

Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi

(Investigation of the Effects of Kernel Functions in Satellite Image Classification Using Support Vector Machines)

Taşkın KAVZOĞLU, İsmail ÇÖLKESEN

Gebze Yüksek Teknoloji Enstitüsü, Jeodezi ve Fotogrametri Mühendisliği Bölümü, Gebze, Kocaeli
kavzoglu@gyte.edu.tr

ÖZET

Uzaktan algılanmış görüntüler ve bu görüntülerin sınıflandırılmasıyla üretilen tematik haritalar, dünya yüzeyindeki objelerin yapısı ve özellikleri hakkında çok önemli bilgiler sunarlar. Tematik haritaların elde edilmesinde kullanılan sınıflandırıcıların etkinliği özellikle zor ve karmaşık sınıflandırma problemleri için büyük önem taşımaktadır. Destek vektör makineleri (DVM) son yıllarda ortaya atılmış ve birçok alanda başarıyla uygulanmış bir makine öğrenme algoritmasıdır. Uzaktan algılama alanındaki uygulamaları ise güncel sayılabilecek niteliktedir. DVM'lerin diğer sınıflandırıcılardan özellikle istatistiksel tabanlı sınıflandırıcılardan daha güçlü ve etkili olduğu ispatlanmıştır.

Bu çalışmada, DVM'lerin sınıflandırma performansının kernel fonksiyonu ve parametre değerlerine bağlı değişimi detaylı şekilde analiz edilmiştir. Analizler sırasında literatürde en yaygın kullanılan dört kernel fonksiyonunun sınıflandırma doğruluğu üzerindeki etkileri incelenmiştir. Kullanılan veri seti için radyal tabanlı fonksiyon ve Pearson VII fonksiyon kernellerinin en yüksek performansı (>%94 genel doğruluk) gösterdikleri belirlenmiştir. Normalleştirilmiş polinom kerneli ise en düşük sınıflandırma doğruluğunu (%91,78) üreten DVM modeli olmuştur. Diğer taraftan, en çok benzerlik yöntemiyle performans karşılaştırması yapıldığında, tüm DVM modellerinin daha yüksek doğruluklu sonuçlar ürettiği saptanmıştır.

Anahtar Kelimeler: Destek vektör makineleri, kernel fonksiyonları, arazi örtüsü ve arazi kullanımı, görüntü sınıflandırma.

ABSTRACT

Remotely sensed images and the thematic maps derived from these images provide invaluable information about the nature of the Earth surface materials and objects. The robustness of classification techniques used to produce these thematic maps can be crucial especially for complex classification problems. Support vector machines (SVMs) are machine learning algorithms that have been recently introduced and successfully used in many fields. Their use in remote sensing is relatively new. It is proved that these algorithms are more robust and effective than other classifiers, particularly the ones on statistical basis.

In this study, a detailed performance analysis was carried out for SVMs with regard to kernel function and chosen parameter values. In the analyses four particular kernel functions that have been most widely used in the literature were investigated with their effects on classification accuracy. It is found that radial basis function and Pearson VII function kernels produced the highest performance (>94%) for the data set considered in this study. Also, normalized polynomial kernel showed a poor performance with the lowest classification accuracy (91,78%) among all SVM models. On the other hand, it is found that all SVM models produced more accurate results compared to maximum likelihood classification.

Key Words: Support vector machines, kernel functions, land cover and land use, image classification.

1. GİRİŞ

Yeryüzü üzerindeki çevresel değişimlerin izlenmesi ve yönetimi gerek sürdürülebilir çevre gerekse doğal kaynakların etkin kullanımı açısından büyük önem taşımaktadır. Küresel ve yerel ölçekteki bu değişimlerin tespitinde uzaktan algılanmış görüntüler sağladıkları eşsiz avantajlar nedeniyle en çok başvurulan kaynak durumundadırlar. Yersel bazlı çalışmalarla karşılaştırıldığında, uzaktan algılama uygulamaları maliyet, zaman, çalışma sahası büyüklüğü noktalarında önemli faydalar sağlamaktadır. Geniş ve erişilmesi mümkün olmayan alanlar için kısa süre içinde önemli araştırmaların yapılabilmesi uzaktan algılama teknolojisi sayesinde mümkün olmaktadır. Bu kapsamda gerçekleştirilecek çalışmalarda uzaktan algılanmış görüntülerin sınıflandırılması sıklıkla başvurulan bir yöntemdir. Literatürde birçok sınıflandırma metot ve yaklaşımı mevcuttur (Tso vd., 2001; Lu vd., 2007). Ayrıca, bu metotların performanslarının analizine yönelik birçok çalışma yapılmıştır (Huang vd., 2002; Pal vd., 2005; Kavzoglu vd., 2008).

Makine öğrenmesi alanındaki başarılı uygulamaları sonrasında, destek vektör

makinelere uzaktan algılama alanında son yıllarda başarıyla kullanılan bir sınıflandırma yöntemidir. Bu sınıflandırma yöntemi, veriyi daha yüksek bir boyuta dönüştürerek oluşturacağı bir hiperdüzlem ile iki sınıfa birbirinden ayırma prensibini esas alır. Yüksek boyuta dönüşüm aşamasında değişik özelliklere sahip fonksiyonlar kullanılır. Bu fonksiyonlar kernel fonksiyonları olarak adlandırılır. Kernel fonksiyonlarının kullanımı için bu fonksiyonların matematiksel ifadesinde bulunan bazı parametrelerin kullanıcı tarafından belirlenmesi gerekir.

Bu çalışmada, destek vektör makineleri için literatürde en çok kullanılan kernel fonksiyonlarının performansları, belirlenen optimum parametre değerleriyle bir Landsat ETM+ uydu görüntüsü kullanılarak değerlendirilmiştir. Bu analizler sırasında, görüntü sınıflandırmada temel ölçüt ya da dayanak olarak kabul edilen en çok benzerlik sınıflandırıcısı da uygulanmış ve destek vektör makineleriyle performans açısından karşılaştırılmıştır.

2. ÇALIŞMA ALANI VE KULLANILAN VERİ

Çalışma alanı olarak seçilen Kocaeli, Marmara denizinin doğusunda ve yaklaşık 3.505km²'lik yüzölçüme sahiptir. Merkez ilçesi İzmit olan Kocaeli'nin diğer ilçeleri ise Başiskele, Çayırova, Darıca, Dilovası, Gebze, Gölcük, Karamürsel, Kandıra, Kartepe, Körfez ve Derince'dir. Bir sanayi ve endüstri kenti olan Kocaeli Türkiye'nin en büyük sanayi kuruluşlarına ev sahipliği yapmaktadır. Kocaeli gayri safi milli hasıladan fert başına düşen payda Türkiye'de birinci sırada yer almaktadır. İstanbul ilinin sınırında bulunması, çevre yolu ve diğer bağlantı yolları üzerinde olması, ulaşım kolaylığı nedeniyle 1980'ler sonrasında şehri bir sanayi kenti haline dönüştürmüştür. Kocaeli ilinin 1970 yılında 385.408 olan nüfusu 2009 yılı sonu itibarıyla 1.522.408 ulaşmıştır (www.tuik.gov.tr). Hızlı nüfus artışı ve sanayileşme kontrolsüz yapılaşma ve arazi bozulmasını (degradasyonunu) beraberinde getirmiştir.

Bu çalışmada ortaya konan amaçları yerine getirmek için tüm sınıflandırma işlemlerinde 30.09.2009 tarihli Landsat ETM+ görüntüsü kullanılmıştır. Bu görüntü üzerinde geometrik rektifikasyon işlemi gerçekleştirilerek UTM projeksiyon sisteminde yeniden örnekleme yapılmıştır. Mevcut hâlihazır ve meşcere haritalarının yanında araziden toplanan veriler ile sınıflandırıcılar için eğitim ve test alanları tespit edilmiştir. Çalışma alanı olan Kocaeli ilini en iyi

şekilde temsil eden altı sınıf (su, geniş yapraklı ağaç, iğne yapraklı ağaç, bozkır, yerleşim ve toprak-taş) belirlenmiş ve bu altı sınıf için eğitim ve test verileri oluşturulmuştur.

3. GÖRÜNTÜ SINIFLANDIRMA YÖNTEMLERİ

Uydu görüntülerinden yeryüzüne ait bilgilerin elde edilmesinde kullanılan en yaygın yöntem görüntülerin sınıflandırılması işlemidir. Görüntü sınıflandırma, görüntüyü oluşturan her bir pikselin tüm bantlardaki değerlerinin diğer pikseller ile karşılaştırılarak benzer piksellerin kullanıcının belirlediği sınıflara ayrılması işlemidir (Campbell, 1996). Diğer bir deyişle; sınıflandırma, yeryüzü objelerinin farklı spektral yansıma değerlerinin tespiti yapılarak görüntü üzerindeki her pikseli ait olduğu özellik grubuna yani sınıfa atama işlemidir. Sınıflandırma sonucu elde edilen görüntüler tematik harita olarak adlandırılır.

Sınıflandırma işleminde genel olarak kontrollü ve kontrolsüz sınıflandırma olarak adlandırılan iki yaklaşım vardır. Uydu görüntülerinin sınıflandırılmasında kontrollü sınıflandırma yöntemi yani eğitim alanlarıyla sınıflandırma metodolojisi sonuçların doğruluğu ve güvenilirliği açısından en çok tercih edilen yöntem olmuştur. Kontrollü sınıflandırma işlemi için literatürde birçok metod sunulmasına karşın, en yaygın kullanılan yöntem en çok benzerlik (EÇB) metodudur. Bu yöntem referans veya temel ölçüt olarak ele alınmış ve yeni metodların performanslarının analizinde literatürde sıklıkla kullanılmıştır.

EÇB yöntemini de kapsayan istatistiksel tabanlı yöntemlerde, her bir sınıfa ait örnek piksellerin normal dağılımda olduğu kabulünün yapılması ve değişik veri yapılarının sınıflandırılmasına olanak vermemesi gibi önemli zayıflıkları olduğu literatürde vurgulanmıştır (Bruzzone vd., 1997; Shrestha vd., 2001; Kavzoglu vd., 2003). Ayrıca, genel olarak yüksek doğruluk veren bu metodlar, spektral ayrımın zor olduğu durumlarda (karışık pikseller, nem ve topografya gibi değişken faktörlerin etkisi, çok sayıda sınıfı ayırmak için tek zamanlı ve az sayıda spektral bant kullanımı vb.) tutarsız sonuçlar üretebilmektedir. Bu zayıflıkları ortadan kaldırmak amacıyla son dönemde gelişmiş sınıflandırma yaklaşımları ile uydu görüntülerinin analizi konusunda çalışmalar yoğun şekilde yürütülmektedir. Bu yaklaşımlardan başlıcaları olarak yapay sinir ağları, karar ağaçları, destek vektör makineleri ve bulanık mantık verilebilir. Bunların uzaktan algılanmış görüntülerin

sınıflandırmasındaki etkinliği birçok çalışmada ortaya konmuştur (Pal vd., 2003; Erbek vd., 2003; Pal vd., 2005; Kavzoglu vd., 2009). Bu metotların kısıtlı eğitim verisi olduğu durumlarda iyi sonuçlar üretilebildiği de araştırmalarla ortaya konmuştur (Paola, 1994; Foody, 1995).

a. En Çok Benzerlik Sınıflandırma Yöntemi

En çok benzerlik (EÇB) yöntemi literatürde yaygın olarak kullanılan istatistiksel tabanlı bir sınıflandırma yöntemidir. Bu yöntemde ortalama değer, varyans ve kovaryans değerlerinin tümü dikkate alınır. Eğitim alanlarını oluşturan sınıflar için olasılık fonksiyonları hesaplanır ve buna göre her bir pikselin hangi sınıfa daha yakın olduğu belirlenir. Bir pikselin hangi sınıfa ait olduğu her bir sınıfa ait olma olasılıklarının hesabından sonra en yüksek olasılıklı gruba atama şeklinde yapılır. Bu noktada kullanıcı tarafından tespit edilecek bir eşik değer sınıflandırılacak pikselin belirlenen sınıflardan veya bu sınıfların dışında bir sınıftan olduğunun tespitinde kullanılır. Piksellerin sınıflandırılmasında tüm sınıflar için hesaplanan olasılık değerinin önceden belirlenen eşik değerinin altında kalması durumunda ilgili pikseller "belirsiz" olarak değerlendirilir.

EÇB yönteminde, sınıf kontrol verilerini oluşturan noktalar kümesindeki dağılımın normal (Gauss) dağılımında olduğu kabulü yapılır. Sınıfların ilk olasılıkları hakkında bilgi mevcut değilse, hepsi eşit olasılıklı olarak kabul edilir. Yöntem, sadece piksel değerlerine göre değil, her sınıf için oluşturacak varyans-kovaryans matris değerini de dikkate alarak sınıf tayini yapar. Böylece metot, örnek piksellerin özellik uzayındaki dağılımlarını da dikkate almış olur (Mather, 1999). Pikselin p sayıdaki bant değerlerini içeren x vektörünün bir k sınıfında olma olasılığı aşağıdaki şekilde hesaplanır.

$$P(x) = 2\pi^{-0.5p} |S_i|^{-0.5} \exp\left[-0.5\left(y^T S_i^{-1} y\right)\right] \quad (1)$$

Bu eşitlikte; $P(x)$ olasılık değerini, S_i i . sınıf için varyans-kovaryans matrisini, $| |$ matrisin determinantını, $y = (x - \bar{x}_i)$ ve \bar{x}_i ise i . sınıf için ortalama değeri ifade eder.

b. DVM İle Sınıflandırma

Destek Vektör Makineleri (DVM) istatistiksel öğrenme teorisine dayalı bir kontrollü sınıflandırma algoritmasıdır. DVM'nin sahip

olduğu matematiksel algoritmalar başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması problemi için tasarlanmış, daha sonra çok sınıflı ve doğrusal olmayan verilerin sınıflandırılması için genelleştirilmiştir. DVM'nin çalışma prensibi iki sınıfı birbirinden ayırabilen en uygun karar fonksiyonun tahmin edilmesi, başka bir ifadeyle iki sınıfı birbirinden en uygun şekilde ayırabilen hiper-düzlemin tanımlanması esasına dayanmaktadır (Vapnik, 1995; Vapnik, 2000). Bir çok alanda başarıyla kullanılan DVM'lerin uzaktan algılama alanında kullanımı konusunda son yıllarda yoğun çalışmalar yürütülmektedir (Foody vd., 2004; Melgani vd., 2004; Pal vd., 2005; Kavzoglu vd., 2009).

(1) Doğrusal Ayrılabilen Veriler için DVM

Destek vektör makineleri ile sınıflandırmada genellikle $\{-1,+1\}$ şeklinde sınıf etiketleri ile gösterilen iki sınıfa ait örneklerin, eğitim verisi ile elde edilen bir karar fonksiyonu yardımıyla birbirinden ayrılması amaçlanır. Söz konusu karar fonksiyonu kullanılarak eğitim verisini en uygun şekilde ayırabilecek hiper-düzlem bulunur.


Şekil 1(a)'da gösterildiği üzere iki sınıflı verileri birbirinden ayırabilen birçok hiper-düzlem çizilebilir. Ancak DVM'nin amacı kendisine en yakın noktalar arasındaki uzaklığı maksimuma çıkaran hiper-düzlemi bulabilmektir. Şekil 1(b)'de görüldüğü üzere sınırı maksimuma çıkararak en uygun ayrımı yapan hiper-düzleme optimum hiper-düzlem ve sınır genişliğini sınırlandıran noktalar ise destek vektörleri olarak adlandırılır.

Doğrusal olarak ayrılabilen iki sınıflı bir sınıflandırma probleminde DVM'nin eğitimi için k sayıda örnekten oluşan eğitim verisinin $\{x_i, y_i\}$, $i = 1, \dots, k$ olduğu kabul edilirse, optimum hiper-düzleme ait eşitsizlikler aşağıdaki şekilde olur:


$$w \cdot x_i + b \geq +1 \quad \text{her } y = +1 \text{ için} \quad (2)$$

$$w \cdot x_i + b \leq -1 \quad \text{her } y = -1 \text{ için} \quad (3)$$

Burada $x \in R^N$ olup N -boyutlu bir uzayı, $y \in \{-1, +1\}$ ise sınıf etiketlerini, w ağırlık vektörünü (hiper-düzlemin normali) ve b eğilim değerini göstermektedir (Osuna vd., 1997). Optimum hiper-düzlemin belirlenebilmesi için bu düzleme paralel ve sınırlarını oluşturacak iki hiper-düzlemin belirlenmesi gerekir (Şekil 2). Bu hiper-düzlemleri oluşturan noktalar destek vektörleri olarak adlandırılır ve bu düzlemler $w \cdot x_i + b = \pm 1$ şeklinde ifade edilirler.



Şekil 1. (a) İki sınıflı bir problem için hiper-düzlemler, (b) Optimum hiper-düzlem ve destek vektörleri.



Şekil 2. Doğrusal olarak ayrılabilen veri setleri için hiper-düzlemin belirlenmesi.

Optimum hiper-düzlemin sınırının maksimuma çıkarılması için $\|w\|$ ifadesinin minimum hale getirilmesi gerekir. Bu durumda en uygun hiper-düzlemin belirlenmesi aşağıdaki sınırlı optimizasyon probleminin çözümünü gerektirir.

$$\min \left[\frac{1}{2} \|w\|^2 \right] \quad (4)$$

Buna bağlı sınırlamalar ise;

$$y_i(w \cdot x_i + b) - 1 \geq 0 \text{ ve } y_i \in \{1, -1\} \quad (5)$$

şeklinde ifade edilir (Vapnik, 1995). Bu optimizasyon problemi Lagrange denklemleri kullanılarak çözülebilir. Bu işlem sonrasında;

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^k \alpha_i y_i (w \cdot x_i + b) + \sum_{i=1}^k \alpha_i \quad (6)$$

eşitliği elde edilir. Sonuç olarak, doğrusal olarak ayrılabilen iki sınıflı bir problem için karar fonksiyonu aşağıdaki şekilde yazılabilir (Osuna vd., 1997).

$$f(x) = \text{sign} \left(\sum_{i=1}^k \lambda_i y_i (x \cdot x_i) + b \right) \quad (7)$$

(2) Doğrusal Ayrılmayan Veriler için DVM

Uydu görüntülerinin sınıflandırılmasında olduğu gibi birçok problemde verilerin doğrusal olarak ayrılması mümkün değildir [Şekil 3(a)]. Bu durumda eğitim verilerinin bir kısmının optimum hiper-düzlemin diğer tarafında kalmasından kaynaklanan problem pozitif bir yapay değişkenin (ξ_i) tanımlanması ile çözülür [Şekil 3(b)]. Sınırın maksimum hale getirilmesi ve yanlış sınıflandırma hatalarının minimum hale getirilmesi arasındaki denge pozitif değerler alan ve C ile gösterilen bir düzenleme parametresi ($0 < C < \infty$) tanımlanmasıyla kontrol edilebilir (Cortes vd., 1995). Düzenleme parametresi ve yapay değişken kullanılarak doğrusal olarak ayırım yapılamayan veriler için optimizasyon problemi:

$$\min \left[\frac{\|w\|^2}{2} + C \cdot \sum_{i=1}^r \xi_i \right] \quad (8)$$

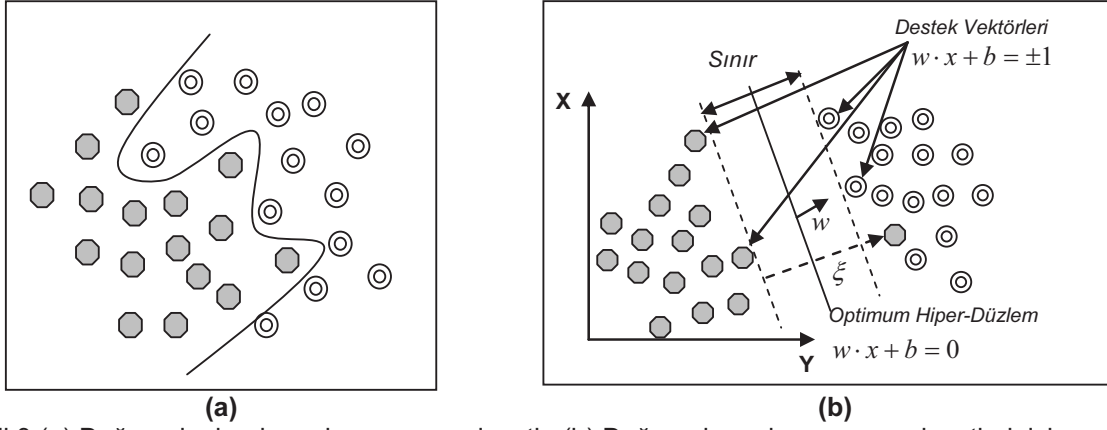
şeklini alır.

Buna bağlı sınırlamalar ise;

$$y_i(w \cdot \varphi(x_i) + b) - 1 \geq 1 - \xi_i \quad (9)$$


$$\xi_i \geq 0 \text{ ve } i = 1, \dots, N$$

şeklinde ifade edilir.



Şekil 3.(a) Doğrusal olarak ayrılabilen veri seti, (b) Doğrusal ayrılabilen veri setleri için hiper-düzlemin belirlenmesi.

Eşitlik 8 ve 9'da ifade edilen optimizasyon probleminin çözümü için Şekil 4'te görüleceği üzere girdi uzayında doğrusal olarak ayrılabilen veri, özellik uzayı olarak tanımlanan yüksek boyutlu bir uzayda görüntülenir. Böylece verilerin doğrusal olarak ayrımı yapılabilmekte ve sınıflar arasındaki hiper-düzlem belirlenebilmektedir.



Şekil 4. Kernel fonksiyonu ile verinin daha yüksek bir boyuta dönüştürülmesi.

Destek vektör makineleri matematiksel olarak $K(x_i, x_j) = \phi(x) \cdot \phi(x_j)$ şeklinde ifade edilen bir kernel fonksiyonu yardımıyla doğrusal olmayan dönüşümler yapılabilmekte ve bu şekilde verilerin yüksek boyutta doğrusal olarak ayrımına imkan sağlamaktadır. Sonuç olarak, kernel fonksiyonu kullanarak doğrusal olarak ayrılabilen iki sınıflı bir problemin çözümü ile ilgili karar kuralı aşağıdaki şekilde yazılabilir (Osuna vd., 1997):

$$f(x) = \text{sign} \left(\sum_i \alpha_i y_i \phi(x) \cdot \phi(x_i) + b \right) \quad (10)$$

Destek vektör makineleri (DVM) ile gerçekleştirilecek bir sınıflandırma işlemi için kullanılacak kernel fonksiyonu ve bu fonksiyona ait optimum parametrelerin belirlenmesi esastır.

Literatürde kernel fonksiyonu olarak en sık kullanılan polinom, radyal tabanlı fonksiyon, Pearson VII (PUK) fonksiyonu ve normalleştirilmiş polinom kernelleri Tablo 1'de formülleri ve parametreleriyle birlikte sunulmuştur. Tablodan görüleceği üzere her kernel fonksiyonu için bazı parametrelerin kullanıcı tarafından belirlenmesi gerekir. PUK kerneli için belirlenmesi gereken parametre sayısı iki iken, diğer fonksiyonlar için sınıflandırmaya esas olacak model oluşumunda bir parametrenin belirlenmesini gerektirmektedir.

Kernel fonksiyonları karşılaştırıldığında polinom ve radyal tabanlı kernellerin daha sade ve anlaşılabilir olduğu ifade edilebilir. Matematiksel olarak basit görünse de, polinomun derecesindeki artış algoritmanın karmaşık bir hal almasına neden olmaktadır. Bu da hem işlem süresini önemli ölçüde artırmakta hem de bir noktadan sonra sınıflandırma doğruluğunu düşürmektedir. Buna karşın radyal tabanlı fonksiyonun kernel boyutu (γ) olarak ifade edilen parametresindeki değişimlerin sınıflandırma performansına etkisinin daha az olduğu görülmüştür (Hsu vd., 2010). Normalleştirilmiş polinom fonksiyonu ise veri setinin normalleştirilmesi yerine polinom kernele ait matematiksel ifadenin normalleştirilmesi amacıyla Arnulf vd. (2001) tarafından önerilmiştir. Normalleştirilmiş polinom kernelinin polinom kernelinin genelleştirilmiş bir hali olduğu söylenebilir. Diğer taraftan, PUK kerneli Pearson genişliği olarak bilinen (σ , ω) iki parametresi ile diğer kernel fonksiyonlarına göre daha karmaşık bir matematiksel yapıya sahiptir. Bu iki parametre sınıflandırma doğruluğuna etki etmekte ve hangi parametre çiftinin en iyi sonuç vereceği önceden bilinmemektedir. Bu nedenle PUK kernelinin kullanımında en uygun parametre çiftinin belirlenmesi önemli bir aşamadır.

Tablo 1. Destek vektör makinelerinde kullanılan temel kernel fonksiyonları ve parametreleri.

Kernel Fonksiyonu	Matematiksel İfadesi	Parametre
Polinom Kerneli	$K(x, y) = ((x \cdot y) + 1)^d$	Polinom derecesi (d)
Normalleştirilmiş Polinom Kerneli	$K(x, y) = \frac{((x \cdot y) + 1)^d}{\sqrt{((x \cdot x) + 1)^d ((y \cdot y) + 1)^d}}$	Polinom derecesi (d)
Radyal Tabanlı Fonksiyon Kerneli	$K(x, y) = e^{-\gamma \ x - x_i\ ^2}$	Kernel boyutu (γ)
Pearson VII (PUK) Kerneli	$\frac{1}{\left[1 + \left(\frac{2 \cdot \sqrt{\ x - y\ ^2} \sqrt{2^{(1/\omega)} - 1}}{\sigma} \right)^2 \right]^\omega}$	Pearson genişliği parametreleri (σ, ω)

Kernel fonksiyonuna özgü parametrelerin yanında tüm destek vektör makineleri için düzenleme parametresi C 'nin kullanıcı tarafından belirlenmesi gerekir. Bu parametre için olması gerekenden çok küçük veya çok büyük değerler seçilmesi durumunda optimum hiper-düzlem doğru belirlenemeyeceğinden sınıflandırma doğruluğunda ciddi düşüş beklenir. Diğer taraftan $C = \infty$ olması durumunda DVM modeli sadece doğrusal olarak ayrılabilen veri setleri için uygun hale gelir. Buradan da görüleceği üzere parametreler için uygun değerlerin seçimi DVM sınıflandırıcısının performansını direkt olarak etkileyen bir faktör durumundadır. Genellikle deneme ve hata stratejisi kullanılmasına karşın, çapraz doğrulama yaklaşımı başarılı sonuçlara ulaşılmasına olanak sağlamaktadır. Çapraz doğrulama yaklaşımında amaç oluşturulan sınıflandırma modelinin performansının belirlenmesidir. Bu amaçla veri seti iki kısma ayrılır. Birinci kısım sınıflandırmaya esas olan model oluşumunda eğitim verisi olarak kullanılırken ikinci kısım modelin performansının belirlenmesi amacıyla test verisi olarak işleme konur. Eğitim seti ile oluşturulan modelin test veri setine uygulanması sonucunda doğru sınıflandırılan örneklerin sayısı sınıflandırıcısının performansını gösterir. Dolayısıyla çapraz geçerlilik yöntemi kullanılarak en iyi sınıflandırma performansının elde edildiği kernel parametrelerinin belirlenmesi ve sınıflandırmaya esas olacak modelin oluşturulmuştur.

4. UYGULAMA

Çalışma alanını kapsayan Landsat ETM+ uydu görüntüsünü sınıflandırmak için öncelikle eğitim ve test verisi hazırlanmıştır. Eğitim veri seti için her sınıfa karşılık 2.000 adet rastgele

seçilmiş piksel ve test veri seti için her sınıfa karşılık 1.000 adet rastgele piksel seçimi yapılmıştır. Bu çalışmadaki tüm sınıflandırma problemlerinde aynı eğitim verisi kullanılmıştır. Her sınıf için eşit miktarda örnek piksel seçilerek sınıflandırma sonucunda elde edilecek sonuçların objektif ve karşılaştırılabilir olması amaçlanmıştır.

Çalışmanın ana hedefi olan destek vektör makinelerinin (DVM) farklı kernel fonksiyonlarıyla göstereceği etkinin araştırılmasında bir temel ölçüt ya da dayanak olarak kullanılan en çok benzerlik (EÇB) sınıflandırıcısı kullanılmıştır. EÇB ve DVM uygulamalarının tamamı MATLAB ortamında yazılmış programlarla gerçekleştirilmiştir. Çalışma alanı için tespit edilen sınıflar Tablo 2'de sunulan sınıf etiket numaraları ile kodlanarak sınıflandırma işlemleri gerçekleştirilmiştir.

Sınıflandırıcıların performanslarının değerlendirilmesinde sınıflandırma sonucu elde edilen hata matrisleri yardımıyla genel sınıflandırma doğrulukları ve Kappa değerleri hesaplanır. Hata matrisinde sınıflandırma sonuçları satırlar ve sütunlar şeklinde gösterilir. Matrisin diyagonal elemanları doğru sınıflandırılan pikselleri gösterirken, satırdaki diğer elemanlar ise farklı sınıfa atanmış diğer bir ifadeyle hatalı sınıflandırılmış test piksellerini gösterir. Genel sınıflandırma doğruluğu, doğru sınıflandırılmış piksel sayısının (diyagonal matris elemanların toplamı) toplam piksel sayısına bölünmesiyle elde edilir. Kappa değeri ise hata matrisinin satır ve sütun toplamları ile köşegeni üzerindeki elemanlar kullanılarak hesaplanır (Congalton vd., 2009).

Tablo 2. Sınıf etiket numaralarının açıklaması.

Sınıf	Açıklama
1	Su (göl, gölet, akarsu, vb.)
2	Geniş yapraklı ağaç
3	İğne yapraklı ağaç
4	Bozkır ve mera alanları
5	Toprak, taş ve kayalık alanlar
6	Yerleşim (bina, yol vb.)

EÇB yöntemi kullanılarak gerçekleştirilen sınıflandırma işlemi için hesaplanan hata matrisi Tablo 3'de verilmiştir. Tablodan da görüleceği üzere sınıflandırmanın genel doğruluğu %91,30 olmuştur. Sınıflara göre EÇB'nin performansı analiz edildiğinde en düşük sınıflandırma doğruluğunun toprak-taş olarak nitelendirilen sınıf için gerçekleştiği görülmektedir. Bu sınıfın örnek piksellerinin ağırlıklı olarak yerleşim etiketi ile sınıflandırıldığı görülmektedir. Bir kısım toprak alanın ise bozkır niteliği yani ot vb. bitkilerle örtülü olduğu görülmektedir.

Tablo 3. En çok benzerlik sınıflandırıcısı için hata matrisi.

Sınıf	1	2	3	4	5	6
1	993	2	0	0	5	0
2	0	975	25	0	0	0
3	0	18	918	34	29	1
4	0	0	43	926	29	2
5	0	0	7	84	746	163
6	0	0	1	6	73	920

Genel Doğruluk : %91,30 Kappa : 0,89

Bölüm 3'de ifade edildiği üzere destek vektör makineleri ile yapılacak sınıflandırma işlemlerinde kullanıcı tarafından eğitim aşaması öncesinde tespit edilmesi gereken parametreler mevcuttur. Bu parametreler kullanılacak kernel fonksiyonuna göre değişiklik göstermektedir.

Tablo 1'de sunulan kernel parametrelerinin seçimi sonuçların doğruluğu üzerinde önemli bir etkiye sahiptir. Ayrıca, tüm DVM uygulamaları için düzenleme parametresinin (C) belirlenmesi esastır. Bu noktadan hareketle, tüm kernel fonksiyonları için en uygun parametre değerinin tespiti çapraz doğrulama yaklaşımı yardımıyla yapılmıştır. Çapraz doğrulamalar sonunda, test veri seti için en yüksek doğruluğu verecek düzenleme parametresi (C) polinom kerneli için 400, normalleştirilmiş polinom kerneli için 1.000,

radyal tabanlı fonksiyon kerneli için 500 ve PUK kerneli için 300 olarak belirlenmiştir. Polinom kerneli için yapılan çalışmalar sonucunda 2. dereceden bir polinom fonksiyonun en yüksek doğruluk değerlerini üreteceği tespit edilmiştir. Normalleştirilmiş polinom kernelinde ise optimum polinom derecesi 3. derece olarak hesaplanmıştır. Her iki polinom kerneli için polinom derecesi artırıldığında, DVM modelinin kompleks hale gelmesi neticesinde sınıflandırma işleminin önemli derecede uzadığı ve sınıflandırma doğruluğunun negatif yönde etkilendiği gözlenmiştir. Radyal tabanlı fonksiyon kerneli için en uygun γ değerinin 2 olduğu hesaplanmıştır. Diğer taraftan, PUK kernelinin iki parametresi (σ , ω) ile yapılan testler sonucunda en uygun değerlerin σ için 0,5, ω için 1,0 olduğu görülmüştür.

Tespit edilen düzenleme parametre değerleriyle kernel parametreleri kullanılarak DVM'nin eğitimleri tamamlanarak test veri seti üzerinde sınıflandırma doğruluk analizi hata matrisleri üzerinden yapılmıştır (Tablo 4). Seçilen kernel fonksiyonları ile DVM sınıflandırma sonuçları genel doğruluk esas alınarak değerlendirildiğinde en düşük doğruluğun normalleştirilmiş polinom kerneli ile (%91,78), en yüksek doğruluğun ise PUK kerneli kullanılarak (%94,83) elde edildiği görülmektedir. Radyal tabanlı fonksiyon kerneli ile elde edilen sınıflandırma doğruluğunun (%94,38) PUK kerneli sonuçlarına yakın olduğu ve bu metotların benzer sonuçlar ürettiği söylenebilir. Tüm DVM tabanlı sınıflandırma işlemleri göz önüne alındığında, genel doğruluk açısından literatürde temel ölçüt kabul edilen EÇB sonuçlarından daha iyi sonuçlar ürettikleri görülmüştür. Bu da DVM metodunun temel aldığı kuramların geçerliliğini ortaya koymaktadır.

Hata matrislerinin detaylı analizi yapıldığında, EÇB dahil tüm sınıflandırma yaklaşımlarının toprak-taş örnek piksellerini yerleşim ve bozkır pikselleriyle karıştırdığı görülmektedir. Spektral özellikleri benzer toprak-taş ve yerleşim piksellerinin ayırımında sınıflandırma yaklaşımlarının etkinliği sonuçlara direkt olarak yansımış durumdadır. Bu çalışmada ele alınan 30 metre konumsal çözünürlüklü görüntü düşünüldüğünde, çalışma alanındaki birçok taş-toprak ve yerleşim pikselinin "karışık" pikseller olduğu ifade edilebilir. Taş-toprak sınıfı için geniş eğitim alanlarının belirlenmesinde güçlük yaşandığı bu noktada belirtilmesi gereken önemli bir husustur.

Tablo 4. Kernel fonksiyonuna bağlı olarak DVM sınıflandırma sonuçları

Sınıf	1	2	3	4	5	6
1	999	0	1	0	0	0
2	1	978	21	0	0	0
3	0	10	963	25	2	0
4	0	0	17	960	16	7
5	3	0	20	52	711	214
6	0	0	3	4	56	937

Genel Doğruluk : %92,47 Kappa : 0,91

(a) Polinom kerneli.

Sınıf	1	2	3	4	5	6
1	999	0	0	0	1	0
2	0	975	25	0	0	0
3	0	14	948	28	9	1
4	0	0	23	936	38	3
5	0	0	14	59	730	197
6	0	0	0	3	78	919

Genel Doğruluk : %91,78 Kappa : 0,90

(b) Normalleştirilmiş polinom kerneli.

Sınıf	1	2	3	4	5	6
1	1000	0	0	0	0	0
2	0	983	17	0	0	0
3	0	5	973	20	2	0
4	0	0	4	975	15	6
5	0	0	5	49	809	137
6	0	0	1	3	73	923

Genel Doğruluk : %94,38 Kappa : 0,93

(c) Radyal tabanlı fonksiyon kerneli.

Sınıf	1	2	3	4	5	6
1	1000	0	0	0	0	0
2	0	989	10	1	0	0
3	0	8	971	17	4	0
4	0	0	4	979	14	3
5	0	0	6	44	830	120
6	0	0	0	5	74	921

Genel Doğruluk : %94,83 Kappa : 0,94

(d) Pearson VII (PUK) kerneli.

Dolayısıyla söz konusu edilen durum, veri ve arazi özellikleri gözetildiğinde normal olarak karşılanmalıdır. Çalışma alanına ait görüntü tüm sınıflandırma yöntemleriyle sınıflandırılarak tematik haritalar üretilmiştir. Bu haritalara örnek olarak en yüksek doğruluğu veren PUK kernelli DVM sınıflandırması sonucu Şekil 5'de sunulmuştur. Tematik haritadan da görüleceği üzere Kocaeli ilinde yapılaşma genellikle deniz kenarı ve ana yol arterleri çevresinde oluşmuştur. E-5 karayolu boyunca olan yapılaşmanın zamanla TEM otoyolu çevresine doğru kaydığı gözlemlenmiştir. Geniş yapraklı ormanlık alanların ağırlıklı olarak şehrin güney kısmında ve iğne yapraklı çam türü ormanların ise daha çok şehrin kuzey kısımlarında (özellikle Karadeniz kıyısında) olduğu görülmüştür.

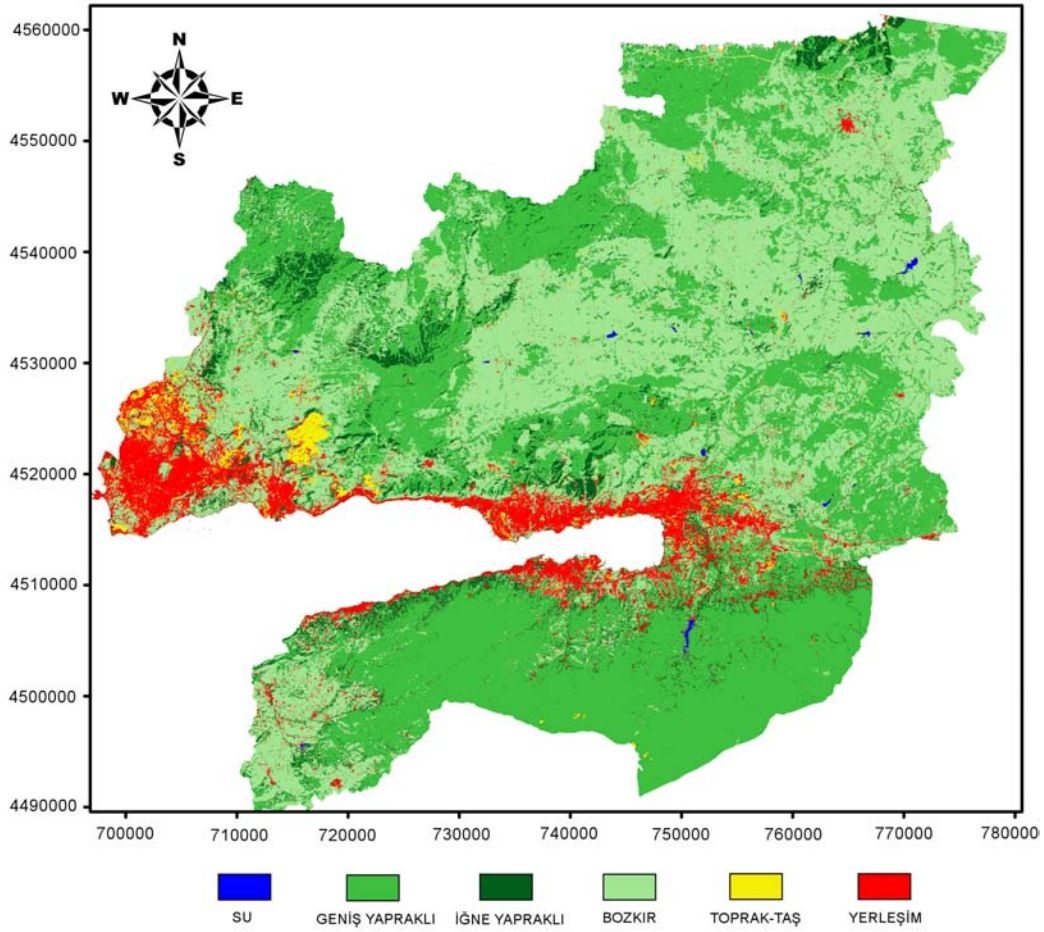
5. SONUÇ

Uydu görüntülerinin sınıflandırılmasıyla elde edilen tematik haritaların doğruluğu birçok bilimsel araştırma için son derece önemlidir. Bu nedenle, kullanılacak veri setinin kalitesi ve temsil

kabiliyetiyle birlikte kullanılacak sınıflandırma yönteminin gücü sonuçlar üzerinde oldukça büyük etkiye sahiptir.

Literatürde birçok yöntem bulunmasına karşın, araştırmacıların yeni yöntem ve yaklaşımlar arayışı devam etmektedir. Birçok araştırmacı tarafından temel metot olarak kabul edilen en çok benzerlik (EÇB) yöntemi, örnek verilerin normal dağılımda olduğu kabulünü yapması nedeniyle standart bir metot olarak görülmemektedir.

Bu arayışlar neticesinde son dönemde yapay sinir ağları, karar ağaçları, bulanık mantık gibi metotlar öne sürülmüştür. Destek vektör makineleri (DVM) de başarılı bir sınıflandırma metodu olarak son dönemde öne sürülen bir makine öğrenme algoritmasıdır.



Şekil 5. Pearson VII (PUK) kernel fonksiyonlu destek vektör makineleri kullanılarak üretilen çalışma alanının tematik haritası.

Bu çalışmada DVM'lerin kullanımında kritik öneme sahip kernel fonksiyonlarının sınıflandırma sonuçlarına yani performansına olan etkileri detaylı şekilde analiz edilmiştir. Bu analiz sırasında dört farklı kernel fonksiyonu optimum parametre seçimi yapılarak çalışma sahası olarak belirlenen Kocaeli iline ait Landsat ETM+ görüntüsünün sınıflandırılmasında kullanılmıştır. DVM'lerin performansı EÇB metodu sonuçlarıyla karşılaştırıldığında daha etkin ve başarılı bulunmuştur. Genel doğruluk açısından performans farkı %3,5'a kadar değişkenlik göstermektedir. Çalışma sahası düşünüldüğünde %3,5 genel doğruluk farkı yaklaşık 131.000 pikselin daha doğru sınıflandırıldığı anlamına gelmektedir. Bu da yaklaşık olarak 117 km²'lik bir alanı ifade etmektedir. Sınıflandırma doğruluğundaki artışın alansal karşılığı, metotların performanslarının sonuçlar üzerindeki etkisini net bir şekilde ortaya koymaktadır.

Burada kullanılan kernel fonksiyonları değerlendirildiğinde DVM ile en yüksek doğruluğun PUK kerneli kullanılması sonucunda üretildiği görülmüştür. Radyal tabanlı fonksiyon kerneli de PUK kerneline yakın sonuçlar üretmiştir. İki kernel benzer sonuçlar üretmesine karşın PUK kerneli için daha fazla parametrenin (C , σ , ω) belirlenmesi ihtiyacı söz konusudur. Ayrıca PUK kerneli kullanılan DVM'lerin daha uzun bir işlem süreci gerektirdiği görülmüştür. Kullanılan kernel fonksiyonları içinde en düşük doğruluğu (%91,78) normalleştirilmiş polinom kernelinin verdiği belirlenmiştir. Her iki polinom tabanlı kernelin uygulanmasında polinom derecesinin artırılmasında bir noktadan sonra sınıflandırma performansı ciddi anlamda azaldığı gözlemlenmiştir. Bu duruma DVM modelinin aşırı kompleks hale gelmesinin neden olduğu düşünülmektedir. Sonuç olarak; yapılan bu çalışma, DVM sınıflandırıcısının optimum kernel fonksiyonları ve parametre değerlerinin seçimiyle uydu görüntülerinin sınıflandırılmasında etkin bir yöntem olduğunu göstermektedir.

KAYNAKLAR

- Arnulf B. A. Graf, S. Borer, 2001, **Normalization in Support Vector Machines**, Lecture Notes in Computer Science, 2191: 277-282.
- Bruzzone, L., Conese, C., Maselli, F., Roli, F., 1997, **Multisource Classification of Complex Rural Areas by Statistical and Neural Network Approaches**, Photogrammetric Engineering and Remote Sensing, 63(5): 523-533.
- Campbell, J.B., 1996, **Introduction to Remote Sensing**, Guilford Press, New York.
- Congalton R.G., Green, K., 2009, **Assessing the Accuracy of Remotely Sensed Data**, 2. Baskı, CRC Press, New York.
- Cortes, C., Vapnik, V., 1995, **Support-Vector Network**, Machine Learning, 20(3): 273-297.
- Erbek, F.S., Özkan, C., Taberner, M., 2003, **Comparison of Maximum Likelihood Classification Method with Supervised Artificial Neural Network Algorithms for Land Use Activities**, International Journal of Remote Sensing, 25(9): 1733-1748.
- Foody, G.M., 1995, **Using Prior Knowledge in Artificial Neural Network Classification with a Minimal Training Set**. International Journal of Remote Sensing, 16(2): 301-312.
- Foody, G.M., Mathur, A., 2004, **A Relative Evaluation of Multiclass Image Classification by Support Vector Machines**, IEEE Transactions on Geoscience and Remote Sensing, 42(6): 1335-1343.
- Huang, C., Davis, L.S., Townshed, J.R.G., 2002, **An Assessment of Support Vector Machines for Land Cover Classification**, International Journal of Remote Sensing, 23(4), 725-749.
- Hsu, C.W., Chang, C.C., Lin, C.J., 2010, **A Practical Guide to Support Vector Classification**, <http://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf>.
- Kavzoglu, T., 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.
- Kavzoglu, T., Mather, P.M., 2003, **The Use of Backpropagating Artificial Neural Networks in Land Cover Classification**, International Journal of Remote Sensing, 24(23): 4907-4938.
- Kavzoglu, T., Reis, S., 2008, **Performance Analysis of Maximum Likelihood and Artificial Neural Network Classifiers for Training Sets with Mixed Pixels**, GIScience and Remote Sensing, 45(3): 330-342.
- Lu, D., Weng, Q., 2007, **A Survey of Image Classification Methods and Techniques for Improving Classification Performance**. International Journal of Remote Sensing 28(5): 823-870.
- Mather, P.M., 1999, **Computer Processing of Remote-Sensed Images**, 2. Baskı, John Wiley and Sons, New York.
- Melgani, F., Bruzzone, L., 2004, **Classification of Hyperspectral Remote Sensing Images with Support Vector Machines**, IEEE Transactions on Geoscience and Remote Sensing, 42(8), 1778-1790.
- Osuna, E.E., Freund, R., Girosi, F., 1997, **Support Vector Machines: Training and Applications**, A.I. Memo No. 1602, C.B.C.L. Paper No. 144, Massachusetts Institute of Technology and Artificial Intelligence Laboratory, Massachusetts.
- Pal, M., Mather, P.M., 2003, **An Assessment of the Effectiveness of Decision Tree Methods for Land Cover Classification**. Remote Sensing of Environment, 86(4): 554-565.
- Pal, M., Mather, P.M., 2005, **Support Vector Machines for Classification in Remote Sensing**, International Journal of Remote Sensing, 26(5): 1007-1011.
- Paola, J.D., 1994, **Neural Network Classification of Multispectral Imagery**. Master Tezi, The University of Arizona, USA.
- Shrestha, D.P., Zinck, J.A., 2001, **Land Use Classification in Mountainous Areas: Integration of Image Processing, Digital Elevation Data and Field Knowledge (Application to Nepal)**. International Journal of Applied Earth Observation and Geoinformation, 3(1): 78-85.
- Tso, B., Mather, P.M., 2001, **Classification Methods for Remotely Sensed Data**, Taylor & Francis, London.
- Vapnik, V.N., 1995, **The Nature of Statistical Learning Theory**, Springer-Verlag, New York.
- Vapnik, V.N., 2000, **The Nature of Statistical Learning Theory**, 2. Baskı, Springer-Verlag, New York.