

DESTEK VEKTÖR MAKİNELERİ TEKNİĞİ İLE SINIFLANDIRMA: RAPİDEYE ÖRNEĞİ

M. Üstüner^a, F. Balık Şanlı^{a,*}, F. Bektaş Balçık^b, M.T. Esetlili^c

^a YTU, İnşaat Fakültesi, Harita Mühendisliği Bölümü 34220 Esenler, İstanbul - (mustuner, fbalik)@yildiz.edu.tr

^b İTÜ, İnşaat Fakültesi, Geomatik Mühendisliği Bölümü 34469 Maslak, İstanbul - bektasfi@itu.edu.tr

^c Ege Üniversitesi, Ziraat Fakültesi, 35100 Bornova-İzmir - tolga.esetlili@ege.edu.tr

ANAHTAR SÖZCÜKLER: Arazi kullanım şekli/örtüsü, RapidEye, Red Edge, Sınıflandırma, DVM

ÖZET:

Uzaktan algılama, tarım alanlarının etkin ve doğru planlanmasında önemli bir role sahiptir. Çok bantlı yüksek çözünürlüklü uydu görüntüleri arazi kullanımı/örtüsü vb. tematik haritaların üretilmesinde sağladığı spektral, mekansal ve zamansal zenginlik nedeniyle yaygın olarak kullanılmaktadır. Uygun bant kombinasyonunun seçiminin yanı sıra uygulanacak algoritma/yöntem de elde edilecek olan bilginin doğruluğu ve kalitesini önemli ölçüde etkileyecektir. Bu çalışmada son yıllarda tarım, bitki örtüsü, orman ve sulak alanların haritalanması aşamasında yaygın olarak kullanılan ve başarılı sonuçlar veren RapidEye çok bantlı uydu görüntüsü kullanılmıştır. RapidEye uydu görüntüsünün mekansal çözünürlüğü 5 m'dir ve spektrumun 400-850 nm aralığında algılama yapan 5 farklı spektral banda sahiptir. 8 Ekim 2010 tarihli RapidEye görüntüsünün sınıflandırılmasında, makine öğrenmesi algoritmalarından Destek Vektör Makineleri (Support Vector Machines) yöntemi kullanılmıştır. Destek vektör makineleri parametrik olmayan yapısı ve uydu görüntülerinin sınıflandırılmasında yüksek sınıflandırma kabiliyeti nedeniyle tercih edilmiştir. Sınıflandırma işleminde, destek vektör makinelerinin iki farklı kernel (çekirdek) fonksiyonu kullanılarak gerçekleştirilmiştir. Çalışma alanı Menemen ovasında yer almaktadır. Tarım arazileri ile kaplı alanda mısır (I. ve II. evre), mera, pamuk, bostan, yapay yüzeyler ve su yüzeyi olmak üzere 7 farklı sınıf belirlenmiştir. Bu sınıf alanlarını uydu görüntüsünden belirleyebilmek amacıyla iki yönlü değerlendirme yapılmıştır. Birincisi RapidEye uydu görüntüsünün bantları kullanılarak 2 farklı veri seti oluşturulmuştur. Birinci veri seti 5 spektral bandın hepsini içerirken, ikinci veri seti rededge (kırmızı kenar) bandı hariç diğer 4 spektral banttan oluşmaktadır. Böylelikle rededge bandının sınıflandırma doğruluğuna etkisi araştırılmıştır. Diğer yandan destek vektör makineleri kullanılarak yapılan sınıflandırmada farklı parametreler denenmiştir, en iyi sonucu veren parametreler araştırılmıştır. Sınıflandırma için test alanları görüntü alımı ile eş zamanlı gerçekleştirilen arazi çalışması ile belirlenmiştir ve el GPS'i kullanılarak konumları tespit edilmiştir. Hata matrisi kullanılarak sınıflandırılmış iki veri seti için genel doğruluk ve Kappa istatistikleri hesaplanmış ve sonuçlar karşılaştırılmıştır. Rededge bandının sınıflandırma doğruluğunu arttırdığı tespit edilmiştir.

KEY WORDS: Land use/cover, RapidEye, RedEdge, Classification, DVM

ABSTRACT:

Remote sensing plays an important role in the efficiently and accurately planning of agricultural lands. Multi-spectral high-resolution satellite images with different spectral, temporal and spatial features are used widely for producing thematic maps, e.g. land use/cover maps. As well as a proper band combination selection, applying an appropriate algorithm / method will significantly affect the quality and accuracy of the extracted information from the satellite images. In this study, RapidEye multispectral satellite image, which is widely used and presents successful results in agriculture, vegetation, forests and wetlands mapping in recent years, was used. It represents a constellation of five mini-satellites and provides high-resolution multi-spectral imagery in five optical bands in the 400-850 nm range. For the classification of RapidEye image acquired on 8 October, one of the machine learning algorithms namely Support Vector Machines (SVM) method was used. It is preferred due to the fact that SVM is a non-parametric classification technique based on statistical learning theory and it has been started to apply on image classification problems successfully. In the SVM classification was performed using two different kernel functions. The study area is located in the Menemen Plane. In the study area which is having agricultural land cover pattern, seven land use categories includes five crop types, namely maize (I and II crop rotation), pasture, cotton, melon fields with artificial surfaces and water bodies are distinguished. In this study as well as performance of SVMs, the affect of red-edge channel of Rapid Eye satellite imagery to the classification accuracy was investigated. For this purpose two different data sets generated with different band combinations are classified with unsupervised classification method. While first data set is a composite image produced by the 5 original band of Rapid Eye image, second data set is a composite of 4 band excluding Rededge channel. On the other hand a set of SVMs with different combinations of kernel types, parameters and error penalty were constructed for analyzing the performance of SVMs. Test and training areas for the classification determined by the field survey carried out simultaneously with image acquisition and the locations of the samples have been identified using a hand-held GPS. For the classified data sets the overall accuracy of the error matrix and Kappa statistics were calculated and the results were compared. It is determined that Rededge band increases the accuracy of the classification, and among the all SVM models radial basis function kernels resulted with the best overall and kappa accuracy (91.3% and 0.8974) for the land use classification.

* Corresponding author. This is useful to know for communication with the appropriate person in cases with more than one author.

1.GİRİŞ

Arazi kullanım bilgisi, ekonomiye dayalı politikaların ve çevresel konuların ele alınmasında önemli bir bileşendir. Ulusal ve küresel anlamda, tarım alanlarının sürekli ve hızlı bir şekilde izlenebilmesi ve sürdürülebilir tarım politikalarının oluşturulabilmesi amacıyla uzaktan algılama tekniği son 30 yıldır işlerle kullanılmaktadır. Uydu görüntülerinin sınıflandırılması ve analizi, uzaktan algılamada bilgi çıkarımı amacıyla kullanılan en yaygın yöntemlerden birisidir. Özellikle son 10 yıldır çoğalan yüksek çözünürlüklü uydu verileri ve gelişmiş sınıflandırma algoritmalarının da kullanılması ile elde edilen bilgilerin doğruluğu ve güvenilirliği giderek artmaktadır. Arazi örtüsünün/kullanım şeklinin uzaktan algılama tekniği kullanılarak haritalanması ise en genel şekli ile görüntünün her bir pikselinin yansıma ve radyans değerinin belirlenen sayıda sınıfa atanması şeklinde gerçekleştirilir (Huang vd. 2001). Ancak, özellikle geniş alanlarda ve heterojen arazi kullanım şekillerinin ve arazi örtüsünün belirlenmesinde uzaktan algılama verileri kullanılarak üretilen tematik haritaların doğrulukları karışık piksel probleminden dolayı azalmaktadır. Sınıflandırma doğruluğunu arttırmak amacı ile farklı uydulardan elde edilmiş sayısal görüntüler üzerinde çok sayıda sınıflandırma yöntemleri uygulanmıştır ve değişik derecelerde başarılar kaydedilmiştir (Townshend 1992, Hall vd. 1995). Bu anlamda literatüre bakıldığında en çok kullanılan sınıflandırma teknikleri arasında En Çok Benzerlik (EÇB)(MLC= Maximum Likelihood), Yapay Sinir Ağları (NNC=Neural Network Classification) (Pao 1989) ve Karar Ağaçları (DTC=Decision Tree Classifiers) (Quinlan 1993) yöntemlerinin kullanıldığı görülmektedir. En yaygın şekilde kullanılan teknik ise kolay uygulanabilmesi ve birçok ticari ve akademik yazılımlarda bulunabilmesi nedeniyle tercih edilen, parametrik bir yöntem olan En Çok Benzerlik tekniğidir (Wang 1990, Hansen vd. 1996). Sınıflandırma işleminde sınıflar eğitim verisinin istatistiksel tanımına göre oluşturulmaktadır. Sınıfları temsil eden referans piksellerin normal dağılımlı olması gerekmez ki çok fazla eğitim verisinin bulunmadığı durumlarda bu mümkün olmamaktadır (Jensen 2000). Ayrıca tüm sınıflara ait spektral çeşitliliği temsil edebilmesi için çok geniş coğrafi alanlarda örnekler alınması gerekmektedir (Mathur ve Foody 2007). Diğer istatistiksel sınıflandırma yöntemlerinden yapay sinir ağları da artık alternatif bir algoritma olarak uzaktan algılama da kullanılmaktadır (Tso ve Mather 2001). Yapay sinir ağları parametrik olmayan bir yaklaşım kullanarak en çok benzerlik yöntemine ait problemlerin üstesinden gelebilmektedir (Kavzoglu ve Mather 2003, Zhang vd. 2007). Verinin istatistiksel dağılımı üzerine bir varsayım yapmaması nedeniyle EÇB yönteminden daha iyi sonuçlar verdiği görülmektedir (Paola ve Schowengerdt 1995), yani EÇB yöntemindeki istatistiksel parametrelerin tahmininden kaynaklı problemler bu yöntemle elelenebilmektedir. Ancak yapay sinir ağlarının başarısı ağırlık ve uygulama algoritmalarının seçimine oldukça fazla bağımlı olması bu yöntemin en büyük kısıtlayıcılarından. Teorisinin üstün olmasına rağmen, yapay sinir ağları uygun olmayan konfigürasyonlar nedeniyle EÇB yönteminden çok daha düşük doğruluklarla sonuçlanabilmektedir (Kavzoglu ve Mather 1999, 2003). Diğer bir parametrik olmayan sınıflandırma tekniği ise karar ağaçları yöntemidir fakat eğitim verisini doğrudan sınıfları belirlemek için kullanılmaktadır. Karar ağaçları sınıflandırma yöntemi, sınıflandırma işlemini basit karar verme işlemlerinden oluşan çoklu adımlara bölmektedir (Safavian ve Landgrebe 1991). Daha sonrada her bir aşamada değişken sayısına bağlı olarak belirlenen tek değişkenli ve çok değişkenli karar ağacı kullanarak çözmektedir (Hansen vd. 2000, Brodley ve Utgoff 1995).

Yukarıda bahsedilen sınıflandırma yöntemleri ile karşılaştırıldığında istatistiksel öğrenme teorisine dayanan Destek Vektör Makineleri (DVM) arazi kullanım şekillerinin belirlenmesinde kullanılan en iyi kontrollü sınıflandırma yöntemi olarak literatürde yerini almaktadır.

1.1 Çalışmada Kullanılan Sınıflandırma Yöntemleri

Uzaktan algılamada, uydu görüntülerinin sınıflandırılması amacıyla bugüne kadar sayısız algoritma/yöntem kullanılmıştır ve hala da daha yüksek performansa erişmek için çalışmalar devam etmektedir. Yapılan çalışmada makine öğrenmesi algoritmalarından Destek Vektör Makineleri (Support Vector Machines) yöntemi kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Destek vektör makineleri parametrik olmayan yapısı ve uydu görüntülerinin sınıflandırılmasında yüksek sınıflandırma kabiliyeti nedeniyle tercih edilmiştir. Sınıflandırma işleminde, destek vektör makinelerinin iki farklı kernel (çekirdek) fonksiyonu kullanılarak gerçekleştirilmiştir. Ayrıca görüntü sınıflandırmada temel ölçüt olarak kabul edilen en çok benzerlik yöntemi de kullanılarak bir sınıflandırma gerçekleştirilmiş ve destek vektör makineleri uygulamalarının sonuçları ile karşılaştırılmıştır.

1.1.1 Destek Vektör Makinaları


Destek vektör makineleri (DVM) istatistiksel öğrenme teorisine dayalı parametrik olmayan bir sınıflandırma yöntemidir (Vapnik, 1995). DVM ikili sınıflandırmalar için geliştirilmiştir ve bu yöntem ile az sayıda örnekleme verisi ile doğru sınıflandırma sonuçları elde etmek mümkündür (Foody ve Mathur, 2004). Özellik uzayında sınıflar arasında ki sınırı belirlemek için optimum algoritmanın kullanıldığı bir yöntemdir. Başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması için tasarlanmış olan yöntem daha sonra çok sınıflı ve doğrusal olmayan verilerin sınıflandırılması için geliştirilmiştir. Temel olarak iki sınıfı birbirinden ayırabilen hiper düzlemin belirlenmesi prensibine dayanmaktadır (Vapnik, 1995). Farklı alanlarda kullanılan DVM ler uzaktan algılama alanında kullanımı ile ilgili çok sayıda çalışma gerçekleştirilmiştir (Zhu ve Blumberg 2002, Pal ve Mather 2005, Dixon ve Candade 2008, Kavzoglu ve diğ., 2009; Song vd. 2012). Bu yöntem kernel fonksiyonları kullanılarak çok boyutlu özellik uzayında çalışma özelliğine sahiptir ve yöntemden elde edilen sonuçlar seçilen kernel ve parametrelerin özelliklerine bağlıdır (Kavzoglu ve Çölkesen, 2009).

2.ÇALIŞMA ALANI VE KULLANILAN VERİLER

2.1 Çalışma alanı

İzmir Menemen Ovası'nın 7,5 x 6,7 km²'lik bir alanını örten ve büyük bir kısmı tarım arazileri ile kaplı olan aynı zamanda yerleşim alanlarını da içeren bir bölge çalışma alanı olarak belirlenmiştir. Kuzeyde Bakırçay havzası ve güneyde İzmir körfezi ile sınırlı bir alan kapsamaktadır. Ege Bölgesinin en uzun ırmaklarından birisi olan Gediz Irmağı'nın Ege Denizi'ne ulaştığı bölgede yer alan Menemen Ovası, Gediz deltası olarak da isimlendirilir (Şekil 1). Araştırma alanı genel olarak Ege Bölgesi ikliminin özelliklerini taşımaktadır. Bölge karakteri olarak yazlar sıcak ve kurak, kışlar ılık ve yağışlıdır. Yıllık yağış ortalaması 616 mm yıllık sıcaklık ortalaması 19° C'dir. Türkiye'nin batı sahillerinde yer alan ve yaklaşık 400 km² yüzölçümüne sahip Menemen Ovası'nın denize yakın bölümlerinde koruma altına alınmış sulak alanlar mevcuttur. Ovanın denize yakın bölgelerinde tuzlu ve alkali yani çorak topraklar yer alırken, orta ve doğu bölümlerinde verimli tarım

arazileri yer almaktadır. Sulama suyu sorunu olmayan Menemen Ovası'nın ürün desenini toprak özellikleri sınırlamaktadır. Buna bağlı olarak tuzlu alkali bölümlerinde tuza dayanıklı olan pamuk tarımı yapılabilirken diğer bölgelerinde mısır, domates, bağ, meyve tarımı ve kışlık sebze tarımı yapılmaktadır.



Şekil 1. Çalışma alanı Menemen Ovası


2.2 Kullanılan Veriler

Bu çalışmada, yüksek çözünürlüklü optik bir uydu olan RapidEye verisi kullanılmıştır. RapidEye uydusu 2009 yılı Şubat ayından itibaren yer yüzeyine ait geniş bir kapsama alanı ile veri sağlamaktadır. Şerit genişliği 77 km olup nadir noktasında tekrar geçiş sıklığı 5,5 gündür. Mekansal çözünürlüğü nadir de 6,5 m, radyometrik çözünürlüğü 16 bittir ve 630 km yükseklikte güneşle eş zamanlı bir yörünge üzerinde alım yapmaktadır. RapidEye görüntüleri aynı algılayıcıları içeren 5 adet mini uydu tarafından kaydedilmektedir. 400 nm ile 850 nm arasında kaydeden 5 spektral bandı vardır. RapidEye uydu görüntüsünü diğer çok bantlı uydu görüntülerinden ayıran en önemli özelliği standart bantların yanı sıra klorofil içeriğine duyarlı olan, elektromanyetik spektrumun 690-730 nm aralığında algılama yapan kırmızı kenar (RE/rededge) bandına sahip ilk yüksek çözünürlüklü uydu görüntüsü olmasıdır. Ayrıca literatürde son yıllarda yapılan çalışmalar incelendiğinde kırmızı kenar (rededge) bandının arazi kullanımı/örtüsü sınıflandırma işleminde sınıflandırma doğruluğunu artırdığı gözlenmiştir. RapidEye uydusu 'Level 1B' ve 'Level 3A' olmak üzere iki ayrı seviyede işlenmiş veri sunmaktadır. Seviye 1B ürünleri minimum düzeyde işlenmiş (örneğin geometrik olarak düzeltilmemiş) verilerdir. Seviye 3A ürünleri ise ortorektifiye edilmiş, radyometrik, geometrik, yersel düzeltmeleri yapılmış ve bir projeksiyon sistemine sahip verilerdir (Sandau, 2010).

Çalışma alanına ait Menemen ovasının tamamını kapsayan görüntü 8 Ekim 2010 tarihinde alınmıştır. Mekansal çözünürlüğü 5x5m olarak örnekleşmiş, 5 spektral banda sahip seviye 3A görüntüsü kullanılmıştır.

2.3 Yersel veri

Sınıflandırma işleminde kullanılmak üzere eğitim ve test alanları görüntü alımı ile eş zamanlı gerçekleştirilen arazi çalışması ile belirlenmiştir ve el GPS'i kullanılarak konumları tespit edilmiştir. Öncelikle sahada yapılan gözlemlere dayalı olarak tarım arazileri ürün deseni belirlenmiş ve her bir sınıfa ait örnekler toplanarak veri tabanına işlenmiştir. Tarım arazileri ile kaplı alanda mısır (I. ve II. evre), mera, pamuk, bostan, yapay yüzeyler ve su yüzeyi olmak üzere 7 farklı sınıf tanımlanmıştır (Şekil 2).



Şekil 2. Çalışma alanı eğitim/test yersel veri seti

3.SINIFLANDIRMA İŞLEMİ VE BULGULAR

Çalışmanın amacı; mısır (I. ve II. evre), mera, pamuk, bostan, yapay yüzeyler ve su yüzeyi olmak üzere sahada belirlenen 7 farklı sınıf alanının yüksek çözünürlüklü RapidEye uydu görüntüsünden belirlenmesinde Destek Vektör Makineleri kontrollü sınıflandırma tekniğinin performansının değerlendirilmesidir. Literatürde yapılan çalışmalar incelendiğinde DVM sınıflandırma verilerinin performansının çoğunlukla orta çözünürlüklü Landsat uydu görüntüsü kullanılarak değerlendirildiği tespit edilmiştir. Bu çalışma ile DVM'lerin performans analizi geometrik ve radyometrik çözünürlüğü yüksek olan bir veri seti ile gerçekleştirilmiştir.

Sahada tespit edilen sınıf alanlarını yüksek çözünürlüklü bir uydu görüntüsünden DVM sınıflandırma tekniği kullanılarak belirleyebilmek amacıyla iki yönlü değerlendirme yapılmıştır. İlk olarak sınıflandırma performansını/doğruluğunu etkileyen sınıflandırma işleminde seçilecek kernel fonksiyonunun türü ve kullanılacak olan parametreler belirlenmeye çalışılmıştır. DVM sınıflandırma performansı EÇB yöntemi ile karşılaştırılarak değerlendirilmiştir. Diğer yandan RapidEye uydu görüntüsünün bantları kullanılarak 2 farklı veri seti oluşturulmuştur. Birinci veri seti 5 spektral bantın hepsini içerirken, ikinci veri seti rededge (kırmızı kenar) bandı hariç diğer 4 spektral banttan oluşmaktadır. Böylelikle rededge bandının sınıflandırma doğruluğuna etkisi araştırılmıştır. Hata matrisi kullanılarak sınıflandırılmış iki veri seti için genel doğruluk ve Kappa istatistikleri hesaplanmış ve sonuçlar karşılaştırılmıştır (Tablo 1 ve Tablo 2).

Destek vektör makineleri kernel fonksiyonları yardımıyla doğrusal olarak ayrılamayan verilerin sınıflandırılması işlemini gerçekleştirmektedir. Literatürde yaygın olarak kullanılan kerneller polinom, radyal tabanlı ve sigmoid kernelleridir. Sınıflandırma işleminde seçilecek kernel fonksiyonunun türü ve kullanılacak olan parametreler sınıflandırma performansını /doğruluğunu etkilemektedir. Bu çalışmada hem matematiksel sadeliği hem de diğer kernel fonksiyonlarına göre yüksek performansa sahip olması nedeniyle polinom ve radyal tabanlı kernel fonksiyonları tercih edilmiştir (Huang vd. 2001, Vapnik 1995, Kavzoglu 2010, Yang 2011). DVM sınıflandırma işleminde tüm kernel fonksiyonları için kullanılan C (düzenleme parametresi) bu çalışmada iki kernel fonksiyonu için de 0-1000 aralığında alınmıştır. Polinom kerneli için gereken parametreler; polinom derecesi, bias, gama ve düzenleme parametresi, radyal tabanlı kernel için ise gama ve düzenleme parametresidir. Gama parametresi sınıflandırma işleminde bant sayısının inversi olarak alınmıştır. Polinom

kerneli 1-6, bias 0-6, düzenleme parametresi 0-1000 aralığında alınarak çeşitli parametre kombinasyonları denenmiş, optimum parametreler bulunmuştur. Hangi parametre kombinasyonunun optimum sonuç vereceği başta bilinmemektedir. Optimum parametreler çeşitli denemeler sonunda tespit edilmiştir.

Öncelikle 5 bantlı veri seti için değerlendirmeler yapılmış ve en iyi sonuç veren parametreler kullanılarak 4 bantlı veri setine uygulanmıştır (Tablo 1).

K.Türü	No	Polinom Derecesi	Bias	Gamma	Error_Penalty	Genel Doğruluk	Kappa
Polinom	1	6	5	0,2	100	%90,0000	0,8820
	2	6	5	0,2	200	%90,0000	0,8820
	3	6	5	0,2	300	%90,4348	0,8871
	4	6	5	0,2	400	%89,5652	0,8769
	5	6	5	0,2	800	%90,0000	0,8820
	6	6	5	0,2	900	%90,4348	0,8871
	7	6	5	0,2	1000	%90,0000	0,8820
Radyal tabanlı	8	x	x	0,2	100	%91,3043	0,8974
	9	x	x	0,2	200	%90,8698	0,8923
	10	x	x	0,2	300	%90,8698	0,8923
	11	x	x	0,2	400	%91,3043	0,8974
	12	x	x	0,2	800	%91,3043	0,8974
	13	x	x	0,2	900	%91,3043	0,8974
	14	x	x	0,2	1000	%91,3043	0,8974
En Çok Benzerlik	15					%86,0870	0,8361

Tablo 1. 5 bantlı veri seti, kullanılan parametreler ve sınıflandırma doğrulukları

5 bantlı görüntüde en yüksek doğruluğu veren parametre setleri rededege (kırmızı kenar) bandı çıkarılmış 4 bantlı görüntüye de uygulanmıştır ve yine radyal tabanlı kernel en yüksek doğruluğu vermiştir (Tablo 2). 5 bantlı ve 4 bantlı veri setleri için en yüksek doğruluğu veren sonuçlara ait hata matrisleri Tablo 3 ve Tablo 4'de sunulmuştur.

K.Türü	No	Polinom Derecesi	Bias	Gamma	Error_Penalty	Genel Doğruluk	Kappa
Polinom	16	6	5	0,2	300	%87,3913	0,8516
R. tabanlı	17	x	x	0,2	100	%89,1304	0,8720
polinom	18	6	5	0,2	900	%86,9565	0,8465
En Çok Benzerlik	19					%84,3478	0,8157

Tablo 2. 4 bantlı veri seti, kullanılan parametreler ve sınıflandırma doğrulukları

Class	musir 1	musir 2	patluk	yapayyüzev	mera	bostan	suyüzevi	Toplam
musir 1	36	5	0	1	0	0	0	42
musir 2	4	26	0	0	0	0	0	30
patluk	0	0	46	0	0	0	0	46
yapayyüzev	0	0	0	36	0	0	0	36
mera	1	0	0	8	20	2	0	31
bostan	0	0	0	0	1	20	0	21
suyüzevi	0	0	0	0	0	0	24	24
Toplam	41	31	46	45	21	22	24	230

Genel Doğruluk=% 80,4348 Kappa= 0,8871

Class	musir 1	musir 2	patluk	yapayyüzev	mera	bostan	suyüzevi	Toplam
musir 1	37	3	0	3	0	0	0	43
musir 2	2	28	0	0	0	0	0	30
patluk	0	0	46	0	0	0	0	46
yapayyüzev	0	0	0	35	0	0	0	35
mera	2	0	0	7	20	2	0	31
bostan	0	0	0	0	1	20	0	21
suyüzevi	0	0	0	0	0	0	24	24
Toplam	41	31	46	45	21	22	24	230

Genel Doğruluk=% 81,3043 Kappa= 0,8974

Class	musir 1	musir 2	patluk	yapayyüzev	mera	bostan	suyüzevi	Toplam
musir 1	28	0	0	2	0	0	0	30
musir 2	6	30	0	2	0	0	0	38
patluk	0	0	46	0	0	0	0	46
yapayyüzev	0	0	0	34	0	0	6	40
mera	7	1	0	7	21	1	0	37
bostan	0	0	0	0	0	21	0	21
suyüzevi	0	0	0	0	0	0	18	18
Toplam	41	31	46	45	21	22	24	230

Genel Doğruluk=% 86,0870 Kappa= 0,8361

Tablo 3. 5 bantlı veri seti için hata matrisi

Class	musir 1	musir 2	patluk	yapayyüzev	mera	bostan	suyüzevi	Toplam
musir 1	29	5	0	1	0	0	0	35
musir 2	6	26	0	0	0	0	0	32
patluk	0	0	46	0	0	0	0	46
yapayyüzev	0	0	0	36	0	0	0	36
mera	6	0	0	8	20	2	0	36
bostan	0	0	0	0	1	20	0	21
suyüzevi	0	0	0	0	0	0	24	24
Toplam	41	31	46	45	21	22	24	230

Genel Doğruluk=% 87,3913 Kappa= 0,8516

Class	musir 1	musir 2	patluk	yapayyüzev	mera	bostan	suyüzevi	Toplam
musir 1	33	3	0	2	0	0	0	38
musir 2	2	27	0	0	0	0	0	29
patluk	0	1	46	0	0	0	0	47
yapayyüzev	0	0	0	35	0	0	0	35
mera	6	0	0	8	20	2	0	36
bostan	0	0	0	0	1	20	0	21
suyüzevi	0	0	0	0	0	0	24	24
Toplam	41	31	46	45	21	22	24	230

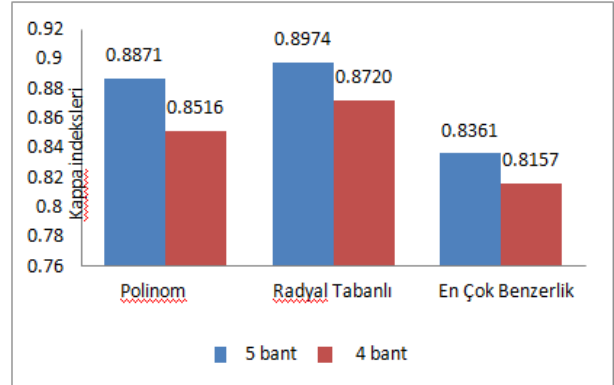
Genel Doğruluk=% 89,1304 Kappa= 0,8720

Class	musir 1	musir 2	patluk	yapayyüzev	mera	bostan	suyüzevi	Toplam
musir 1	26	0	0	2	0	0	0	28
musir 2	6	29	0	2	0	0	0	37
patluk	0	1	46	0	0	0	0	47
yapayyüzev	0	0	0	34	0	0	6	40
mera	9	1	0	7	20	1	0	38
bostan	0	0	0	0	1	21	0	22
suyüzevi	0	0	0	0	0	0	18	18
Toplam	41	31	46	45	21	22	24	230

Genel Doğruluk=% 84,3478 Kappa= 0,8157

Tablo 4. 4 bantlı veri seti için hata matrisi

Şekil 3 ile farklı yöntemler kullanılarak sınıflandırılan 2 farklı veri seti ile elde edilen Kappa istatistik doğruluk değerleri gösterilmiştir.



Şekil 3: Kappa İstatistik değerleri

4.SONUÇLAR

Bu çalışma ile iki hedef belirlenmiştir. Çalışmada öncelikle farklı kontrollü sınıflandırma yöntemleri karşılaştırılmıştır. Elde edilen sonuçlar göstermektedir DVM sınıflandırma performansı açısından seçilen çalışma bölgesinde EÇB sınıflandırma yöntemine göre daha yüksek doğrulukta sonuçlar vermektedir. DVM doğrusal olmayan veri gruplarının farklı parametre ve kernel tipleri kullanılarak sınıflandırılmasına izin vermektedir. Bu çalışma kapsamında farklı parametreler ve iki farklı kernel türü kullanılarak Menemen Ovası için en uygun sınıflandırma parametre ve kernel türü belirlenmiştir. Çalışmada radyal tabanlı kernel fonksiyonu hem polinom kernel fonksiyonundan hem de EÇB sınıflandırma yönteminden daha başarılı sonuçlar vermiştir. Sınıflandırma genel doğruluğu 2 farklı veri seti için genel doğruluk ve kapa istatistiği için sırasıyla % 91,3043 ve 0,8974 (5 bantlı) ve %89,1304 ve 0,8720 (4 bantlı) olarak hesaplanmıştır.

Bu çalışmanın en son adımında rededege (kırmızı kenar) bandın sınıflandırma sonucuna etkisi araştırılmıştır. Radyal tabanlı

kernel fonksiyonu hem polinom kernel fonksiyonundan hem de EÇB sınıflandırma yönteminden daha başarılı sonuçlar vermiştir. Rededge bandı içeren 5 bantlı veri seti ile 4 bantlı veri setine göre daha yüksek doğruluklu sınıflandırma sonuçları elde edilmiştir.

Uygulama süreleri karşılaştırıldığında en yüksek genel doğruluk ve Kappa istatistik sonucuna sahip Radyal tabanlı kernel fonksiyonu en uzun süreli işlem olarak belirlenmiştir. Literatürde radial tabanlı ve polinomal tabanlı birbirine göre üstün olarak belirleyen farklı çalışmalar mevcuttur.

Kaynaklar

Brodley, C. E., ve Utgoff, P. E., (1995). Multivariate decision trees. *Machine Learning*, 19, 45–77.

Cortes, C., ve Vapnik, V., (1995). Support vector networks. *Machine Learning*, 20, 1-25.

Dixon, B. ve Candade, N., (2008). Multispectral landuse classification using neural networks and support vector machines: one or the other, or both? *International Journal of Remote Sensing*, 4(20), 1185–1206.

Foody, G.M. ve Mathur, A. (2004). Toward intelligent training of supervised image classifications: directing training data acquisition for SVM classification. *Remote Sensing of Environment*, 93, 107–117.

Hall, F. G., Townshend, J. R., and Engman, E. T., (1995). Status of remote sensing algorithms for estimation of land surface state parameters. *Remote Sensing of Environment*, 51, 138–156.

Hansen, M., Dubayah, R., ve DeFries, R., (1996). Classification trees: an alternative to traditional land cover classifiers. *International Journal of Remote Sensing*, 17, 1075–1081.

Hansen, M., DeFries, R. S., Townshend, J. R. G., ve Sohlberg, R., (2000). Global land cover classification at 1 km spatial resolution using a classification tree approach. *International Journal of Remote Sensing*, 21, 1331–1364.

Huang, C., Townshend, J.R.G., Liang, S., Kalluri, S.N.V. and Defries, R.S., 2001. Impact of sensor's point spread function on land cover characterization: assessment and deconvolution. *Remote Sensing of Environment*, 80, pp. 203–212.

Jensen, J.R., (2000). *Remote Sensing of the Environment, an Earth Resource Perspective*. Upper Saddle River, NJ: Princeton Hall

Kavzoglu, T. ve Mather, P.M., (1999). Pruning artificial neural networks: an example using land cover classification of multi-sensor images. *International Journal of Remote Sensing*, 20, 2787–2803.

Kavzoglu, T. ve Mather, P.M., (2003). The use of backpropagating artificial neural networks in land cover classification. *International Journal of Remote Sensing*, 24, 4907–4938.

Kavzoglu, T., ve Colkesen, I., (2009). A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, 11(5), 352–359.

Mathur, A., ve Foody, G.M., (2008). Crop classification by support vector machine with intelligently selected training data for an operational application. *International Journal of Remote Sensing*, 29(8), 2227–2240

Paola, J.D. and Schowengerdt, R.A., (1995). A detailed comparison of backpropagation neural-network and maximum-likelihood classifiers for urban land-use classification. *IEEE Transactions on Geoscience and Remote Sensing*, 33, 981–996.

Quinlan, J. R., (1993). *C4.5 Programs for Machine Learning*. San Mateo, CA: Morgan Kaufmann Publishers.

Pao, Y.-H., (1989). *Adaptive Pattern Recognition and Neural Networks*. New York: Addison-Wesley.

Safavian, S. R., and Landgrebe, D., (1991). A survey of decision tree classifier methodology. *IEEE Transactions on Systems, Man, and Cybernetics*, 21, 660–674.

Sandau, R., 2010, Status and trends of small satellite missions for Earth observation. *Acta Astronautica*, 66, 1–12.

Song, X., Duan, Z., ve Jiang, X., (2012). Comparison of artificial neural networks and support vector machine classifiers for land cover classification in Northern China using a SPOT-5 HRG image. *International Journal of Remote Sensing* 33(10), 3301–3320

Townshend, J. R. G., (1992). Land cover. *International Journal of Remote Sensing*, 13, 1319–1328.

Tso, B.K.C. and Mather, P.M., (2001). *Classification Methods for Remotely Sensed Data*. London: Taylor and Francis.

Vapnik, V.N., (1995). *The Nature of Statistical Learning Theory*. New York: Springer-Verlag.

Wang, F., (1990). Fuzzy supervised classification of remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 28, 194–201.

Zhang, Y., GAO, J. ve Wang, J., (2007). Detailed mapping of a salt farm from Landsat TM imagery using neural network and maximum likelihood classifiers: a comparison. *International Journal of Remote Sensing*, 28, 2077–2089.

Zhu, G. ve Blumberg, D.G., (2002). Classification using ASTER data and SVM algorithms: The case study of Beer Sheva, Israel. *Remote Sensing of Environment*, 80, 233–240.