

Fonksiyonel Ağaçlar ile Obje-Tabanlı Sınıflandırma: WorldView-2 Uydu Görüntüsü Örneği

(Object-Based Classification with Functional Trees: A Case Study of Worldview-2 Imagery)

İsmail ÇOLKESEN

Gebze Teknik Üniversitesi, Harita Mühendisliği Bölümü, Gebze, Kocaeli

icolkesen@gtu.edu.tr

ÖZ

Son yıllarda, metre altı mekânsal çözünürlük sağlayan yüksek çözünürlüklü uydu görüntülerinin varlığı ile birlikte sınıflandırma işlemi geleneksel piksel-tabanlı görüntü analizinden obje-tabanlı görüntü analizine yönelmiştir. Herhangi bir sınıflandırma probleminde olduğu gibi, uygun bir sınıflandırma algoritmasının seçilmesi obje-tabanlı tematik harita üretimi işleminin başarısı içinde oldukça önemlidir. Karar ağaçları (KA) ve özellikle KA türevleri (örneğin rastgele orman ve rotasyon orman) hem piksel hem de obje tabanlı sınıflandırmada başarılı bir şekilde kullanılmaktadır. Bu bağlamda, çoklu lojistik regresyon ve KA algoritmalarının birleşimine dayalı fonksiyonel ağaçlar (FA) birçok görüntü tanıma probleminde etkili bir şekilde kullanılan ancak uzaktan algılanmış görüntülerin sınıflandırılması için oldukça yeni bir sınıflandırma algoritmasıdır. Bu çalışmada, yüksek çözünürlüklü WorldView-2 uydu görüntüsünün obje-tabanlı yaklaşımla sınıflandırılması probleminde FA algoritmasının sınıflandırma performansı incelenmiştir. Algoritmanın performansı geleneksel KA ve KA'nı temel sınıflandırıcı olarak kullanan hızlandırma algoritmasının (Adaboost) performansı ile karşılaştırılmıştır. Sınıflandırma sonuçları, FA algoritmasının segmente edilmiş görüntü objelerinin sınıf etiketlerinin tahmin edilmesinde geleneksel KA algoritmasından daha başarılı olduğunu ve hesaplanan sınıflandırma doğruluğundaki iyileşmenin yaklaşık %3 olduğunu gösterirken, algoritmanın karar ağaçlarını esas alan hızlandırma algoritması ile aynı performansı sergilediğini göstermektedir. Hızlandırma algoritmasında temel sınıflandırıcı olarak FA kullanılması durumunda, sınıflandırma doğrulukları arasındaki farkların KA ve KA'nı esas alan hızlandırma algoritması için %4 ve %2 olarak hesaplandığı görülmüştür. Wilcoxon işaretli sıralar testi sonuçlarına göre algoritmaların sınıflandırma performansındaki bu artışların istatistiksel olarak anlamlı olduğu ortaya konulmuştur.

Anahtar Kelimeler: Fonksiyonel ağaçlar, karar ağaçları, hızlandırma, Worldview-2, obje-tabanlı sınıflandırma.

ABSTRACT

During the recent years, with the availability of very high resolution of satellite imagery providing sub-meter spatial resolution, the image classification process has been shift from conventional pixel-based to object-based image analysis. As in any classification problem, selection of suitable classification algorithm is also crucial for the success of the object-based thematic

mapping process. Decision trees (DT) and especially its derivatives (e.g. random forest and rotation forest) have been successfully applied for both pixel-based and object-based classification task. In this context, functional trees (FT) based on the combination of multiple logistic regression and DT algorithms have been effectively used in many pattern recognition problems but relatively new for classification of remotely sensed imagery. In this study, the classification performance of the FT and was investigated for object-based image analysis of high resolution WorldView-2 imagery. Its performance was compared with conventional DT and its widely-used variant boosting (Adaboost) in which DT is used as the base classifier in the ensemble. Classification results show that FT algorithm produced similar performances with boosted-DT while it outperformed conventional DT algorithm in predicting segmented image objects labels and improvement in the estimated classification accuracy was about 3%. When the FT was used as a base classifier in boosting algorithm, it was observed that the difference in accuracies was calculated as 4% and 2% for DT and boosted-DT, respectively. The improvements in the performances of the algorithms were also found to be statistically significant considering the Wilcoxon's signed ranks test results.

Keywords: Functional trees, decision trees, boosting, WorldView-2, object-based classification.

1. GİRİŞ

Uzaktan algılanmış görüntülerin sınıflandırılması yeryüzüne ait arazi örtüsü ve arazi kullanımına ilişkin bilgilerin elde edilmesinde en yaygın kullanılan yöntemdir. Son yıllara kadar, söz konusu bilgilerin çıkarılmasında piksel-tabanlı sınıflandırma yaklaşımı standart yöntem olarak kabul edilirken, özellikle yüksek çözünürlüklü görüntülerin (1m ve daha yüksek çözünürlük) kullanıma sunulması ile birlikte obje-tabanlı sınıflandırma yaklaşımı ön plana çıkmış ve obje-tabanlı yaklaşım ile sınıflandırma doğruluğunda önemli derecede artış sağlandığı birçok çalışmada vurgulanmıştır (Blaschke, 2010; Myint, vd., 2011; Colkesen vd., 2017). Bunun temel nedeni, yüksek çözünürlüklü görüntüler üzerindeki doğal arazi örtüsü ve kullanım sınıflarının kendi içerisindeki spektral değişkenlikleri ve sınıfların birbirleri arasında spektral benzerlikleri nedeniyle piksel-tabanlı yaklaşımların sınıfların birbirinden ayırt edilmesi

noktasında yetersiz kalması ve dolayısıyla düşük sınıflandırma doğruluğu elde etmesidir (Myint, vd., 2011; Johnson, 2013).

Obje-tabanlı sınıflandırma yaklaşımında temel düşünce benzer spektral özelliklere sahip görüntü piksellerinden oluşan homojen yapılı görüntü objelerinin oluşturulması ve objeler için tanımlanan spektral, istatistiksel, doku ve geometrik özellikler dikkate alınarak görüntü objelerinin sınıflandırılmasıdır (Baatz, vd., 2000; Belgiu, vd., 2014). Obje-tabanlı görüntü analizinde, görüntü segmentasyonu, obje özelliklerinin belirlenmesi (spektral, geometrik veya ilişkisel) ve segmente edilen görüntü objelerinin belirli arazi kullanımı ve arazi örtüsü sınıflarından birine sınıflandırılmasını içeren üç temel işlem adımı mevcuttur (Belgiu, vd., 2014; Kavzoglu, vd., 2015). Obje-tabanlı yaklaşımda da sınıflandırma işleminde kullanılacak algoritma seçimi sınıflandırma doğruluğunu etkileyen önemli bir işlem adımıdır. Bu nedenle, son yıllarda en yakın komşuluk algoritması gibi klasik sınıflandırma algoritmaları yerine piksel-tabanlı sınıflandırmada etkinliği kabul edilen makine öğrenme algoritmalarının obje-tabanlı görüntü analizindeki kullanımı uzaktan algılamada önemli bir araştırma konusu olarak ortaya çıkmıştır (Heuman, 2011; Ghosh and Joshi, 2014; Qian et al., 2015; Kavzoglu vd., 2015).

Karar ağaçları (KA) literatürde yaygın kullanımı olan bir sınıflandırma ve örüntü tanımlama algoritmasıdır (Rogan, vd., 2008; Kavzoglu, vd., 2010). Algoritma bir sınıflandırma problemini hiyerarşik veya çok aşamalı bir yapıya dönüştürerek hedef sınıfların birbirinden ayırt edilmesi prensibini esas almaktadır (Swain, vd., 1977; Mather, vd., 2011). Diğer bir ifadeyle, uzaktan algılanmış görüntüleri de içerisine alan karmaşık yapıdaki veri setlerinin sınıflandırılması problemini aşamalı bir hale getirerek basit bir karar verme işlemi gerçekleştirir (Safavian vd., 1991). Bu özelliği sayesinde KA, uzaktan algılama alanında hem piksel hem de obje-tabanlı sınıflandırma problemlerinin çözümünde yaygın bir kullanıma sahiptir (Heuman, 2011; Cordeiro vd., 2015, Low vd., 2015).

Matematiksel olarak kolay ifade edilebilen ve programlanabilen yapısı nedeniyle KA, ağaç yapısını esas alan yeni nesil algoritmaların geliştirilmesinde veya birden fazla algoritmanın bir arada kullanıldığı hibrit yapılı sınıflandırma modellerinin oluşturulmasında tercih edilen algoritmaların başında gelmektedir. Birden fazla karar ağacı yapısının bir araya getirilmesi ve her bir KA tahmininden yola çıkılarak sonuç

tahminlerin yapılması esasına dayanan rastgele orman algoritması KA'nı esas alan algoritmalara örnek olarak gösterilebilir (Pal, 2005). Bunun dışında literatürde sınıflandırma işleminin gerçekleştirilmesinde başarıyla kullanılan hızlandırma, torbalama ve rastgele orman gibi toplu öğrenme algoritmalarının kullanıldığı uygulamalarda genellikle temel sınıflandırıcı olarak KA tercih edilmektedir (Kavzoglu vd., 2013). Son yıllarda farklı örüntü tanıma problemlerinin çözümünde kullanılan fonksiyonel ağaçlar (FA), KA ile çoklu lojistik regresyon algoritmalarının bir arada kullanıldığı hibrit yapılı sınıflandırma algoritmalar arasındadır. Uzaktan algılanmış görüntülerin sınıflandırılması probleminde performansı henüz test edilmeyen fonksiyonel ağaç yapıları, literatürde raster ve vektör yapılı veri modellerinin entegrasyonu, kanser vakalarının ayırt edilmesi, astronomik gözlemlerin sınıflandırılması, istenmeyen elektronik postaların tespiti, hiperspektral veriler ve dijital görüntülerin sınıflandırması olmak üzere bir çok çalışmada kullanılan bir algoritmadır (Vasconcellos, vd., 2011; Grandchamp, 2012; Ozcift, vd., 2013; Akçetin, vd., 2014; Popescu, vd., 2014; Hu, vd., 2016). FA, ağaç yapısı oluşumunda genellikle tek değişkenli sınıflandırmalar kullanan basit bir KA yapısını, çoklu lojistik regresyon algoritması yardımıyla çok değişkenli sınıflandırmalar yapabilmesine imkan sağlamaktadır (Gama, 2004; Witten, vd., 2011).

Bu çalışmada, yüksek çözünürlüklü WorldView-2 uydu görüntüsünün obje-tabanlı yaklaşımla sınıflandırılması ve tematik harita üretiminde FA ve FA'ı esas alan hızlandırma algoritmasının kullanımı ele alınmıştır. Algoritmanın sınıflandırma performansının karşılaştırılması ve objektif olarak analiz edilmesi amacıyla geleneksel KA ve KA'nı esas alan hızlandırma algoritması da değerlendirmeye alınmıştır.

2. ÇALIŞMA ALANI VE KULLANILAN VERİ

Kocaeli iline bağlı Darıca ilçesini içerisine alan yaklaşık 280 hektarlık bölge çalışma alanı olarak belirlenmiştir (Şekil 1). İlçe mavi bayraklı plajları, kumsalları, çeşitli rekreasyon alanları ve birçoğu yazlık evlerden oluşan yapısıyla Marmara bölgesinin en önemli turizm merkezlerinden birisi durumundadır. Sahip olduğu doğal özelliklerle bir cazibe merkezi konumunda olan çalışma alanı yoğun yapılaşma baskısı altında doğal hayatı koruyabilmiş ender alanlardandır.

2013 Mayıs ve Haziran aylarında gerçekleştirilen saha çalışmaları neticesinde



Şekil 1. Çalışma alanı ve konumu

çalışma bölgesinde 10 farklı arazi örtüsü ve arazi kullanım sınıfının varlığı tespit edilmiştir. Bunlar içerisinde su, toprak, bozkır, yol, geniş ve iğne yapraklı ağaçlar olarak tanımlanan temel arazi örtüsü sınıflarının yanı sıra çatıların yapımında kullanılan malzemenin türüne göre bina sınıfları yer almaktadır. Çalışma alanında betonarme kaplamaya sahip olan bina çatıları bina-beyaz, kiremit kaplamaya sahip bina çatıları bina-kırmızı ve gri renkli kiremit veya metal malzemeye kaplanan bina çatıları ise bina-gri olarak kendi içerisinde sınıflandırılarak her biri arazi kullanım sınıfı olarak tanımlanmıştır. Bu sınıflara ilave olarak, gölge probleminden kaynaklanabilecek sınıflandırma hatalarının azaltılması amacıyla gölge sınıfı da uygulamada değerlendirmeye alınmıştır.


3. SINIFLANDIRMA ALGORİTMALARI

a. Karar Ağaçları

Birçok sınıflandırma probleminde, veri seti ile sınıflar arasındaki ilişkinin bir bütün olarak değil de aşamalar halinde ele alınması farklı ölçeklerde veya farklı detay seviyelerindeki nesneler arasındaki ilişkilerin daha kolay bir şekilde ortaya koyulmasına imkan sağlamaktadır. Akış şemalarına benzeyen yapılarıyla karar ağaçları farklı seviyelerdeki sınıflandırmaları ayrı hiyerarşik seviyelerde gerçekleştirmektedir. Söz konusu hiyerarşik sınıflandırma mekanizması çok

bantlı bir uydu görüntüsü açısından ele alınırsa, karar ağacı yapısının oluşturulmasında veri setinin içerisindeki her bir sınıfın kendi içerisindeki spektral özellikler ve diğer sınıflarla olan spektral ilişkiler esas alınmaktadır. Karar-kutu (black-box) algoritmalar olarak bilinen yapay sinir ağları ile karşılaştırıldığında, ağaç yapısının görsel olarak kolay yorumlanabilmesi ve sınıflandırma işleminde kullanılan karar kurallarının anlaşılabilir ve sade olması nedeniyle karar ağaçları beyaz-kutu (white-box) algoritmalar olarak bilinmektedirler (Mather and Koch, 2011).

Şekil 2'de kırmızı, yeşil, mavi ve NIR bantlar kullanılarak orman, su ve toprak sınıflarının ayırt edilmesi amacıyla oluşturulan örnek bir KA modeli gösterilmiştir. Şekilden de görüleceği üzere basit bir ağaç yapısı düğüm, dal ve yaprak olarak adlandırılan üç temel kısımdan oluşur. Bu ağaç yapısında her bir öznelilik (uydu görüntüsü için bant değeri) bir düğüm tarafından temsil edilir. Dallar ve yapraklar ağaç yapısının diğer elemanlarıdır. Ağaçta en son kısım yaprak en üst kısım ise kök olarak adlandırılır. Kök ve yapraklar arasında kalan kısımlar ise dal olarak ifade edilir (Quinlan, 1993). Eğitim verilerine ait öznelilik bilgilerinden yararlanılarak bir ağaç yapısı oluşturulmasında temel prensip verilere ilişkin bir dizi sorular sorulması ve elde edilen cevaplar doğrultusunda hareket edilerek en kısa sürede sonuca gidilmesi olarak ifade edilebilir. Bu şekilde



Şekil 2. Üç sınıfa sahip dört bantlı veri seti için oluşturulan karar ağacı yapısı.

karar ağacı sorulara aldığı cevapları toplayarak karar kuralları oluşturur. Ağacın ilk düğümü olan kök düğümünde verilerin sınıflandırılması ve ağaç yapısının oluşturulması için sorular sorulmaya başlanır ve dalları olmayan düğümler ya da yapraklar bulunana kadar bu işlem devam eder (Pal, vd., 2003). Şekildeki örnek ağaç yapısı göz önüne alındığında, sınıf etiketi belli olmayan bir pikselin, kızılötesi banttaki spektral parlaklık değeri 48'den küçük veya eşitse ve aynı pikselin kırmızı banttaki parlaklık değeri 29,5'den küçük veya eşitse söz konusu piksel su sınıfındadır sonucuna ulaşılır.

Karar ağaçlarının oluşturulmasındaki en önemli işlem adımı ağaçtaki dallanmanın hangi kriterlere göre yapılacağı ya da hangi bant değerlerine göre ağaç yapısının oluşturulacağıdır (Mather ve Koch, 2011). Karar ağacı oluşturulmasında kullanılan en temel algoritma Hunt algoritmasıdır (Hunt, 1962). Bu algoritmanın en önemli eksikliği dallanmaya esas olacak özelliklerin rastgele seçilmesidir. Literatürde bu eksikliğin giderilmesi ve dallanmaya esas olacak özelliklerin belirli bir kıstas göz önüne alınarak tespit edilmesi amacıyla çeşitli algoritmalar geliştirilmiştir. Bunlardan en önemlisi Quinlan (1987) tarafından geliştirilen ID3 algoritması olup,

bu algoritma dallanma için seçilecek özelliğin entropi ölçütüne göre belirlendiği bir algoritmadır. Bu algoritma ile ağaç oluşumunda entropi'ye dayalı bilgi kazancı hesaplanarak en yüksek değere sahip özellik dikkate alınarak karar ağacı oluşumu ve dallanması gerçekleştirilir. ID3 algoritmasının geliştirilmiş hali olan ve günümüzde karar ağacı oluşumunda standart yaklaşım olarak kabul edilen C4.5 algoritması yine entropi ölçütüne dayalı bir algoritma olup bilgi kazancı yerine kazanç oranı kriteri kullanarak dallanmaya esas olacak özelliği belirlemektedir (Quinlan, 1993, Kavzoğlu vd., 2010).

b. Hızlandırma

Toplu öğrenme yaklaşımı tek bir sınıflandırıcı yerine birden çok sınıflandırıcıyı içerecek şekilde bir sınıflandırıcı kümesinin oluşturulması ve küme içerisindeki sınıflandırıcıların tahminlerinden yola çıkılarak sınıf etiketi belli olmayan örneklerin sınıflandırılması esasına dayanmaktadır (Dietterich, 2000). Günümüze kadar toplu öğrenme algoritması olarak başta hızlandırma, torbalama, rastgele orman ve dönüşümlü orman olmak üzere birçok algoritma geliştirilmiştir (Du, vd., 2012; Kavzoğlu, vd., 2013; Xia, vd., 2014).

Hızlandırma algoritması eğitim veri setindeki her bir örneğe ağırlık verilmesi esasına dayanmaktadır (Freund, vd., 1996; Tso, vd., 2009). Eğitim veri seti içerisindeki her bir örneğin ağırlıkları başlangıçta eşit olarak alınır. Daha sonra toplu öğrenme kümesi içerisindeki her bir sınıflandırıcı için eğitim verisindeki örnekler için sınıf etiketleri tahmin edilir. Tahmin edilen sınıf etiketleri ile bilinen sınıf etiketleri karşılaştırılarak, eğitim veri seti içerisinde hangi örneğin hatalı sınıflandırıldığı tespit edilir. Bir sonraki adımda eğitim veri seti içerisinde hatalı sınıflandırılan bu örneklerin ağırlığı artırılarak sınıflandırma işlemi tekrar edilir. Hatalı sınıflandırılan örneklerin ağırlıklarının artırılması ile sınıflandırıcıların bu örnekler üzerine odaklanması sağlanır. Hızlandırma algoritması bu iteratif yaklaşımla eğitim veri seti içerisinde doğru sınıflandırılan pikseller yerine hatalı sınıflandırılan piksellere yoğunlaşarak sınıflandırma doğruluğunu artırılmasını amaçlamaktadır.

Literatürde hızlandırma yöntemiyle sınıflandırıcıların birleştirilmesinde en çok tercih edilen algoritma Adaboost algoritmasıdır (Tso vd., 2009; Canty, 2014). Adaboost toplu öğrenme kümesi içerisindeki her bir sınıflandırıcının eğitiminde kullanılacak örneklerin seçiminde iki yaklaşım kullanır. Bunlardan birincisi örneklerin olasılıklarına dayalı olarak eğitim setinin oluşturulmasıdır. İkincisi ise, basit bir biçimde tüm örneklerin ve ağırlıklarının kullanılmasıdır. Bu yöntemin ana düşüncesi her bir örneğin hatasının o örneğin olasılığı ile belirlenmesidir. Adaboost yönteminde başlangıçta her bir örneğin olasılığı $1/N$ olarak kabul edilir. Daha sonra eğitilen her bir sınıflandırıcının ürettiği sonuçlar dikkate alınarak hatalı sınıflandırılan pikseller ile ilgili olasılıklar tekrar hesaplanır. Eğitimden sonra, her bir sınıflandırıcının ağırlıklı oyu kullanılarak birleşime ait tahminler yapılır. Her bir sınıflandırıcıya ait ağırlıklar, sınıflandırıcıların eğitiminde kullanılan ağırlıklı örneklerden elde edilen doğruluğa göre hesaplanır.

c. Fonksiyonel Karar Ağaçları


Karar ağaçlarının kullanıldığı bir sınıflandırma probleminde genelde çoklu kararlar ara düğümlerde alınırken, regresyon problemlerinde ağacın yaprak kısmında çoklu kararlar alınmaktadır. Fonksiyonel karar ağaçları bu iki yaklaşımın bir birleşimi olarak düşünülebilir. Diğer bir ifadeyle, fonksiyonel ağaçlar (FA) hem ara düğümlerde hem de yapraklarda tüm girdi özelliklerine (bantlara) ait bilgileri kullanır (Gama, 2004). Tek değişkenli karar ağaçları bir düğüm noktasında sadece tek bir öznelik değerini

(spektral bant değerini) dikkate alarak ağacın bölünmesi veya dallanması işlemini gerçekleştirirken, FA hem yaprakta hem de ara düğümlerde mevcut tüm öznelik değerlerinin kullanılmasına imkan sağlar (Vascocellos, vd., 2011).

FA oluşumunda kullanılan algoritma ağaç oluşumunda yukarıdan-aşağıya tekrarlamalı bölünme stratejisini kullanmaktadır. Ağacın her bir düğümünde bölünme tekil olmasına karşın, hem veri setindeki orijinal özellikler hem de bir özellik oluşturucu fonksiyon (çoklu lojistik regresyon) kullanarak üretilen yeni özellikler dikkate alınır. Her bir yeni özelliğin değeri düğüm noktasına ulaşan her bir örnek için regresyon fonksiyonunun tahmininden elde edilir (Landwehr, vd., 2005). Ağaç yapısı oluşturulduktan sonra, aşağıdan-yukarıya yaklaşımı ile budama işlemi gerçekleştirilir. Yaprak olmayan her bir düğüm noktasında üç durum söz konusudur. Bunlardan ilki, ağaç yapısında budama yapılmamasıdır. İkincisi, düğüm noktasının tek bir sonucu veya sabit değeri içeren bir yaprakla yer değiştirmesidir. Üçüncüsü ise, düğüm noktasının bir fonksiyonu (örneğin lojistik regresyon) içeren bir yaprakla yer değiştirmesidir (Gama, 2004).

FA ile sınıf etiketi belli olmayan bir örnek için, ağacın kök düğümünden başlayıp yaprak düğümüne doğru ilerlenmesi ile tahmin işlemi gerçekleştirilir. Ağacın her bir karar düğümünde ayrı bir regresyon fonksiyon kullanılır. Bu fonksiyon ile özellik sayısı artırılır ve elde edilen olasılıklara göre ağaç içerisinde hangi yoldan devam edeceğine karar verilir. Eğer bir yaprağa ulaşırsa, bu örnek ya bir sabit olarak sınıflandırılır ya da yapraktaki diğer bir regresyon fonksiyonuna ulaşır. Şekil 3'de Landsat TM uydu görüntüsünün kırmızı (K), yeşil (Y), mavi (M) ve NIR bantları kullanılarak üç farklı arazi örtüsü sınıfının ayırt edilmesi problemi için oluşturulan örnek bir fonksiyonel ağaç yapısı modeli gösterilmiştir.

FA algoritması ile sınıflandırma veya sınıf etiketlerinin tahmini şu şekilde gerçekleştirilir: Öncelikle eğitim veri seti kullanılarak ağaç yapısı oluşturulur. Sınıf etiketi belli olmayan bir örnek ağacın kök noktasından modele girer ve bir yaprağa ulaşmaya kadar ağaçta ilerler. Ağaç yapısındaki her bir iç düğümde (iç karar düğümünde) örneğe ait tüm öznelikler (spektral bant değerleri) bu düğümde eğitim veri setindeki sınıf sayısı kadar ayrı ayrı oluşturulan çoklu regresyon modeline uygulanır. Söz konusu piksel için regresyon modellerden elde edilen olasılıklar dikkate alınarak örneğin ağaçta hangi yoldan



Şekil 3. Üç sınıfa sahip dört bantlı veri seti için oluşturulan fonksiyonel ağaç yapısı.

devam edeceğine karar verilir. Ağacın herhangi bir yaprağına ulaşıldığında sınıf etiketi belli olmayan bir örneğin hangi sınıfa atıldığı iki şekilde belirlenebilir. Eğer ulaşılan yaprakta belirli bir sınıf var ise pikselin o sınıfa ait olduğuna karar verilir. Eğer ulaşılan yaprakta yeni çoklu regresyon model varsa, örneğe ait spektral bant değerleri regresyon modellerine uygulanır ve modelden çıkan olasılık sonuçlarına göre örneğin ait olduğu sınıf belirlenir (Landwehr, vd., 2005; Rodriguez, vd., 2010; Ozcift, vd., 2013).

FA algoritmasının temel yapı taşlarından biri olan lojistik regresyon analizi birçok örüntü tanıma probleminde kullanılan popüler bir algoritmadır (Witten, vd., 2011). Lojistik regresyon analizi, ikili sonucu olan ve tek bir bağımsız değişkene sahip regresyon problemlerinin çözümünde kullanılırken, ikili sonucu olan ve birden fazla değişkenin olduğu problemlerde çoklu lojistik regresyon algoritması kullanılır. Lojistik regresyon algoritmasının sonucu genelde 0 ve 1 olarak kodlanır. Burada 1 ilgi duyulan olayın var olduğunu gösterirken 0 ilgi duyulan olayın olmadığını göstermektedir.

Bir regresyon probleminde p sayıda bağımsız değişkenin (uzaktan algılamada bant sayısı) olduğunu ve bu değişkenlerin $X = (x_1, \dots, x_p)$ şeklinde bir vektörle gösterildiği düşünülün. Bu

durumda çoklu regresyon için logit fonksiyonu $y(x)$ Eşitlik (1)'de gösterildiği şekilde ifade edilir.

$$y(x) = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p \quad (1)$$

Bu durumda lojistik regresyon modeli

$$p(x) = \frac{e^{\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p}}{1 + e^{\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p}} \quad (2)$$

şeklinde. Bu eşitlikte, $p(x)$ model sonucuna ilişkin olasılığı, $x_1, \dots, x_p$ bağımsız değişkenleri ve $\beta_0, \beta_1, \dots, \beta_p$ ise regresyon modeline ilişkin katsayıları göstermektedir.

4. MATERYAL VE YÖNTEM

Uygulama kapsamında temel veri kaynağı olarak 2013 tarihinde kaydedilen 0.5m pankromatik ve 2m mekânsal çözünürlüklü 8 multispektral banda sahip Worldview-2 (WV-2) uydu görüntüsü kullanılmıştır. WV-2 uydusu klasik kırmızı (630-690 nm), yeşil (510-580 nm), mavi (450-510 nm) ve yakın kızılötesi (770-895 nm) bantlarına ilave olarak kıyı (400-450nm), sarı (585-625 nm), kırmızı-kenar (705-745 nm) ve ikinci bir kızılötesi (860-1040 nm) bantta görüntüleme yapmaktadır. Çalışmada değerlendirmeye alınan WV-2 görüntüsüne ait

işlem düzeyi 2A (level2A) olup, görüntü tedarikçi firma tarafından radyometrik ve geometrik olarak düzeltilmiş ve UTM (Universal Transverse Mercator) projeksiyon sisteminde WGS84 (World Geodetic System 1984) datumunda tanımlanmıştır. WV-2'nin 0.5m pankromatik ve 2m multispektral görüntülerin kaynaştırılmasında Gram-Schmidt algoritmasından yararlanılmış ve kaynaştırma sonucu elde edilen görüntünün yeniden örneklemeinde literatürde yüksek çözünürlüklü görüntülerin kaynaştırılmasında görüntü netliği ve detayların korunması açısından bir çok çalışmada tercih edilen Bilineer enterpolasyon tekniği kullanılmıştır (Palubinskas, 2013; Jawak vd., 2013; Ghosh vd., 2013).

Çalışma kapsamında, WV-2 uydu görüntüsünün obje-tabanlı yaklaşımla sınıflandırılmasında üç temel işlem adımı takip edilmiştir. İlk olarak uydu görüntüsünün segmentasyon işlemi gerçekleştirilerek görüntü objeleri elde edilmiş ve söz konusu görüntü objelerine ilişkin özellikler tanımlanmıştır. İkinci aşamada, bölge içerisindeki arazi örtüsü ve kullanım sınıflarını temsil eden örnekleme alanları tespit edilerek görüntü objeleri ile ilişkilendirilmiş ve sınıflandırma modellerinin oluşturulmasında kullanılmak üzere eğitim ve test veri setleri oluşturulmuştur. Üçüncü aşamada ise çalışma kapsamında değerlendirmeye alınan sınıflandırma algoritmaları için en uygun sınıflandırma modelleri oluşturulmuş ve segmente edilen görüntünün tamamı söz konusu modeller ile sınıflandırılarak tematik harita üretimi gerçekleştirilmiştir.

WV-2 görüntüsünün segmente edilmesi ve görüntü objelerine ait özelliklerin tanımlanması işlemleri eCognition Developer 9.0 yazılımı yardımıyla gerçekleştirilmiştir. Segmentasyon işlemi için literatürde yaygın olarak kullanılan çoklu çözünürlük segmentasyonu algoritması kullanılmıştır (Baatz vd., 2000). Algoritma ile segmentasyon işleminin gerçekleştirilmesinde ihtiyaç duyulan ölçek parametresinin tespitinde Drăguț, vd. (2010) tarafından önerilen ESP yazılımından yararlanılmıştır. ESP yazılımının çalışma prensibi, kullanıcı tarafından belirlenen bir parametre aralığında ve ön görülen artış miktarına göre görüntünün iteratif bir şekilde segmentasyonunun yapılması ve her iterasyon sonucunda lokal varyans değerlerinin (görüntü objeleri arasındaki standart sapmaların ortalaması) hesaplanması esasına dayanmaktadır. Lokal varyans değerleri arasındaki değişim oranları içerisinde ani artışların görülüşü parametre değerlerinin optimum ölçek parametresi olarak

kullanılabilecek aday ölçek parametreleri olduğu ifade edilmektedir (Drăguț, vd. 2010).

Bu çalışmada, ESP yazılımında ölçek parametre değer aralığı minimum 10 ve maksimum 100 olarak belirlenmiş ve ölçek parametresindeki artış miktarı 1 olarak seçilmiştir. ESP yazılımı tarafından hesaplanan lokal varyans değişim oranlarının analizi neticesinde WV-2 görüntüsü için dört aday ölçek parametre değeri (19, 29, 37 ve 59) olduğu tespit edilmiştir. Yazılım tarafından belirlenen aday ölçek parametreleri kullanılarak ayrı ayrı segmentasyon işlemi gerçekleştirilmiş ve ölçek parametresinin 19 olarak seçilmesiyle arazi örtüsü ve arazi kullanım sınıflarının temsili ve birbirinden ayırt edilmesi noktasında daha anlamlı görüntü objelerinin elde edildiği görülmüştür. Belirlenen bu ölçek parametresi yardımıyla segmentasyon işlemi gerçekleştirilmiş ve sonuçta 125.350 görüntü objesi elde edilmiştir. Çoklu çözünürlük segmentasyonu ile segmentasyon işleminin gerçekleştirilmesinde WV-2 görüntüsünün tüm bantları değerlendirmeye alınmış ve her bandın ağırlığı eşit alınmıştır.

Segmentasyon sonucu üretilen görüntü objelerine ilişkin ortalama spektral parlaklık değerleri hesaplanmış ve sınıflandırma işleminin gerçekleştirilmesinde objelerin bu özelliklerinden yararlanılmıştır. Görüntü objelerine ilişkin özelliklerin tanımlanmasının ardından, tematik harita üretimine esas teşkil edecek sınıflandırma modellerinin oluşturulması amacıyla öncelikle gerçekleştirilen saha çalışmaları, bölgeye ilişkin mevcut hâlihazır haritalar ve Google Earth veri tabanında servis edilen farklı tarihli yüksek çözünürlüklü uydu görüntüleri yardımıyla örnekleme alanları tespit edilmiştir. Segmentasyon neticesinde elde edilen görüntü objeleri, belirlenen örnekleme alanları ile ilişkilendirilerek çalışma alanındaki arazi örtüsü ve kullanım sınıflarını temsil eden toplam 3.187 referans görüntü objesi belirlenmiştir. Elde edilen referans objeleri içerisinde rastgele örnekleme prensibinden hareketle ayrı ayrı eğitim ve test veri setleri oluşturulmuştur. Sonuç olarak sınıflandırma işleminde kullanılmak üzere her bir sınıf için yaklaşık eşit sayıda görüntü objesi içerecek şekilde toplam 1.805 referans obje eğitim verisi olarak belirlenirken, aynı prensipten hareketle yaklaşık eşit sayıda görüntü objesi içerecek şekilde toplam 1.382 referans obje test veri seti olarak belirlenmiştir. Segmente edilen görüntünün sınıflandırılması işlemleri açık kaynak kodlu Java programlama dilinde hazırlanmış Weka 6.0 yazılımı yardımıyla gerçekleştirilmiştir. Sınıflandırma işleminde çalışma amacına uygun

olarak fonksiyonel ağaçlar (FA), karar ağaçları (KA) ve söz konusu iki algoritmanın ayrı ayrı temel sınıflandırıcı olarak kullanıldığı Adaboost sınıflandırma algoritmaları değerlendirilmeye alınmıştır.

Değerlendirmeye alınan sınıflandırma algoritmalarının performanslarının karşılaştırılması ve analizinde öncelikli olarak genel sınıflandırma doğruluklarından yararlanılmıştır. Bu değerlendirmelerin yanı sıra, arazi örtüsü ve arazi kullanım sınıflarının üretilen tematik haritalarda nicelik ve mekânsal olarak yerleşimler arasındaki farklılıkların analiz edilmesi amacıyla miktar ve yerleşim uyumsuzlukları ölçütleri kullanılmıştır. Miktar uyumsuzluğu (MU), üretilen harita üzerindeki sınıflara ilişkin niceliksel oranlarına ait hatanın bir ölçütü iken, yerleşim uyumsuzluğu (YU) tematik harita üzerinde sınıfların mekânsal olarak yerleşimindeki hatayı ifade etmektedir (Pontius vd., 2011). Diğer bir ifadeyle, hesaplanan MU ölçütünün yüksek değerler alması tematik harita üzerindeki sınıfların niceliksel toplamalarının olması gerekenden önemli derecede farklı olduğunu gösterirken, YU ölçütü yüksek değerler aldığı sınıfların mevcut mekânsal dağılımları ile tematik harita üzerindeki dağılımları arasında önemli derecede farklılıklar olduğunu ifade etmektedir (Warrens, 2015).

Değerlendirmeye alınan algoritmaların sınıflandırma performansları arasındaki farklılıkların istatistiksel olarak anlamlılığının tespiti amacıyla Wilcoxon işaretli sıralar testinden (Wilcoxon's signed ranks test) yararlanılmıştır. İki sınıflandırma algoritmasının performans farklılıklarının sıralanması esasına dayanan istatistik test, hesaplanan farkların pozitif (T_+) ve negatif (T_-) farklar olarak ayrı ayrı sıralanmasını ve daha sonra birbirleriyle karşılaştırılmasını esas almaktadır. Karşılaştırma yapılan örnek sayısı (n) 50'ye eşit veya küçükse Wilcoxon's işaretli sıralar dağılım tablosu dikkate alınırken, örnek sayısı 50'den fazla olduğunda veri setinin normal dağılımda olduğu kabul edilerek Eşitlik (3) yardımıyla istatistik hesaplama yapılır ve normal dağılım tablosundan yararlanılır (Japkowicz vd., 2011). Hesaplanan test istatistiği (z), belirlenen güven aralığında kritik tablo değerinden büyük olduğunda değerlendirmeye alınan iki sınıflandırma sonucu arasında istatistik olarak anlamlı bir fark olduğu sonucuna varılır (Japkowicz vd., 2011).

$$z = \frac{\min(T_+, T_-) - \frac{1}{4}n(n+1)}{\sqrt{\frac{1}{24}n(n+1)(2n+1)}} \quad (3)$$

5. UYGULAMA

Uygulama kapsamında, segmentasyon sonucu elde edilen görüntü objeleri için WV-2 görüntüsünün sekiz spektral bandına ait ortalama parlaklık değerleri hesaplanmış ve sınıflandırma işleminde söz konusu özellikler kullanılmıştır. Karar ağaçları ile sınıflandırma işleminde tek değişkenli karar ağacı algoritmalarından C4.5 algoritması kullanılmıştır. KA modeli oluşturulmasında dallanmaya esas olacak özneliliklerin seçiminde kazanç oranı kriteri, oluşturulan karar ağacının sadeleştirilmesi ve sınıflandırma doğruluğunun artırılması amacıyla ön budama yöntemi kullanılmıştır. C4.5 algoritması ile oluşturulan ağaç modelinde toplam 129 düğüm, 65 yaprak bulunmakla birlikte ağacın kök düğümünde dallanmaya esas olacak özellik olarak WV-2'nin kırmızı bandı için hesaplanan ortalama değer seçildiği görülmüştür. Oluşturulan karar ağacı yapısında, kök düğümünden sonraki ikinci düzey bölünmelerde ise WV-2'nin kızılötesi-2 bandı ve mavi bandı yardımıyla hesaplanan ortalama değerlerin seçildiği görülmüştür. Diğer taraftan, FA yardımıyla ağaç yapısı oluşumunda hem ara hem de yapraklarda çoklu lojistik regresyon algoritması kullanılmıştır. Eğitim veri seti kullanılarak oluşturulan FA modelinin kök düğümünde çoklu lojistik regresyon algoritmasının yer aldığı toplam 21 düğüm ve 11 yaprakta oluştuğu görülmüştür. Oluşan FA modeli, KA ile oluşturulan modele göre daha sade bir yapıdadır. FA modelinde kök düğümünden sonraki ikinci düzey düğümlerin birinde WV-2'nin kızılötesi-1 bandı yardımıyla hesaplanan ortalama değerlerin seçildiği, diğer düğümde ise lojistik regresyon modelinin yer aldığı görülmüştür. Bu yapısı ile oluşturulan FA modelinin KA modeline göre daha sade bir yapıda olduğu ifade edilebilir.

Toplu öğrenme algoritması olarak literatürde yaygın bir kullanımı olan Adaboost algoritması kullanımında iterasyon sayısı olarak bilinen ve toplu öğrenme modeli içerisinde kaç adet ağaç kullanılacağını gösteren parametrenin kullanıcı tarafından belirlenmesi gerekmektedir. Bu amaca yönelik olarak çapraz doğrulama yaklaşımı yardımıyla hem KA'nı hem de FA'ı esas alan Adaboost modelleri için en uygun parametre değerleri ayrı ayrı belirlenmiştir. Eğitim veri seti

kullanılarak gerçekleştirilen çapraz doğrulamalar sonucunda en yüksek sınıflandırma doğruluğunu veren iterasyon parametresinin KA'nı esas alan modelde 70, FA'ı esas alan modelde 50 olduğu tespit edilmiştir.

Eğitim veri seti yardımıyla oluşturan sınıflandırma modellerinin performansları, test veri seti için hesaplanan doğruluk ölçütleri kullanılarak analiz edilmiştir (Tablo 1). Tablo incelendiğinde, algoritmalar içerisinde en düşük genel sınıflandırma doğruluğunun standart KA sınıflandırıcısıyla %89,87 (Kappa değeri 0.89) olarak elde edildiği görülmektedir. FA ile oluşturulan sınıflandırma modeli için hesaplanan genel doğruluk %92,26 (Kappa değeri 0.92) olup, KA ile karşılaştırıldığında sınıflandırma doğruluğunda %2,39 oranında artış olmuştur. KA ve FA için hesaplanan hata matrislerindeki toplam hatayı ifade eden ve tabloda toplam uyumsuzluk olarak ifade edilen değerler incelendiğinde, FA algoritmasının daha düşük hataya sahip olduğu görülmektedir. Diğer bir ifadeyle, test verisindeki (referans harita) görüntü objelerine ait bilinen sınıf etiketleri ile FA tarafından söz konusu objeler için tahmin edilen sınıf etiketleri (üretilen tematik harita) arasında yüksek bir uyum (benzerlik) olduğu ifade edilebilir. Toplam hatayı oluşturan Miktar uyumsuzluğu (MU) ve yerleşim uyumsuzluğu (YU) değerleri incelendiğinde, FA'nın daha düşük daha düşük hata değerlerine sahip olduğu görülmektedir.

Tablo 1. Obje-tabanlı sınıflandırma sonuçları.

	KA	FA	KA*	FA*
Genel doğruluk (%)	89,87	92,26	92,62	93,85
Kappa değeri	0,89	0,92	0,91	0,93
MU	38	18	23	17
YU	102	89	79	68
Toplam hata	140	107	102	85

KA ve FA algoritmalarının toplu öğrenme algoritmasında temel sınıflandırıcı olarak kullanılması durumunda elde edilen sınıflandırma sonuçları da Tablo 1'de verilmiştir. Tablodan da görüleceği üzere Adaboost algoritmasında FA temel sınıflandırıcı olarak kullanıldığında (FA*) %93,85 genel doğruluğa ulaşılırken, KA temel sınıflandırıcı olarak kullanıldığında (KA*) hesaplanan genel doğruluk %92,62'dir. Elde edilen bu sonuç hızlandırma algoritmasında FA kullanımı ile genel sınıflandırma doğruluğunda %1,23 düzeyinde bir iyileşme olduğunu


göstermektedir. Bununla birlikte söz konusu iki algoritmanın, hızlandırma algoritması ile birlikte kullanılması durumunda genel sınıflandırma doğruluğunda KA'nın tekil kullanımına göre %2,75 ve FA'nın tekil kullanımına göre %1,59'luk artış hesaplanmıştır. Diğer bir ifadeyle, KA'nın ve FA'nın tekil kullanımı yerine, hızlandırma algoritması ile birlikte kullanımı genel sınıflandırma doğruluğunu önemli derecede arttırırken, hesaplanan hata değerleri (MU ve YU) ve dolayısıyla hata matrislerindeki toplam hata oranı önemli derecede azalmıştır.

Sınıflandırma performansları arasındaki farklılıkların anlamlılığı Wilcoxon testi yardımıyla istatistiksel olarak analiz edilmiş ve algoritmaların ikili karşılaştırmaları sonucunda elde edilen istatistiksel değerleri Tablo 2'de verilmiştir. Tablodan da görüleceği üzere, FA ile KA'nı esas alan hızlandırma algoritması (KA*) arasındaki doğruluk farklılığının anlamlılığı için hesaplanan istatistik değeri ($z = 0,513$), %95 güven aralığında kritik tablo değerinden ($z_{\%95} = 1,96$) düşüktür. Bu sonuç, iki algoritmanın istatistiksel olarak benzer sınıflandırma performansı gösterdiğini ifade etmektedir. Bunun haricinde tablodaki diğer tüm ikili karşılaştırmalar için hesaplanan istatistik değeri kritik tablo değerinden büyük olup istatistiksel olarak algoritmaların sınıflandırma performanslarının birbirinden farklı olduğunu göstermektedir. Diğer bir ifadeyle söz konusu algoritmalar ile elde edilen sonuçlar istatistiksel olarak birbirlerinden farklıdır.

Tablo 2. Wilcoxon işaretli sıralar test sonuçları.

	FA	KA*	FA*
KA	2,976	4,098	5,268
FA		0,513	2,593
KA*			2,018

Çalışma kapsamında değerlendirmeye alınan tüm algoritmalarla ilişkin sınıflandırma sonuçları bir arada değerlendirildiğinde, en yüksek doğruluğun FA algoritmasının hızlandırma algoritmasında temel sınıflandırıcı olarak kullanıldığı sınıflandırma modeli ile %93,85 olarak elde edildiği görülmüştür. Söz konusu sınıflandırma modeli, diğer modeller ile karşılaştırıldığında, en düşük toplam hata, MU ve YU değerlerine sahiptir. Diğer bir ifadeyle, FA'ı esas alan Adaboost modeli tarafından üretilen tematik haritada ilgi duyulan arazi örtüsü ve arazi



Şekil 4. (a) FA* ve (b) KA algoritmaları ile üretilen tematik haritalar.

kullanım sınıflarını temsil eden görüntü objelerinin gerçekte olması gereken mekânsal konum ve dağılımlara yüksek doğrulukta sınıflandırılmıştır. Çalışma kapsamında değerlendirmeye alınan tüm sınıflandırma modelleri segmente edilen görüntüye uygulanarak ayrı ayrı tematik haritalar üretilmiştir. Söz konusu haritalara örnek olarak FA'ı esas alan Adaboost modeli ve standart KA ile üretilen tematik haritalar Şekil 4'de gösterilmiştir. Tematik haritalar incelendiğinde KA ile üretilen haritada (Şekil 4b) arazi örtüsü ve arazi kullanım sınıfları arasındaki hatalı sınıflandırmaların fazla oluşu nedeniyle haritanın gürültü oranı yüksektir. Buna karşın FA'ı esas alan toplu öğrenme (sınıflandırma) modeli (FA*) ile üretilen haritada (Şekil 4a) sınıflar arasındaki karışıklık oranı daha az olduğundan haritada bir süreklilik söz konusudur. Dolayısıyla sınıflar arasındaki ayırım artarak, kolay yorumlanabilir hale gelmiştir. Bu

durum özellikle benzer spektral özelliklere sahip sınıfların ayırt edilmesinde FA algoritmasının daha başarılı olduğunu destekler niteliktedir.

6. SONUÇ VE ÖNERİLER

Obje-tabanlı görüntü sınıflandırma özellikle yüksek çözünürlüklü görüntüler üzerinden bilgi çıkarımı ve tematik harita üretiminde başarıyla kullanılan bir görüntü analiz yaklaşımıdır. Obje-tabanlı yaklaşımda segmentasyon sonucu elde edilen görüntü objelerinin belirlenen arazi örtüsü veya kullanım sınıfına atanması neticesinde tematik harita üretimi söz konusudur. Bu nedenle sınıflandırma işleminde kullanılacak algoritma obje-tabanlı görüntü analizi ile üretilen tematik harita doğruluğunu direkt olarak etkilemektedir. Bu çalışmada, KA ve çoklu lojistik regresyon algoritmalarının bir arada kullanıldığı FA sınıflandırıcısının obje-tabanlı görüntü analizinde

kullanımı incelenmiş ve sınıflandırma performansı standart KA algoritması ile karşılaştırılmıştır. Bu temel performans karşılaştırmasının yanı sıra toplu öğrenme algoritmasında her iki karar ağacı modelinin (KA ve FA) ayrı ayrı temel sınıflandırıcı olarak (Adaboost) kullanımı da ele alınmış ve sınıflandırma performanslarındaki farklılıklar istatistiksel olarak analiz edilmiştir.

Çalışma sonuçlarının analizi neticesinde önemli bulgulara ulaşılmıştır. Bunlardan ilki yüksek çözünürlüklü WV-2 görüntüsünün objektanlı yaklaşımla sınıflandırılması probleminin çözümünde standart KA algoritması yerine hibrit ağaç yapıları olarak ifade edilen FA kullanımıyla genel sınıflandırma doğruluğunda yaklaşık %3'lük bir iyileşme olduğu görülmüştür. Wilcoxon işaretli sıralar test sonuçları sınıflandırma doğruluğundaki bu artışın istatistiksel olarak anlamlı bir artış olduğunu, dolayısıyla FA'nın daha üstün bir performans gösterdiğini doğrular niteliktedir. İkinci olarak, her iki algoritmanın Adaboost algoritmasında temel sınıflandırıcı olarak kullanımı neticesinde, FA algoritmasını esas alan sınıflandırma modelinin tematik harita doğruluğunda yine istatistiksel olarak anlamlı artışlara (yaklaşık %2) neden olduğu görülmüştür. Üçüncü olarak, KA ve FA sınıflandırıcılarının tekil kullanımı yerine toplu öğrenme algoritmalarında temel sınıflandırıcı olarak kullanılmasının algoritmaların performansını yaklaşık %2-3 oranında arttırdığı tespit edilmiştir. Wilcoxon test sonuçları da algoritmaların performanslarında bu düzeydeki iyileşmelerin istatistiksel olarak anlamlı olduğunu desteklemektedir. Tüm çalışma sonuçları bir arada değerlendirildiğinde, FA algoritmasının uygulama kapsamında değerlendirmeye alınan veri seti ve sınıflandırma probleminin çözümü noktasında hem tekil kullanımının hem de toplu öğrenme modelinde temel sınıflandırıcı olarak kullanımının standart ağaç yapısına göre istatistiksel olarak daha üstün bir performans sergilediğini göstermektedir.

KAYNAKLAR

Akçetin, E., Çelik, U., (2014). **İstenmeyen elektronik posta (Spam) tespitinde karar ağacı algoritmalarının performans kıyaslaması**, *İnternet Uygulamaları ve Yönetimi*, 5(2),43-56.

Baatz, M., Schape, A., (2000). **Multi resolution segmentation-an optimization approach for high quality multi scale image segmentation**, *Proceedings of Twelfth Angewandte Geographische Informationsverarbeitung*, Germany: Karlsruhe Institute of Technology, May 25-27.

Belgiu, M., Drăguț, L., (2014). **Comparing supervised and unsupervised multiresolution segmentation approaches for extracting buildings from very high resolution imagery**, *ISPRS Journal of Photogrammetry and Remote Sensing*, 96,67-75.

Blaschke, T., (2010). **Object based image analysis for remote sensing**, *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), 2-16.

Canty, M. J., (2014). **Image analysis, classification and change detection in remote sensing: With algorithms for ENVI/IDL and python**, Third Edition, Boca Raton (USA): CRC Press.

Colkesen, I., Kavzoglu, T., (2017). **The use of logistic model tree (LMT) for pixel- and object-based classifications using high resolution worldview-2 imagery**, *Geocarto International*,32, 71-86.

Cordeiro, C. L. D., Rossetti, D. D., (2015). **Mapping vegetation in a late Quaternary landform of the Amazonian wetlands using object-based image analysis and decision tree classification**, *International Journal of Remote Sensing*, 36(13), 3397-3422.

Dietterich, T. G., (2000). **An experimental comparison of three methods for constructing ensembles of decision trees: Bagging, boosting, and randomization**, *Machine Learning*, 40(2), 139-157.

Drăguț, L., Tiede, D., Levick, S. R., (2010). **ESP: a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data**, *International Journal of Geographical Information Science*, 24 (6),859-71.

Du, P. J., Xia, J. S., Zhang, W., Tan, K., Liu, Y., Liu, S. C., (2012). **Multiple Classifier System for Remote Sensing Image Classification: A Review**, *Sensors*, 12(4), 4764-4792.

- Freund, Y., Schapire, R. E., (1996). **Experiments with a new boosting algorithm**, In: Saitta, L. (Ed.), Proceedings of the Thirteenth International Conference on Machine Learning (ICML-96). Morgan Kaufmann, 148-156.
- Gama, J., (2004). **Functional trees**, Machine Learning, 55(3), 219-250.
- Ghosh, A., Joshi, P. K., (2013), **Assessment of pan-sharpened very high-resolution WorldView-2 images**, International Journal of Remote Sensing, 34(23), 8336-8359.
- Ghosh, A., Joshi, P. K., (2014), **A comparison of selected classification algorithms for mapping bamboo patches in lower Gangetic plains using very high resolution WorldView 2 imagery**, International Journal of Applied Earth Observation and Geoinformation, 26, 298-311.
- Grandchamp, E., (2012). **Raster and Vector Integration for Fuzzy Vector Information Representation Within GIS**. INTECH Open Access Publisher.
- Heumann, B.W., (2011). **An object-based classification of mangroves using a hybrid decision tree-support vector machine approach**, Remote Sensing, 3 (11), 2440-2460.
- Hu, M.H., Dong, Q.L., Liu, B.L., (2016). **Classification and characterization of blueberry mechanical damage with time evolution using reflectance, transmittance and interactance imaging spectroscopy**, Computers and Electronics in Agriculture, 122, 19-28.
- Hunt, E.B., (1962). **Concept learning: An information processing problem**. New York, USA:Wiley.
- Japkowicz, N., Shah, M., (2011). **Evaluating learning algorithm: A classification perspective**, New York, USA: Cambridge University Press.
- Jawak, S. D., Luis, A. J., (2013). **A comprehensive evaluation of pan-sharpening algorithms coupled with resampling methods for image synthesis of very high resolution remotely sensed satellite data**, Advances in Remote Sensing, 2, 332-344.
- Johnson, B. A., (2013), **High-resolution urban land-cover classification using a competitive multi-scale object-based approach**, Remote Sensing Letters, 4(2), 131-140.
- Kavzoglu, T., Colkesen, I., Yomralioglu, T. (2015), **Object-based classification with rotation forest ensemble learning algorithm using very-high-resolution WorldView-2 image**, Remote Sensing Letters, 6(11), 834-843.
- Kavzoglu, T., Colkesen, I., (2013). **An assessment of the effectiveness of a rotation forest ensemble for land-use and land-cover mapping**, International Journal of Remote Sensing, 34(12), 4224-424.
- Kavzoğlu, T., Çölkesen, İ., (2010). **Karar ağaçları ile uydu görüntülerinin sınıflandırılması: Kocaeli örneği**, Harita Teknolojileri Elektronik Dergisi, 2, 36-45.
- Landwehr, N., Hall, M., Frank, E., (2005) **Logistic model trees**, Machine Learning, 59(1-2), 161-205.
- Low, F., Conrad, C., Michel, U., (2015), **Decision fusion and non-parametric classifiers for land use mapping using multi-temporal RapidEye data**, ISPRS Journal of Photogrammetry and Remote Sensing, 108, 191-204.
- Mather, P.M., Koch, M., (2011), **Computer processing of remotely-sensed images: An introduction**, Fourth Edition, Chichester, UK: Wiley-Blackwell.
- Myint, S. W., Gober, P., Brazel, A., Grossman-Clarke, S., Weng, Q. H., (2011). **Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery**, Remote Sensing of Environment, 115(5): 1145-1161.
- Ozcift, A., Gulten, A., (2013). **Genetic algorithm wrapped Bayesian network feature selection applied to differential diagnosis of erythemato-squamous diseases**. Digital Signal Processing, 23(1), 230-237.
- Pal, M., (2005). **Random forest classifier for remote sensing classification**, International Journal of Remote Sensing, 26(1), 217-222.

- Palubinskas, G., (2013). **Fast, simple, and good pan-sharpening method**, Journal of Applied Remote Sensing, 7(1),1-12.
- Pal, M., Mather, P. M., (2003). **An assessment of the effectiveness of decision tree methods for land cover classification**, Remote Sensing of Environment, 86(4), 554-565.
- Pontius, R. G., Millones, M., (2011). **Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment**, International Journal of Remote Sensing, 32(15), 4407-4429.
- Popescu, M.C., Sasu, L.M., (2014). **Feature Extraction, Feature Selection and Machine Learning for Image Classification: A Case Study**. 2014 International Conference on Optimization of Electrical and Electronic Equipment (Optim), 968-973.
- Qian, Y. G., Zhou, W. Q., Yan, J. L., Li, W. F., Han, L. J., (2015). **Comparing machine learning classifiers for object-based land cover classification using very high resolution imagery**, Remote Sensing, 7(1), 153-168.
- Quinlan J.R., (1987). **Simplifying decision trees**, International Journal of Man-Machine Studies, 27, 221-234
- Quinlan, J. R., (1993). **C4.5: Programs for Machine Learning**, San Mateo (CA): Morgan Kaufmann.
- Rodriguez, J. J., Garcia-Osorio, C., Maudes, J., Diez-Pastor, J. F., (2010). **An experimental study on ensembles of functional trees**, Multiple Classifier Systems, 5997, 64-73.
- Safavian, S. R., Landgrebe, D., (1991). **A survey of decision tree classifier methodology**, IEEE Transactions on Systems Man and Cybernetics, 21(3), 660-674.
- Swain P.H., Hauska H., (1977). **Decision tree classifier - design and potential**, IEEE Transactions on Geoscience and Remote Sensing, 15(3), 142-147.
- Tso B., Mather, P. M., (2009). **Classification methods for remotely sensed data**. Second Edition, Boca Raton (FL): CRC Press.
- Vasconcellos, E. C., de Carvalho, R. R., Gal, R. R., LaBarbera, F. L., Capelato, H. V., Velho, H. F. C., Trevisan, M., Ruiz, R. S. R., (2011). **Decision tree classifiers for star/galaxy deparation**, Astronomical Journal, 141(6), 1-17.
- Warrens, M. J., (2015). **Properties of the quantity disagreement and the allocation disagreement**, International Journal of Remote Sensing, 36(5), 1439-1446
- Witten I. H., Frank E., Hall M. A., (2011). **Data mining: practical machine learning tools and techniques**, Third edition, Burlington (MA): Morgan Kaufman.
- Xia, J. S., Du, P. J., He, X. Y., Chanussot, J., (2014). **Hyperspectral Remote Sensing Image Classification Based on Rotation Forest**, IEEE Geoscience and Remote Sensing Letters, 11(1), 239-243.