ürünü

MODIS Seviye 1B ürününün kısa tanıtımı URL4 , Toller vd. (2012), Xiong vd. (2006)'yi baz alan bu alt bölümde sunulmaktadır.

Seviye 1 işlemi iki aşamadan oluşur: yani Seviye 1A ve Seviye 1B. Bunlardan birincisi, Seviye 0 MODIS verilerini açmak ve doğrulamak için kullanılırken, ikincisi Seviye 1A veri ürününde yer alan ham dedektör çıktı değerlerinin radyometrik kalibrasyonunu içerir. Seviye 1B kalibre edilmiş veriler, görüntü üretmek için diğer uygulamalar tarafından girdi olarak kullanılır. Seviye 1A coğrafi konum ve Seviye 1B yazılım sistemleri, Terra ve Aqua tarafından toplanan verileri işlemek ve ardından ilgili ürün dosyalarını oluşturmak için kullanılır. 2 saatlik Seviye 0 veri seti, her biri yaklaşık 5 dakika MODIS verisi içeren bir dizi granüle, Seviye 1A koduyla düzenlenmiştir. Düzey 1A coğrafi konumlandırma algoritması, her bir MODIS mekansal ögesi için jeodezik konumu (enlem, boylam ve yükseklik), zeminle uydu yönünü ve aralığını ve Güneş yönünü hesaplar. Bir tarama MODIS için 1.4771 saniye sürer; Bu nedenle, 5 dakikalık Seviye 1B ürün dosyası genelde 203 tam tarama ve bazen 204 tam tarama içermektedir. Seviye 1B ürünleri Çizelge 2.4'de özetlenmiştir.

Çizelge 2.4 Seviye 1B ürün özeti


Ürün adı	Ürün İçeriği	Bantlar	Mekansal Bantlar
MOD/MYD02QKM	Kalibre edilmiş Dünya görüntüsü verileri	1,2	250 m
MOD/MYD02HKM	Kalibre edilmiş Dünya görüntüsü verileri (ayrıca 1 ve 2 bantlarını içerir ve bunlar 500 m çözünürlüğe kadar toplanır)	3-7	500 m
MOD/MYD02HKM	Kalibre edilmiş Dünya görüntüsü verileri (ayrıca 1-7 bantlarını içerir ve bunlar 1000 m çözünürlüğe kadar toplanır)	8-36	1000 m
MOD/MYD02OBC	Kalibratör ve mühendislik verileri	N/A	N/A

Reflektif güneş bantları için iki kalibre edilmiş veri ürünü, yani reflektans ve Dünyadan çıkma radyansı Seviye 1B'de sağlanır. Kullanıcı, reflektans ve radyansları hesaplamak için Seviye 1B ürünündeki ilgili Bilimsel Veri Setinde (Scientific Data Set - SDS) yazılan verileri nasıl dönüştüreceğini bilmelidir. Yansıtıcı bant detektörleri tarafından ölçülen ham sinyaller DN olarak verilir ve bu değerler aşağıdaki sensör kaynaklı etkiler için Seviye 1B'de düzeltilir:

- Elektronik kaymalar,
- Analogtan sayısal dönüştürücülerde sapmalar
- Tarama ayna reflektansının açısız farklılıkları,
- Araçlardaki ve odaksal düzlem sıcaklıklarında değişikliklerden kaynaklanan değişiklikler, ve son olarak

- Orta kızılötesi (Shortwave Infrared - SWIR) bantları 5, 6, 7 ve 26'daki verilen bant dışı spektral tepki

Ardından, düzeltilmiş dijital sayılar, dn^a , her bir bandta detektörden detektöre olan kalibrasyon parametrelerindeki belirli varyasyonların etkileri için de ayrıca ayarlanır. Ayarlanan dn^a 'in yeni değerleri şimdi dn^b 'dir (her bir dn^b sabit olmayan nokta sayısıdır) ve bunlar SDS'deki 16 bitlik temsile göre ölçeklendirilmektedir. $[dn_{min}, dn_{max}]$ 'in bütün dizisindeki her bir dn^b , Şekil 2.6'da gösterilen ve Ölçeklendirilmiş Tamsayı (Scaled Integer - SI) simgesi olarak adlandırılan $[0, 32767]$ 'in dizi içinde ölçeklendirilmektedir.



Şekil 2.6 Seviye 1B ürünündeki dn^b 'nin ölçekli tamsayı gösterim (Toller vd. 2012)

Reflektif güneş bantları için reflektans değerlerini, Θ , hesaplamada aşağıdaki denklem kullanılır:

$$\Theta = \delta \cdot (SI - \gamma), \quad (2.9)$$

Burada δ ve γ karşılık gelen reflektif güneş enerjisi bandının sırasıyla karşılık gelen reflektans ölçeği ve reflektans kayma değerleridir ve ilgili bantın SDS'sinde öznitelik değerleri olarak mevcuttur. Bir de aşağıdaki denklem yardımı ile benzer şekilde parlaklıkları da hesaplayabiliriz:

$$\Psi = \alpha \cdot (SI - \omega). \quad (2.10)$$

Burada α ve ω , sırasıyla ilgili radyans ölçeği ve radyans kayma değeridir. Reflektif güneş enerjisi bantlarındaki verilerin birimleri Çizelge 2.5'te verilmektedir. Termal yayıcı bantlar için radyanslar, 32-bit kayan nokta formatıyla Seviye 1B'de gösterilir.

Yayıcı bant detektörleri tarafından ölçülen DN değerleri aşağıdaki etkiler için Seviye 1B'de düzeltilir:

- Analog-sayısal dönüştürücülerdeki sapmalar,
- cihazın ve optiklerin kendinden emisyonlu olması, ve
- Uzun dalga bantlardaki optik parazitlenme

Radyans değerlerinin 16 bit tam sayıya ölçeklendirilmesi, reflektif güneş enerjisi bantları için açıklandığı gibi aynen uygulanır. Termal yayıcı bantlar için radyans değerlerinin hesaplaması, Eşitlik (2.10)'de gösterildiği gibi yine benzer şekilde yapılır.

Çizelge 2.5 Yansıtıcı solar bantların birimleri

Ölçülen Nicelik	Birimi
dn ^b	birimsiz
Reflektans	birimsiz
Reflektans ölçeği	birimsiz
Reflektans kayması	birimsiz
Radyans	W/m ² /μm/sr
Radyans ölçeği	W/m ² /μm/sr
Radyans kayması	birimsiz

2.4.2. MODIS kar algoritması ve seviye 3 günlük kar ürünü

MODIS kar algoritmasının ve Seviye 3 MOD/MYD10A1 günlük kar ürününün kısa tanımı Hall vd. (2002), Riggs vd. (2006), Tekeli vd. (2005) baz alınarak verilmiştir.

1999'da fırlatılmasından bu yana, MODIS tarafından Terra uydusunda toplanan veriler, her MODIS 500 m pikselin kar veya kar değil olarak sınıflandırıldığı SNOWMAP algoritması yoluyla genel kar örtüsü haritasını çıkarmak için yoğun şekilde kullanılmıştır (Salomonson ve Appel 2006). Kar haritalama algoritması esas olarak, eşik testleri serisi ve MODIS bulut maskesi ile birlikte, 4 (0.555 μm merkezli) ve 6 (1.640 μm merkezli) numaralı MODIS bantlarının kullanıldığı NDSI temel alınarak oluşturulmuştur (Hall vd. 2002, Salomonson ve Appel 2006). Aqua'daki MODIS cihazının 6. bandında 15 işlevsiz detektör (20 üzerinden) bulunması nedeniyle, bu cihaz için 4 ve 6 bant ölçümlerine dayalı NDSI hesaplamaları kullanılamamaktadır (Salomonson ve Appel 2006).

Kar algılamanın arkasındaki temel mantık, kar reflektansının görünür dalgaboylarında yüksek ve yakın kızılötesinde ise düşük olmasıdır. MODIS, Eşitlik (2.11)'te verilen NDSI değerini hesaplamak için 4 bantı (0.545-0.565 μm) ve 6 (1.628-1.652 μm) bantının kullanıldığı tam otomatik bir kar haritalama algoritması kullanılır:

$$\text{NDSI} = \frac{\text{bant}_4 - \text{bant}_6}{\text{bant}_4 + \text{bant}_6}. \quad (2.11)$$

Yoğun olmayan ormanlık bir alanda bir pikselin NDSI değeri ≥ 0.4 ise ve bant 2'deki reflektans oranı (0.841-0.876 μm) $> \% 11$ ise; kar olarak etiketlenir. Bununla birlikte, çok düşük reflektans değerleri NDSI paydasını oldukça küçük yapar ve ladin ormanları gibi çok koyu pikselleri yanlışlıkla kar olarak sınıflandırılabilir. Bu nedenle, bant 4'teki reflektans oranı (0.545-0.565 μm) $< 10\%$ olduğunda, piksel diğer koşullar karşılansa bile kar olarak etiketlenmez.

Bir orman meşçeresi karla kaplı olduğunda, spektral tepki görünürdeki reflektans genellikle kızıl ötesi reflektans oranına göre artacak ve NDVI'da bir azalmaya neden olacak şekilde değişir. Yoğun ormanlık alanlardaki kar haritalamasını iyileştirmek için NDSI ve NDVI birlikte kullanılır. NDVI hesaplamasında MODIS 1 (0.620-0.670 μm) ve 2 (0.841-0.876 μm) bantları kullanılır ve değeri ≈ 0.1 ise, NDSI değeri < 0.4 olsa bile, piksel kar olarak etiketlenebilir.

Ek olarak, 31 (10.780-11.280 μm) ve 32 (11.770-12.270 μm) numaralı MODIS kızılötesi bantlar, yanlışlıkla sınıflandırılan karın ortadan kaldırılması ve kar haritalamanın doğruluğunun artırılması amacıyla yerin sıcaklığını hesaplamak için bölünmüş pencere tekniği kullanılarak hesaba katılmaktadır. Bu termal maskeyi kullanarak sıcaklık $> 283 \text{ K}$ olan pikseller kar olarak etiketlenmez.

Aqua üzerindeki MODIS bant 6 işlevselliği yaklaşık $\% 30$ olduğundan dolayı, bu sensör için şerit seviyesi algoritmasındaki kar haritalama, bant 7 (2.105-2.155 μm)'ye kaydırılmıştır.

Seviye 2 ve Seviye 3'te üretilen yedi MODIS kar ürünü vardır ve bunlar farklı zamansal ve mekansal çözünürlükte dirler (Bakınız Çizelge 2.6).

Kar ürünleri için dosya formatı HDF-EOS'dir. Her bir günlük kar ürünü, MOD/MYD10A1, sinüs biçimli bir projeksiyonu bulunan bir $10^{\circ} \times 10^{\circ}$ (1200×1200 km) karodur. Bir MOD/MYD10A1'de dört SDS mevcuttur: KKA haritası, kesirli KKA, kar albedo ve QA verileri. Gün için bir gözlem seçmek için Denklem (2.12)'te verilen skor algoritması kullanılmaktadır:

$$\text{score} = 0.5SE + 0.3ND + 0.2OC, \quad (2.12)$$

Burada SE 'nin güneşin yüksekliği, ND en alt noktadan olan uzaklık ve OC ise gözlem kapsamıdır. KKA haritasını oluşturmak için; en büyük kapsama alanı ile birlikte öğle saatine en yakın zaman gözlem puanlama/skorlama algoritması tarafından seçilir, daha sonra kar, karla kaplı su kaynakları, toprak, su, bulut veya diğer koşullar olarak sınıflandırılır.

Çizelge 2.6 MODIS'in kar verisi ürünleri

Ürünün adı	Seviye	Veri boyutu	Mekansal çözünürlük	Zamansal çözünürlük
MOD/MYD10_L2	L2	1354 × 2000 km	500 m	görüntü
MOD/MYD10L2G	L2G	1200 × 1200 km	500 m	aynı günde taranan çoklu görüntü
MOD/MYD10A1	L3	1200 × 1200 km	500 m	gün
MOD/MYD10A2	L3	1200 × 1200 km	500 m	8 gün
MOD/MYD10C1	L3	360° × 180° (global)	0.05° × 0.05°	gün
MOD/MYD10C2	L3	360° × 180° (global)	0.05° × 0.05°	8 gün
MOD/MYD10C	L3	360° × 180° (global)	0.05° × 0.05°	ay

L2G ürününde parçalı/kesirli KKA'dan gelen gözlemler, Eşitlik (2.12)'teki aynı skor algoritması kullanılarak günlük kesirli kar örtüsünü belirlemede kullanılır. Parçalı/kesirli kar, parçalı/kesirli kar örtüsü haritasına göre % 0-100 aralığında verilir. Bu harita, karasal su kaynaklarını içerir ve karsız pikseller su, bulut veya diğer durumlar olarak sınıflandırılır.

MODIS yüzey reflektans ürününü kullanarak kar albedosu, görünür ve yakın kızılötesi bantlar için belirlenir. Elde edilen harita, kar albedosunu 0-100 aralığında gösterir ve kar içermeyen özellikler farklı değerlerle etiketlenir. Bir MOD/MYD10A1 günlük kar karosundaki tanımlayıcı özelliklerin bir özeti Çizelge 2.7'de verilmektedir.

Çizelge 2.7 MOD/MYD10A1 günlük kar tipi özellikleri

Koordinat sistemi	Kartezyen
Geçerli aralık	0-254
Dolum değeri	255 (Şeritteki boşlukları doldurmak için kullanılır)
Veri değerlerinin karşılığı	0: kayıp veri
	1: karar yok
	11: gece
	25: karsız
	37: göl
	39: okyanus
	50: bulut
	100: donmuş göl
	200: kar
	254: doymuş detektör
255: boşluk doldurma	

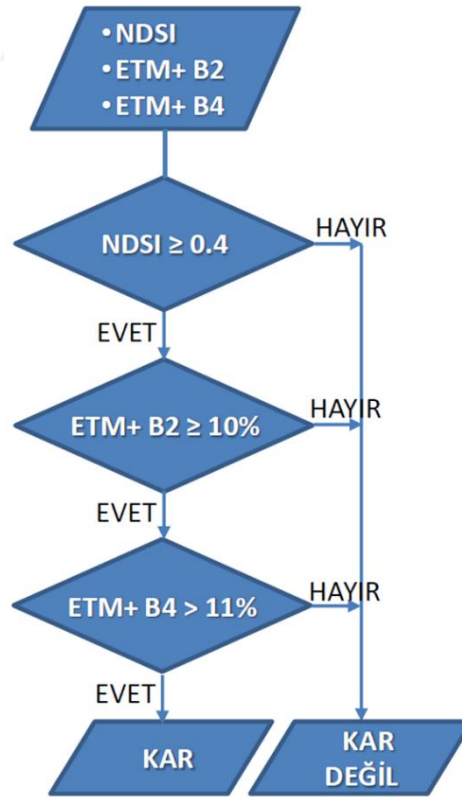
2.5. Veri Seti İle İlgili Ön İşleme

Tüm MODIS yüzey reflektans görüntüleri, ilgili Landsat görüntü projeksiyonuyla eşleşmesi için WGS84 referanslı ortak bir UTM projeksiyonuna yeniden projeksiyonlandırılır. 1-7 arasındaki MODIS bantlarının yüzey reflektans değerlerine ek olarak, NDSI ve NDVI (Denklem 2.13) girdi değişkenleri (diğer bir deyişle, tahmin

unsurları) olarak kullanılır. Bulutlu, bulut gölgesi, su ve kötü kalite pikseller, ilgili MODIS yardımcı verilerinden elde edilen mekansal maskeler yardımıyla analizlerden çıkarılmıştır.

$$NDVI_{MODIS} = \frac{bant2 - bant1}{bant2 + bant1} \quad (2.13)$$

Referans FKÖ haritaları daha yüksek mekansal çözünürlüklü Landsat 7/8 görüntülerinin ikili sınıflandırılmasıyla elde edilmiştir. Orijinal MODIS ikili kar haritalama algoritmasına eşdeğer olan bu ikili sınıflandırma algoritmasında, $NDSI \geq 0.4$ ve Landsat ETM+ bant 2 reflektans $\geq \%10$ ve bant 4 reflektans $> \%11$ ise, piksel kar olarak etiketlenmiştir (Klein vd. 1998). Bir MODIS pikselinde merkezlenmiş 500 m yarıçaplı dairesel bir alan içindeki karla kaplı Landsat piksellerinin yüzdesi hesaplanarak, her MODIS pikseli için FKÖ değeri elde edilmiştir (Bakınız Şekil 2.7). Çizelge 2.8, analizlerde kullanılan tahminleyici ve tepki değişkenleriyle ilgili ayrıntılı bilgi vermektedir.



Şekil 2.7 Landsat ETM+ görüntülerinden ikili kar haritası üretilmesi.

Çizelge 2.8 DVM modellerinde kullanılan MODIS ve Landsat 7/8 verileri

Tahminleyici değişken olarak kullanılan MODIS verileri	
Bant 1	620-670 nm
Bant 2	841-876 nm
Bant 3	459-479 nm
Bant 4	545-565 nm
Bant 5	1230-1250 nm
Bant 6	1628-1652 nm
Bant 7	2105-2155 nm
NDSI	$(bant4 - bant6) / (bant4 + bant6)$
NDVI	$(bant2 - bant1) / (bant2 + bant1)$
Referans FKÖ haritalarını üretmek için kullanılan ETM+/OLI bantları	
Bant 2/3	0.52-0.60/0.533-0.590 μ m
Bant 4/5	0.77-0.90/0.851-0.879 μ m
Bant 5/6	1.55-1.75/1.566-.1651 μ m

2.5.1. MODIS verisinin ön işleme

MODIS Seviye 1B ürünü, SI bilimsel veri formatında radyometrik açıdan kalibre edilmiş ve geometrik bakımdan konumlandırılmış dünya görüntüsü veri setleri sağlamaktadır. MOD02HKM Seviye 1B ürünü, 500 m mekansal çözünürlükte elektromanyetik spektrumun görünür ve yakın kızıl ötesi kısmında MODIS'in ilk yedi reflektif bantları (yani, 1-7 bantları) için Atmosferüstü (Top of Atmospheric – TOA) radyometrik bilgileri içerir (Xiong vd. 2006). Mart 2000 ile Nisan 2016 arasında Ilgaz Dağlarında çekilen toplamda 13 adet MOD02HKM görüntüsü MODIS Seviye 1'in ve Atmosfer Arşiv ve Dağıtım Sistemi internet sayfasından (<https://ladsweb.modaps.eosdis.nasa.gov>) indirilmiştir (Bakınız Çizelge 2.9) .

Çizelge 2.9 DVM eğitilmesinde ve testinde kullanılan Landsat 7/8 ve MODIS çifti

Görüntü Çiftleri	Görüntü Tarihi	Görüntü Zamanı Landsat/MODIS	ETM+/OLI tile İz/Sıra – İşlenme Seviyesi	Mevcut Piksel Sayısı
Eğitim Veri Seti				
1	07.03.2000	08:19/08:55	177/32 - L1T	3,340
2	23.12.2001	08:15/08:45	177/32 - L1T	9,571
3	02.02.2014	08:28/09:30	177/32 - L1T	15,880
4	18.02.2014	08:28/07:55	177/32 - L1T	12,284
5	04.01.2015	08:27/09:30	177/32 - L1T	5,117
6	25.03.2015	08:26/07:55	177/32 - L1T	14,162
7	15.01.2016	08:28/08:45	177/32 - L1T	14,198
8	28.04.2016	08:26/07:55	177/32 - L1T	14,238
Test Veri Seti				
A	26.12.2002	08:15/08:45	177/32 - L1T	10,796
B	06.04.2005	08:16/08:40	177/32 - L1T	15,015
C	22.01.2007	08:17/08:40	177/32 - L1T	18,189
D	09.03.2015	08:26/07:55	177/32 - L1T	14,916
E	08.02.2016	08:27/09:30	177/32 - L1T	8,579

Tüm MOD02HKM görüntüleri, ilgili Landsat görüntülerinin projeksiyonlarıyla uyuşması için, MODIS Yeniden Projeksiyonlandırma (Dwyer ve Schmidt 2006) kullanılarak WGS84 referanslı ortak bir UTM projeksiyonuna yeniden projeksiyonlandırılmıştır. KKA'nın en uygun tespiti, verilerin fiziksel birimlerle ifade edilmesini gerektirdiğinden dolayı (Hall vd. 1995), SI gösteriminde (yani, 0-32767) geçerli verilerin dinamik aralığı, Toller vd. (2012) tarafından verilen denklem kullanılarak TOA reflektans değerlerine dönüştürülmüştür. Tüm geçersiz (yani, kullanılmayan) SI verileri maskelenmiştir. Daha sonra, her MOD02HKM görüntüsü için NDSI ve NDVI haritaları üretildi. MOD02HKM ve MOD021KM radyans verileri, orijinal MODIS kar ürününde girdi olarak kullanılmıştır (Riggs vd. 2016). Bu nedenle, DVM'den türevli FKÖ haritaları ile MODIS FKÖ ürünleri arasında karşılaştırma yapmak için analizlerde aynı veri kaynakları kullanılmıştır.

Arazi örtüsü bilgisi, Uluslar arası Jeosfer-Biyosfer Programı (The International Geosphere-Biosphere Programme - IGBP) çerçevesinde üretilen 500 m mekansal çözünürlükteki MODIS MCD12Q1 ürününden elde edilmiştir (Friedl vd. 2010). Dobrev ve Klein (2011)'de olduğu gibi MCD12Q1'deki orijinal arazi örtüsü sınıfları sekiz gruba ayrılmıştır ve su pikselleri maskelenmiştir.

MODIS MCD12Q1 ürününden elde edilen arazi örtüsünün doğruluğu, tez çalışması kapsamında yürütülen arazi çalışmalarınca toplanan toplam 387 adet referans yer verisi kullanılarak hata matrisi analizi (Congalton 1991) aracılığıyla değerlendirilmiş olup (Bakınız Çizelge 2.10), ilgili MODIS ürünün genel doğruluğunun %93.3 olduğu tespit edilmiştir.

Çizelge 2.10 Hata Matrisi Analizi (Arazi Kod Açıklamaları: 1: herdem yeşil ormanlar, 2: yaprak dökken ormanlar 3: karışık ormanlar 4: çim ve çalılık alanlar 5: savanalar 6: karışık tarımsal alanlar 7: açık ve seyrek bitki örtüsü 8: daimi sulak alanlar)

Sınıf Kodu	Sınıflandırılan Veri								Satır Toplamı
	1	2	3	4	5	6	7	8	
1	30	0	3	1	0	0	0	0	34
2	0	1	0	0	0	0	0	0	1
3	1	1	16	1	0	0	0	0	19
4	3	7	2	268	3	0	0	0	283
5	0	0	0	1	8	0	0	0	9
6	0	0	0	1	2	37	0	0	40
7	0	0	0	0	0	0	1	0	1
8	0	0	0	0	0	0	0	0	0
Sütun Toplamı	34	9	21	272	13	37	1	0	387

Bulut örtülü pikseller, bulut gölgesi ve buluta yakın pikseller MODIS bulut maskesi ürününden türetilen bir mekansal maske tarafından engellenmiştir (Ackerman vd. 2010).

2.5.2. Landsat 7 ETM+ ve Landsat 8 OLI referanslı FKÖ haritaları

Landsat ETM+'nın Tarama Çizgi Düzelticisi (Scan Line Corrector - SLC), 31 Mayıs 2003'te kalıcı olarak arızalanmış ve görüntü başına piksellerin yaklaşık % 22'sinde tarama yapılmamış ve ETM+ verilerinin bilimsel uygulamalarını ciddi şekilde kısıtlamıştır (Chen vd. 2011). Bu nedenle ETM+ sensörünün SLC arızasından ötürü ilgili her bir görüntüdeki boşluklar, Scaramuzza vd. (2004) tarafından önerilen metodoloji ile doldurulmuştur.

Tüm ilgili Landsat 7 ETM+ ve Landsat 8 OLI görüntüleri Birleşik Devletler Jeoloji Araştırmasının (USGS) (<http://earthexplorer.usgs.gov>) internet sitesinden indirilmiştir. Görüntüler minimum bir bulut örtüsüne sahip olacak şekilde ve seviye 1T (L1T) olarak bilinen, dijital topografya (Wulder vd. 2012) kullanılarak hassas coğrafi kayıt ve ortorektifikasyon içeren analize hazır bir formatta seçilmiştir.

Bütün Landsat 7 ETM+ ve Landsat 8 OLI görüntüleri, MODIS ikili kar örtüsü haritalama algoritmasının ETM+ ve OLI versiyonu kullanılarak ikili kar/kar değil haritalar olarak sınıflandırılmıştır (Hall vd. 1995). 30 m çözünürlüklü Landsat ikili kar haritaları, her MODIS pikselinde bulunan 500 m yarıçap merkezli bir daire içindeki KKA fraksiyonunu hesaplamak için kullanılmıştır. Dobrev ve Klein (2011) ve Painter vd. (2009) tarafından da uygulanan bu metod MODIS'in jeolojik konum belirsizliğinden kaçınmak için tercih edilmiştir (Wolfe 2006).

2.6. Deneysel Tasarım

2.6.1. Örneklem boyutu ve örneklem türü

Eğitilen görüntülerden elde edilen mevcut piksellerin tümü 88,790 gözlemde oluşan tek bir veri setinde birleştirilmiş ve örneklem çerçevesi olarak kullanılmıştır.

DVM modellerinin kesinliği hakkında örneklem boyutunun etkisini incelemek için küçük, orta, büyük olarak üç farklı boyuttaki örnekler, örneklem çerçevesinden edinilmiştir. Küçük, orta ve büyük boyutlu örnekler toplam gözlemlerin sırasıyla %2'sini, %15'ini ve %30'unu içermiştir. Her bir piksel için on tahmin unsuru değişkeninden oluşan eğitim verisi, MOD02HKM 1'den 7'ye kadar olan bantlardan, NDSI'den, NDVI'den ve arazi örtüsü sınıfından elde edilen TOA reflektans değerlerini içermektedir.

Örneklem boyutunun etkisine ek olarak örneklem türünün etkisi de incelenmiştir. İlk olarak, üç farklı boyuttaki örnekler basit rastgele örnekleme ile seçilmiştir. Sonra tabakalı rastgele örnekleme kullanılmıştır. Modellerin herhangi bir FKÖ değerine yanlı olmasını engellemek için 0.0 ile 1.0 arasındaki FKÖ değerleri için 0.1 aralıklarla tabakalama uygulanmıştır. Yukarıda bahsedilen süreç sayesinde altı farklı türde model eğitim seti oluşturulmuş olup, bunların ayrıntıları Çizelge 2.11'da verilmektedir.

Çizelge 2.11 Örneklem boyutuna ve örneklem türüne göre eğitim piksellerinin sayısı (BR: Basit rastgele örnekleme, TR_FKÖ: Fraksiyonel kar örtüsü bakımından tabakalandırılmış rastgele örnekleme)

Örneklem için kullanılabilir toplam piksel (gözlem) sayısı	88,790	
Örnek Boyutu	Örneklem Türü	Örneklenen Piksel Sayısı
Küçük (2%)	BR	1,277
	TR_FKÖ	1,211
Orta (15%)	BR	9,361
	TR_FKÖ	9,308
Büyük (30%)	BR	18,600
	TR_FKÖ	18,790

2.6.2. DVM modellerin eğitimi ve performans ölçütleri

Başarılı bir DVM uygulaması, iki DVM anahtar parametresinin optimum seçimini gerektirir. Bunlar kernel fonksiyonu ve parametre düzenleyicisi C 'dir. Bununla birlikte bu parametrelerin seçimi için benzersiz ve evrensel olarak kabul gören bir yöntem yoktur, bu da genellikle bir temel deneme-yanılma yaklaşımına neden olur (Mountrakis vd. 2011, Yuan ve Lee 2015).

DVM uygulamalarında kullanılan kernel fonksiyonları dört ana kategori altında gruplandırılabilir; doğrusal, polinomial, Radyal Taban Fonksiyonu (Radial Basis Function - RBF) ve sigmoid kernellerdir. UA literatüründe RBF, yani $(e^{-\gamma\|(\mathbf{x}-\mathbf{x}_i)\|^2})$, ve polinom kernel, yani $((\mathbf{x} \cdot \mathbf{y}) + 1)^d$, sıklıkla tercih edilmektedir (Huang vd. 2002b, Pal ve Mather 2005). RBF kerneli, için kernel genişliği γ ve C tanımlanmalıdır. Öte yandan polinom kernel için, polinomun derecesi (d) ve C belirlenmelidir. Bu parametreler için en uygun değerleri seçmek için çapraz doğrulamalı örgülü arama yöntemi Kavzoglu ve Colkesen (2009) tarafından önerildiği gibi kullanılmıştır. Bu yaklaşımda (C, γ) ve (C, d) 'nin katlanarak büyüyen silsilesi bulunan daha kaba bir örgü uygulanmaktadır ve örgüdeki en uygun bölge belirlendiğinde daha hassas bir örgülü araştırma yürütülmektedir. Son olarak en yüksek çapraz doğrulama kesinliği veren parametre çifti

nihai eğitim süreci için kullanılmaktadır. RBF çekirdeği için γ 10^{-3} - 10^3 aralığında seçilirken, C $\{2^{-15}, 2^0, \dots, 2^{15}\}$ ‘teki değerler alınmıştır. Polinom kernel için d derecesi $\{2, 3, 4\}$ setinden değerler alınmıştır. DVM regresyon modellerinin performansı Hataların Kareler Ortalamasının Karekökü (Root Mean Squared Error - RMSE) ve Pearson Korelasyon Katsayısı (R) kullanılarak değerlendirilmiştir:

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^N (\hat{y}_i - y_i)^2}{N}}, \quad (2.14)$$

$$R = \frac{N \sum_{i=1}^N y_i \hat{y}_i - \sum_{i=1}^N y_i \sum_{i=1}^N \hat{y}_i}{\sqrt{N \sum_{i=1}^N y_i^2 - \left(\sum_{i=1}^N y_i \right)^2} \sqrt{N \sum_{i=1}^N \hat{y}_i^2 - \left(\sum_{i=1}^N \hat{y}_i \right)^2}}, \quad (2.15)$$

Burada N toplam gözlem sayısını, y_i , i . referans değerini, ve \hat{y}_i ise i . tahmin edilen değeri belirtmektedir.

3. BULGULAR VE TARTIŞMA

3.1. Eğitim Verisi Üzerinde DVM

DVM modellerin eğitimi boyunca her bir örneklem türündeki veri %70 eğitim ve %30 doğrulama şeklinde iki alt kümeye ayrılmıştır. Her bir örneklem türü için eğitim evresi boyunca test verisi üzerinde R bakımından en yüksek performanslı DVM modeli seçilmiştir. Beş farklı DVM modelinin eğitim performansı kıyaslandığında, oldukça benzer sonuçlar verdiği gözlemlenmektedir. RBF, Doğrusal, 2., 3. ve 4. dereceden polinom modellerin R değerleri sırasıyla 0.9790, 0.9605, 0.9766, 0.9790 ve 0.9784 ile eğitim veri seti üzerine de gayet iyi ve oldukça benzer sonuçlar vermektedir (Bakınız Çizelge 3.1).

Çizelge 3.1 Her bir örneklem türü ve örnek boyutu için modellerin eğitim sürecinde % 30'luk test verisi üzerinde en iyi R değerini veren seçilmiştir. Kalın yazılan R değerleri her bir tür için en iyi eğitim performansını göstermektedir

Kernel	Örneklem türü	Örneklem boyutu	Eğitim		Test	
			RMSE	R	RMSE	R
RBF	BR	Küçük	0.0880	0.9791	0.0914	0.9775
		Orta	0.1236	0.9576	0.1266	0.9549
		Büyük	0.0900	0.9778	0.0947	0.9748
	TR_FKÖ	Küçük	0.1303	0.9516	0.1373	0.9503
		Orta	0.0809	0.9821	0.0890	0.9785
		Büyük	0.0908	0.9772	0.0875	0.9790
Doğrusal	BR	Küçük	0.1213	0.9595	0.1223	0.9595
		Orta	0.1201	0.9601	0.1230	0.9576
		Büyük	0.1208	0.9597	0.1244	0.9561
	TR_FKÖ	Küçük	0.1211	0.9581	0.1311	0.9544
		Orta	0.1228	0.9581	0.1236	0.9583
		Büyük	0.1218	0.9586	0.1195	0.9605
2. Derece Polinom	BR	Küçük	0.0942	0.9760	0.0950	0.9766
		Orta	0.0991	0.9732	0.0995	0.9725
		Büyük	0.0973	0.9740	0.1005	0.9715
	TR_FKÖ	Küçük	0.0956	0.9742	0.1096	0.9686
		Orta	0.1000	0.9723	0.1005	0.9725
		Büyük	0.0973	0.9741	0.0942	0.9759
3. Derece Polinom	BR	Küçük	0.0870	0.9796	0.0907	0.9787
		Orta	0.0919	0.9768	0.0937	0.9755
		Büyük	0.0899	0.9778	0.0942	0.9750
	TR_FKÖ	Küçük	0.0876	0.9783	0.1036	0.9718
		Orta	0.0909	0.9771	0.0914	0.9772
		Büyük	0.0911	0.9771	0.0877	0.9790
4. Derece Polinom	BR	Küçük	0.0867	0.9795	0.0904	0.9784
		Orta	0.0928	0.9767	0.0940	0.9757
		Büyük	0.0950	0.9764	0.0995	0.9732
	TR_FKÖ	Küçük	0.0920	0.9760	0.1051	0.9709
		Orta	0.0920	0.9765	0.0925	0.9766
		Büyük	0.0969	0.9756	0.0940	0.9772

RBF, doğrusal ve 3. dereceden polinom için en iyi eğitim performansları büyük boyutlu eğitim verileriyle elde edilmiştir, FKÖ bakımından tabakalı rastgele örnekleme tarafından örneklendirilmiştir. 2. derece ve 4. derece polinomlar küçük boyutlu veri ile en iyi eğitim performansını vermiş ve basit rastgele örneklemeyle örneklendirilmiştir. Ancak her bir model türü hem örnekleme türüne hem de örnekleme boyutuna göre ayrı ayrı değerlendirildiğinde ilgili RMSE ve R değerleri bakımından önemli bir değişiklik gözlemlenmemiştir. Bu sonuçlar, model oluşturma sürecinde kullanılan eğitim verileri, tahminleyici değişkenler (yani, bağımsız değişkenler) ile bunlara ait tepki değişkeni (yani, bağımlı değişken) arasındaki ilişkiyi yeterince temsil ediyorsa eğitim verisinin boyutu ve örnekleme türünün eğitim evresinde DVM'in tahmin performansı üzerinde etkisi olmadığını göstermektedir.

Model eğitimleri sonucunda elde edilen optimal kernel parametreleri Çizelge 3.2'de verilmiştir.

Çizelge 3.2 Kernel fonksiyonları için belirlenen optimal değerler

Kernel Fonksiyonu	C	γ	R
RBF	260.8576	4.2855	0.9790
Doğrusal	9.1396	-	0.9605
2. Derece Polinom	18.2176	-	0.9766
3. Derece Polinom	0.2500	-	0.9790
4. Derece Polinom	0.0677	-	0.9784

3.2. Test Verisi Üzerinde DVM

Modellerin eğitimi sırasında kullanılmayan bağımsız test görüntüleri, DVM FKÖ modellerinin performansını objektif olarak değerlendirmek için en uygun veri setidir. En iyi eğitim performansına göre Çizelge 3.3'de beş bağımsız test görüntüsü ve birleşik test verisi üzerine DVM'in sonuçları sunulmaktadır. Her biri kalın yazılmış dizi her bir

test setindeki ilgili R ve RMSE deęerlerini gstermektedir. Bu deęerler en iyi gzlemlenen eęitim performansını veren ilgili modelin, model ayarlama parametreleribaz alınarak hesaplanmıřtır.

İlk bakıřta genel bir ıkarım olarak, eęitim ařamasında gzlemlenen, en iyi eęitim performansına sahip DVM modellerinin R deęerleri RBF kernel iin 0.9139 ile 0.9681, doęrusal kernel iin 0.9168 ile 0.9712, 2. derece polinom kernel iin 0.8886 ile 0.9716, 3. derece polinom kernel iin 0.8438 ile 0.9523, 4. derece polinom kernel iin ise 0.8719 ve 0.9524 aralıęında bulunmaktadırdır.

En iyi eęitim performansına sahip DVM modellerinin RMSE deęerleri RBF iin 0.1077 - 0.2825, doęrusal iin 0.0792 - 0.3015, 2. derece polinom iin 0.1105 - 0.2400, 3. derece polinom iin 0.1140 - 0.2723, ve son olarak, 4. derece polinom iin 0.1410 - 0.2502 aralıęında bulunmaktadırdır.

Çizelge 3.3 RBF, Doğrusal, 2. 3. ve 4. Derece Polinom kernel fonksiyonu kullanan DVM modellerinin beş bağımsız test görüntüsü ve toplamda 67.495 pikselden oluşan birleşik test veri seti üzerindeki performansı. Kalın harfle belirtilen satır, en iyi eğitim performansı bakımından ilgili modelin test sonuçlarını göstermektedir (K: küçük, O: orta, B: büyük)

Model	Örneklem türü		A		B		C		D		E		Birleşik	
			RMSE	R	RMSE	R	RMSE	R	RMSE	R	RMSE	R	RMSE	R
RBF	BR	K	0.1927	0.9416	0.0946	0.9706	0.1407	0.9501	0.1020	0.8471	0.1968	0.9081	0.1431	0.9528
		O	0.2350	0.9399	0.1054	0.9688	0.1253	0.9556	0.0953	0.9180	0.1428	0.9374	0.1419	0.9514
		B	0.2910	0.9346	0.1198	0.9678	0.1766	0.9429	0.1082	0.8524	0.2249	0.9073	0.1848	0.9427
	TR FKÖ	K	0.3092	0.9442	0.1358	0.9635	0.1420	0.9516	0.1247	0.9184	0.1535	0.9326	0.1768	0.9389
		O	0.2490	0.8695	0.2099	0.8451	0.3028	0.8021	0.1145	0.8040	0.2393	0.8384	0.2337	0.8714
		B	0.2825	0.9379	0.1212	0.9681	0.1785	0.9431	0.1077	0.8588	0.2196	0.9139	0.1825	0.9457
Doğrusal	BR	K	0.2825	0.9166	0.0923	0.9716	0.1275	0.9541	0.0804	0.9164	0.1448	0.9357	0.1521	0.9399
		O	0.3040	0.9182	0.0951	0.9698	0.1246	0.9561	0.0787	0.9159	0.1432	0.9372	0.1580	0.9355
		B	0.2989	0.9187	0.0937	0.9703	0.1247	0.9560	0.0784	0.9171	0.1429	0.9375	0.1562	0.9372
	TR FKÖ	K	0.3281	0.9232	0.0973	0.9678	0.1246	0.9565	0.0788	0.9147	0.1448	0.9364	0.1659	0.9316
		O	0.3045	0.9147	0.0925	0.9712	0.1282	0.9536	0.0783	0.9188	0.1418	0.9384	0.1583	0.9350
		B	0.3015	0.9168	0.0923	0.9712	0.1268	0.9545	0.0792	0.9182	0.1425	0.9378	0.1573	0.9371
2. Derece Polinom	BR	K	0.2046	0.9380	0.1364	0.9716	0.1701	0.9455	0.1105	0.8886	0.2400	0.8976	0.1693	0.9524
		O	0.2516	0.9330	0.1145	0.9700	0.1756	0.9452	0.0997	0.8757	0.2569	0.8827	0.1787	0.9446
		B	0.2423	0.9268	0.1135	0.9717	0.1803	0.9412	0.0975	0.8855	0.2631	0.8734	0.1787	0.9442
	TR FKÖ	K	0.2716	0.9366	0.1257	0.9654	0.1985	0.9324	0.1022	0.8495	0.3314	0.7569	0.2054	0.9253
		O	0.2377	0.9272	0.1142	0.9720	0.1737	0.9401	0.0918	0.8853	0.2427	0.8734	0.1715	0.9446
		B	0.2298	0.9306	0.1192	0.9715	0.1788	0.9433	0.1040	0.8876	0.2597	0.8819	0.1766	0.9475
3. Derece Polinom	BR	K	0.2664	0.9422	0.1655	0.9573	0.2070	0.9352	0.1317	0.8720	0.2517	0.8906	0.2022	0.9439
		O	0.2869	0.9421	0.1456	0.9526	0.2089	0.9279	0.1174	0.8290	0.2353	0.8999	0.1993	0.9354
		B	0.3063	0.9365	0.1450	0.9532	0.2115	0.9283	0.1120	0.8332	0.2487	0.8916	0.2058	0.9327
	TR FKÖ	K	0.3826	0.9317	0.1622	0.9271	0.2264	0.9185	0.1192	0.7911	0.2363	0.8910	0.2309	0.8972
		O	0.2969	0.9387	0.1381	0.9552	0.1953	0.9345	0.1145	0.8163	0.2133	0.9116	0.1931	0.9354
		B	0.2723	0.9396	0.1498	0.9523	0.2163	0.9253	0.1140	0.8438	0.2360	0.9043	0.1985	0.9387
4. Derece Polinom	BR	K	0.2502	0.9432	0.2027	0.9524	0.2163	0.9330	0.1410	0.8719	0.2498	0.8882	0.2100	0.9428
		O	0.2920	0.9344	0.1889	0.9390	0.2694	0.8980	0.1187	0.8353	0.2585	0.8873	0.2297	0.9261
		B	0.3294	0.9294	0.2022	0.9409	0.2568	0.9157	0.1337	0.8476	0.2841	0.8775	0.2417	0.9294
	TR FKÖ	K	0.3365	0.9270	0.1711	0.9113	0.2219	0.9077	0.1292	0.7639	0.2641	0.8447	0.2246	0.8952
		O	0.3004	0.9343	0.1429	0.9540	0.1981	0.9299	0.1137	0.8304	0.2139	0.9077	0.1955	0.9351
		B	0.2899	0.9356	0.1873	0.9468	0.2580	0.9173	0.1347	0.8461	0.2664	0.9022	0.2285	0.9375

DVM modellerin performansları sırasıyla Çizelge 3.4’de verildiği üzere eğitim boyunca bilgisayar açısından vurgulanan hesaba dayalı verimlilik bakımından değerlendirildiğinde, hem model oluşturmanın karmaşıklığındaki hem de eğitim verisindeki artışın eğitim zamanındaki bir artışla sonuçlandığı gözlemlenmektedir. Eğitim verisinin boyutunun küçük olduğu yerde seçilen RBF modeli için ortalama eğitim zamanı 278.79 saniyedir. Büyük boyutlu veri ile eğitimi yapılan 3. dereceden polinom modelinin eğitimi için ortalama gerekli zaman 106,014.65 saniyedir (Çizelge 3.3).

Bu çalışmadaki mevcut güç Intel Core i7 3537U 2.00 GHz işlemcili ve 6 GB RAM’i olan bir bilgisayar tarafından sağlanmaktadır.

Çizelge 3.4 DVM modellerinin eğitimi boyunca saniye bazında geçirilen ortalama CPU zamanları

Kernel Fonksiyonu	Örneklem Boyutu		
	Küçük	Orta	Büyük
RBF	278.79	2,299.50	8,457.31
Doğrusal	10,374.62	49,335.69	100,794.23
2. derece Polinom	7,969.15	46,327.25	96,512.34
3. derece Polinom	10,040.63	42,625.48	106,014.65
4. derece Polinom	8,905.60	45,536.91	92,053.59

Çizelge 3.5’te sunulan sonuçlara göre MOD10A1 ürünü test veri setlerindeki en zayıf performansı vermektedir, buna karşın FKÖ haritalaması performanslarında DVM modelleri arasında belirgin farklar görülmemektedir. Ancak üretilen modellerin performansında ve aynı şekilde MOD10A1 ürününün performansında istatistiksel bakımdan önemli farklılıklar olup olmadığına karar vermek için RANOVA (Davis 2002) yapılmakta ve aşağıdaki hipotezler her bir performans ölçümü için ayrı ayrı test edilmektedir:

Çizelge 3.5 DVM ve MOD10A1’den elde edilen FKÖ değerleri için bağımsız test veri setlerine ait RMSE ve R değerleri

Test Set	RBF		Doğrusal		2. derece polinom		3. derece polinom		4. derece polinom		MOD10A1	
	RMSE	R	RMSE	R	RMSE	R	RMSE	R	RMSE	R	RMSE	R
A	0.2825	0.9379	0.3015	0.9168	0.2046	0.9380	0.2723	0.9396	0.2502	0.9432	0.5221	0.6870
B	0.1212	0.9681	0.0923	0.9712	0.1364	0.9716	0.1498	0.9523	0.2027	0.9524	0.2652	0.8461
C	0.1785	0.9431	0.1268	0.9545	0.1701	0.9455	0.2163	0.9253	0.2163	0.9330	0.2738	0.8478
D	0.1077	0.8588	0.0792	0.9182	0.1105	0.8886	0.1140	0.8438	0.1410	0.8719	0.1836	0.7089
E	0.2196	0.9139	0.1425	0.9378	0.2400	0.8976	0.2360	0.9043	0.2498	0.8882	0.3803	0.6885
Birleşik	0.1825	0.9457	0.1573	0.9371	0.1693	0.9524	0.1985	0.9387	0.2100	0.9428	0.3245	0.8270

$$H_0 : M_{Model_i} = M_{Model_j}$$

$$H_1 : M_{Model_i} \neq M_{Model_j}$$

Burada, M_{Model_i} , karşılaştırmalarda kullanılan ilişkili modelin (yani DVM ya da MOD10A1) performans ölçütünün (yani R ve RMSE) beklenen değerini göstermektedir. RANOVA boyunca $\alpha = 0.05$ önem seviyesinde Fisher'in En Az Anlamlı Fark (Least Significant Difference - LSD) (Dodge 2008) testi de istatistiksel bakımdan farklı modelleri tanımlamak için uygulanmıştır. Sonuçlar Çizelge 3.6 ve Çizelge 3.7'da gösterilmektedir.

Çizelge 3.6 RMSE değerleri bakımından RANOVA test sonuçlarının kıyaslaması (*, ortalama farkın $\alpha = 0.05$ önem seviyesinde istatistiksel açıdan önemli olduğunu göstermektedir)

RMSE _i	RMSE _j	Ortalama Fark RMSE _i - RMSE _j	LSD testinin p değeri
RBF	Doğrusal	0.0321	0.057
	2. derece Polinom	0.0102	0.515
	3. derece Polinom	-0.0158	0.069
	4. derece Polinom	-0.0297	0.102
	MOD10A1	-0.1429	0.002*
Doğrusal	RBF	-0.0321	0.057
	2. derece Polinom	-0.0219	0.445
	3. derece Polinom	-0.0479	0.047
	4. derece Polinom	-0.0617	0.053
	MOD10A1	-0.1750	0.000*
2. derece Polinom	RBF	-0.0102	0.515
	Doğrusal	0.0219	0.445
	3. derece Polinom	-0.0260	0.067
	4. derece Polinom	-0.0399	0.003*
	MOD10A1	-0.1531	0.007*
3. derece Polinom	RBF	0.0158	0.069
	Doğrusal	0.0479	0.047*
	2. derece Polinom	0.0260	0.067
	4. derece Polinom	-0.0399	0.237
	MOD10A1	-0.1531	0.006*
4. derece Polinom	RBF	0.0297	0.102
	Doğrusal	0.0617	0.053
	2. derece Polinom	0.0399	0.003*
	3. derece Polinom	0.0139	0.237
	MOD10A1	-0.1133	0.022*
MOD10A1	RBF	0.1429	0.002*
	Doğrusal	0.1750	0.00*
	2. derece Polinom	0.1531	0.007*
	3. derece Polinom	0.1271	0.006*
	4. derece Polinom	0.1133	0.022*

Çizelge 3.7 R değerleri bakımından RANOVA test sonuçlarının kıyaslaması (*, ortalama farkın $\alpha = 0.05$ önem seviyesinde istatistiksel açıdan önemli olduğunu göstermektedir)

R_i	R_j	Ortalama Fark $R_i - R_j$	LSD Testinin p Değeri
RBF	Doğrusal	-0.0113	0.370
	2. derece Polinom	-0.0044	0.504
	3. derece Polinom	0.0106	0.016*
	4. derece Polinom	0.0060	0.347
	MOD10A1	0.1604	0.002*
Doğrusal	RBF	0.0113	0.370
	2. derece Polinom	0.0070	0.514
	3. derece Polinom	0.0219	0.166
	4. derece Polinom	0.0174	0.209
	MOD10A1	0.1717	0.001*
2. derece Polinom	RBF	0.0044	0.016*
	Doğrusal	-0.0070	0.166
	3. derece Polinom	0.0150	0.102
	4. derece Polinom	0.0104	0.466
	MOD10A1	0.1647	0.001*
3. derece Polinom	RBF	-0.0106	0.016*
	Doğrusal	-0.0219	0.166
	2. derece Polinom	-0.0150	0.102
	4. derece Polinom	-0.0046	0.466
	MOD10A1	0.1498	0.003*
4. derece Polinom	RBF	-0.0060	0.347
	Doğrusal	-0.0174	0.209
	2. derece Polinom	-0.0104	0.031*
	3. derece Polinom	0.0046	0.466
	MOD10A1	0.1544	0.002*
MOD10A1	RBF	-0.1604	0.002*
	Doğrusal	-0.1717	0.001*
	2. derece Polinom	-0.1647	0.001*
	3. derece Polinom	-0.1498	0.003*
	4. derece Polinom	-0.1544	0.002*

Çiftler halinde yapılan karşılaştırmaların sonuçları RBF, doğrusal ve 2., 3. ve 4. dereceden Polinom modelleri arasında istatistiki açıdan önemli bir fark olmadığını ortaya çıkarmaktadır. Fakat bunlar bütün test veri setlerindeki MOD10A1 ürününden daha üstün durumdadır.

4. SONUÇLAR

Kar örtüsünün sürekli olarak izlenmesi, hem yerel hem de küresel ölçekte yeryüzünün hidrolojisi, meteorolojisi ve iklimindeki değişiklikleri izlemek açısından çok büyük öneme sahiptir. Bu çalışmada, FKÖ haritalaması için parametrik olmayan DVM yönteminin uygunluğu araştırılmıştır. NDSI, NDVI ve 1-7 MODIS bantlarının yüzey reflektans değerleri tahminleyici değişkenler olarak kullanılırken, referans FKÖ değerleri daha yüksek mekansal çözünürlüklü Landsat 7/8 verilerinden üretilip, tepki değişkeni olarak kullanılmıştır.

Bağımsız test görüntüleri üzerinde farklı konfigürasyonlara sahip DVM modellerinin performanslarının, MODIS'in kendi FKÖ ürünü olan MOD10A1'e göre daha iyi olduğu gözlemlenmiştir. DVM'lerin geleneksel istatistiksel yöntemlere göre avantajı, bir dizi tahmin değişkeni ve bir tepki arasındaki temel ilişkiyle ilgili herhangi bir önsel varsayımda bulunmamasından kaynaklanır. Ek olarak, eğitilen DVM modeller FKÖ değerlerini verimli ve hızlı bir şekilde hesaplayabilmektedir. DVM modellerin eğitim süreci yalnızca iki parametreye bağlıdır; kernel fonksiyonu ve C 'nin seçimi, bu nedenle model oluşturma süreci oldukça basittir.

Her türlü ölçüm cihazındaki (bizim çalışmamızda MODIS) son teknolojik gelişmeler, analiz etmek için devasa ve sürekli büyüyen bir bilgi kaynağı (yani, büyük veriler) yaratmaktadır. Bu durum biz bilim insanlarını, makine öğrenme konularını veri madenciliği ve model optimizasyonu alanlarında kullanmak üzere konum almamıza, ve yakın gelecekte Yöneylem Araştırmaları (Operartional Research - YA) alanındaki çalışmalarımızı geliştirmeye zorlamaktadır. Bu araştırma, UA'da ilk kez MODIS verilerinden FKÖ haritalaması için DVM'in uygulanabilirliğini ve kullanımını değerlendirmede katkı sağlamaktadır. DVM modeller ile MODIS verilerinden FKÖ haritalarının üretilmesi süreci; *istatistiksel analiz, matematiksel modelleme ve karar verme teorisi* gibi matematik bilimlerinden tekniklerin kullanılmasını içermektedir. Bu nedenle, makine öğrenme ile FKÖ haritalama yöntemlerinin geliştirilmesi, UA alanında bulunan açık bir YA problemi olarak düşünülebilir. DVM kullanarak FKÖ haritalamadaki yaklaşımımız, kesinlikle bu alanındaki umut verici ilerlemelerden biri olacaktır.

KAYNAKLAR

- Ackerman, S., Frey, R., Strabala, K., Liu, Y., Gumley, L., Baum, B. and Menzel, P., 2010. *Discriminating clear-sky from cloud with MODIS: Algorithm theoretical basis document (MOD35)*. Paper presented at the MODIS Cloud Mask Team, Cooperative Institute for Meteorological Satellite Studies, University of Wisconsin.
- Akyurek, Z., Hall, D. K., Riggs, G. A. and Sensoy, A., 2010. Evaluating the utility of the ANSA blended snow cover product in the mountains of eastern Turkey. *International Journal of Remote Sensing*, 31(14), 3727-3744. doi:10.1080/01431161.2010.483484
- Aydinozu, D., Ibret, U. and Aydin, M., 2011. *Analysis of Terrain Usage in Kastamonu-Ilgaz Mountain Natural Park*. Paper presented at the International Symposium on Environmental Protection and Planning: Geographic Information Systems (GIS) and Remote Sensing (RS) Applications (ISEPP), İzmir - TURKEY.
- Beniston, M., 2003. Climatic Change in Mountain Regions: A Review of Possible Impacts. In H. F. Diaz (Ed.), *Climate Variability and Change in High Elevation Regions: Past, Present & Future* (pp. 5-31). Dordrecht, Netherlands: Springer.
- Brown, R. D., Brasnett, B. and Robinson, D., 2003. Gridded North American monthly snow depth and snow water equivalent for GCM evaluation. *Atmosphere-Ocean*, 41(1), 1-14. doi:10.3137/ao.410101
- Brown, R. D. and Goodison, B. E., 1996. Interannual variability in reconstructed Canadian snow cover, 1915-1992. *Journal of Climate*, 9(6), 1299-1318.
- Bruzzone, L. and Melgani, F., 2005. Robust multiple estimator systems for the analysis of biophysical parameters from remotely sensed data. *IEEE Transactions on Geoscience and Remote Sensing*, 43(1), 159-174.
- Campbell, C. and Ying, Y., 2011. *Learning with Support Vector Machines*: Morgan & Claypool Publishers.
- Chen, J., Zhu, X., Vogelmann, J. E., Gao, F. and Jin, S., 2011. A simple and effective method for filling gaps in Landsat ETM+ SLC-off images. *Remote Sensing of Environment*, 115(4), 1053-1064. doi:<https://doi.org/10.1016/j.rse.2010.12.010>
- Clark, M. P., Slater, A. G., Barrett, A. P., Hay, L. E., McCabe, G. J., Rajagopalan, B. and Leavesley, G. H., 2006. Assimilation of snow covered area information into hydrologic and land-surface models. *Advances in Water Resources*, 29(8), 1209-1221.
- Cline, D. W., Bales, R. C. and Dozier, J., 1998. Estimating the spatial distribution of snow in mountain basins using remote sensing and energy balance modeling. *Water Resources Research*, 34(5), 1275-1285.

- Congalton, R. G., 1991. A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data. *Remote Sensing of Environment*, 37, 35-46.
- Davis, C. S., 2002. *Statistical methods for the analysis of repeated measurements*: Springer Science & Business Media.
- Dietz, A. J., Kuenzer, C., Gessner, U. and Dech, S., 2012. Remote sensing of snow – a review of available methods. *International Journal of Remote Sensing*, 33(13), 4094-4134. doi:10.1080/01431161.2011.640964
- Dobreva, I. D. and Klein, A. G., 2011. Fractional snow cover mapping through artificial neural network analysis of MODIS surface reflectance. *Remote Sensing of Environment*, 115(12), 3355-3366.
- Dodge, Y., 2008. *The Concise Encyclopedia of Statistics*. New York: Springer.
- Dozier, J., 1992. Opportunities to improve hydrologic data. *Reviews of Geophysics*, 30(4), 315-331.
- Drucker, H., Burges, C. J., Kaufman, L., Smola, A. and Vapnik, V., 1997a. Support vector regression machines. *Advances in Neural Information Processing Systems*, 9, 155-161.
- Drucker, H., Burges, C. J. C., Kaufman, L., Smola, A. and Vapnik, V., 1997b. Support Vector Regression Machines. In M. C. Mozer, M. I. Jordan, & T. Petsche (Eds.), *Advances in Neural Information Processing Systems 9* (Vol. 9, pp. 155-161). USA: The MIT Press.
- Dwyer, J. and Schmidt, G., 2006. The MODIS Reprojection Tool. In J. J. Qu, W. Gao, M. Kafatos, R. E. Murphy, & V. V. Salomonson (Eds.), *Earth Science Satellite Remote Sensing: Vol. 2: Data, Computational Processing, and Tools* (pp. 162-177). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Fisher, W. D., Camp, T. K. and Krzhizhanovskaya, V. V., 2017. Anomaly detection in earth dam and levee passive seismic data using support vector machines and automatic feature selection. *Journal of Computational Science*.
- Foody, G. M. and 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.
- Foster, J., Liston, G., Koster, R., Essery, R., Behr, H., Dumenil, L., Versegny, D., Thompson, S., Pollard, D. and Cohen, J., 1996. Snow cover and snow mass intercomparisons of general circulation models and remotely sensed datasets. *Journal of Climate*, 9(2), 409-426.
- Friedl, M. A., Sulla-Menashe, D., Tan, B., Schneider, A., Ramankutty, N., Sibley, A. and Huang, X., 2010. MODIS Collection 5 global land cover: Algorithm refinements and characterization of new datasets. *Remote Sensing of Environment*, 114(1), 168-182.

- Gafurov, A. and Bárdossy, A., 2009. Cloud removal methodology from MODIS snow cover product. *Hydrology and Earth System Sciences*, 13, 1361-1373.
- Goward, S. N., Masek, J. G., Williams, D. L., Irons, J. R. and Thompson, R., 2001. The Landsat 7 mission: Terrestrial research and applications for the 21st century. *Remote Sensing of Environment*, 78(1), 3-12.
- Guide, A.-U., 2010. ATCOR-2/3 User Guide (Ver. 7.1). Web Erişim tarihi:
- Hall, D. K. and Martinec, J., 1985. *Remote Sensing of Ice and Snow*. NY, USA: Chapman and Hall.
- Hall, D. K., Riggs, G. A. and Salomonson, V. V., 1995. Development of Methods for Mapping Global Snow Cover Using Moderate Resolution Imaging Spectroradiometer Data. *Remote Sensing of Environment*, 54, 127-140.
- Hall, D. K., Riggs, G. A. and Salomonson, V. V., 2006. MODIS Snow and Sea Ice Products. In J. J. Qu, W. Gao, M. Kafatos, R. E. Murphy, & V. V. Salomonson (Eds.), *Earth Science Satellite Remote Sensing. Volume 1: Science and Instruments* (pp. 154-181). Beijing: Springer.
- Hall, D. K., Riggs, G. A., Salomonson, V. V., DiGirolamo, N. E. and Bayr, K. J., 2002. MODIS snow-cover products. *Remote Sensing of Environment*, 83, 181-194.
- Hartman, M. D., Baron, J. S., Lammers, R. B., Cline, D. W., Band, L. E., Liston, G. E. and Tague, C., 1999. Simulations of snow distribution and hydrology in a mountain basin. *Water Resources Research*, 35(5), 1587-1603.
- Haykin, S., 2009. *Neural Networks and Learning Machines* (3rd ed.). New Jersey: Prentice Hall, Pearson Education.
- Hongen, Z. and Suhong, L., 2004, 20-24 Sept. 2004. *Moderate fraction snow mapping in Tibetan Plateau*. Paper presented at the Geoscience and Remote Sensing Symposium, 2004. IGARSS '04. Proceedings. 2004 IEEE International.
- Hosaka, M., Nohara, D. and Kitoh, A., 2005. Changes in snow cover and snow water equivalent due to global warming simulated by a 20km-mesh global atmospheric model. *Sola*, 1, 93-96.
- Huang, C., Davis, L. and Townshend, J., 2002a. An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23(4), 725-749.
- Huang, C., Davis, L. S. and Townshend, J. R. G., 2002b. An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23(4), 725-749. doi:10.1080/01431160110040323
- Hüsler, F., Jonas, T., Wunderle, S. and Albrecht, S., 2012. Validation of a modified snow cover retrieval algorithm from historical 1-km AVHRR data over the European Alps. *Remote Sensing of Environment*, 121, 497-515.

- Kaheil, Y. H., Rosero, E., Gill, M. K., McKee, M. and Bastidas, L. A., 2008. Downscaling and forecasting of evapotranspiration using a synthetic model of wavelets and support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 46(9), 2692-2707.
- Karnieli, A., Ben-Dor, E., Bayarjargal, Y. and Lugasi, R., 2004. Radiometric saturation of Landsat-7 ETM+ data over the Negev Desert (Israel): problems and solutions. *International Journal of Applied Earth Observation and Geoinformation*, 5(3), 219-237.
- Kavzoglu, T. and 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.
- Klein, A. G. and Barnett, A. C., 2003. Validation of daily MODIS snow cover maps of the Upper Rio Grande River Basin for the 2000–2001 snow year. *Remote Sensing of Environment*, 86(2), 162-176.
- Klein, A. G., Hall, D. K. and Riggs, G. A., 1998. Improving snow cover mapping in forests through the use of a canopy reflectance model. *Hydrological Processes*, 12(10), 1723-1744.
- Kumar, D., Meghwani, S. S. and Thakur, M., 2016. Proximal support vector machine based hybrid prediction models for trend forecasting in financial markets. *Journal of Computational Science*, 17, Part 1, 1-13.
- Kuter, N., 2008. Evaluation of Ilgaz Mountain National Park in Terms of Forest Landscape and Aesthetics. *Turkish Journal of Forestry*, 1, 36-47.
- Kuter, N. and Kuter, S., 2016, 23-26 May, 2016. *Binary Snow Mapping in Kurşunlu Forest Sub-District by Using Support Vector Machines*. Paper presented at the 4th International Geography Symposium - GEOMED 2016, Antalya, Turkey.
- Latenser, M. and Schneebeli, M., 2003. Long-term snow climate trends of the Swiss Alps (1931–99). *International Journal of Climatology*, 23(7), 733-750.
- Lehning, M., Völksch, I., Gustafsson, D., Nguyen, T. A., Stähli, M. and Zappa, M., 2006. ALPINE3D: a detailed model of mountain surface processes and its application to snow hydrology. *Hydrological Processes*, 20(10), 2111-2128.
- Luojus, K. P., Pulliainen, J. T., Metsamaki, S. J. and Hallikainen, M. T., 2007. Snow-covered area estimation using satellite radar wide-swath images. *IEEE Transactions on Geoscience and Remote Sensing*, 45(4), 978-989.
- Malnes, E. and Guneriussen, T., 2002. *Mapping of snow covered area with Radarsat in Norway*. Paper presented at the Geoscience and Remote Sensing Symposium, 2002. IGARSS'02. 2002 IEEE International.
- Marty, C., 2008. Regime shift of snow days in Switzerland. *Geophysical Research Letters*, 35(12), L12501.

- Mattera, D. and Haykin, S., 1999. Support vector machines for dynamic reconstruction of a chaotic system. In S. Bernhard, J. C. B. Christopher, & J. S. Alexander (Eds.), *Advances in Kernel Methods - Support Vector Learning* (pp. 211-241). Cambridge: MIT Press.
- Metsämäki, S., Vepsäläinen, J., Pulliainen, J. and Sucksdorff, Y., 2002. Improved linear interpolation method for the estimation of snow-covered area from optical data. *Remote Sensing of Environment*, 82(1), 64-78.
- Mountrakis, G., Im, J. and Ogole, C., 2011. Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), 247-259.
- Mustaffa, Z., Yusof, Y. and Kamaruddin, S. S., 2014. Enhanced artificial bee colony for training least squares support vector machines in commodity price forecasting. *Journal of Computational Science*, 5(2), 196-205.
- Müller, K.-R., Smola, A. J., Rätsch, G., Schölkopf, B., Kohlmorgen, J. and Vapnik, V., 1997. Predicting time series with support vector machines. In W. Gerstner, A. Germond, M. Hasler, & J.-D. Nicoud (Eds.), *Artificial Neural Networks — ICANN'97: 7th International Conference Lausanne, Switzerland, October 8–10, 1997 Proceedings* (pp. 999-1004). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Painter, T. H., Dozier, J., Roberts, D. A., Davis, R. E. and Green, R. O., 2003. Retrieval of subpixel snow-covered area and grain size from imaging spectrometer data. *Remote Sensing of Environment*, 85(1), 64-77.
- Painter, T. H., Rittger, K., McKenzie, C., Slaughter, P., Davis, R. E. and Dozier, J., 2009. Retrieval of subpixel snow covered area, grain size, and albedo from MODIS. *Remote Sensing of Environment*, 113(4), 868-879.
- Pal, M. and Mather, P., 2005. Support vector machines for classification in remote sensing. *International Journal of Remote Sensing*, 26(5), 1007-1011.
- Parajka, J. and Blöschl, G., 2008. Spatio-temporal combination of MODIS images—potential for snow cover mapping. *Water Resources Research*, 44(3), 1-13.
- Poon, S. K. and Valeo, C., 2006. Investigation of the MODIS snow mapping algorithm during snowmelt in the northern boreal forest of Canada. *Canadian Journal of Remote Sensing*, 32(3), 254-267.
- Qu, J. J., Gao, W., Kafatos, M., Murphy, R. E. and Salomonson, V. V., 2006. *Earth Science Satellite Remote Sensing. Volume 1: Science and Instruments*. Beijing: Springer.
- Rango, A. and Martinec, J., 1979. Application of a snowmelt-runoff model using Landsat data. *Hydrology Research*, 10(4), 225-238.

- Richards, J. A. and Jia, X., 2006. *Remote sensing digital image analysis: An introduction* (4th ed.). Germany: Springer.
- Riggs, G. A., Hall, D. K. and Román, M. O., 2016. MODIS Snow Products Collection 6 User Guide. Web adresi: http://modis-snow-ice.gsfc.nasa.gov/uploads/C6_MODIS_Snow_User_Guide.pdf, Erişim tarihi: 10.10.2017.
- Riggs, G. A., Hall, D. K. and Salomonson, V. V., 2006. MODIS Snow Products User Guide to Collection 5. Web adresi: http://modis-snow-ice.gsfc.nasa.gov/uploads/sug_c5.pdf, Erişim tarihi: 10.10.2017.
- Rodell, M. and Houser, P., 2004. Updating a land surface model with MODIS-derived snow cover. *Journal of Hydrometeorology*, 5(6), 1064-1075.
- Romanov, P., Tarpley, D., Gutman, G. and Carroll, T., 2003. Mapping and monitoring of the snow cover fraction over North America. *Journal of Geophysical Research: Atmospheres*, 108(D16).
- Rosenthal, W. and Dozier, J., 1996. Automated mapping of montane snow cover at subpixel resolution from the Landsat Thematic Mapper. *Water Resources Research*, 32(1), 115-130.
- Roy, D. P., Wulder, M., Loveland, T. R., Woodcock, C., Allen, R., Anderson, M., Helder, D., Irons, J., Johnson, D. and Kennedy, R., 2014. Landsat-8: Science and product vision for terrestrial global change research. *Remote Sensing of Environment*, 145, 154-172.
- Salomonson, V. V. and Appel, I., 2004. Estimating fractional snow cover from MODIS using the normalized difference snow index. *Remote Sensing of Environment*, 89, 351-360.
- Salomonson, V. V. and Appel, I., 2006. Development of the Aqua MODIS NDSI Fractional Snow Cover Algorithm and Validation Results. *IEEE Transactions on Geoscience and Remote Sensing*, 44, 1747-1756.
- Salomonson, V. V., Barnes, W., Maymon, P. W., Montgomery, H. E. and Ostrow, H., 1989. MODIS: advanced facility instrument for studies of the Earth as a system. *Geoscience and Remote Sensing, IEEE Transactions on*, 27, 145-153.
- Scaramuzza, P., Micijevic, E. and Chander, G., 2004. SLC-off Gap-Filled Products Gap-Fill Algorithm Methodology Phase 2 Gap-Fill Algorithm. *US Geological Survey Earth Resources Observation and Science (EROS) Center*.
- Shamir, E. and Georgakakos, K. P., 2006. Distributed snow accumulation and ablation modeling in the American River basin. *Advances in Water Resources*, 29(4), 558-570.
- Siljamo, N. and Hyvärinen, O., 2011. New geostationary satellite-based snow-cover algorithm. *Journal of Applied Meteorology and Climatology*, 50(6), 1275-1290.

- Sirguey, P., Mathieu, R. and Arnaud, Y., 2009. Subpixel monitoring of the seasonal snow cover with MODIS at 250 m spatial resolution in the Southern Alps of New Zealand: Methodology and accuracy assessment. *Remote Sensing of Environment*, 113(1), 160-181.
- Smola, A. J. and Schölkopf, B., 2004. A tutorial on support vector regression. *Statistics and Computing*, 14(3), 199-222.
- Tekeli, A. E., Akyürek, Z., Şorman, A. A., Şensoy, A. and Şorman, Ü., 2005. Using MODIS snow cover maps in modeling snowmelt runoff process in the eastern part of Turkey. *Remote Sensing of Environment*, 97, 216-230.
- Toller, G. N., Isaacman, A., Kuyper, J., Geng, Z. and Xiong, J., 2012. *MODIS Level 1B Product User's Guide: For Level 1B Version 6.1.14 (Terra) and Version 6.1.17 (Aqua)*. Greenbelt: NASA/Goddard Space Flight Center.
- URL1. Web adresi: <http://ankaraobm.ogm.gov.tr/ilgazOIM/Sayfalar/default.aspx>, Erişim tarihi: 20.07.2017.
- URL2. Web adresi: https://support.hdfgroup.org/release4/doc/UG_PDF.pdf, Erişim tarihi: 10.10.2017.
- URL3. Web adresi: <http://edhs1.gsfc.nasa.gov/waisdata/sdp/pdf/tp17050001.pdf>, Erişim tarihi: 10.10.2017.
- URL4. Web adresi: https://modis.gsfc.nasa.gov/data/atbd/atbd_mod28_v3.pdf, Erişim tarihi: 26.07.2017.
- URL5. Web adresi: <https://landsat.usgs.gov/what-are-band-designations-landsat-satellites>, Erişim tarihi: 27.07.2017.
- Vapnik, V. N., 1995. *The Nature of Statistical Learning Theory*: Springer Heidelberg.
- Verbeiren, S., Eerens, H., Piccard, I., Bauwens, I. and Van Orshoven, J., 2008. Sub-pixel classification of SPOT-VEGETATION time series for the assessment of regional crop areas in Belgium. *International Journal of Applied Earth Observation and Geoinformation*, 10(4), 486-497.
- Vermote, E. F., Kotchenova, S. Y. and Ray, J. P., 2011. MODIS Surface Reflectance User's Guide (Ver. 1.3). Web adresi: http://modis-sr.ltdri.org/guide/MOD09_UserGuide_v1_3.pdf, Erişim tarihi: 10.10.2017.
- Vikhamar, D. and Solberg, R., 2003. Snow-cover mapping in forests by constrained linear spectral unmixing of MODIS data. *Remote Sensing of Environment*, 88(3), 309-323.
- Wang, X., Xie, H. and Liang, T., 2008. Evaluation of MODIS snow cover and cloud mask and its application in Northern Xinjiang, China. *Remote Sensing of Environment*, 112(4), 1497-1513.

- Wolfe, R. E., 2006. MODIS Geolocation. In J. J. Qu, W. Gao, M. Kafatos, R. E. Murphy, & V. V. Salomonson (Eds.), *Earth Science Satellite Remote Sensing. Volume 1: Science and Instruments* (pp. 50-73). Beijing: Springer.
- Wulder, M. A., Masek, J. G., Cohen, W. B., Loveland, T. R. and Woodcock, C. E., 2012. Opening the archive: How free data has enabled the science and monitoring promise of Landsat. *Remote Sensing of Environment*, 122, 2-10.
- Xiong, X., Isaacman, A. and Barnes, W., 2006. MODIS Level-1B Products. In J. Qu, W. Gao, M. Kafatos, R. Murphy, & V. Salomonson (Eds.), *Earth Science Satellite Remote Sensing* (pp. 33-49): Springer Berlin Heidelberg.
- Xu, L., Niu, R. and Penga, L., 2008. *Snow Cover Area Changing Analysis over Tibetan Plateau with MODIS and ASTER Data*. Paper presented at the XXI ISPRS Congress, Beijing, China.
- Yuan, F.-C. and Lee, C.-H., 2015. Using least square support vector regression with genetic algorithm to forecast beta systematic risk. *Journal of Computational Science*, 11, 26-33.
- Zhang, T., 2005. Influence of the seasonal snow cover on the ground thermal regime: An overview. *Reviews of Geophysics*, 43(4), 1-23.
- Zheng, S., Shi, W.-z., Liu, J. and Tian, J., 2008. Remote sensing image fusion using multiscale mapped LS-SVM. *IEEE Transactions on Geoscience and Remote Sensing*, 46(5), 1313-1322.
- Zhu, J., Shi, J. and Wang, Y., 2012. Subpixel snow mapping of the Qinghai-Tibet Plateau using MODIS data. *International Journal of Applied Earth Observation and Geoinformation*, 18, 251-262.

EKLER

EK 1 MATLAB Programında Uydu Görüntülerinden Eğitim ve Test Veri Setlerinin Oluşturulması İçin Kullanılan Fonksiyon

```
function y = fsceextract
```

```
% Author: Bora Berkay ÇİFTÇİ  
% Date : Şubat 2017
```

```
% GET THE ARCGIS SHAPE FILE IN WHICH POINTS ARE STORED  
CurrentFolder = pwd;  
[FileName1,PathName1] = uigetfile('*.shp', 'SELECT THE MOD02 POINT SHAPE  
FILE');  
cd(PathName1);  
S = shaperead(FileName1);  
dimensions = size(S);  
row=dimensions(1);  
% column=dimensions(2);  
  
XX=[S(:).X]; % X & Y COORDINATES OF POINTS IN THE SHAPE FILE  
YY=[S(:).Y];
```

```
% GET THE MODIS FSC IMAGE  
[FileName2,PathName2] = uigetfile('*.tif', 'SELECT THE MODIS FSC IMAGE');  
cd(PathName2);  
fsc = double(geotiffread(FileName2));  
info_fsc=geotiffinfo(FileName2);  
refmatrix_fsc=info_fsc.RefMatrix;
```

```
% GET THE NDSI IMAGE  
[FileName3,PathName3] = uigetfile('*.tif', 'SELECT THE NDSI IMAGE');  
cd(PathName3);  
ndsi = double(geotiffread(FileName3));  
info_ndsi=geotiffinfo(FileName3);  
refmatrix_ndsi=info_ndsi.RefMatrix;
```

```
% GET THE NDVI IMAGE  
[FileName4,PathName4] = uigetfile('*.tif', 'SELECT THE NDVI IMAGE');
```

```

cd(PathName4);
ndvi = double(geotiffread(FileName4));
info_ndvi=geotiffinfo(FileName4);
refmatrix_ndvi=info_ndvi.RefMatrix;

```

```

%GET THE LAND COVER TYPE IMAGE
[FileName5,PathName5] = uigetfile(*.tif, 'SELECT THE LAND COVER TYPE
IMAGE');
cd(PathName5);
Lc = double(geotiffread(FileName5));
info_Lc=geotiffinfo(FileName5);
refmatrix_Lc=info_Lc.RefMatrix;

```

```

%GET THE CLOUD/WATER MASK IMAGE
[FileName6,PathName6] = uigetfile(*.tif, 'SELECT THE CLOUD/WATER MASK
IMAGE');
cd(PathName6);
cwm = double(geotiffread(FileName6));
info_cwm=geotiffinfo(FileName6);
refmatrix_cwm=info_cwm.RefMatrix;
%nz=sum(cwm(:) == 1); %number of 1s in the cloud/water mask image

```

```

%GET THE MOD02 SI FLAG BAD DATA MASK
[FileName9,PathName9] = uigetfile(*.tif, 'SELECT THE MOD02 SI FLAG BAD
DATA MASK');
cd(PathName9);
SI = double(geotiffread(FileName9));
info_SI=geotiffinfo(FileName9);
refmatrix_SI=info_SI.RefMatrix;

```

```

%GET THE MOD02 FILES IN WHICH TOA REFLECTANCE VALUES FOR
BANDS 1-7 ARE STORED
[FileName7,PathName7] = uigetfile(*.tif, 'SELECT THE MOD02 TOA FILES',
'Multiselect', 'on');
cd(PathName7);
[m,n]=size(FileName7);

```

```

%Pre-allocation matrix for MOD02 TOA reflectances for bands 1-7
x=zeros(n,row);

```

```

xx=zeros(n,row);

%SAVE MODIS FSC TRAINING & TEST DATA INTO A csv file PART-I
[FileName8,PathName8] = uinputfile('*.csv', 'SAVE THE MODIS FSC TRAINING &
TEST DATA FILE AS');

tstart=tic;

%GET THE EACH IMAGE PIXEL'S VALUE ONTO POINT
for i=m:n

    %Read MOD02 TOA files
    cd(PathName7);
    s1=char(FileName7(i));
    mod02=double(geotiffread(s1));
    info_mod02=geotiffinfo(s1);
    refmatrix_mod02=info_mod02.RefMatrix;

    [r,c] = map2pix(refmatrix_mod02, XX,YY);      %MOD02 BAND 1 VALUES
    idx=sub2ind(size(mod02), round(r), round(c));
    x(i,:)=mod02(idx);
    xx(i,:)=(x(i,:)-min(x(i,:)))/(max(x(i,:))-min(x(i,:))); %Standardize the values between
[0,1]
end

[r1,c1] = map2pix(refmatrix_fsc, XX,YY);      %FSC VALUES
idx1=sub2ind(size(fsc), round(r1), round(c1));
a1=fsc(idx1);

[r2,c2] = map2pix(refmatrix_ndsi, XX,YY);      %NDSI VALUES
idx2=sub2ind(size(ndsi), round(r2), round(c2));
a2=ndsi(idx2);

[r3,c3] = map2pix(refmatrix_ndvi, XX,YY);      %NDVI VALUES
idx3=sub2ind(size(ndvi), round(r3), round(c3));
a3=ndvi(idx3);

[r4,c4] = map2pix(refmatrix_Lc, XX,YY);      %LAND COVER VALUES
idx4=sub2ind(size(Lc), round(r4), round(c4));
a4=Lc(idx4);

[r5,c5] = map2pix(refmatrix_cwm, XX,YY);      %CLOUD/WATER MASK
VALUES
idx5=sub2ind(size(cwm), round(r5), round(c5));
a5=cwm(idx5);

```

```

[r6,c6] = map2pix(refmatrix_SI, XX,YY);      %MOD02 SI FLAG BAD DATA
MASK
idx6=sub2ind(size(SI), round(r6), round(c6));
a6=SI(idx6);

%Find & assign the incremental FSC Classes
a7=zeros(1,numel(a1));
for i=1:numel(a1)
    if a1(i)<0.1
        a7(i)=1;
    else if a1(i)>=0.1 && a1(i)<0.2
        a7(i)=2;
    else if a1(i)>=0.2 && a1(i)<0.3
        a7(i)=3;
    else if a1(i)>=0.3 && a1(i)<0.4
        a7(i)=4;
    else if a1(i)>=0.4 && a1(i)<0.5
        a7(i)=5;
    else if a1(i)>=0.5 && a1(i)<0.6
        a7(i)=6;
    else if a1(i)>=0.6 && a1(i)<0.7
        a7(i)=7;
    else if a1(i)>=0.7 && a1(i)<0.8
        a7(i)=8;
    else if a1(i)>=0.8 && a1(i)<0.9
        a7(i)=9;
    else
        a7(i)=10;
    end
end
end
end
end
end
end
end
end
end
end
end
end

y(:,1)=a1;
y(:,2:8)=xx';
y(:,9)=(a2-min(a2))/(max(a2)-min(a2)); %Standardize the values between [0,1]
y(:,10)=(a3-min(a3))/(max(a3)-min(a3));
y(:,11)=a4;
y(:,12)=a7;
y(:,13)=a5;

```

```

y(:,14)=a6;

%Find the rows with Cloud/Water mask value equal to 1
y1= y(y(:,13)==1,:);

%Find the rows with MOD02 SI Flag mask values equal to 1
y2= y1(y1(:,14)==1,:);

%Find the rows with LAND COVER is not water/snow/ice (Lc=9)
y3= y2(y2(:,11)~=9,:);

%The resultant data matrix
y4=y3(:,1:end-2);

%COLUMN HEADERS FOR MODIS FSC TRAINING & TEST FILE
headers1=['fsc',',',',mod02_b01',',',',mod02_b02',',',',mod02_b03',',',',mod02_b04',',',',mod02_b05',',',',mod02_b06',',',',mod02_b07',',',',ndsi',',',',ndvi',',',',land_cover',',',',fsc_class'];

%SAVE MODIS FSC TRAINING & TEST DATA INTO A csv file PART-II
cd(PathName8);
fid = fopen(FileName8,'w');
fprintf(fid,'%s\r\n',headers1);
fclose(fid);
dlmwrite(FileName8,y4,'-append','delimiter',',','precision',9);

telapsed=toc(tstart);
fprintf('Process time in sec. = %f\n',telapsed)

cd(CurrentFolder);

```

EK 2 MATLAB Programında DVM Kernel Fonksiyonlarından Doğrusal

```
%function borasvm_linear_optimize builds an SVM regression model with linear kernel  
%function to predict FSC values from MODIS data by inputting range of  
%BoxConstraint values for optimize SVM parameter settings
```

```
function y = borasvm_linear_optimize(M,N)
```

```
%Author: Bora Berkay ÇİFTÇİ  
%Date : March 2017
```

```
tic;  
tstart=tic;
```

```
%Get the CSV File containing SVM TRAINING Inputs and Targets  
CurrentFolder = pwd;
```

```
[FileName1,PathName1] = uigetfile('*.csv', 'SELECT THE SVM TRAINING CSV  
FILE');  
cd(PathName1);  
fid = fopen(FileName1);  
input = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f %f',  
'Delimiter',';', 'HeaderLines',1);  
fclose(fid);
```

```
%SVM TRAINING INPUT MATRIX
```

```
svm_input(:,1) = double(input{2});  
svm_input(:,2) = double(input{3});  
svm_input(:,3) = double(input{4});  
svm_input(:,4) = double(input{5});  
svm_input(:,5) = double(input{6});  
svm_input(:,6) = double(input{7});  
svm_input(:,7) = double(input{8});  
svm_input(:,8) = double(input{9});  
svm_input(:,9) = double(input{10});  
svm_input(:,10) = double(input{11});
```

```
%SVM TRAINING TARGET MATRIX
```

```
svm_target(:,1) = double(input{1});
```

```
%Get the CSV File containing SVM VALIDADTION DATA SET
```

```

[FileName2,PathName2] = uigetfile('*.csv', 'SELECT THE SVM VALIDATION CSV
FILE');
cd(PathName2);
fid = fopen(FileName2);
validation = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',',','HeaderLines',1);
fclose(fid);

%SVM VALIDATION INPUT
val_input(:,1) = double(validation{2});
val_input(:,2) = double(validation{3});
val_input(:,3) = double(validation{4});
val_input(:,4) = double(validation{5});
val_input(:,5) = double(validation{6});
val_input(:,6) = double(validation{7});
val_input(:,7) = double(validation{8});
val_input(:,8) = double(validation{9});
val_input(:,9) = double(validation{10});
val_input(:,10) = double(validation{11});

%SVM VALIDATION OBSERVED RESPONSE
val_observed(:,1)=double(validation{1});

%SAVE THE SVM ERROR RESULTS _ PART I
[FileName9,PathName9] = uiputfile('*.csv', 'SAVE THE SVM ERROR RESULT AS');

%GET THE SVM INDEPENDENT TEST DATA SETS
[FileName3,PathName3] = uigetfile('*.csv', 'SELECT THE SVM 1ST INDEPENDENT
TEST DATA CSV FILE');
cd(PathName3);
fid = fopen(FileName3);
test1 = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',',','HeaderLines',1);
fclose(fid);

%TEST1 INPUT MATRIX
test1_input(:,1) = double(test1{2});
test1_input(:,2) = double(test1{3});
test1_input(:,3) = double(test1{4});
test1_input(:,4) = double(test1{5});
test1_input(:,5) = double(test1{6});
test1_input(:,6) = double(test1{7});
test1_input(:,7) = double(test1{8});
test1_input(:,8) = double(test1{9});
test1_input(:,9) = double(test1{10});
test1_input(:,10) = double(test1{11});

```

```
%TEST1 TARGET MATRIX
test1_target(:,1) = double(test1{1});
```

```
[FileName4,PathName4] = uigetfile('*.csv', 'SELECT THE SVM 2ND
INDEPENDENT TEST DATA CSV FILE');
cd(PathName4);
fid = fopen(FileName4);
test2 = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',';', 'HeaderLines',1);
fclose(fid);
```

```
%TEST2 INPUT MATRIX
test2_input(:,1) = double(test2{2});
test2_input(:,2) = double(test2{3});
test2_input(:,3) = double(test2{4});
test2_input(:,4) = double(test2{5});
test2_input(:,5) = double(test2{6});
test2_input(:,6) = double(test2{7});
test2_input(:,7) = double(test2{8});
test2_input(:,8) = double(test2{9});
test2_input(:,9) = double(test2{10});
test2_input(:,10) = double(test2{11});
```

```
%TEST2 TARGET MATRIX
test2_target(:,1) = double(test2{1});
```

```
[FileName5,PathName5] = uigetfile('*.csv', 'SELECT THE SVM 3RD
INDEPENDENT TEST DATA CSV FILE');
cd(PathName5);
fid = fopen(FileName5);
test3 = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',';', 'HeaderLines',1);
fclose(fid);
```

```
%TEST3 INPUT MATRIX
test3_input(:,1) = double(test3{2});
test3_input(:,2) = double(test3{3});
test3_input(:,3) = double(test3{4});
test3_input(:,4) = double(test3{5});
test3_input(:,5) = double(test3{6});
test3_input(:,6) = double(test3{7});
test3_input(:,7) = double(test3{8});
test3_input(:,8) = double(test3{9});
```



```
test3_input(:,9) = double(test3{10});
test3_input(:,10) = double(test3{11});
```

```
%TEST3 TARGET MATRIX
test3_target(:,1) = double(test3{1});
```

```
[FileName6,PathName6] = uigetfile('*.csv', 'SELECT THE SVM 4TH INDEPENDENT
TEST DATA CSV FILE');
cd(PathName6);
fid = fopen(FileName6);
test4 = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',',','HeaderLines',1);
fclose(fid);
```

```
%TEST4 INPUT MATRIX
test4_input(:,1) = double(test4{2});
test4_input(:,2) = double(test4{3});
test4_input(:,3) = double(test4{4});
test4_input(:,4) = double(test4{5});
test4_input(:,5) = double(test4{6});
test4_input(:,6) = double(test4{7});
test4_input(:,7) = double(test4{8});
test4_input(:,8) = double(test4{9});
test4_input(:,9) = double(test4{10});
test4_input(:,10) = double(test4{11});
```

```
%TEST4 TARGET MATRIX
test4_target(:,1) = double(test4{1});
```

```
[FileName7,PathName7] = uigetfile('*.csv', 'SELECT THE ANN 5TH INDEPENDENT
TEST DATA CSV FILE');
cd(PathName7);
fid = fopen(FileName7);
test5 = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',',','HeaderLines',1);
fclose(fid);
```

```
%TEST5 INPUT MATRIX
test5_input(:,1) = double(test5{2});
test5_input(:,2) = double(test5{3});
test5_input(:,3) = double(test5{4});
test5_input(:,4) = double(test5{5});
test5_input(:,5) = double(test5{6});
test5_input(:,6) = double(test5{7});
test5_input(:,7) = double(test5{8});
```

```

test5_input(:,8) = double(test5{9});
test5_input(:,9) = double(test5{10});
test5_input(:,10) = double(test5{11});

%TEST5 TARGET MATRIX
test5_target(:,1) = double(test5{1});

[FileName8,PathName8] = uigetfile('*.*', 'SELECT THE ANN 6TH INDEPENDENT
TEST DATA CSV FILE');
cd(PathName8);
fid = fopen(FileName8);
test6 = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',' ','HeaderLines',1);
fclose(fid);

%TEST6 INPUT MATRIX
test6_input(:,1) = double(test6{2});
test6_input(:,2) = double(test6{3});
test6_input(:,3) = double(test6{4});
test6_input(:,4) = double(test6{5});
test6_input(:,5) = double(test6{6});
test6_input(:,6) = double(test6{7});
test6_input(:,7) = double(test6{8});
test6_input(:,8) = double(test6{9});
test6_input(:,9) = double(test6{10});
test6_input(:,10) = double(test6{11});

%TEST6 TARGET MATRIX
test6_target(:,1) = double(test6{1});

%SVM WITH LINEAR KERNEL FOR RANGE OF BC VALUES FROM M TO N

rng default          %For reproducibility, set the random seed

params = hyperparameters('fitrsvm',svm_input,svm_target);

params(1,1).Range=[M,N];      %BoxConstraint range
params(1,1).Transform='none'; %BoxConstraint transformation to log scale
params(2,1).Optimize=false;   %do not optimize for KernelScale
params(3,1).Optimize=false;   %do not optimize for Epsilon

startSVM = tic;             %START CPU TIME COUNTER

```

```

mdl=fitrsvm(svm_input,svm_target,'KernelFunction', 'linear',
'OptimizeHyperparameters', params, 'HyperparameterOptimizationOptions',
struct('AcquisitionFunctionName', 'expected-improvement-plus',
'MaxObjectiveEvaluations', 30));

endSVM = toc(startSVM);      %STOP CPU TIME COUNTER

trn_predicted = predict(mdl,svm_input); %prediction on training data
val_predicted = predict(mdl,val_input); %prediction on validation data

%training phase errors
trn_rmse=sqrt(sum((svm_target(:)-trn_predicted(:)).^2)/numel(svm_target));
trn_mae=(sum(abs(svm_target(:)-trn_predicted(:))))/numel(svm_target);
trn_r=corrcoef(svm_target, trn_predicted);

%validation phase errors
val_rmse=sqrt(sum((val_observed(:)-val_predicted(:)).^2)/numel(val_observed));
val_mae=(sum(abs(val_observed(:)-val_predicted(:))))/numel(val_observed);
val_r=corrcoef(val_observed, val_predicted);

%INDEPENDENT TEST SETS PREDICTED VALUES
test1_predicted = predict(mdl,test1_input); %prediction on test1 data
test2_predicted = predict(mdl,test2_input); %prediction on test1 data
test3_predicted = predict(mdl,test3_input); %prediction on test1 data
test4_predicted = predict(mdl,test4_input); %prediction on test1 data
test5_predicted = predict(mdl,test5_input); %prediction on test1 data
test6_predicted = predict(mdl,test6_input); %prediction on test1 data

%INDEPENDENT TEST SETS ERROR CALCULATIONS
%TEST1
test1_rmse=sqrt(sum((test1_target(:)-test1_predicted(:)).^2)/numel(test1_target));
test1_mae=(sum(abs(test1_target(:)-test1_predicted(:))))/numel(test1_target);
test1_r=corrcoef(test1_target, test1_predicted);

%TEST2
test2_rmse=sqrt(sum((test2_target(:)-test2_predicted(:)).^2)/numel(test2_target));
test2_mae=(sum(abs(test2_target(:)-test2_predicted(:))))/numel(test2_target);
test2_r=corrcoef(test2_target, test2_predicted);

```

```
%TEST3
test3_rmse=sqrt(sum((test3_target(:)-test3_predicted(:)).^2)/numel(test3_target));
test3_mae=(sum(abs(test3_target(:)-test3_predicted(:))))/numel(test3_target);
test3_r=corrcoef(test3_target, test3_predicted);
```

```
%TEST4
test4_rmse=sqrt(sum((test4_target(:)-test4_predicted(:)).^2)/numel(test4_target));
test4_mae=(sum(abs(test4_target(:)-test4_predicted(:))))/numel(test4_target);
test4_r=corrcoef(test4_target, test4_predicted);
```

```
%TEST5
test5_rmse=sqrt(sum((test5_target(:)-test5_predicted(:)).^2)/numel(test5_target));
test5_mae=(sum(abs(test5_target(:)-test5_predicted(:))))/numel(test5_target);
test5_r=corrcoef(test5_target, test5_predicted);
```

```
%TEST6
test6_rmse=sqrt(sum((test6_target(:)-test6_predicted(:)).^2)/numel(test6_target));
test6_mae=(sum(abs(test6_target(:)-test6_predicted(:))))/numel(test6_target);
test6_r=corrcoef(test6_target, test6_predicted);
```

```
%COMBINED ERROR MATRIX
```

```
error(1,1)=trn_rmse;
error(1,2)=trn_mae;
error(1,3)=trn_r(2);
```

```
error(1,4)=val_rmse;
error(1,5)=val_mae;
error(1,6)=val_r(2);
```

```
error(1,7)=test1_rmse;
error(1,8)=test1_mae;
error(1,9)=test1_r(2);
```

```
error(1,10)=test2_rmse;
error(1,11)=test2_mae;
error(1,12)=test2_r(2);
```

```
error(1,13)=test3_rmse;
error(1,14)=test3_mae;
```



```
fprintf('Process time in sec. = %f\n',tapsed)
```

```
cd(CurrentFolder);
```



EK 3 MATLAB Programında DVM Kernel Fonksiyonlarından RBF

%function borasvm_rbf_optimize builds an SVM regression model with gaussian kernel
%function to predict FSC values from MODIS data by inputting range of
%BoxConstraint values between [M, N] for optimize SVM parameter settings

```
function y = borasvm_rbf_optimize(M,N)
```

```
%Author: Bora Berkay ÇİFTÇİ  
%Date : March 2017
```

```
tic;  
tstart=tic;
```

```
%Get the CSV File containing SVM TRAINING Inputs and Targets  
CurrentFolder = pwd;
```

```
[FileName1,PathName1] = uigetfile('*.*csv', 'SELECT THE SVM TRAINING CSV  
FILE');  
cd(PathName1);  
fid = fopen(FileName1);  
input = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f',  
'Delimiter',',','HeaderLines',1);  
fclose(fid);
```

```
%SVM TRAINING INPUT MATRIX  
svm_input(:,1) = double(input{2});  
svm_input(:,2) = double(input{3});  
svm_input(:,3) = double(input{4});  
svm_input(:,4) = double(input{5});  
svm_input(:,5) = double(input{6});  
svm_input(:,6) = double(input{7});  
svm_input(:,7) = double(input{8});  
svm_input(:,8) = double(input{9});  
svm_input(:,9) = double(input{10});  
svm_input(:,10) = double(input{11});
```

```
%SVM TRAINING TARGET MATRIX  
svm_target(:,1) = double(input{1});
```

```
%Get the CSV File containing SVM VALIDADTION DATA SET
```

```

[FileName2,PathName2] = uigetfile('*.csv', 'SELECT THE SVM VALIDATION CSV
FILE');
cd(PathName2);
fid = fopen(FileName2);
validation = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',',','HeaderLines',1);
fclose(fid);

%SVM VALIDATION INPUT
val_input(:,1) = double(validation{2});
val_input(:,2) = double(validation{3});
val_input(:,3) = double(validation{4});
val_input(:,4) = double(validation{5});
val_input(:,5) = double(validation{6});
val_input(:,6) = double(validation{7});
val_input(:,7) = double(validation{8});
val_input(:,8) = double(validation{9});
val_input(:,9) = double(validation{10});
val_input(:,10) = double(validation{11});

%SVM VALIDATION OBSERVED RESPONSE
val_observed(:,1)=double(validation{1});

%SAVE THE SVM ERROR RESULTS _ PART I
[FileName9,PathName9] = uiputfile('*.csv', 'SAVE THE SVM ERROR RESULT AS');

%GET THE SVM INDEPENDENT TEST DATA SETS
[FileName3,PathName3] = uigetfile('*.csv', 'SELECT THE SVM 1ST INDEPENDENT
TEST DATA CSV FILE');
cd(PathName3);
fid = fopen(FileName3);
test1 = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',',','HeaderLines',1);
fclose(fid);

%TEST1 INPUT MATRIX
test1_input(:,1) = double(test1{2});
test1_input(:,2) = double(test1{3});
test1_input(:,3) = double(test1{4});
test1_input(:,4) = double(test1{5});
test1_input(:,5) = double(test1{6});
test1_input(:,6) = double(test1{7});
test1_input(:,7) = double(test1{8});
test1_input(:,8) = double(test1{9});
test1_input(:,9) = double(test1{10});
test1_input(:,10) = double(test1{11});

```



```
%TEST1 TARGET MATRIX
test1_target(:,1) = double(test1{1});
```

```
[FileName4,PathName4] = uigetfile('*.csv', 'SELECT THE SVM 2ND
INDEPENDENT TEST DATA CSV FILE');
cd(PathName4);
fid = fopen(FileName4);
test2 = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',';', 'HeaderLines',1);
fclose(fid);
```

```
%TEST2 INPUT MATRIX
test2_input(:,1) = double(test2{2});
test2_input(:,2) = double(test2{3});
test2_input(:,3) = double(test2{4});
test2_input(:,4) = double(test2{5});
test2_input(:,5) = double(test2{6});
test2_input(:,6) = double(test2{7});
test2_input(:,7) = double(test2{8});
test2_input(:,8) = double(test2{9});
test2_input(:,9) = double(test2{10});
test2_input(:,10) = double(test2{11});
```

```
%TEST2 TARGET MATRIX
test2_target(:,1) = double(test2{1});
```

```
[FileName5,PathName5] = uigetfile('*.csv', 'SELECT THE SVM 3RD
INDEPENDENT TEST DATA CSV FILE');
cd(PathName5);
fid = fopen(FileName5);
test3 = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',';', 'HeaderLines',1);
fclose(fid);
```

```
%TEST3 INPUT MATRIX
test3_input(:,1) = double(test3{2});
test3_input(:,2) = double(test3{3});
test3_input(:,3) = double(test3{4});
test3_input(:,4) = double(test3{5});
test3_input(:,5) = double(test3{6});
test3_input(:,6) = double(test3{7});
test3_input(:,7) = double(test3{8});
test3_input(:,8) = double(test3{9});
```

```
test3_input(:,9) = double(test3{10});
test3_input(:,10) = double(test3{11});
```

```
%TEST3 TARGET MATRIX
test3_target(:,1) = double(test3{1});
```

```
[FileName6,PathName6] = uigetfile('*.csv', 'SELECT THE SVM 4TH INDEPENDENT
TEST DATA CSV FILE');
cd(PathName6);
fid = fopen(FileName6);
test4 = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',';', 'HeaderLines',1);
fclose(fid);
```

```
%TEST4 INPUT MATRIX
test4_input(:,1) = double(test4{2});
test4_input(:,2) = double(test4{3});
test4_input(:,3) = double(test4{4});
test4_input(:,4) = double(test4{5});
test4_input(:,5) = double(test4{6});
test4_input(:,6) = double(test4{7});
test4_input(:,7) = double(test4{8});
test4_input(:,8) = double(test4{9});
test4_input(:,9) = double(test4{10});
test4_input(:,10) = double(test4{11});
```

```
%TEST4 TARGET MATRIX
test4_target(:,1) = double(test4{1});
```

```
[FileName7,PathName7] = uigetfile('*.csv', 'SELECT THE ANN 5TH INDEPENDENT
TEST DATA CSV FILE');
cd(PathName7);
fid = fopen(FileName7);
test5 = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',';', 'HeaderLines',1);
fclose(fid);
```

```
%TEST5 INPUT MATRIX
test5_input(:,1) = double(test5{2});
test5_input(:,2) = double(test5{3});
test5_input(:,3) = double(test5{4});
test5_input(:,4) = double(test5{5});
test5_input(:,5) = double(test5{6});
test5_input(:,6) = double(test5{7});
test5_input(:,7) = double(test5{8});
```

```

test5_input(:,8) = double(test5{9});
test5_input(:,9) = double(test5{10});
test5_input(:,10) = double(test5{11});

%TEST5 TARGET MATRIX
test5_target(:,1) = double(test5{1});

[FileName8,PathName8] = uigetfile('*.*csv', 'SELECT THE ANN 6TH INDEPENDENT
TEST DATA CSV FILE');
cd(PathName8);
fid = fopen(FileName8);
test6 = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',' ','HeaderLines',1);
fclose(fid);

%TEST6 INPUT MATRIX
test6_input(:,1) = double(test6{2});
test6_input(:,2) = double(test6{3});
test6_input(:,3) = double(test6{4});
test6_input(:,4) = double(test6{5});
test6_input(:,5) = double(test6{6});
test6_input(:,6) = double(test6{7});
test6_input(:,7) = double(test6{8});
test6_input(:,8) = double(test6{9});
test6_input(:,9) = double(test6{10});
test6_input(:,10) = double(test6{11});

%TEST6 TARGET MATRIX
test6_target(:,1) = double(test6{1});

%SVM WITH LINEAR KERNEL FOR RANGE OF BC VALUES FROM M TO N

rng default %For reproducibility, set the random seed

params = hyperparameters('fitrsvm',svm_input,svm_target);

params(1,1).Range=[M,N]; %BoxConstraint range
params(1,1).Transform='none'; %BoxConstraint transformation to log scale
params(2,1).Optimize=true; %Optimize for KernelScale
params(2,1).Transform='none'; %Do not transform to log scale
params(3,1).Optimize=false; %Do not optimize for Epsilon

```

```

startSVM = tic;           %START CPU TIME COUNTER

mdl=fitrsvm(svm_input,svm_target,'KernelFunction', 'rbf',
'OptimizeHyperparameters', params, 'HyperparameterOptimizationOptions',
struct('AcquisitionFunctionName', 'expected-improvement-plus',
'MaxObjectiveEvaluations', 30));

endSVM = toc(startSVM);   %STOP CPU TIME COUNTER

trn_predicted = predict(mdl,svm_input); %prediction on training data
val_predicted = predict(mdl,val_input); %prediction on validation data

%training phase errors
trn_rmse=sqrt(sum((svm_target(:)-trn_predicted(:)).^2)/numel(svm_target));
trn_mae=(sum(abs(svm_target(:)-trn_predicted(:))))/numel(svm_target);
trn_r=corrcoef(svm_target, trn_predicted);

%validation phase errors
val_rmse=sqrt(sum((val_observed(:)-val_predicted(:)).^2)/numel(val_observed));
val_mae=(sum(abs(val_observed(:)-val_predicted(:))))/numel(val_observed);
val_r=corrcoef(val_observed, val_predicted);

%INDEPENDENT TEST SETS PREDICTED VALUES
test1_predicted = predict(mdl,test1_input); %prediction on test1 data
test2_predicted = predict(mdl,test2_input); %prediction on test1 data
test3_predicted = predict(mdl,test3_input); %prediction on test1 data
test4_predicted = predict(mdl,test4_input); %prediction on test1 data
test5_predicted = predict(mdl,test5_input); %prediction on test1 data
test6_predicted = predict(mdl,test6_input); %prediction on test1 data

%INDEPENDENT TEST SETS ERROR CALCULATIONS
%TEST1
test1_rmse=sqrt(sum((test1_target(:)-test1_predicted(:)).^2)/numel(test1_target));
test1_mae=(sum(abs(test1_target(:)-test1_predicted(:))))/numel(test1_target);
test1_r=corrcoef(test1_target, test1_predicted);

```

```

%TEST2
test2_rmse=sqrt(sum((test2_target(:)-test2_predicted(:)).^2)/numel(test2_target));
test2_mae=(sum(abs(test2_target(:)-test2_predicted(:))))/numel(test2_target);
test2_r=corrcoef(test2_target, test2_predicted);

%TEST3
test3_rmse=sqrt(sum((test3_target(:)-test3_predicted(:)).^2)/numel(test3_target));
test3_mae=(sum(abs(test3_target(:)-test3_predicted(:))))/numel(test3_target);
test3_r=corrcoef(test3_target, test3_predicted);

%TEST4
test4_rmse=sqrt(sum((test4_target(:)-test4_predicted(:)).^2)/numel(test4_target));
test4_mae=(sum(abs(test4_target(:)-test4_predicted(:))))/numel(test4_target);
test4_r=corrcoef(test4_target, test4_predicted);

%TEST5
test5_rmse=sqrt(sum((test5_target(:)-test5_predicted(:)).^2)/numel(test5_target));
test5_mae=(sum(abs(test5_target(:)-test5_predicted(:))))/numel(test5_target);
test5_r=corrcoef(test5_target, test5_predicted);

%TEST6
test6_rmse=sqrt(sum((test6_target(:)-test6_predicted(:)).^2)/numel(test6_target));
test6_mae=(sum(abs(test6_target(:)-test6_predicted(:))))/numel(test6_target);
test6_r=corrcoef(test6_target, test6_predicted);
%COMBINED ERROR MATRIX
error(1,1)=trn_rmse;
error(1,2)=trn_mae;
error(1,3)=trn_r(2);

error(1,4)=val_rmse;
error(1,5)=val_mae;
error(1,6)=val_r(2);

error(1,7)=test1_rmse;
error(1,8)=test1_mae;
error(1,9)=test1_r(2);

error(1,10)=test2_rmse;
error(1,11)=test2_mae;
error(1,12)=test2_r(2);

```



```
telapsed=toc(tstart);
```

```
fprintf('Process time in sec. = %f\n',telapsed)
```

```
cd(CurrentFolder);
```



EK 4 MATLAB Programında DVM Kernel Fonksiyonlarından Polinom

%function borasvm_polynom_optimize builds an SVM regression model with polynomial kernel
%function of degree L to predict FSC values from MODIS data by inputting range of %BoxConstraint values between [M, N] for optimize SVM parameter settings

```
function y = borasvm_polynom_optimize(M,N,L)
```

```
%Author: Bora Berkay ÇİFTÇİ  
%Date : March 2017
```

```
tic;  
tstart=tic;
```

```
%Get the CSV File containing SVM TRAINING Inputs and Targets  
CurrentFolder = pwd;
```

```
[FileName1,PathName1] = uigetfile('*.csv', 'SELECT THE SVM TRAINING CSV  
FILE');  
cd(PathName1);  
fid = fopen(FileName1);  
input = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f',  
'Delimiter',',','HeaderLines',1);  
fclose(fid);
```

```
%SVM TRAINING INPUT MATRIX
```

```
svm_input(:,1) = double(input{2});  
svm_input(:,2) = double(input{3});  
svm_input(:,3) = double(input{4});  
svm_input(:,4) = double(input{5});  
svm_input(:,5) = double(input{6});  
svm_input(:,6) = double(input{7});  
svm_input(:,7) = double(input{8});  
svm_input(:,8) = double(input{9});  
svm_input(:,9) = double(input{10});  
svm_input(:,10) = double(input{11});
```

```
%SVM TRAINING TARGET MATRIX
```

```
svm_target(:,1) = double(input{1});
```

```
%Get the CSV File containing SVM VALIDADTION DATA SET
```

```
[FileName2,PathName2] = uigetfile('*.csv', 'SELECT THE SVM VALIDATION CSV  
FILE');  
cd(PathName2);
```



```

fid = fopen(FileName2);
validation = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',';', 'HeaderLines',1);
fclose(fid);

%SVM VALIDATION INPUT
val_input(:,1) = double(validation{2});
val_input(:,2) = double(validation{3});
val_input(:,3) = double(validation{4});
val_input(:,4) = double(validation{5});
val_input(:,5) = double(validation{6});
val_input(:,6) = double(validation{7});
val_input(:,7) = double(validation{8});
val_input(:,8) = double(validation{9});
val_input(:,9) = double(validation{10});
val_input(:,10) = double(validation{11});

%SVM VALIDATION OBSERVED RESPONSE
val_observed(:,1)=double(validation{1});

%SAVE THE SVM ERROR RESULTS _ PART I
[FileName9,PathName9] = uigetfile(*.csv', 'SAVE THE SVM ERROR RESULT AS');

%GET THE SVM INDEPENDENT TEST DATA SETS
[FileName3,PathName3] = uigetfile(*.csv', 'SELECT THE SVM 1ST INDEPENDENT
TEST DATA CSV FILE');
cd(PathName3);
fid = fopen(FileName3);
test1 = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',';', 'HeaderLines',1);
fclose(fid);

%TEST1 INPUT MATRIX
test1_input(:,1) = double(test1{2});
test1_input(:,2) = double(test1{3});
test1_input(:,3) = double(test1{4});
test1_input(:,4) = double(test1{5});
test1_input(:,5) = double(test1{6});
test1_input(:,6) = double(test1{7});
test1_input(:,7) = double(test1{8});
test1_input(:,8) = double(test1{9});
test1_input(:,9) = double(test1{10});
test1_input(:,10) = double(test1{11});

%TEST1 TARGET MATRIX
test1_target(:,1) = double(test1{1});

```

```

[FileName4,PathName4] = uigetfile('*.csv', 'SELECT THE SVM 2ND
INDEPENDENT TEST DATA CSV FILE');
cd(PathName4);
fid = fopen(FileName4);
test2 = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',';', 'HeaderLines',1);
fclose(fid);

%TEST2 INPUT MATRIX
test2_input(:,1) = double(test2{2});
test2_input(:,2) = double(test2{3});
test2_input(:,3) = double(test2{4});
test2_input(:,4) = double(test2{5});
test2_input(:,5) = double(test2{6});
test2_input(:,6) = double(test2{7});
test2_input(:,7) = double(test2{8});
test2_input(:,8) = double(test2{9});
test2_input(:,9) = double(test2{10});
test2_input(:,10) = double(test2{11});

%TEST2 TARGET MATRIX
test2_target(:,1) = double(test2{1});

[FileName5,PathName5] = uigetfile('*.csv', 'SELECT THE SVM 3RD
INDEPENDENT TEST DATA CSV FILE');
cd(PathName5);
fid = fopen(FileName5);
test3 = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',';', 'HeaderLines',1);
fclose(fid);

%TEST3 INPUT MATRIX
test3_input(:,1) = double(test3{2});
test3_input(:,2) = double(test3{3});
test3_input(:,3) = double(test3{4});
test3_input(:,4) = double(test3{5});
test3_input(:,5) = double(test3{6});
test3_input(:,6) = double(test3{7});
test3_input(:,7) = double(test3{8});
test3_input(:,8) = double(test3{9});
test3_input(:,9) = double(test3{10});
test3_input(:,10) = double(test3{11});

%TEST3 TARGET MATRIX
test3_target(:,1) = double(test3{1});

```

```

[FileName6,PathName6] = uigetfile('*.csv', 'SELECT THE SVM 4TH INDEPENDENT
TEST DATA CSV FILE');
cd(PathName6);
fid = fopen(FileName6);
test4 = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',' ','HeaderLines',1);
fclose(fid);

%TEST4 INPUT MATRIX
test4_input(:,1) = double(test4{2});
test4_input(:,2) = double(test4{3});
test4_input(:,3) = double(test4{4});
test4_input(:,4) = double(test4{5});
test4_input(:,5) = double(test4{6});
test4_input(:,6) = double(test4{7});
test4_input(:,7) = double(test4{8});
test4_input(:,8) = double(test4{9});
test4_input(:,9) = double(test4{10});
test4_input(:,10) = double(test4{11});

%TEST4 TARGET MATRIX
test4_target(:,1) = double(test4{1});

[FileName7,PathName7] = uigetfile('*.csv', 'SELECT THE ANN 5TH
INDEPENDENT TEST DATA CSV FILE');
cd(PathName7);
fid = fopen(FileName7);
test5 = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',' ','HeaderLines',1);
fclose(fid);

%TEST5 INPUT MATRIX
test5_input(:,1) = double(test5{2});
test5_input(:,2) = double(test5{3});
test5_input(:,3) = double(test5{4});
test5_input(:,4) = double(test5{5});
test5_input(:,5) = double(test5{6});
test5_input(:,6) = double(test5{7});
test5_input(:,7) = double(test5{8});
test5_input(:,8) = double(test5{9});
test5_input(:,9) = double(test5{10});
test5_input(:,10) = double(test5{11});

%TEST5 TARGET MATRIX
test5_target(:,1) = double(test5{1});

```

```

[FileName8,PathName8] = uigetfile('*.csv', 'SELECT THE ANN 6TH INDEPENDENT
TEST DATA CSV FILE');
cd(PathName8);
fid = fopen(FileName8);
test6 = textscan(fid, '%f %f %f %f %f %f %f %f %f %f %f %f',
'Delimiter',',','HeaderLines',1);
fclose(fid);

%TEST6 INPUT MATRIX
test6_input(:,1) = double(test6{2});
test6_input(:,2) = double(test6{3});
test6_input(:,3) = double(test6{4});
test6_input(:,4) = double(test6{5});
test6_input(:,5) = double(test6{6});
test6_input(:,6) = double(test6{7});
test6_input(:,7) = double(test6{8});
test6_input(:,8) = double(test6{9});
test6_input(:,9) = double(test6{10});
test6_input(:,10) = double(test6{11});

%TEST6 TARGET MATRIX
test6_target(:,1) = double(test6{1});

%SVM WITH LINEAR KERNEL FOR RANGE OF BC VALUES FROM M TO N

rng default %For reproducibility, set the random seed

params = hyperparameters('fitrsvm',svm_input,svm_target);

params(1,1).Range=[M,N]; %BoxConstraint range
params(1,1).Transform='none'; %BoxConstraint transformation to log scale
params(2,1).Optimize=false; %Do not optimize for KernelScale
params(2,1).Transform='none'; %Do not transform to log scale
params(3,1).Optimize=false; %Do not optimize for Epsilon

startSVM = tic; %START CPU TIME COUNTER

mdl=fitrsvm(svm_input,svm_target,'KernelFunction', 'polynomial',
'PolynomialOrder', L, 'OptimizeHyperparameters', params,
'HyperparameterOptimizationOptions', struct('AcquisitionFunctionName', 'expected-
improvement-plus', 'MaxObjectiveEvaluations', 30));

endSVM = toc(startSVM); %STOP CPU TIME COUNTER

trn_predicted = predict(mdl,svm_input); %prediction on training data

```

```

val_predicted = predict mdl, val_input); %prediction on validation data
%training phase errors
trn_rmse=sqrt(sum((svm_target(:)-trn_predicted(:)).^2)/numel(svm_target));
trn_mae=(sum(abs(svm_target(:)-trn_predicted(:))))/numel(svm_target);
trn_r=corrcoef(svm_target, trn_predicted);

% validation phase errors
val_rmse=sqrt(sum((val_observed(:)-val_predicted(:)).^2)/numel(val_observed));
val_mae=(sum(abs(val_observed(:)-val_predicted(:))))/numel(val_observed);
val_r=corrcoef(val_observed, val_predicted);

%INDEPENDENT TEST SETS PREDICTED VALUES
test1_predicted = predict mdl, test1_input); %prediction on test1 data
test2_predicted = predict mdl, test2_input); %prediction on test1 data
test3_predicted = predict mdl, test3_input); %prediction on test1 data
test4_predicted = predict mdl, test4_input); %prediction on test1 data
test5_predicted = predict mdl, test5_input); %prediction on test1 data
test6_predicted = predict mdl, test6_input); %prediction on test1 data

%INDEPENDENT TEST SETS ERROR CALCULATIONS
%TEST1
test1_rmse=sqrt(sum((test1_target(:)-test1_predicted(:)).^2)/numel(test1_target));
test1_mae=(sum(abs(test1_target(:)-test1_predicted(:))))/numel(test1_target);
test1_r=corrcoef(test1_target, test1_predicted);

%TEST2
test2_rmse=sqrt(sum((test2_target(:)-test2_predicted(:)).^2)/numel(test2_target));
test2_mae=(sum(abs(test2_target(:)-test2_predicted(:))))/numel(test2_target);
test2_r=corrcoef(test2_target, test2_predicted);

%TEST3
test3_rmse=sqrt(sum((test3_target(:)-test3_predicted(:)).^2)/numel(test3_target));
test3_mae=(sum(abs(test3_target(:)-test3_predicted(:))))/numel(test3_target);
test3_r=corrcoef(test3_target, test3_predicted);

%TEST4
test4_rmse=sqrt(sum((test4_target(:)-test4_predicted(:)).^2)/numel(test4_target));
test4_mae=(sum(abs(test4_target(:)-test4_predicted(:))))/numel(test4_target);
test4_r=corrcoef(test4_target, test4_predicted);

%TEST5
test5_rmse=sqrt(sum((test5_target(:)-test5_predicted(:)).^2)/numel(test5_target));
test5_mae=(sum(abs(test5_target(:)-test5_predicted(:))))/numel(test5_target);

```

```

test5_r=corrcoef(test5_target, test5_predicted);

%TEST6
test6_rmse=sqrt(sum((test6_target(:)-test6_predicted(:)).^2)/numel(test6_target));
test6_mae=(sum(abs(test6_target(:)-test6_predicted(:))))/numel(test6_target);
test6_r=corrcoef(test6_target, test6_predicted);

%COMBINED ERROR MATRIX
error(1,1)=trn_rmse;
error(1,2)=trn_mae;
error(1,3)=trn_r(2);

error(1,4)=val_rmse;
error(1,5)=val_mae;
error(1,6)=val_r(2);

error(1,7)=test1_rmse;
error(1,8)=test1_mae;
error(1,9)=test1_r(2);

error(1,10)=test2_rmse;
error(1,11)=test2_mae;
error(1,12)=test2_r(2);

error(1,13)=test3_rmse;
error(1,14)=test3_mae;
error(1,15)=test3_r(2);

error(1,16)=test4_rmse;
error(1,17)=test4_mae;
error(1,18)=test4_r(2);

error(1,19)=test5_rmse;
error(1,20)=test5_mae;
error(1,21)=test5_r(2);

error(1,22)=test6_rmse;
error(1,23)=test6_mae;
error(1,24)=test6_r(2);

error(1,25)=endSVM;

%SAVE THE SVM TO A MATLAB WORKSPACE FOR FURTHER USE

```

```

cd(PathName9);
b1='svm_polynom_';
b2=num2str(L);
b3='_BC_';
b4=num2str mdl.BoxConstraints(1);
b5='.mat';
b6=strcat(b1,b2,b3,b4,b5);
save(b6);

y=error;

% COLUMN HEADERS & WRITING THE ERROR OUTPUT TO A COMMA
% SEPARATED CSV FILE
headers1=['trn_rmse',',','trn_mae',',','trn_r',',','val_rmse',',','val_mae',',','val_r',',','test1_rmse',',','test1_mae',',','test1_r',',','test2_rmse',',','test2_mae',',','test2_r',',','test3_rmse',',','test3_mae',',','test3_r',',','test4_rmse',',','test4_mae',',','test4_r',',','test5_rmse',',','test5_mae',',','test5_r',',','test6_rmse',',','test6_mae',',','test6_r',',','cpu_time'];

% SAVE THE ANN ERROR RESULTS _ PART II
cd(PathName9);
fid = fopen(FileName9,'w');
fprintf(fid,'%s\r\n',headers1);
fclose(fid);
dlmwrite(FileName9,y,'-append','delimiter',',','precision',9);

telapsed=toc(tstart);

fprintf('Process time in sec. = %f\n',telapsed)

cd(CurrentFolder);

```

ÖZGEÇMİŞ

Adı Soyadı : Bora Berkay ÇİFTÇİ
Doğum Yeri : Bornova
Doğum Tarihi : 04/01/1988
Medeni Hali : Bekar
Yabancı Dili : İngilizce
Adres : Hoşdere Caddesi Yukarı Ayrancı Çankaya/ANKARA
Tel : (0541) 228 1081
E-Posta : boraberkeybb@hotmail.com
Eğitim Durumu
Lise : Kurtuluş Lisesi 2005
Lisans : Karadeniz Teknik Üniversitesi 2013
Yüksek Lisans : Çankırı Karatekin Üniversitesi
Çalıştığı Kurum ve Yıl
Yayınları

1. Kuter, S., Çiftçi, B.B. ve Weber, G.-W., 2017. “Snow Cover Mapping from Satellite Data by Artificial Neural Networks and Support Vector Machines”, The International Conference on Operational Research for Development 2017 (ICORD 2017), 13-14 Temmuz, 2017, Université Laval, Québec, Canada.
2. Çiftçi, B. B. Kuter, S., Akyürek, Z. and Weber, G. W. (2017). Fractional Snow Cover Mapping by Artificial Neural Networks and Support Vector Machines. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, IV-4/W4, pp. 179-187. doi: 10.5194/isprs-annals-IV-4-W4-179-2017.