BİNALARIN YÜKSEK ÇÖZÜNÜRLÜKLÜ UYDU GÖRÜNTÜLERİNDEN DESTEK VEKTÖR MAKİNELERİ SINIFLANDIRMA TEKNİĞİ KULLANILARAK BELİRLENMESİ

Dilek Koç San[1] ve *Mustafa Türker*[2]

[1]ODTÜ, Fen Bilimleri Enstitüsü, Jeodezi ve Coğrafi Bilgi Teknolojileri EABD, 06531 Ankara, Türkiye - dkoc@metu.edu.tr
[2]Hacettepe Univ., Müh. Fak., Jeodezi ve Fotogrametri Mühendisliği Bölümü, Beytepe, 06800 Ankara, Türkiye - mturker@hacettepe.edu.tr

ÖZET

Bu çalışmada, binalar yüksek çözünürlüklü uydu görüntülerinden Destek Vektör Makineleri (DVM) sınıflandırma tekniği kullanılarak belirlenmiş ve yardımcı verilerin sınıflandırma işlemine etkisi değerlendirilmiştir. İzlenen ana adımlar şu şekildedir: (i) Normalleştirilmiş Sayısal Yüzey Modelinin (nSYM) hesaplanması, (ii) Görüntü ortorektifikasyonu, (iii) Normalleştirilmiş Fark Bitki Örtüsü İndeksinin (NFBÖİ) hesaplanması, (iv) Temel Bileşenler Analizi, (v) Yoğunluk Görüntüsünün oluşturulması, (vi) DVM Sınıflandırması ve (vii) Artefaktların yok edilmesi. Sınıflandırma işlemi, IKONOS pankromatik görüntü ile zenginleştirilmiş renkli görüntünün dört spektral bandı (Mavi, Yeşil, Kırmızı, Yakın Kızılötesi), nSYM, NFBÖİ, Birinci Ana Bileşen ve Yoğunluk Görüntüsü kullanılarak yapılmıştır. Binaların belirlenmesi işleminde nSYM'nin kullanılması avantaj sağlamaktadır, çünkü binalar arazi yüzeyi üzerindeki üç boyutlu objeler olup nSYM kullanılarak araziden ayırt edilebilirler. Benzer şekilde, NFBÖİ görüntüsü de özellikle yeşil alanlarla çevrili binaların belirlenmesinde faydalı olmaktadır. Bu çalışmada, Birinci Ana Bileşen ve Yoğunluk Görüntüleri de ek bantlar olarak kullanılmıştır, çünkü bu görüntüler orijinal görüntülerden daha iyi yorumlanabilir. Önerilen yaklaşım Ankara'nın Batıkent bölgesinde seçilmiş olan üç test alanında üç farklı eğitim alanı örneği boyutu (500, 1000 ve 2000) kullanılarak test edilmiştir. Genel olarak yardımcı verilerin sınıflandırma doğruluğunu arttırdığı görülmüştür. Yardımcı verilerden nSYM ve NFBÖİ bantlarının sınıflandırmaya dahil edilmesi doğruluğu önemli ölçüde arttırırken Birinci Ana Bileşen ve Yoğunluk Görüntülerinin sınıflandırmaya dahil edilmesi ise doğrulukta dikkate değer pozitif bir etki yapmamıştır. Yine genel olarak örnek sayısındaki artışın sınıflandırma doğruluğunu arttırdığı görülmüş ancak bu artış %2'yi geçmemiştir. Bu nedenle, elde edilen sonuçlara dayanarak, örnek sayısının çok fazla arttırılmasına gerek olmadığı söylenebilir. DVM sınıflandırma sonuçları incelendiğinde, tüm test alanları için, yardımcı veriler kullanıldığında binaların belirlenmesi doğruluğu %90'ın üzerinde hesaplanmıştır. Elde edilen sonuçlar, bina sınırlarının yüksek çözünürlüklü uydu görüntülerinden yardımcı veriler de kullanılarak, DVM sınıflandırma tekniği ile oldukça başarılı bir şekilde belirlenebileceğini göstermektedir.

Anahtar Sözcükler: Bina Belirleme, DVM, Sınıflandırma, nSYM, NFBÖİ, Yüksek Çözünürlüklü Uydu Görüntüleri, IKONOS

ABSTRACT

BUILDING DETECTION FROM HIGH RESOLUTION SATELLITE IMAGES USING SUPPORT VECTOR MACHINES CLASSIFICATION TECHNIQUE

In this study, the buildings are detected using the Support Vector Machines (SVM) classifier and the incorporation of ancillary data to the classification process is evaluated. The main steps are as follows: (i) Calculation of the normalized Digital Surface Model (nDSM), (ii) Orthorectification of the image, (iii) Calculation of the Normalized Difference Vegetation Index (NDVI), (iv) Principal Component Analysis, (v) Intensity image generation, (vi) SVM Classification and (vii) Removing the artefacts. The classification process is performed using the four spectral bands (Blue, Green, Red, and Near Infrared) of the IKONOS pan-sharpened image, the nDSM, NDVI, First Principal Component (1st PC) and the Intensity Image. The inclusion of the nDSM band is useful in the building extraction process because the buildings are the objects with different heights over the terrain and they can be clearly separated from the terrain using the nDSM. Similarly, the NDVI image is useful for those buildings that are surrounded by vegetated areas. In addition, the first Principal Component and the intensity image are also used as additional bands because they may be more interpretable than the original data. The proposed approach was implemented in three sub-areas, which were selected from Batikent, Ankara using three different sample sizes (500, 1000 and 2000). It was observed that using the ancillary data increases the building detection accuracy considerably. Including the nDSM and NDVI bands in the classification process as additional bands increases the accuracy significantly. However, the inclusion of the 1st PC and the intensity image bands did not have remarkable effect in the accuracy. When the affect of the training sample size on the classification accuracy is evaluated it can be said that generally increasing the training size increases the accuracy, however the increase is not more than %2. Therefore, it can be stated that small training size (i.e. 500 pixels) appears to be enough. For three sub-areas the building detection percentages using the additional data were calculated higher than 90%. The obtained results indicate that the building areas can be detected quite successfully using SVM classification technique and the ancillary data.

Keywords: Building Detection, SVM, Classification, nDSM, NDVI, High Resolution Satellite Images, IKONOS

1. GİRİŞ

Binaların hava fotoğraflarından ve yüksek çözünürlüklü uydu görüntülerinden otomatik olarak belirlenmesi son zamanlarda önemli bir araştırma konusu olmuştur. Bina sınırlarının otomatik olarak bulunmasında, öncelikle binaların yaklaşık yerlerinin belirlenmesi önemlidir. Olası bina alanlarının belirlenmesi için sınıflandırma teknikleri, bölümlere ayırma ve kenar belirleme gibi işlemler kullanılmaktadır.

Son zamanlarda yapılan çalışmalar, DVM sınıflandırma tekniğinin uzaktan algılama görüntülerinin sınıflandırılmasında ümit verici olduğunu göstermektedir (Huang vd, 2002; Zhu ve Blumberg, 2002; Pal ve Mather, 2005; Foody ve Mathur, 2004). Watanachaturaporn vd. (2008) DVM sınıflandırma tekniğini En Büyük Olasılık, Geri Beslemeli Sinir Ağları, Radyal Temelli Fonksiyon Sinir Ağları ve Karar Ağacı sınıflandırma teknikleri ile karşılaştırmış ve DVM sınıflandırma tekniğinin önemli ölçüde daha başarılı olduğu sonucuna varmışlardır.

Başlangıçta DVM sınıflandırma tekniği iki sınıflı sınıflandırma problemlerinde kullanılmak üzere tasarlanmış, daha sonra çok sınıflı sınıflandırmalar için de kullanılmak üzere geliştirilmiştir. Önerilen bu çalışmada binaları belirlemek için iki sınıflı DVM sınıflandırma tekniği kullanılmıştır, çünkü ilgilenilen tek bir sınıf (bina sınıfı) bulunmaktadır. Foody vd. (2006) tek sınıf odaklı DVM sınıflandırmasının uzaktan algılama çalışmalarında önemli potansiyeli olduğunu iddia etmektedirler. Boyd vd. (2006) bu sınıflandırma tekniğini tek bir spesifik sınıfın haritalanmasında kullanmıştır. Sanchez vd. (2007) tarafından yapılan bir diğer çalışmada ise Landsat 7 ETM+ görüntülerinden yine spesifik bir sınıfın belirlenmesi için bu sınıflandırma tekniği kullanılmıştır. Geleneksel sınıflandırma tekniklerinde bütün sınıfların belirlenmesi ve tüm sınıflar için eğitim alanları toplanması önemlidir. Fakat, eğer sınıflandırma aşamasında tek bir sınıfla ilgileniliyorsa geleneksel tekniklerin kullanılması uygun olmayabilmektedir (Foody vd., 2006).

Bu nedenle, bu çalışmada bina alanlarını belirlemek için DVM sınıflandırma tekniği kullanılmıştır. Spektral bantlara ek olarak nSYM (Normalleştirilmiş Sayısal Yüzey Modeli), NFBÖİ (Normalleştirilmiş Fark Bitki Örtüsü İndeksi), 1.TB (Temel Bileşen) ve Yoğunluk Görüntüleri de kullanılmış ve bu görüntülerin sınıflandırma doğruluğuna etkileri incelenmiştir. Ayrıca, farklı sayıdaki eğitim alanı örneklerinin sınıflandırma sonucuna etkileri de incelenmiştir. Elde edilen sonuçlar En Büyük Olasılık sınıflandırma tekniği ile de karşılaştırılmıştır.

2. METODOLOJİ

Geliştirilen yaklaşımın akış şeması şekil 1'de verilmiştir. Öncelikle, eş yükselti eğrileri ve üç boyutlu noktaları içeren mevcut vektör veriden Sayısal Arazi Modeli (SAM), stero pankromatik uydu görüntülerinden Sayısal Yüzey Modeli (SYM) oluşturulmuş ve SAM SYM'den çıkarılarak nSYM hesaplanmıştır. Daha sonra, oluşturulan SYM kullanılarak keskinleştirilmiş renkli görüntü ortorektifiye edilmiştir. Diğer taraftan, Normalleştirilmiş Fark Bitki Örtüsü İndeksi (NFBÖİ) hesaplanmış, Temel Bileşenler Analizi yapılmış ve Yoğunluk Görüntüsü hesaplanmıştır. Bu işlemlerin ardından bina alanlarını bulmak amacıyla ortorektifiye edilmiş, keskinleştirilmiş renkli uydu görüntüleri oluşturulan ek bantlar ile birlikte ikili DVM sınıflandırma tekniği kullanılarak bina alanları ve bina olmayan alanlar olarak sınıflandırılmıştır. Son olarak, artefaktlar morfolojik operasyonlar kullanılarak yok edilmiş ve bu işlem sonucunda binalar belirlenmiştir.

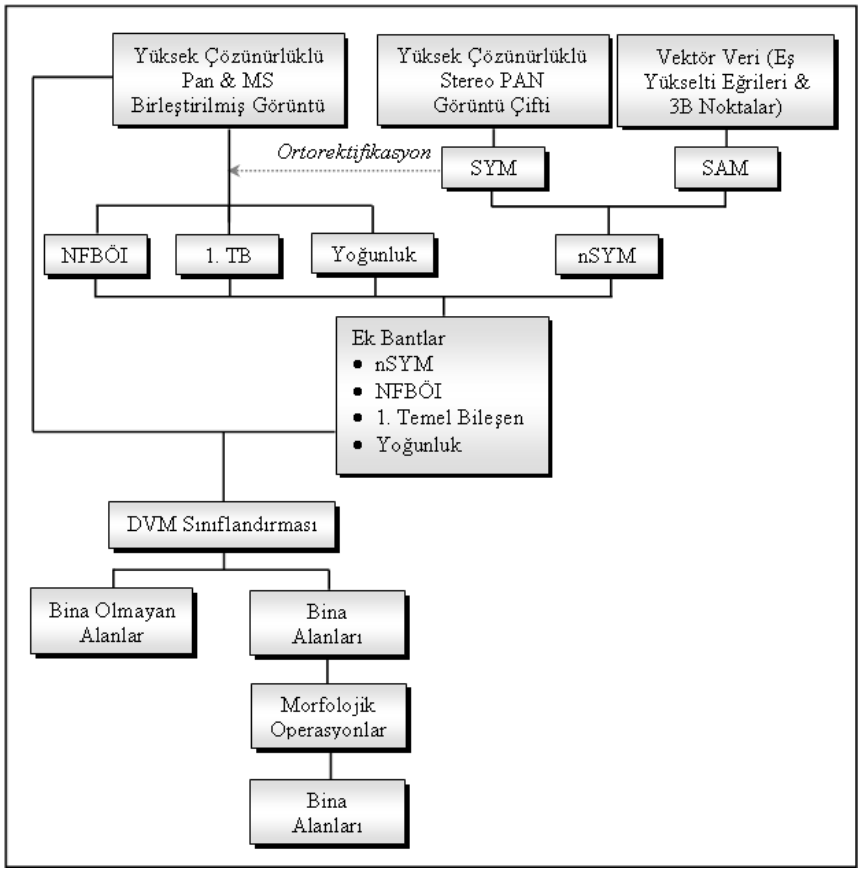

Şekil 1: Önerilen bina belirleme akış şeması

3. ÇALIŞMA ALANI VE VERİ SETLERİ

Geliştirilen yaklaşım farklı şekil ve kullanımdaki binaları içeren Batıkent, Ankara'da uygulanmıştır (Şekil 2). Batıkent Projesi Türkiye'de kooperatifler yoluyla yapılmış en büyük toplu konut projesidir. Proje 10 km^2'lik bir alanı kapsamaktadır ve 50.000 konut ünitesi olarak 25.000 kişi için planlanmıştır. Bu proje 1979 yılında Ankara Büyükşehir Belediye Başkanlığı'nın liderliğinde oluşan Kent-Koop (Batıkent Konut Yapı Kooperatifleri Birliği) tarafından başlatılmıştır. Batıkent planlı ve düzenli gelişen, farklı şekil ve kullanımdaki yapıları içerdiğinden bu çalışmada test alanı olarak kullanılmıştır.

Çalışmada kullanılan veri setleri, IKONOS stero pankromatik ve keskinleştirilmiş renkli uydu görüntüleridir. Aynı yörüngeden uçuşa paralel olarak çekilen stero görüntüler 4 Ağustos 2002 tarihlidir. Görüntüler "Geo" IKONOS formatındadır. Bu formattaki görüntülerin yatay konumsal doğruluğu yaklaşık 15 m'dir. Sayısal Arazi Modeli oluşturmak için kullanılan eş yükselti eğrileri Ankara Büyükşehir Belediyesi, Su ve Kanalizasyon İdaresi Genel Müdürlüğü (ASKİ) tarafından 1999 yılında yaptırılan ve Ankara metropolitan alanını kapsayan 1:1.000 ölçekli veriden üretilmiştir.

Batıkent bölgesinde farklı karakteristikte üç test alanı seçilmiş ve seçilen bu alanlar bina ve bina olmayan alanlar olarak sınıflandırılmıştır (Şekil 3).

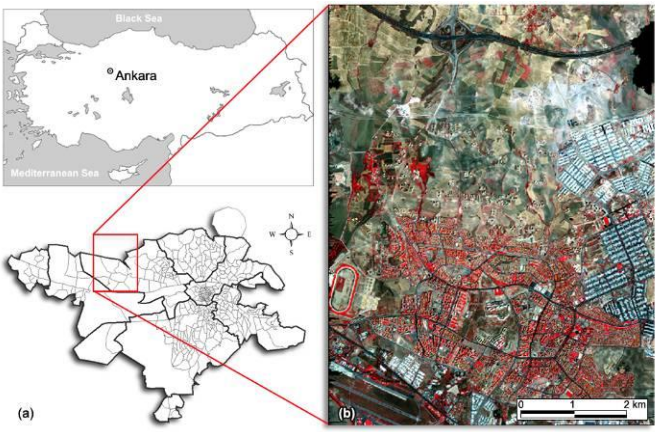

Şekil 2: Çalışma alanı, Batıkent, Ankara

Şekil 3: Batıkent bölgesinde seçilen test alanları.

4. YARDIMCI VERİLERİN HAZIRLANMASI

4.1. Normalleştirilmiş Sayısal Yüzey Modelinin Hesaplanması

Bina belirleme çalışmalarında yükseklik modellerinin kullanımı önem arz etmektedir. Araziden belli bir yükseklikte olan kentsel nesneler, nSYM'ye bir eşik değerinin uygulanması ile tespit edilebilmektedirler. SAM topoğrafyanın yükseklik modelidir ve yerden yüksekte olan nesneleri içermez. SYM ise yeryüzeyinin yükseklik modelidir ve topoğrafyanın yanısıra tüm üç boyutlu nesneleri de içerir. Dolayısı ile, SYM'den SAM'in çıkarılmasıyla nSYM elde edilir.

Bu çalışmada SAM mevcut sayısal vektör veritabanındaki eş yükselti eğrileri ve noktasal yükseklik verilerinden, SYM ise stereo IKONOS uydu görüntülerinden PCI Geomatica 9.1 görüntü işleme yazılımının OrthoEngine modülü kullanılarak elde edilmiştir. SYM oluşturmak için Diferansiyel Küresel Konumlandırma Sistemi kullanılarak 48 kontrol noktası toplanmıştır. Bu noktalardan 24 adeti Yer Kontrol Noktası (YKN), geri kalan 24 adeti ise Bağımsız Denetim Noktası (BDN) olarak kullanılmıştır. Elde edilen SAM'in doğruluğu 0.2 m, SYM'nin doğruluğu ise 0.7 m olarak hesaplanmıştır. SAM ve SYM'nin elde edilmesi ve doğruluk analizleri ile ilgili detaylar Koç ve Türker (2005)'de verilmiştir. Daha sonra, SYM'den SAM çıkarılarak nSYM oluşturulmuştur. Binalarla ağaçları birbirinden ayırt edebilmek için bitki örtüsü indeksi bantı kullanılarak yeşil alanlar maskelenmiştir. Diğer taraftan, nSYM'ye 3 m eşik değeri uygulanarak bu değerin üzerinde yüksekliğe sahip kent nesnelerinin yer yüzeyinden ayrılmaları sağlanmıştır. Eşik değerinin 3 m alınmasının nedeni 3 m'den daha alçak objeleri, bina olamayacakları gerekçesiyle, elimine etmektir. Böylece yalnız bina alanlarının yüksekliklerini içeren bir nSYM elde edilmiştir. Seçilen test alanları için elde edilen nSYM'ler Şekil 4'te verilmiştir.

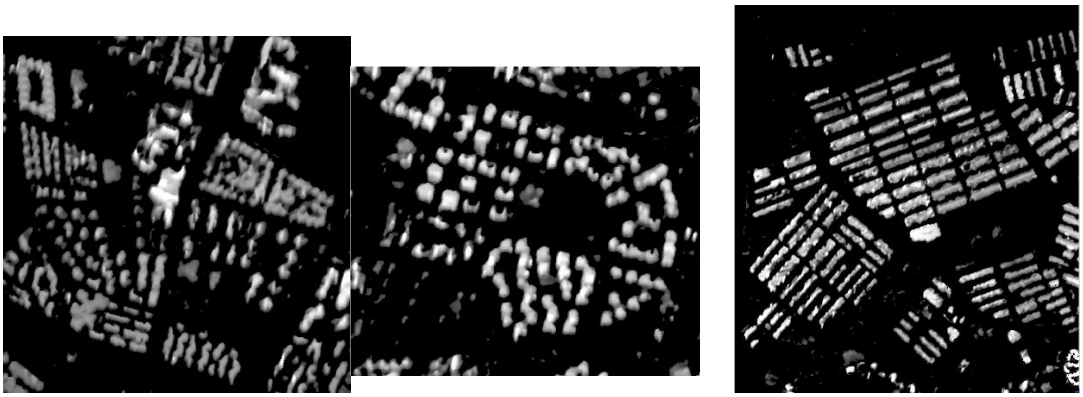

Şekil 4: Test alanlarına ait nSYM sonuçları.

4.2. Ortorektifikasyon

Çalışmada kullanılan IKONOS uydu görüntüleri "Geo" formatında ve yaklaşık 15m konumsal doğruluktadır. Dolayısı ile, görüntüdeki geometrik hataları yok etmek ve görüntünün eş yükselti eğrileri ve referens bina veri tabanıyla doğru bir şekilde çakışmasını sağlamak amacıyla görüntünün ortorektifikasyonu yapılmıştır (Şekil 5). Pankromatik ve keskinleştirilmiş renkli uydu görüntülerinin ortorektifikasyonu yapılırken daha önce oluşturulmuş olan SYM kullanılmıştır.

Şekil 5: (a) Ortorektifikasyondan önce ve (b) sonra referans bina sınırlarıyla çakıştırılan keskinleştirilmiş IKONOS renkli görüntü.

4.3. Normalleştirilmiş Fark Bitki Örtüsü İndeksinin (NFBÖİ) Hesaplanması

Normalleştirilmiş Fark Bitki Örtüsü İndeksi (NFBÖİ), görüntüdeki bitkisel alanları belirlemek için kullanılmaktadır. Dolayısı ile, ortorektifiye edilmiş keskinleştirilmiş renkli IKONOS görüntülerinin kırmızı ve yakın kızıl ötesi bantları kullanılarak NFBÖİ bantı hesaplanmıştır (1). Test alanları için elde edilmiş olan NFBÖİ sonuçları şekil 6'da gösterilmiştir.

$$NDVI = \frac{PSM4 - PSM3}{PSM4 + PSM3} \qquad (1)$$

PSM3: IKONOS keskinleştirilmiş renkli görüntünün Kırmızı bandı
PSM4: IKONOS keskinleştirilmiş renkli görüntünün Yakın Kızıl Ötesi bandı

Şekil 6: Test alanlarına ait NFBÖİ bantları.

4.4. Temel Bileşenler Analizi

Temel Bileşenler Analizi (TBA) çok bantlı görüntülerdeki bantlar arası korelasyonu yok etmek için kullanılan bir görüntü analizi tekniğidir. Dolayısı ile, bu analiz tekniği esas olarak bant sayısını azaltmakta kullanılmaktadır. Fakat, yapılmış olan bazı çalışmalarda TBA sonuçlarının orjinal bantlardan daha iyi yorumlanabilir olduğu tespit edilmiştir (Singh ve Harrison, 1985). Bu çalışmada TBA keskinleştirilmiş IKONOS renkli bantlarına (Mavi, Yeşil, Kırmızı ve Yakın Kızıl Ötesi) uygulanmış ve dört bileşen oluşturulmuştur. Bilindiği üzere, bu bileşenlerden birincisi (1. TB) en çok veriyi içermektedir. Test alanları için elde edilmiş olan 1. TB'ler şekil 7'de gösterilmiştir.

Şekil 7: Test alanlarına ait 1.Temel Bileşen görüntüleri.

4.5. Yoğunluk Görüntüsü

Yoğunluk görüntüsü keskinleştirilmiş IKONOS renkli bantların (Mavi, Yeşil ve Kırmızı) aritmetik ortalamaları alınarak hesaplanmıştır (2). Test alanları için elde edilmiş olan yoğunluk görüntüleri şekil 8'de gösterilmiştir.

$$DN_{(\text{Yoğunluk Görüntüsü})} = ([DN_{(Band1)} + DN_{(Band2)} + DN_{(Band3)}] / 3) \qquad (2)$$

Şekil 8: Test alanlarına ait Yoğunluk görüntüleri.

5. DESTEK VEKTÖR MAKİNELERİ SINIFLANDIRMASI

DVM sınıflandırma tekniği, istatistiksel öğrenme teorisine dayalı bir eğitimli sınıflandırma tekniği olup temelleri Vapnik (1995) tarafından geliştirilmiştir. DVM sınıflandırmasında başlıca üç aşama bulunmaktadır. İlk olarak eğitim hücreleri özellik vektörü olarak ifade edilir. Sonra, bu özellik vektörleri kernel fonksiyonları kullanılarak özellik uzayına eşlenir. Son olarak sınıfları en uygun şekilde ayıran n-boyutlu hiper düzlem oluşturulur.

DVM ikili sınıflandırma probleminde eğitim kümesini $(x_1, r_1), \ldots, (x_i, r_i)$, $x_i \in R^n$ kullanarak ve $r_i \in \{1,-1\}$ olacak şekilde bir model geliştirir. Burada x_i spektral değer, r_i ise sınıf etiketidir. Öğrenme işlemi sırasında, iki sınıf arasındaki aralığı maksimum yapacak en uygun hiper düzlemi bulunur. İki sınıfı birbirinden ayırabilecek birçok hiper düzlem bulunabilmektedir ancak amaç en optimum olanını bulmak ve aralığı maksimum almaktır. Sınıfları ayıracak hiper düzlem şu şekilde tanımlanabilir:

$$w.x + b = 0 \tag{3}$$

Burada, w hiper düzleme olan normal, b ise sapmadır. Doğrusal olarak ayrılabilen iki sınıf örneğinde hiper düzlem şu şekilde tanımlanabilir.

$$ri\ (w.x_i + b) - 1 \geq 0 \tag{4}$$

Hiper düzlemler üzerindeki noktalar "destek vektör" olarak adlandırılmaktadır. Bu düzlemler optimum ayırıcı düzlemi bulmakta kullanılır. Optimum ayırıcı düzlem diğer düzlemlere paralel ve ikisinin ortasındadır. Bu düzlemler arasındaki aralık $2/\|w\|$ ($\|w\|$ w'nin Euclidean normu) dir. Aralığın maksimize edilmesi optimizasyon problemine neden olmaktadır (5).

$$\text{Küçükle: } \{1/2\ \|w\|^2\} \tag{5}$$

Bu problem Lagrange denklemi ile tanımlanabilir:

$$\text{Büyükle: } \sum_{i=1}^{k} \alpha_i - \frac{1}{2} \sum_{i=1}^{k} \sum_{i=1}^{k} \alpha_i\, \alpha_i\, r_i\, r_i \left(x_i . x_j\right) \tag{6}$$

$$\text{Kısıtlamalar: } \sum_{i=1}^{k} \alpha_i\, r_i = 0 \quad \text{and } \alpha_i \geq 0, \quad i = 1,2, \ldots, k \tag{7}$$

Veriyi iki sınıftan birine (+1 sınıflardan birini, -1 diğerini göstermektedir) sınıflandırabilmek için karar kuralı uygulanır.

$$f(x) = sign\left(\sum_{sv} r_i\, \alpha_i^o (x_i . x) + b^o \right) \tag{8}$$

Veri setlerinin karışık olması durumunda ve doğrusal olarak ayrılması mümkün değilse eşitlik 8 sağlanamaz ve bu nedenle arttıran yapay değişken (ξ) ve ceza parametreleri (C) tanımlanmalıdır. Bu parametrelerin eklenmesiyle optimizasyon problemi ve kısıtlamalar şu şekilde olmaktadır:

$$\min = \left[\frac{\|w\|^2}{2} + C \sum_{i=1}^{r} \xi_i \right] \tag{9}$$

$$ri\ (w.x_i + b) \geq 1 - \xi_i \tag{10}$$

Yukarıdaki eşitlikte C parametresi düzenleme parametresidir ve gürültülü eğitim alanları ile sınıflandırma karmaşası arasındaki dengeyi tanımlar. Doğrusal olmayan sınıflandırmada eğitim alanları yüksek boyutlu (özellik) uzaya transfer

edilerek çözümlenir. Bu durumda, problem kernel fonksiyonu (K) kullanılarak çözülür ve Kernel fonksiyonunu kullanmak karar kuralında aşağıda verilen değişikliğe yol açar:

$$f(x) = sign\left(\sum_{sv} r_i \alpha_i^o K(x_i . x) + b^o\right) \tag{11}$$

Bu çalışmada bina ve bina olmayan alanlar ikili DVM sınıflandırması uygulanarak ikiye ayrılmıştır. Yardımcı verilerin sınıflandırma işlemine katılmasının sınıflandırma doğruluğunu etkilediği bilinmektedir. Bu nedenle bu çalışmada sınıflandırma sırasında IKONOS görüntüsünün spektral bantlarına ek olarak nSYM, NFBÖİ, 1. TB ve Yoğunluk görüntüleri yardımcı veriler olarak kullanılmıştır. Kullanılan veri setleri ve içerdikleri bantlar tablo 1'de verilmiştir. nSYM'de binalar araziden ayırt edilebildiğinden sınıflandırmaya katılmasının yararlı olabileceği düşünülmektedir. Benzer şekilde NFBÖİ görüntüsünün de sınıflandırmada kullanılmasının, özellikle yeşil alanlarla çevrili binaların belirlenmesinde, faydalı olabileceği düşünülmektedir. Öte yandan, 1.TB ve yoğunluk görüntüleri orijinal görüntülerden daha iyi yorumlanabildiğinden sınıflandırma sırasında ek bant olarak kullanılmıştır. Sınıflandırma işleminde kullanılan bantlar aşağıdaki gibi etiketlenmiştir:

B_1 ⇒ Keskinleştirilmiş Mavi bant
B_2 ⇒ Keskinleştirilmiş Yeşil bant
B_3 ⇒ Keskinleştirilmiş Kırmızı bant
B_4 ⇒ Keskinleştirilmiş Yakın Kızıl Ötesi bant
B_{nSYM} ⇒ Normalleştirilmiş sayısal yüzey modeli (nSYM) bandı
$B_{NFBÖİ}$ ⇒ Normalleştirilmiş Fark Bitki Örtüsü Indeksi (NFBÖİ) bandı
B_{TB1} ⇒ Birinci Temel Bileşen bandı
B_Y ⇒ Yoğunluk Görüntüsü bandı

Veri Setleri	Bantlar
Set 1	B_1, B_2, B_3, B_4
Set 2	B_1, B_2, B_3, B_4, B_{nSYM}
Set 3	B_1, B_2, B_3, B_4, $B_{NFBÖİ}$
Set 4	B_1, B_2, B_3, B_4, B_{TB1}
Set 5	B_1, B_2, B_3, B_4, B_Y
Set 6	B_1, B_2, B_3, B_4, B_{nDSM}, $B_{NFBÖİ}$
Set 7	B_1, B_2, B_3, B_4, B_{TB1}, B_Y
Set 8	B_1, B_2, B_3, B_4, B_{nSYM}, $B_{NFBÖİ}$, B_{TB1}, B_Y

Tablo 1: Destek Vektör Makineleri Sınıflandırmasında kullanılan veri setleri ve içerdikleri bantlar

Bu çalışmada tespit edilecek sınıf bina sınıfıdır. Fakat, alanda bina olmayan sınıflar örneğin, bitki, yol, boş alan, yaya kaldırımı, gölge, vb. sınıflar da mevcuttur. Dolayısı ile, bina sınıfını bina olmayan sınıflardan ayırabilmek için hem bina hem de bina olmayan sınıflardan eğitim alanı örneklerinin toplanması gerekir. Bina ve bina olmayan sınıflar için eşit sayıda eğitim hücresi toplanmıştır. Bina olmayan alanlar için eğitim hücre yüzdesi alt sınıfların görüntüdeki dağılımlarına göre belirlenmiştir. Test alanlarından her sınıf ve alt sınıflar için toplanan eğitim hücre sayıları ve yüzdeleri tablo 2, tablo 3 ve tablo 4'de verilmiştir.

Classes	Sub-Classes	Eğitim Alanı Hücre Sayıları
Bina (% 50)	Bina (%50)	250, 500, 1000
Bina-Olmayan (% 50)	Bitki (%20)	100, 200, 400
	Yol (%14)	70, 140, 280
	Boş alan (%12)	60, 120, 240
	Yaya kaldırımı (%2)	10, 20, 40
	Gölge (%2)	10, 20, 40
Toplam (%100)	Toplam (%100)	500, 1000, 2000

Tablo 2: I. Test alanı için toplanan eğitim hücreleri sayıları

Sınıflar	Alt-Sınıflar	Eğitim Alanı Hücre Sayıları
Bina (% 50)	Building (%50)	250, 500, 1000
	Bitki (%15)	75, 150, 300

Bina-Olmayan (% 50)	Yol (%15)	75, 150, 300
	Gölge (%10)	50, 100, 200
	Yaya kaldırımı (%2)	10, 20, 40
	Boş alan (%8)	40, 80, 160
Toplam (%100)	Toplam (%100)	500, 1000, 2000

Tablo 3: II. Test alanı için toplanan eğitim hücreleri sayıları

Sınıflar	Alt-Sınıflar	Eğitim Alanı Hücre Sayıları
Bina (% 50)	Building (%50)	250, 500, 1000
Bina-Olmayan (% 50)	Boş alan (%24)	120, 240, 480
	Yol (%12)	60, 120, 240
	Bitki (%10)	50, 100, 200
	Yaya kaldırımı (%2)	10, 20, 40
	Gölge (%2)	10, 20, 40
Toplam (%100)	Toplam (%100)	500, 1000, 2000

Tablo 4: III. Test alanı için toplanan eğitim hücreleri sayıları

Eğitim alanı hücrelerinin toplanmasından sonra, veri setlerini azaltmak ve gereksiz bantları sınıflandırmaya katmamak amacıyla, Jeffries-Matusita (Richards, 1999)'ya dayalı istatistiksel teknik kullanılarak sınıflar arasındaki spektral ayrılabilirlik değerleri hesaplanmıştır. Spektral ayrılabilirlik değerleri 0 – 2 arasında bir değer alır ve seçilen eğitim alanlarının istatistiksel olarak ne derece ayrılabilir olduğunu gösterir. Yüksek değerler sınıfların istatistiksel olarak ayrılabildiğini, düşük değerler ise sınıflar arasında spektral çakışma olduğunu gösterir. Test alanları için hesaplanmış olan spektral ayrılabilirlik değerleri tablo 5'de verilmiştir.

Test Alanları	Veri-Setleri	Bantlar	Spektral Ayrılabilirlik Değerleri		
			500	1000	2000
I. Test Alanı	Set 1	B_1, B_2, B_3, B_4	1.7058	1.6985	1.6980
	Set 2	B_1, B_2, B_3, B_4, B_{nSYM}	1.8640	1.8518	1.8535
	Set 3	B_1, B_2, B_3, B_4, $B_{NFBÖİ}$	1.8279	1.8271	1.8218
	Set 4	B_1, B_2, B_3, B_4, B_{TB1}	1.7070	1.6990	1.6983
	Set 5	B_1, B_2, B_3, B_4, B_Y	1.7069	1.6992	1.6988
	Set 6	B_1, B_2, B_3, B_4, B_{nSYM}, $B_{NFBÖİ}$	1.9203	1.9150	1.9137
	Set 7	B_1, B_2, B_3, B_4, B_{TB1}, B_Y	1.7082	1.7000	1.6991
	Set 8	B_1, B_2, B_3, B_4, B_{nSYM}, $B_{NFBÖİ}$, B_{TB1}, B_Y	1.9210	1.9155	1.9142
II. Test Alanı	Set 1	B_1, B_2, B_3, B_4	1.7656	1.7556	1.7783
	Set 2	B_1, B_2, B_3, B_4, B_{nSYM}	1.8359	1.8225	1.8373
	Set 3	B_1, B_2, B_3, B_4, $B_{NFBÖİ}$	1.8637	1.8592	1.8715
	Set 4	B_1, B_2, B_3, B_4, B_{TB1}	1.7666	1.7559	1.7787
	Set 5	B_1, B_2, B_3, B_4, B_Y	1.7665	1.7561	1.7785
	Set 6	B_1, B_2, B_3, B_4, B_{nSYM}, $B_{NFBÖİ}$	1.9078	1.9014	1.9083
	Set 7	B_1, B_2, B_3, B_4, B_{TB1}, B_Y	1.7679	1.7565	1.7789
	Set 8	B_1, B_2, B_3, B_4, B_{nSYM}, $B_{NFBÖİ}$, B_{TB1}, B_Y	1.9088	1.9019	1.9087
III. Test Alanı	Set 1	B_1, B_2, B_3, B_4	1.5823	1.6014	1.6099
	Set 2	B_1, B_2, B_3, B_4, B_{nSYM}	1.9486	1.9386	1.9447
	Set 3	B_1, B_2, B_3, B_4, $B_{NFBÖİ}$	1.6660	1.6509	1.6581
	Set 4	B_1, B_2, B_3, B_4, B_{TB1}	1.5870	1.6027	1.6105
	Set 5	B_1, B_2, B_3, B_4, B_Y	1.5848	1.6022	1.6103
	Set 6	B_1, B_2, B_3, B_4, B_{nSYM}, $B_{NFBÖİ}$	1.9760	1.9620	1.9640
	Set 7	B_1, B_2, B_3, B_4, B_{TB1}, B_Y	1.5906	1.6040	1.6117
	Set 8	B_1, B_2, B_3, B_4, B_{nSYM}, $B_{NFBÖİ}$, B_{TB1}, B_Y	1.9774	1.9624	1.9642

Tablo 5: Veri setleri ve farklı sayıdaki (500, 1000, 2000) eğitim hücreleri için hesaplanmış olan spektral ayrılabilirlik değerleri

Hesaplanmış olan spektral ayrılabilirlik değerleri incelendiğinde, spektral bantlara ek olarak 1.TB (Set 4) veya yoğunluk görüntüsünün (Set 5) ya da her ikisinin (Set 7) kullanılmasının, sadece spektral bantların kullanılmasıyla karşılaştırıldığında, sonuçları çok az etkilediklerini söylemek mümkündür. Ayrıca, nSYM ve NFBÖİ bantlarını birlikte

ek bant olarak kullanmak ayrılabilirliği, sadece birini kullanmaktan daha çok, arttırmaktadır. Bu nedenle Set 2, Set 3, Set 4, Set 5 ve Set 7 sınıflandırma işleminde kullanılmamıştır.

Spektral ayrılabilirlik değerleri incelendiklerinde nSYM verisinin ayrılabilirliği, her üç test alanında, önemli ölçüde arttırdığı görülmektedir. NFBÖİ görüntüsü ayrılabilirliği I. ve II. test alanları için önemli ölçüde arttırmakta, III. test alanında ise az bir artış sağlamaktadır. Farklı bölgelerde farklı etkinin olmasının nedeninin farklı yeşil alan miktarlarından kaynaklandığı düşünülmektedir. I. ve II. test alanlarında bina çevrelerinde yeşil alanlar bulunmaktadır, III. test alanında ise oldukça az yeşil alan vardır. Tüm veri setleri için ayrılabilirlik sonuçları değerlendirildiğinde Set 6 ve Set 8'in en iyi sonuçlar verdiği ve bu iki veri seti arasında önemli bir fark olmadığı görülmüştür.

DVM sınıflandırması uygulanırken kernel metodunun ve C parametresinin belirlenmesi önemlidir. Bu çalışmada genellikle iyi sonuç veren Radyal Taban Fonksiyonu (RTF) kullanılmıştır. RTF doğrusal olarak ayrılamayan problemlerde kullanılabilmektedir. C parametresi değeri olarak 1000 alınmıştır.

6. ARTEFAKTLARIN YOK EDİLMESİ

Sınıflandırma işlemi sırasında yanlış sınıflandırılan hücrelerden dolayı elde edilen olası bina alanları artefaktlar içerebilmektedir. Bunları gidermek için "açılma" ve "kapanma" morfolojik operasyonları kullanılmıştır. Morfolojik operasyonlar görüntüleri şekle göre işleyen görüntü işleme operasyonlarıdır. Bu çalışmada, yapılanma elemanından küçük olan görüntü detaylarını yok etmek için "açılma" ve "kapanma" operasyonları izotropik yapılanma elemanı ile birlikte kullanılmış ve böylece, objelerin genel biçimleri bozulmamıştır (Sonka vd., 1998). Aşınmayı takip eden genişleme "açılma"yı oluşturur. Görüntünün (f), yapılanma elemanı (k) ile açılması "$f \circ k$" ile gösterilir ve (12)'deki gibi tanımlanır. Genişlemeyi takip eden aşınma ise "kapanma" olarak adlandırılır. Görüntünün (f), yapılanma elemanı (k) ile kapanması "$f \bullet k$" ile gösterilir ve (13)'deki gibi tanımlanır.

$$f \circ k = \left(f \Theta k \right) \oplus k \tag{12}$$

$$f \bullet k = \left(f \oplus k \right) \Theta k \tag{13}$$

Açılma filtresi ince çıkıntıları, dışarı doğru olan sivri sınır düzensizliklerini, ince birleşimleri ve izole olmuş küçük objeleri yok eder. Kapanma filtresi ise ince girintileri, içe doğru olan sivri sınır düzensizliklerini ve küçük boşlukları yok eder (Gonzales vd., 2004). Bu nedenle, açılma ve kapanma operasyonlarını birleştirmek artefaktları ve gürültüyü yok etmek için oldukça elverişli olabilmektedir.

7. TARTIŞMA

Önerilen yaklaşımla belirlenmiş olan bina alanlarının doğruluklarını hesaplayabilmek için 1999 yılına ait mevcut sayısal bina vektör veritabanı uydu görüntüsünden güncellenmiş ve bu veri seti referans bina veri tabanı olarak kullanılmıştır. Belirlenen bina alanları ile referans bina alanları karşılaştırılmış ve dört ölçü değeri (Doğru Pozitif - DP, Doğru Negatif - DN, Yanlış Pozitif - YP ve Yanlış Negatif - YN) hesaplanmıştır (Shufelt ve McKeown, 1993). Doğru Pozitif (DP), hem önerilen yöntem sonucunda hem de referans veride bina olarak belirlenen alanlardır. Doğru Negatif (DN), hem önerilen yöntem sonucunda hem de referans veride arka plan (bina olmayan alan) olarak belirlenen alanlardır. Yanlış Pozitif (YP), yalnız önerilen yöntem sonucunda bina olarak belirlenen alanları temsil ederken Yanlış Negatif (YN), yalnız referans veride bina olarak belirlenen alanları temsil etmektedir. Ayrıca, ayrılma katsayısı (YP/DP), kaçırma katsayısı (YN/ DP), bina belirleme yüzdesi (100 * DP / (DP+YN)) ve kalite yüzdesi (100 * DP / (DP+YP+YN)) değerleri de hesaplanmıştır. Ayrılma katsayısı yanlışlıkla bina olarak bulunan alanların oranıdır ve fazladan bina alanı olarak belirlenen alanların, doğru bir şekilde bina alanı olarak belirlenen alanlara bölünmesiyle elde edilir. Kaçırma katsayısı, kaçırılan bina alanları oranını göstermekte olup gerçekte bina olduğu halde yaklaşımda bina olarak belirlenmeyen alanların, doğru bir şekilde bina alanı olarak belirlenen alanlara oranıdır. Bina belirleme yüzdesi (BBY) doğru bulunan binaların yüzdesini göstermektedir. Kalite yüzdesi (KY) yaklaşımın performansının toplam ölçümünü göstermektedir. Test alanları için DVM sınıflandırmasının nicel değerlendirme sonuçları tablo 6, tablo 7 ve tablo 8'de verilmiştir.

Veri Setleri	Eğitim Hücresi Sayısı	DP	DN	YP	Ayrılma Katsayısı	Kaçırma Katsayısı	Bina Belirleme Yüzdesi	Kalite Yüzdesi
Set 1	500	107785	27089	52527	0.49	0.25	79.92	57.52
	1000	108266	26608	53708	0.50	0.25	80.27	57.41
	2000	108739	26135	53370	0.49	0.24	80.62	57.76
	500	122746	12128	53357	0.43	0.10	91.01	65.21

Set 6	1000	124703	10171	54985	0.44	0.08	92.46	65.68
	2000	125062	9812	56145	0.45	0.08	92.73	65.47
Set 8	500	122726	12148	54505	0.44	0.10	90.99	64.80
	1000	124465	10409	54408	0.44	0.08	92.28	65.76
	2000	125187	9687	58037	0.46	0.08	92.82	64.89

Tablo 6: I. Test alanı için DVM sınıflandırmasının nicel değerlendirmesi

I. test alanı için DVM sınıflandırma sonuçları incelendiğinde, sonuçların Set 6 ve Seti 8 için BBY ve KY açısından oldukça benzer olduğu görülmektedir. Set 6 için 500, 1000 ve 2000 eğitim örneği kullanıldığında BBY yüzde 91.01, 92.46 ve 92.73 olarak hesaplanmıştır. Benzer şekilde Set 8 için 500, 1000 ve 2000 eğitim örneği kullanıldığında BBY yüzde 90.99, 92.28 ve 92.82 olarak hesaplanmıştır. Bunun yanında, 500, 1000 ve 2000 eğitim örneği kullanıldığında Set 6 için KY değerleri yüzde 65.21, 65.68 ve 65.47, Set 8 için ise yüzde 64.80, 65.76 ve 64.89 olarak bulunmuştur. Diğer taraftan, Set 1'in kullanılmasıyla yapılan sınıflandırma sonucunda daha düşük doğruluk değerleri elde edilmiştir. Bu veri setinde 500, 1000 ve 2000 eğitim örneği kullanıldığında BBY yüzde 79.92, 80.27 ve 80.62, KY ise yüzde 57.52, 57.41 ve 57.76 olarak hesaplanmıştır.

Veri Setleri	Eğitim Hücresi Sayısı	DP	DN	YP	Ayrılma Katsayısı	Kaçırma Katsayısı	Bina Belirleme Yüzdesi	Kalite Yüzdesi
Set 1	500	68206	8026	44330	0.65	0.12	89.47	56.57
	1000	67676	8556	36698	0.54	0.13	88.78	59.93
	2000	67306	8926	35638	0.53	0.13	88.29	60.16
Set 6	500	70733	5499	28524	0.40	0.08	92.79	67.52
	1000	70650	5582	27630	0.39	0.08	92.68	68.02
	2000	70608	5624	27701	0.39	0.08	92.62	67.94
Set 8	500	70592	5640	28209	0.40	0.08	92.60	67.59
	1000	70544	5688	26960	0.38	0.08	92.54	68.36
	2000	70590	5642	27450	0.39	0.08	92.60	68.08

Tablo 7: II. Test alanı için DVM sınıflandırmasının nicel değerlendirmesi

II. test alanında, I. test alanında olduğu gibi, Set 6 ve Set 8 için, benzer BBY ve KY değerleri hesaplanmıştır. Set 6 için 500, 1000 ve 2000 eğitim örneği kullanıldığında BBY yüzde 92.79, 92.68 ve 92.62 olarak hesaplanmıştır. Benzer şekilde Set 8 için 500, 1000 ve 2000 eğitim örneği kullanıldığında BBY yüzde 92.60, 92.54 ve 92.60 olarak hesaplanmıştır. Diğer taraftan, Set 1 kullanılarak yapılan sınıflandırma sonucunda daha düşük doğruluk değerleri elde edilmiştir. Bu veri setinde 500, 1000 ve 2000 eğitim örneği kullanıldığında BBY yüzde 89.47, 88.78 ve 88.29 olarak hesaplanmıştır. KY değerleri, 500, 1000 ve 2000 eğitim örneği kullanıldığında Set 6 için yüzde 67.52, 68.02 ve 67.94, Set 8 için yüzde 67.59, 68.36 ve 68.08 olarak hesaplanmıştır. Fakat aynı değerlendirme faktörü Set 1 için yüzde 56.57, 59.93 ve 60.16 olarak bulunmuştur.

Veri Setleri	Eğitim Hücresi Sayısı	DP	DN	YP	Ayrılma Katsayısı	Kaçırma Katsayısı	Bina Belirleme Yüzdesi	Kalite Yüzdesi
Set 1	500	502690	54066	233752	0.47	0.11	90.29	63.59
	1000	500026	56730	191293	0.38	0.11	89.81	66.84
	2000	504238	52518	189289	0.38	0.10	90.57	67.59
Set 6	500	534047	22709	194754	0.36	0.04	95.92	71.06
	1000	533200	23556	173068	0.32	0.04	95.77	73.06
	2000	531866	24890	150653	0.28	0.05	95.53	75.19

Set 8	500	531293	25463	196213	0.37	0.05	95.43	70.56
	1000	532450	24306	178581	0.34	0.05	95.63	72.41
	2000	532352	24404	158827	0.30	0.05	95.62	74.39

Tablo 8: III. Test alanı için DVM sınıflandırmasının nicel değerlendirmesi

III. test alanı için DVM sınıflandırma sonuçları incelendiğinde Set 6 ve Set 8 için BBY ve KY açısından oldukça benzer oldukları görülmektedir. Set 6 için 500, 1000 ve 2000 eğitim örneği kullanıldığında BBY yüzde 95.92, 95.77 ve 95.53 olarak hesaplanmıştır. Benzer şekilde, Set 8 için 500, 1000 ve 2000 eğitim örneği kullanıldığında BBY yüzde 95.43, 95.63 ve 95.62 olarak hesaplanmıştır. Bunun yanında 500, 1000 ve 2000 eğitim örneği kullanıldığında Set 6 için KY değerleri yüzde 71.06, 73.06 ve 75.19 olarak, Set 8 için ise yüzde 70.56, 72.41 ve 74.39 olarak bulunmuştur. Diğer taraftan, Set 1 kullanılarak yapılan sınıflandırma sonucunda daha düşük doğruluk değerleri elde edilmiştir. Şöyle ki, 500, 1000 ve 2000 eğitim örneği kullanıldığında BBY yüzde 90.29, 89.81 ve 90.57, KY ise yüzde 63.59, 66.84 ve 67.59 olarak hesaplanmıştır.

Sonuçlar değerlendirildiğinde eğitim alanı örneği sayısını artırmanın sonuçlarda önemli bir değişikliğe neden olmadığı görülmektedir. Bu nedenle, eğitim örneği sayısını 500 olarak almanın uygun olduğu tespit edilmiştir. Diğer taraftan, bu çalışmada kullanılan yardımcı verilerin sınıflandırma doğruluğunu önemli ölçüde arttırdığı belirlenmiştir. Özellikle nSYM ve NFBÖİ bantlarının sınıflandırmada ek bantlar olarak kullanılmasının sonuçları olumlu etkilediği tespit edilmiştir. Ancak bu bantlara ek olarak 1. TB ve yoğunluk görüntüsü kullanmanın sonuçlarda önemli bir değişikliğe neden olmadığı belirlenmiştir. Özetle, Set 6'nın sınıflandırmada en iyi sonucu verdiği söylenebilir. Test alanları için, Set 6 bantları ve 500 eğitim alanı örneğinin kullanılması ile elde edilen DVM sınıflandırma sonuçları Şekil 9'da verilmiştir. Ayrıca, elde edilen DVM sınıflandırma sonuçlarını En Büyük Olasılık Sınıflandırma Tekniği sonuçları ile karşılaştırmak için Set 6 verileri ve 500 eğitim alanı örneği kullanılarak çok sınıflı sınıflandırma yapılmıştır. Bu sınıflandırmaya ait nicel değerlendirme sonuçları tablo 9'de verilmiştir.

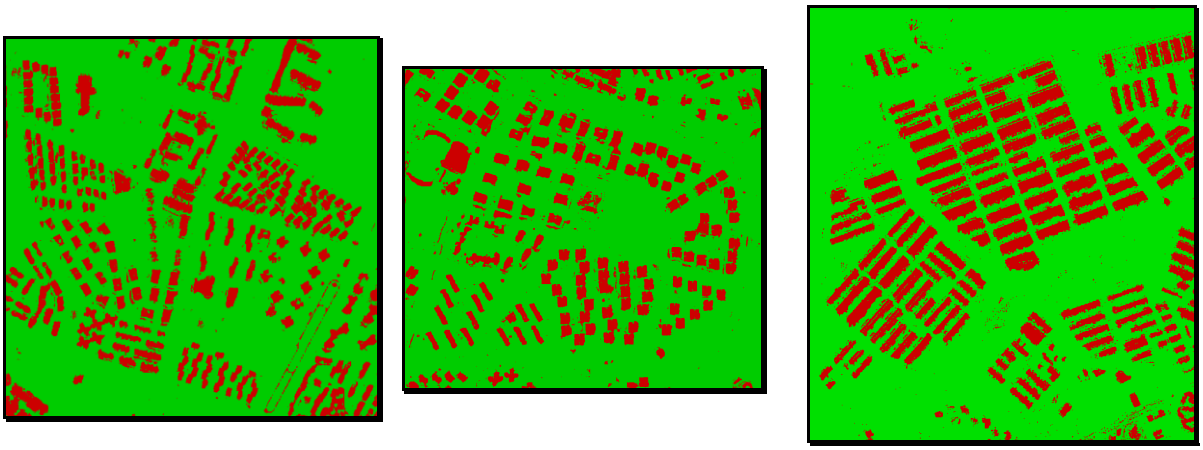

Şekil 9: Set 6 verileri ve 500 adet eğitim alanı hücresi kullanılarak yapılan DVM sınıflandırma sonuçları

DVM sınıflandırma sonuçları ile En Büyük Olasılık Sınıflandırma Tekniği sonuçları karşılaştırıldığında, I. ve II. test alanları için hem BBY ve hem de KY değerlendirme faktörleri DVM sınıflandırmasında daha yüksektir. III. Test alanı için, KY yine DVM sınıflandırma sonuçlarından daha yüksek hesaplanmış ancak BBY En Büyük Olasılık Sınıflandırma Tekniğinde daha yüksek bulunmuştur. Bunun nedeni, III. Test alanındaki binaların genellikle benzer spektral yansıma değerlerine sahip olmalarıdır. Çünkü, bu gibi durumlarda geleneksel sınıflandırma teknikleri de iyi sonuç verebilmektedir.

Test Alanları	DP	DN	YP	Ayrılma Katsayısı	Kaçırma Katsayısı	Bina Belirleme Yüzdesi	Kalite Yüzdesi
I. Test Alanı	90090	44784	15644	0.17	0.50	66.80	59.85
II. Test Alanı	50614	25618	14526	0.29	0.51	66.39	55.77
III. Test Alanı	541028	15728	457655	0.85	0.03	97.18	53.33

Tablo 9: Set 6 verileri ve 500 adet eğitim alanı hücresi kullanılarak yapılan En Büyük Olasılık

Sınıflandırmanın nicel değerlendirme sonuçları

8. SONUÇLAR

Elde edilen sonuçlar değerlendirildiğinde, DVM sınıflandırma tekniği kullanılarak binaların yüksek çözünürlüklü uydu görüntülerinden oldukça başarılı bir şekilde belirlenebildiği görülmektedir. Tüm veri setleri için değerlendirme yapıldığında: BBY I. Test alanında yüzde 79.92 – 92.82 aralığında, II. Test alanında yüzde 88.29 – 92.79 aralığında ve III. Test alanında yüzde 89.81 – 95.92 aralığında hesaplanmıştır. Benzer şekilde, KY I. Test alanında yüzde 57.41 – 65.68 aralığında, II. Test alanında yüzde 56.57 – 68.36 aralığında ve III. Test alanında ise yüzde 63.59 – 74.39 aralığında hesaplanmıştır. Genel olarak, BBY yüzde 79.92 – 95.92 KY ise yüzde 56.57 – 74.39 aralığında bulunmuştur. Farklı veri setleri için doğruluklar incelendiğinde yardımcı verilerin sınıflandırma doğruluğunu önemli ölçüde arttırdığı görülmektedir. Spektral bantlara ek olarak yardımcı verilerin kullanılması halinde BBY değer aralığı yüzde 90.99 – 95.92, KY değer aralığı ise yüzde 64.80 – 74.39 olarak değişmektedir. nSYM ve NFBÖİ bantlarının sınıflandırmada kullanılması durumunda doğruluk değerleri önemli ölçüde artarken 1.TB ve Yoğunluk görüntüsünün kullanılması ise doğrulukta önemli bir artış sağlamamıştır.

Eğitim alanı örneği sayısının DVM sınıflandırması doğruluğuna olan etkisi incelendiğinde örnek sayısındaki artışın, genel olarak, sınıflandırma doğruluğunu arttırdığı söylenebilir. Ancak bu artışın yüzde 2 den fazla olmadığı görülmüştür. Bu nedenle, bu çalışmada elde edilen sonuçlara göre eğitim alanı örneği sayısını çok fazla arttırmaya gerek olmadığı söylenebilir. DVM ve En Büyük Olasılık sınıflandırma sonuçlarının karşılaştırılması yapıldığında, DVM'nin daha iyi sonuçlar verdiği tespit edilmiştir.

KAYNAKLAR

BOYD, D. S.; SANCHEZ-HERNANDEZ, C.; FOODY, G. M. (2006), "Mapping a Specific Class for Priority Habitats Monitoring from Satellite Sensor Data", *International Journal of Remote Sensing*, Vol.27, No. 13, (2631-2644).
FOODY, G. M.; MATHUR, A. (2004), "A relative Evaluation of Multiclass Image Classification by Support Vector Machines", *IEEE Transactions on Geoscience and Remote Sensing*, Vol.42, No. 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, (1-14).
GONZALEZ, R. C.; WOODS, R. E.; EDDINS, S. L. (2004), *Digital Image Processing Using Matlab*, Pearson Education, Inc. Upper Saddle River, New Jersey.
HUANG, C.; DAVIS, L. S.; TOWNSHEND, **J. R. G.** (2002), "An assessment of support vector machines for land cover classification", *Int. J. Remote Sens.*, vol. 23, no. 4, (725–749).
KOÇ D.; TÜRKER M. (2005), **"**IKONOS Pankromatik Uydu Görüntülerinden Sayısal Yükseklik Modeli Oluşturulması", *Harita Dergisi*, Sayı: 134, (31-43).
PAL, M.; P. M. MATHER, (2005), "Support vector machines for classification in remote sensing," *Int. J. Remote Sens.*, vol. 26, no. 5, (1007–1011).
RICHARDS, J.A. (1999), *Remote Sensing Digital Image Analysis*, Springer-Verlag, Berlin, p. 240.
SANCHEZ-HERNANDEZ, C.; BOYD, D. S.; FOODY G., M. (2007), "One-Class Classification for a Specific Land-Cover Class: SVDD Classification of Fenland", *IEEE Transactions on Geoscience and Remote Sensing*, Vol.45, No. 4, pp. (1061-1073).
SHUFELT, J.A.; MCKEOWN, D.M. (1993), "Fusion of Monocular Cues to Detect Man-Made Structures in Aerial Imagery", *CVGIP: Image Understanding*, 57 (3), (307-330).
SINGH, A.; HARRISON, A. (1985), Standardized Principal Components, *International Journal of Remote Sensing*, 6, (883-896).
SONKA, M.; HLAVAC, V.; BOYLE, R. (1998), *Image Processing, Analysis, and Machine Vision*, PWS Publishing.
VAPNIK, V. N. (1995), *The Nature of Statistical Learning Theory*, New York: Springer-Verlag, ISBN 0-387-94559-8.
WATANACHATURAPORN, P.; ARORA M. K.; VARSHNEY P. K. (2008), "Multisource Classification Using Support Vector Machines: An Emprical Comparison with Decision Tree and Neural Network Classifiers", *Photogrammetric Engineering and Remote Sensing*, Vol. 74, No. 2, (239 – 246).
ZHU, G.; BLUMBERG, D. G. (2002), "Classification using ASTER data and SVMalgorithms: The case study of Beer Sheva, Israel," *Remote Sensing of Environment*, vol. 80, no. 2, (233–240).