

FARKLI BOYUTTA EĞİTİM ÖRNEKLERİ İÇİN DESTEK VEKTÖR MAKİNELERİNİN SINIFLANDIRMA PERFORMANSININ ANALİZİ

İ. Çölkese¹, T. Kavzoğlu²

Gebze Yüksek Teknoloji Enstitüsü, Jeodezi ve Fotogrametri Mühendisliği Bölümü, 41400, Gebze, Kocaeli
¹icolkesen@gyte.edu.tr, ²kavzoglu@gyte.edu.tr

ÖZET

Uydu görüntüleri yardımıyla yeryüzünün çeşitli özelliklerini gösteren tematik haritaların üretilmesi uzaktan algılama alanında önemli bir araştırma konusudur. Uzaktan algılanmış görüntülerden tematik harita üretiminde en sık kullanılan yöntem sınıflandırmadır. Destek vektör makineleri son yıllarda uydu görüntülerinin sınıflandırılmasında başarıyla kullanılan bir kontrollü sınıflandırma yöntemidir. Yöntem sınıflandırma işleminde, sınıfları birbirinden ayıran optimum hiper düzlemin belirlenmesi esasına dayanmaktadır. Optimum hiper düzlem sınıflar arasındaki sınır teşkil eden pikseller yardımıyla oluşturulan destek vektörleri ile belirlenebilmektedir. Dolayısıyla sınırlı sayıda eğitim verisi olması durumunda da yöntemin yüksek sınıflandırma doğruluğu üreteceği düşünülmektedir. Bu çalışmada, Gebze ilçesini kapsayan 2009 tarihli Landsat TM görüntüsünün destek vektör makineleri ile sınıflandırılması ve bölgeye ait genel arazi kullanımını gösteren tematik haritanın oluşturulması hedeflenmiştir. Destek vektör makinelerinin eğitiminde farklı boyutta altı eğitim seti (her bir sınıf için 100, 250, 500, 1.000, 1.500 ve 2.000 piksel) kullanılmış ve test verisi (her bir sınıf için 5.000 piksel) için hesaplanan genel sınıflandırma doğrulukları analiz edilmiştir. Yöntemin farklı boyuttaki eğitim veri setleri için sınıflandırma performansı en çok benzerlik yöntemi ile karşılaştırılmış ve elde edilen genel sınıflandırma doğrulukları arasındaki farklar istatistiksel olarak analiz edilmiştir. Sınıflandırma sonuçları, eğitim seti boyutundaki artışa paralel olarak destek vektör makinelerinin performansında yaklaşık %1'lik bir iyileşme olduğunu göstermektedir. Diğer taraftan, en çok benzerlik yönteminin performansında ise %2'lik bir değişim olduğu görülmüştür. Her iki yöntemin sınıflandırma performansı karşılaştırıldığında, destek vektör makineleri ile özellikle sınırlı sayıda eğitim piksellerinden oluşan veri setleri için %3 daha doğru sınıflandırma sonucu elde edildiği görülmüştür. Yapılan testler bu performans farklılığının istatistiksel olarak anlamlı olduğunu göstermiştir. Elde edilen sonuçlar, destek vektör makinelerinin sınırlı sayıda eğitim veri seti için sınıflandırma performansının en çok benzerlik yöntemine göre daha iyi olduğunu destekler niteliktedir.

Anahtar Sözcükler: Arazi Örtüsü, Sınıflandırma, Tematik Harita, Destek Vektör Makineleri, En Çok Benzerlik.

AN ANALYSIS OF CLASSIFICATION PERFORMANCE OF SUPPORT VECTOR MACHINES FOR DIFFERENT TRAINING DATA SIZE

ABSTRACT

Producing thematic maps representing various characteristics of the Earth's surface with the help of satellite images is an important research agenda in the remote sensing field. Classification is a commonly used approach to create thematic maps from the remotely sensed image data. Support vector machines are supervised classification algorithms that have been recently successfully applied in the classification of remote sensing images. In the classification process, the method determines a hyper plane that optimally separates classes. An optimal hyper plane can be determined with the help of support vectors created by the border pixels. Therefore, it is thought that the method can produce high classification accuracy in the case of limited number of training data. In this study, Landsat TM image acquired in 2009 covering Gebze district were classified using support vector machines and thematic map representing general land use and land cover types of the study area was produced. Six different sizes of training data sets (100, 250, 500, 1.000, 1.500 and 2.000 pixels for each class) were used for the training of support vector machines and overall classification accuracies computed for test data set (5.000 pixels for each class) were analyzed. Classification performances of the method for different sizes of training data sets were compared with the maximum likelihood method and differences between the overall classification accuracies were statistically analyzed. Classification results indicated that improvements in the classification performance of support vector machines by about 1% were parallel with the increase in the size of training set. On the other hand, it was seen that the performance of maximum likelihood method changed by about 2% with the increasing training data size. When the classification performances of two classification methods were compared it was observed that higher classification accuracies about 3% obtained with the support vector machines especially for the data sets consisting of limited size of training pixels. The tests performed suggest that the differences in the performance are statistically significant. Results produced in this research show that classification performance of support vector machines better than the maximum likelihood classifier for a limited size of training data.

Keywords: Land cover, Classification, Thematic map, Support vector machines, Maximum likelihood.

1. GİRİŞ

Dünya nüfusundaki hızlı artışa paralel olarak insanların gereksinim duyduğu ihtiyaçlar artmakta ve sınırlı olan doğal kaynaklar üzerindeki aktiviteler değişmektedir. Söz konusu aktiviteler ve artan ihtiyaçlar yeryüzünde meydana gelen değişimler üzerinde önemli bir etkiye sahiptir. Arazi kullanımı ve arazi örtüsü üzerindeki değişimler insan kaynaklı değişimler arasında en önemli olanlardır (Lambin et al., 2001). Sanayileşme ve hızlı kentleşme temel ekosistem, küresel çeşitlilik ve bölgesel iklim değişiklikleri gibi bir çok çevresel değeri olumsuz etkilemektedir (Imura et al., 1999). Bu nedenle yeryüzüne ait envanterlerin çıkarılması ve zaman içinde meydana gelen değişimlerin belirlenmesi doğal kaynakların korunması ve etkin kullanımı açısından son derece önemlidir.

Uzaktan algılama teknolojileri sahip olduğu önemli avantajlarla yeryüzünün görüntülenmesi ve yeryüzüne ait önemli bilgilerin elde edilmesi noktasında önemli bir kaynak durumundadır. Uzaktan algılanmış görüntülerin sınıflandırılması ile yeryüzünün çeşitli özelliklerini gösteren tematik haritalar üretilebilmekte, arazi örtüsü ve kullanım şekilleri detaylı olarak analiz edilebilmektedir. Sınıflandırılma işlemi genel olarak görüntü üzerinde belirli bir yansıtma ve parlaklık değerine sahip piksellerin arazi örtüsü sınıflarından birine atanması olarak ifade edilebilir (Lillesand et al., 2008). Literatürde uydu görüntülerinin sınıflandırılması ve tematik haritaların elde edilmesi amacıyla bir çok sınıflandırma algoritması geliştirilmiştir (Jain et al., 2000; Lu and Weng, 2007). Sınıflandırma algoritmaları arasında paralel kenar, en yakın komşuluk ve en çok benzerlik algoritmaları uygulamalarda en sık kullanılanlar arasındadır. İstatistiksel tabanlı bu algoritmalar her bir sınıfa ait örnek piksellerin normal dağılımında olduğu kabulünü yapmaktadır. Bu kabul, söz konusu algoritmaların her tür verinin sınıflandırmada kullanımına olanak vermemekte ve spektral ayrımın zor olduğu görüntüler için tutarsız sonuçlar üretmelerine neden olmaktadır (Bruzzone et al., 1997; Zhong et al., 2007). Bununla birlikte, sınıflandırıcının eğitimi için kullanılan örnek piksel sayısının az olduğu durumlarda söz konusu istatistiksel algoritmalar düşük sınıflandırma performansı sergileyebilmektedir. Bu zayıflıkları ortadan kaldırmak amacıyla son dönemde daha güçlü sınıflandırma yaklaşımları ile uydu görüntülerinin sınıflandırılması konusunda yoğun çalışmalar yürütülmektedir. Bu yaklaşımlardan yapay sinir ağları, karar ağaçları, bulanık mantık ve destek vektör makineleri sınıflandırmadaki etkinlikleri ile öne çıkanlar arasındadır (Huang et al., 2002; Kavzoglu and Mather, 2003; Wang and Jamshidi, 2004; Rogan et al., 2008).

Uydu görüntülerinin sınıflandırması sonucunda üretilen tematik haritaların doğruluğu ve güvenilirliği birçok araştırma için kritik öneme sahiptir. Sınıflandırma sonuçlarını ve üretilen tematik haritaların doğruluğunu etkileyen faktörlerin başında sınıflandırmada kullanılacak yöntem ve veri gelmektedir. Yüksek sınıflandırma doğruluğu üretebilen kontrollü sınıflandırma yöntemleri kullanımında yeryüzünü temsil eden örnekleme alanlarından yararlanılmaktadır. Yersel olarak örnekleme alanlarına ait bilgilerin toplanması pahalı ve karmaşık işlemleri içermektedir. Diğer taraftan düşük konumsal çözünürlüğe sahip veya karışık pikselleri içeren görüntüler üzerinden yeterli sayıda eğitim alanının belirlenmesi güçleşmektedir. Oluşturulan eğitim veri setinin boyutu sınıflandırma sonucu üretilen tematik haritaların doğruluğunu etki eden önemli bir faktördür. Sınıflandırıcılar verinin veya özellik uzayının sınıflara bölünmesinde farklı metotlar kullandığından, belirli bir sınıflandırma probleminin çözümünde kullanılacak eğitim veri seti boyutu sınıflandırma doğruluğunu etkileyebilmektedir (Foody et al., 2006; Chi et al., 2008). Örneğin en çok benzerlik yönteminde eğitim alanlarını oluşturan sınıflar için olasılık fonksiyonları hesaplanmakta ve buna göre bir pikselin hangi sınıfa daha yakın olduğu belirlenebilmektedir. Diğer taraftan paralel kenar sınıflandırıcısı için histogram yardımıyla sınıflara ait alt ve üst sınırların tanımlanması önem arz ederken, en yakın uzaklık yönteminde sınıfların ortalaması önemlidir. Söz konusu istatistiksel yöntemlerin aksine son yıllarda kullanılmaya başlanan karar ağaçları, yapay sinir ağları ve destek vektör makineleri gibi ileri sınıflandırma yöntemleri ise sınıflar arasındaki sınır oluşturan piksellerin belirlenmesini esas almaktadır (Huang et al., 2002).

Bu çalışmada, destek vektör makineleri ile 2009 tarihinde kaydedilen Landsat TM uydu görüntüsü kullanılarak Gebze ilçesinin genel arazi kullanımı ve arazi örtüsünün tespiti amaçlanmıştır. Destek vektör makinelerinin eğitiminde farklı boyutta altı eğitim seti (her bir sınıf için 100, 250, 500, 1.000, 1.500 ve 2.000 piksel) kullanılmış ve test verisi (her bir sınıf için 5.000 piksel) için elde edilen genel sınıflandırma doğrulukları analiz edilmiştir. Yöntemin farklı boyuttaki eğitim veri setleri için sınıflandırma performansı en çok benzerlik yöntemi ile karşılaştırılmış ve elde edilen genel

tematik haritaların üretilmesinde kontrollü sınıflandırma tekniklerinden olan en çok benzerlik (EÇB) ve destek vektör makineleri (DVM) yöntemleri kullanılmıştır.

Çalışmada kullanılan yöntemlerin farklı eğitim seti için sınıflandırma performanslarının değerlendirilmesinde öncelikli olarak sınıflandırma sonucunda elde edilen genel doğruluklar kullanılmıştır. Bu değerlendirmelerin yanında sınıflandırıcıların (DVM ve EÇB) eğitiminde kullanılan altı farklı veri seti için hesaplanan performans farklarının istatistiksel olarak anlamlılığı Z testi ile analiz edilmiştir. Z testi, sınıflandırma sonucu elde edilen Kappa değerlerinin karşılaştırılması amacıyla kullanılan istatistiksel bir testtir. İki farklı sınıflandırma yöntemi veya iki farklı eğitim seti için elde edilen genel sınıflandırma doğruluğu arasındaki farkın istatistiksel olarak anlamlı olup olmadığının tespitinde hesaplanan Kappa değerlerinin karşılaştırılması esasına dayanmaktadır (Foody, 2004). Z istatistik değeri aşağıdaki şekilde hesaplanarak Kappa değerleri arasındaki farkın anlamlılığı test edilir.

$$Z = \frac{K_1 - K_2}{\sqrt{\sigma(K_1) + \sigma(K_2)}} \quad (1)$$

Bu eşitlikte K_1 ve K_2 karşılaştırılan iki Kappa değerini, $\sigma(K_1)$ ve $\sigma(K_2)$ ise Kappa değerleri için hesaplanan varyans değerlerini ifade etmektedir. Hesaplanan Z değeri önceden belirlenen güven aralığındaki ($Z_{\alpha/2}$) kritik değer ile karşılaştırılır. Hesaplanan Z değeri %95 güven aralığındaki $Z = 1.96$ kritik değerinden büyük olduğunda iki sınıflandırma sonucu arasındaki farkın istatistiksel olarak anlamlı olduğu söylenebilir. Bu durum iki bağımsız Kappa değerinin istatistiksel olarak farklı olduğunu, dolayısıyla iki sınıflandırıcıya ait performansların birbirinden farklı olduğunu göstermektedir.

3.1. En Çok Benzerlik Sınıflandırıcısı

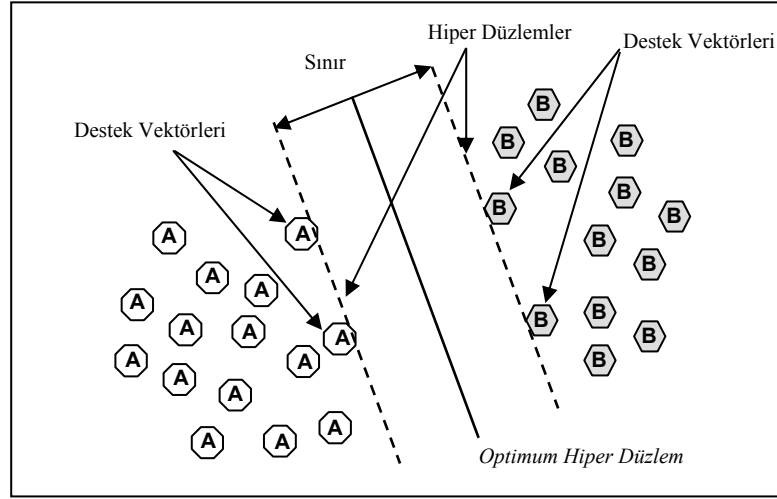
En çok benzerlik (EÇB) yöntemi uzaktan algılanmış görüntülerin sınıflandırılmasında yaygın olarak kullanılan istatistiksel bir sınıflandırma yöntemidir. Yöntem sınıflandırma işleminin gerçekleştirilmesinde ortalama değer, varyans ve kovaryans gibi istatistiksel değerleri dikkate almaktadır. EÇB sınıflandırıcısı, eğitim örneklerini oluşturan sınıflar için olasılık fonksiyonları hesaplar ve her bir pikselin hangi sınıfa daha yakın olduğunu tespit eder. Bir piksele ait sınıf etiketi hesaplanan olasılıklara göre, pikselin en yüksek olasılıklı sınıfa atanması ile belirlenir. EÇB yönteminde, eğitim verilerinin ve sınıfları oluşturan piksellerin normal dağılımında olduğu kabul edilir. Yöntem sınıflandırmada, her sınıf için oluşturulacak varyans-kovaryans matris değerlerini de dikkate alarak, örnek piksellerin özellik uzayındaki dağılımlarını dikkate almaktadır (Mather, 1999). Bir pikselin p sayıdaki bant değerlerini içeren x vektörünün bir k sınıfında olma olasılığı aşağıdaki şekilde hesaplanır.

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

Bu eşitlikte; $P(x)$, olasılık değerini; S_i , i . sınıf için varyans-kovaryans matrisini; $| \cdot |$, matrisin determinantını ifade etmektedir.

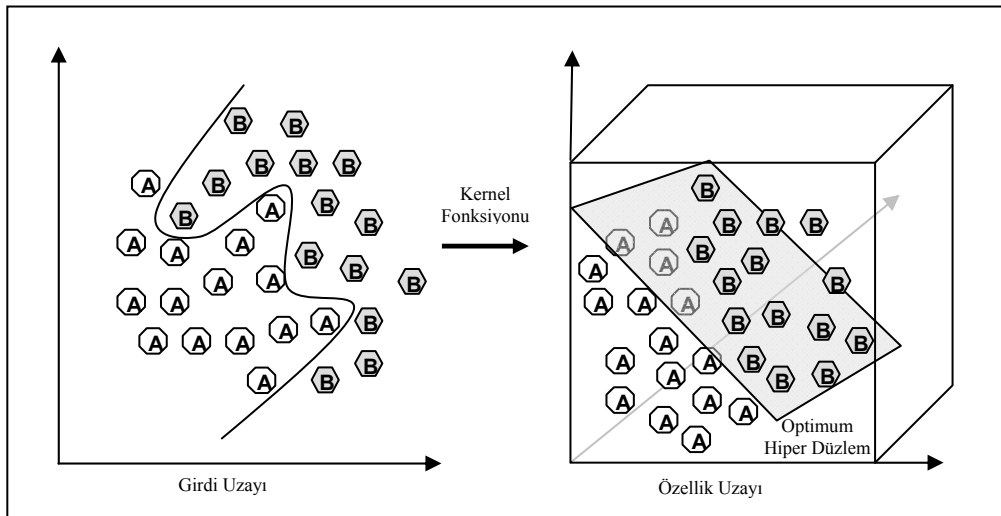
3.2. Destek Vektör Makineleri Sınıflandırıcısı

Destek vektör makineleri (DVM) uzaktan algılanmış görüntülerin sınıflandırılmasında son yıllarda kullanılan etkili bir sınıflandırma algoritmasıdır (Foody and Mathur, 2004; Dixon and Candade, 2008). DVM'nin çalışma prensibi genel olarak iki sınıfa ait verileri birbirinden en uygun şekilde ayıran karar sınırlarının (hiper düzlemlerin) belirlenmesidir (Vapnik, 2000). Doğrusal olarak ayrılabilen iki sınıflı bir verinin sınıflandırılması DVM için en temel sınıflandırma problemidir. Bu problemin çözümü için DVM iki sınıf arasındaki ayrımı en iyi yapan ve sınıflar arasındaki sınırın maksimum olduğu optimum bir hiper düzlemi belirlemeye çalışır (Şekil 2). Optimum hiper düzlem, her bir sınıfa ait piksellerin hiper düzleme olan uzaklıklarını maksimum hale getirir (Huang et al., 2002). Hiper düzlemlere en yakın pikseller iki sınıf arasındaki sınırı belirleyen destek vektörlerini oluştururlar.



Şekil 2. Doğrusal olarak ayrılabilen veriler için optimum hiper düzlem ve destek vektörleri.

Uzaktan algılanmış görüntülerin sınıflandırılması problemi de olduğu gibi doğrusal olarak ayrılamayan verilerin sınıflandırılmasında hiper düzlemlerin doğrusal eşitliklerle belirlenmesi mümkün değildir. Bu problemin çözümü için, doğrusal olarak ayrılabilen veriler için oluşturulan eşitlikler doğrusal olarak ayrılamayan veriler için genelleştirilmiştir (Cortes and Vapnik, 1995). Bu durumda destek vektör makineleri, sınıflar arasındaki sınırı maksimuma getirirken hatalı sınıflandırılmış piksellerin sayısını minimum hale getirecek bir hiper düzlem bulmaya çalışır (Pal and Mather, 2005). Bu noktada kullanıcı tarafından belirlenen bir düzenleme parametresi ile sınırın maksimum hale gelmesi ve hatanın minimum hale gelmesi kriterleri arasındaki dengeleme sağlanmaktadır. Doğrusal eşitliklerle hiper düzlemin belirlenememesi durumunda veri seti kernel fonksiyonları olarak bilinen doğrusal olmayan fonksiyonlar yardımıyla daha yüksek boyutlu bir uzayda görüntülenir (Şekil 3). Destek vektör makinelerinin kullandığı bu fonksiyonlar doğrusal olmayan dönüşümler yapılabilmekte ve verilerin yüksek boyutta doğrusal olarak ayrılabilmesine imkan sağlamaktadır (Vapnik, 2000). Literatürde birçok kernel fonksiyonu tanımlanmış olmasına rağmen, radyal tabanlı fonksiyon (RTF) problem çözümündeki etkinliği ve yüksek sınıflandırma doğruluğu üretmesi nedeniyle en çok tercih edilen kernel fonksiyonudur (Huang et al., 2002; Melgani and Bruzzone, 2004). RTF kerneli kullanımında kullanıcı tarafından belirlenen iki parametre (düzenleme parametresi ve kernel genişliği) söz konusudur. Söz konusu parametrelerin alacağı değerler DVM ile elde edilecek sınıflandırma doğruluğunu direkt olarak etkilemektedir (Kavzoglu and Colkesen, 2009; Pal and Foody, 2010). Bu nedenle DVM'nin eğitimi sırasında optimum parametre değerlerinin belirlenerek sınıflandırma işlemi gerçekleştirilmelidir.



Şekil 3. Doğrusal olarak ayrılamayan verilerin kernel fonksiyonu ile yüksek boyutlu uzayda görüntülenmesi.

4. UYGULAMA

2009 tarihli Landsat TM uydu görüntüsünün sınıflandırması için ilk olarak altı arazi örtüsü sınıfını temsil eden örnekleme alanları belirlenmiştir. Söz konusu örnekleme alanlarından yararlanarak MATLAB yazılımında hazırlanan bir program ile rastgele örnekleme prensibinden hareketle eğitim ve test verileri oluşturulmuştur. Destek vektör makinelerinin (DVM) sınırlı sayıdaki eğitim verisi için sınıflandırma performansının belirlenmesi amacıyla sınıflandırıcının eğitiminde kullanılmak üzere farklı boyutta rastgele seçilmiş altı eğitim seti (her bir sınıf için 100, 250, 500, 1.000, 1.500 ve 2.000 piksel) hazırlanmıştır. Söz konusu eğitim setleri ile oluşturulan DVM modellerinin geçerliliği ve sınıflandırma performansının tespiti için her sınıfa karşılık 5.000 adet rastgele seçilmiş pikselden oluşan test veri seti oluşturulmuştur. Her sınıf için eşit miktarda örnek piksel seçilerek sınıflandırma sonucunda elde edilecek sonuçların objektif ve karşılaştırılabilir olması amaçlanmıştır. DVM yönteminin söz konusu veri setleri için sınıflandırma performansı en çok benzerlik yönteminin performansı ile karşılaştırılarak sonuçlar istatistiksel olarak analiz edilmiştir.

Altı farklı eğitim seti ile en çok benzerlik yönteminin (EÇB) eğitimi yapılmış ve sınıflandırmaya esas olacak modeller oluşturulmuştur. Söz konusu modellerin geçerliliği test veri seti kullanılarak analiz edilmiş, elde edilen genel sınıflandırma doğrulukları ve kappa değerleri Tablo 1’de gösterilmiştir. Tablodan da görüleceği üzere EÇB yönteminin eğitimi toplam 600 piksel (her bir sınıf için 100 piksel) kullanılarak gerçekleştirildiğinde en düşük sınıflandırma doğruluğu (%89,89) elde edilmiştir. Diğer taraftan toplam 3.000 pikselin (her bir sınıf için 500 piksel) kullanıldığı eğitim verisi ile oluşturulan EÇB modeli test veri setine uygulandığında en yüksek sınıflandırma doğruluğu %90,70 olarak hesaplanmıştır. Elde edilen sınıflandırma sonuçları eğitim veri setinin boyutundaki artışın EÇB yönteminin sınıflandırma performansında pozitif bir etkisinin olduğunu göstermektedir. EÇB yönteminin sınıflandırma performansındaki bu durum, yöntemin her veri seti için yeni bir olasılık fonksiyonu ve olasılık hesaplaması, oluşturulan varyans-kovaryans matrislerinin birbirinden farklı olması gibi nedenlerden kaynaklanabileceği düşünülmektedir.

Tablo 1. En çok benzerlik ve destek vektör makineleri kullanılarak farklı boyuttaki eğitim setleri için elde edilen sınıflandırma sonuçları.

Sınıflandırma Yöntemi	En çok benzerlik		Destek vektör makineleri		
	Genel Doğruluk (%)	Kappa Değeri	Genel Doğruluk (%)	Kappa Değeri	
Eğitimde kullanılan toplam piksel sayısı	600	89,89	0,879	92,44	0,909
	1.500	90,21	0,883	92,70	0,912
	3.000	90,70	0,888	92,83	0,914
	6.000	91,37	0,896	93,11	0,917
	9.000	91,60	0,899	93,20	0,918
	12.000	91,36	0,896	92,86	0,914

Destek vektör makineleri ile yapılacak sınıflandırma öncesinde kullanıcı tarafından bir takım parametrelerin belirlenmesi gerekmektedir (Kavzoğlu ve Çölkesen, 2010). Bu parametreler seçilecek Kernel fonksiyonuna göre değişiklik göstermektedir. Bu çalışmada DVM ile yapılan sınıflandırmada radyal tabanlı fonksiyon kerneli kullanılmıştır. Raydal tabanlı fonksiyon kullanılması durumunda kullanıcı tarafından belirlenmesi gereken parametreler düzenleme parametresi ve kernel genişliğidir. Altı farklı eğitim seti için kullanılacak en uygun parametreler çapraz-geçerlilik yöntemiyle ayrı ayrı belirlenmiş ve sınıflandırmaya esas olacak DVM modelleri oluşturulmuştur. Söz konusu modeller test veri setine uygulanarak Tablo 1’de gösterilen sınıflandırma sonuçları elde edilmiştir. Tablodan da görüleceği üzere eğitim veri setinin boyutundaki artışa karşılık destek vektör makinelerinin sınıflandırma performansında yaklaşık %1’lik bir iyileşme gözlemlenmiştir. En düşük sınıflandırma

doğruluğu (%92,44) toplam 600 pikselin kullanıldığı eğitim seti ile elde edilirken, %93,20 olarak hesaplanan en yüksek doğruluk toplam 9.000 pikselin kullanıldığı eğitim seti için hesaplanmıştır.

Eğitim setindeki artışların sınıflandırma performansına etkisinin istatistiksel olarak anlamlılığının tespiti için Z testi kullanılmıştır ve elde edilen istatistik değerler Tablo 2’de gösterilmiştir. Eğitim için kullanılan toplam piksel sayıları sırasıyla 600–1.500, 1.500–3.000, 3.000–6.000, 6.000–9.000 ve 9.000–12.000 şeklinde gruplandırılarak, EÇB ve DVM yöntemlerinin bu aralıklardaki performans farklılıkları Z testi ile analiz edilmiştir. Tablodan da görüleceği üzere EÇB’nin eğitiminde 3.000 piksel kullanımı ile 6.000 piksel kullanımı ile elde edilen sınıflandırma sonuçlarına Z testi uygulandığında, 2.70 test değeri hesaplanmıştır. Bu değer 0,05 güven aralığındaki $Z = 1.96$ kritik değerinden büyük olduğundan genel doğruluklar arasındaki farkın istatistiksel olarak anlamlı olduğu ifade edilebilir. Bu durum EÇB’nin 3.000–6.000 piksel değerleri için sınıflandırma performansının farklı olduğunu göstermektedir. Z test değerinin hesaplandığı diğer tüm aralıklar da ise DVM ve EÇB’nin sınıflandırma doğrulukları arasındaki fark istatistiksel olarak anlamsız olduğu görülmüştür. Örneğin 600–1.500 aralığı için, DVM’nin 600 pikselle eğitimi sonucunda elde edilen sınıflandırma doğruluğu (%92,40) ile 1.500 pikselle eğitimi sonucunda elde edilen doğruluk (%92,70) arasındaki fark istatistiksel olarak anlamsızdır. Diğer bir ifadeyle DVM’nin söz konusu iki farklı eğitim seti için sınıflandırma performansının istatistiksel olarak aynı olduğu ifade edilebilir.

Tablo 2. DVM ve EÇB’nin farklı eğitim setleri için performans analizinde hesaplanan Z test değerleri

	Z test değerleri				
	600–1.500	1.500–3.000	3.000–6.000	6.000–9.000	9.000–12.000
EÇB	1.24	1.95	2.70	0.99	1.00
DVM	1.13	0.56	1.30	0.43	1.57

Tablo 2’de gösterilen beş test aralığına ilave olarak EÇB ve DVM yöntemlerinin en yüksek ve en düşük sınıflandırma sonuçlarını ürettiği 600 ve 9.000 pikselden oluşan eğitim veri setleri için performans farklılıkları da Z testi kullanılarak analiz edilmiştir. Analiz sonucunda EÇB yöntemi için 6.86 ve DVM için 3.42 Z test değerleri hesaplanmıştır. Bu değerler $Z = 1.96$ kritik değerinden büyük olduğundan genel doğruluklar arasındaki farkın istatistiksel olarak anlamlı olduğu ifade edilebilir. Bu sonuç DVM ve EÇB yöntemlerinin sınıflandırma performanslarındaki iyileşmenin eğitim setindeki artışa paralel olduğunu göstermektedir.

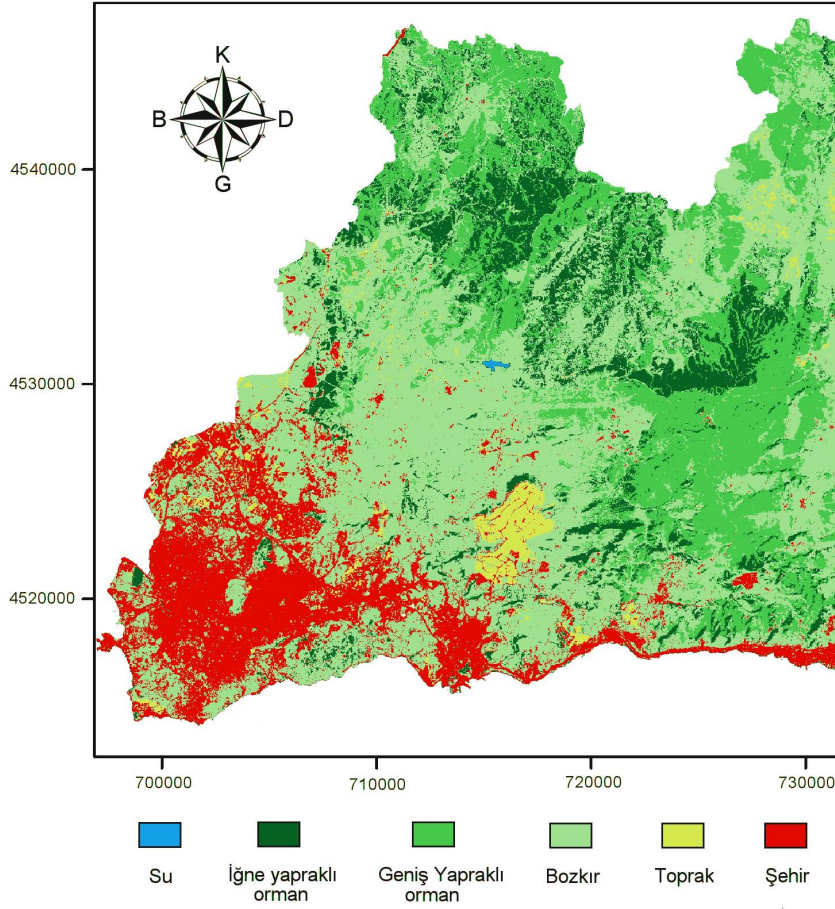
Çalışmada kullanılan altı farklı eğitim seti için EÇB ve DVM yöntemlerinin sınıflandırma performansları birbirleri ile karşılaştırıldığında, DVM’nin EÇB yönteminden yaklaşık %3 daha doğru sonuçlar ürettiği görülmüştür. Sınıflandırma doğrulukları arasındaki bu farkların anlamlılığının Z testi kullanılarak analiz edilmiş ve elde edilen Z test değerleri Tablo 3’te gösterilmiştir. Tablodan da görüleceği üzere altı farklı eğitim veri seti için hesaplanan istatistiksel değerler $Z = 1.96$ kritik değerinden büyük olduğundan hesaplanan genel doğruluklar arasındaki farklar istatistiksel olarak anlamlıdır. Bu durum DVM’nin bu çalışmada değerlendirmeye alınan altı farklı eğitim seti için EÇB’den daha doğru sonuçlar ürettiğini desteklemektedir.

Tablo 3. DVM ve EÇB yöntemlerinin performanslarının istatistiksel olarak analizi için hesaplanan Z test değerleri

	Z test değerleri					
	600	1.500	3.000	6.000	9.000	12.000
EÇB - DVM	10.46	10.36	8.98	7.58	7.02	6.45

Oluşturulan DVM ve EÇB modelleri ile Landsat TM görüntüsü sınıflandırılmış ve Gebze ilçesine ait genel arazi kullanım şekillerini ve arazi örtüsünü gösteren tematik haritalar üretilmiştir. Söz konusu

tematik haritalardan DVM'nin toplam 9.000 piksel kullanılarak oluşturulan modeli ile üretileni Şekil 4'de gösterilmiştir.



Şekil 4. Landsat TM görüntüsünün DVM ile sınıflandırılması sonucu elde edilen tematik harita.

5. SONUÇLAR

Uzaktan algılanmış görüntüler yardımıyla arazi örtüsü ve kullanım şekilleri gibi yeryüzünün çeşitli özelliklerini gösteren tematik haritaların üretilmesi üzerinde yoğun olarak çalışılan araştırma konularından birisidir. Kontrollü sınıflandırma yöntemlerinden en çok benzerlik ve en yakın komşuluk gibi istatistiksel kabule dayalı yöntemler karmaşık yapıdaki veriler için tutarsız sonuçlar üretebilmektedir. Bu problemlerin çözümü ve sınıflandırma doğruluğunu artırılmasına yönelik yapay sinir ağları, karar ağaçları ve bulanık mantık gibi ileri sınıflandırma yöntemleri öne sürülmüş ve istatistiksel yöntemlere göre daha başarılı sonuçlar elde edilmiştir. Destek vektör makineleri (DVM) de son yıllarda uzaktan algılanmış görüntülerin sınıflandırılmasında etkin bir şekilde kullanılan ileri sınıflandırma algoritmalarından birisidir.

Bu çalışmada DVM'nin farklı boyuttaki eğitim setleri için sınıflandırma performansı araştırılmış ve elde edilen sonuçlar en çok benzerlik yöntemi ile karşılaştırılarak istatistiksel olarak analiz edilmiştir. Bu analiz sırasında 2009 tarihli Landsat TM uydu görüntüsü üzerinden Gebze ilçesinin genel arazi kullanımını ve arazi örtüsünü temsil eden örneklem alanları belirlenerek DVM ve EÇB'nin eğitiminde kullanılmak üzere altı farklı veri seti oluşturulmuştur. DVM'nin altı eğitim veri seti için sınıflandırma performansı incelendiğinde en düşük sayıdaki eğitim seti (toplam 600 piksel) kullanılarak oluşturulan DVM modeli ile %92,44'lük sınıflandırma doğruluğuna ulaşılırken, en yüksek sayıdaki eğitim veri seti (toplam 12.000 piksel) için sınıflandırma doğruluğu %92,86 olarak hesaplanmıştır. EÇB yöntemi ile yapılan sınıflandırma sonucunda ise en yüksek sınıflandırma doğruluğunun %91,60, en düşük sınıflandırma doğruluğunun ise %89,89 olduğu görülmüştür. Her iki yöntemin farklı eğitim seti için sınıflandırma doğrulukları karşılaştırıldığında DVM ve EÇB'nin sınıflandırma performanslarındaki iyileşmeler eğitim veri setinin boyutundaki artışla paralellik gösterdiği belirlenmiştir. Bu sonuç DVM makinelerinin sınırlı sayıda eğitim veri seti için EÇB

yönteminden daha iyi olduğunu göstermektedir. DVM ve EÇB yöntemleri için söz konusu performans değişimlerin istatistiksel anlamlılığı Z testi kullanılarak analiz edilmiştir. İstatistiksel analizde her iki yöntemin performansı oluşturulan beş grup (600–1.500, 1.500–3.000, 3.000–6.000, 6.000–9.000 ve 9.000–12.000) içerisinde değerlendirilmiştir. Elde edilen sonuçlar, toplam 3.000 piksel kullanılarak oluşturulan EÇB modelinin ürettiği sınıflandırma doğruluğunun, 6.000 piksel kullanılarak elde edilen sınıflandırma doğruluğundan farklı olduğunu, diğer aralıktaki değerler için benzer olduğunu göstermiştir. DVM ve EÇB yöntemlerinin birbirlerine göre performansları karşılaştırıldığında ise DVM'nin değerlendirmeye alınan altı eğitim seti içinde EÇB'den daha doğru sınıflandırma sonuçları ürettiği belirlenmiştir. Her iki yöntemin sınıflandırma doğruluğu arasındaki performans farklılıklarının anlamlılığı Z testi ile analiz edilmiştir. Özellikle çalışmada kullanılan en az sayıda eğitim pikselini içeren toplam 600 pikseli veri seti için DVM'nin sınıflandırma performansının EÇB'ye göre %3 daha iyi olduğu ve bu performans farkının istatistiksel olarak anlamlı olduğu görülmüştür. Yapılan performans analizleri ve elde edilen istatistiksel test sonuçları destek vektör makinelerinin sınırlı sayıda eğitim veri seti için sınıflandırma performansının yüksek olduğunu destekler niteliktedir.

KAYNAKLAR

- 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*, Second Edition (New York: The Guilford Press).
- Chi, M., Feng, R., Bruzzone, L.,** 2008, Classification of hyperspectral remote-sensing data with primal SVM for small-sized training dataset problem, *Advance in Space Research*, 41(1), 1793–1799.
- Cortes, C., Vapnik, V.,** 1995, Support-vector networks, *Machine Learning*, 20(3), 273-297.
- Dixon, B., Candade, N.,** 2008, Multispectral landuse classification using neural networks and support vector machines: one or the other, or both?, *International Journal of Remote Sensing*, 29(4), 1185-1206.
- Foody, G.M.,** 2004, Thematic map comparison: Evaluating the statistical significance of differences in classification accuracy, *Photogrammetric Engineering and Remote Sensing*, 70(5), 627-633.
- 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.
- Foody, G.M., Mathur, A., Sanchez-Hernandez, C., Boyd, D.S.,** 2006, Training set size requirements for the classification of a specific class, *Remote Sensing of Environment*, 104(1), 1-14.
- Huang, C., Davis, L.S., Townshend, J.R.G.,** 2002, An assessment of support vector machines for land cover classification, *International Journal of Remote Sensing*, 23(4), 725-749.
- Imbernon, J.,** 1999, Pattern and development of land-use changes in the Kenyan highlands since the 1950s, *Agriculture Ecosystems & Environment*, 76(1), 67-73.
- Imura, H., Chen, J., Kaneko, S., Matsumoto, T.,** 1999, Analysis of industrialization, urbanization and land-use change in East Asia according to the DSPER framework. In *proceedings of 1999 NIES Workshop on Information Bases and Modelling for Land-use and Land-cover Change in East Asia*. Tsukuba, Japan.
- Jain, A.K., Duin, R.P.W., Mao, J.C.,** 2000, Statistical pattern recognition: A review, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(1), 4-37.
- Kavzoglu, T., Colkesen, I.,** 2010, Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi, *Harita Dergisi*, 144(7), 73-82.
- 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.
- Lambin, E.F., Turner, B.L., Geist, H.J., Agbola, S.B., Angelsen, A., Bruce, J.W., Coomes, O.T., Dirzo, R., Fischer, G., Folke, C., George, P.S., Homewood, K., Imbernon, J., Leemans, R., Li, X.B., Moran, E.F., Mortimore, M., Ramakrishnan, P.S., Richards, J.F., Skanes, H., Steffen, W., Stone, G.D., Svedin, U., Veldkamp, T.A., Vogel, C., Xu, J.C.,** 2001, The causes of land-use and land-cover change: moving beyond the myths, *Global Environmental Change-Human and Policy Dimensions*, 11(4), 261-269.
- Lillesand, T.M., Kiefer, R.W., Chipman, J.W.,** 2008, *Remote Sensing and Image Interpretation, Sixth Edition*, (New York: John Wiley & Sons).
- 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 Remotely Sensed Images*, Second Edition (Chichester: John Wiley & Sons).
- 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.

- Pal, M., Foody, G.M.**, 2010, Feature selection for classification of hyperspectral data by SVM, *IEEE Transactions on Geoscience and Remote Sensing*, 48(5), 2297–2307.
- 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 Thesis*, The University of Arizona, USA.
- Rogan, J., Franklin, J., Stow, D., Miller, J., Woodcock, C., Roberts, D.**, 2008, Mapping land-cover modifications over large areas: A comparison of machine learning algorithms, *Remote Sensing of Environment*, 112(5), 2272-2283.
- Vapnik, V.N.**, 2000, *The Nature of Statistical Learning Theory*, Second Edition (New York: Springer-Verlag).
- Wang, Y., Jamshidi, M.**, 2004, Fuzzy logic applied in remote sensing image classification, *2004 IEEE International Conference on Systems, Man & Cybernetics*, 1-7, 6378-6382.
- Zhong, Y.F., Zhang, L.P., Gong, J.Y., Li, P.X.**, 2007, A supervised artificial immune classifier for remote-sensing imagery, *IEEE Transactions on Geoscience and Remote Sensing*, 45(12), 3957-3966.