

HIPERSPEKTRAL GÖRÜNTÜLERİN SINIFLANDIRILMASINDA FARKLI BOYUTTA EĞİTİM KÜMELERİ İÇİN TOPLU ÖĞRENME ALGORİTMALARININ PERFORMANS ANALİZİ

Ö.H. Ertekin*, İ. Çölkesen

Gebze Teknik Üniversitesi, Mühendislik Fakültesi,
Harita Mühendisliği Bölümü, 41400 Gebze-Kocaeli
(habibertekin@gtu.edu.tr; icolkesen@gtu.edu.tr)

ANAHTAR SÖZCÜKLER: Hiperspektral Görüntü, Adaboost, Rastgele Orman, Rotasyon Orman, Toplu Öğrenme

ÖZET:

Günümüze kadar, uydu görüntülerinin sınıflandırma doğruluğunu arttırmak amacıyla çok sayıda sınıflandırma yöntemi geliştirilmiştir. Son zamanlarda, toplu öğrenme algoritmaları benzer spektral özellikli bantların yüzlercesine sahip olan hiperspektral verileri sınıflandırmasındaki başarıları nedeniyle etkili olarak kullanılmaktadır. Sınıflandırıcı toplulukları olarak da bilinen toplu öğrenme bilinmeyen bir örnek üzerinde bir sonuç kararı vermek için birden çok sınıflandırıcının kullanımına dayanan gelişmiş sınıflandırma teknikleridir. Bu çalışmada, karar ağacına dayalı toplu öğrenme algoritmaları yani, Adaboost, rastgele orman (RO) ve rotasyon orman (RotOr) hiperspektral görüntülerin sınıflandırılması için kullanılmış ve performansları değişik boyutlardaki eğitim veri kümesi kullanımı bakımından analiz edilmiş ve karşılaştırılmıştır. Bu amaç için, popüler hiperspektral veri setlerinden olan Indian pine (IP) and Kennedy Space Center (KSC) veri setleri temel veri kaynağı olarak kullanılmıştır. Genel doğruluk ve Kappa değeri ölçütleri toplu öğrenme algoritmalarının sınıflandırma performanslarını değerlendirmek ve eğitim kümesi boyutunun sınıflandırma doğruluğu üzerindeki etkisini incelemek için kullanılmıştır. Elde edilen sonuçlar, özellikle her iki hiperspektral görüntü için sınırlı eğitim veri kümesinin kullanılması durumunda (örneğin; eğitim veri setinin %10-20 olarak kullanıldığı durumlar), RotOr algoritmasının sınıflandırma performansının, RO ve AdaBoost'un performansları ile karşılaştırıldığında üstün bulunduğunu göstermiştir. Ayrıca, RotOr ve AdaBoost performanslarının, fazla sayıda eğitim örneklerinin kullanıldığı durumda (örneğin; % 80-90 eğitim kümesi oranları) benzer performanslar sergilediği görülmüştür. En yüksek sınıflandırma doğrulukları RotOr algoritması tarafından IP ve KSC veri kümeleri için sırasıyla 92% ve 96% olarak hesaplanmıştır. Sınıflandırma doğruluklarındaki farklılıklar, McNemar testi sonuçlarına göre RO ve AdaBoost ile karşılaştırıldığında istatistiksel olarak anlamlı bulunmuştur. Çalışma sonuçları RotOr algoritmasının sınırlı eğitim örnekleri kullanan hiperspektral görüntülerin sınıflandırılmasında potansiyel faydasını göstermiştir.

KEYWORDS: Hyperspectral Image, Adaboost, Random Forest, Rotation Forest, Ensemble Learning

ABSTRACT:

Up to now, numerous classification methods have been developed to increase the classification accuracy of satellite images. In recent years, ensemble learning algorithms have been effectively used due to their success in classifying hyperspectral data having hundreds of spectral bands with similar spectral properties. Ensemble learning also known as classifier ensembles is one of the advanced classification techniques based on the use of multiple classifiers to make a final decision on an unknown sample. In this study, decision tree-based ensemble learning algorithms namely, AdaBoost, random forest (RO) and rotation forest (RotFor) were used for the classification of hyperspectral imagery and their performances were compared and analysed in terms of using training dataset at various sizes. For this purpose, two well-known hyperspectral datasets, Indian pine (IP) and Kennedy Space Center (KSC) datasets were used as main data sources. Overall accuracy and Kappa coefficient measures were used for assessing the classification performance of the ensemble learning algorithms and investigating the effect of the training set size on the classification accuracy. Results showed that classification performance of RotFor algorithm was found to be superior compared to those of RF and AdaBoost, especially in the case of using limited training dataset (i.e. 10-20% training datasets ratios) for both hyperspectral images. Moreover, performances of RotFor and AdaBoost were seen to approach in the case of using numerous training samples (i.e. 80-90% training datasets ratios). The highest classification accuracies were estimated by RotFor algorithm as 92% and 96% for IP and KSC datasets, respectively. Improvements in classification accuracies were statistically significant compared to RF and AdaBoost according to McNemar's test result. All in all, the results of the study showed the potential usefulness of RotFor algorithm in hyperspectral image classification using limited training samples.

1. GİRİŞ

Uzaktan algılamada arazi örtüsünün ve arazi kullanımının doğru bir şekilde analiz edilmesi, görüntü elemanlarının doğru bir şekilde sınıflandırılabilmesi ile doğrudan ilişkilidir. Spektral çözünürlüğü yüksek hiperspektral sensörlerden elde edilen görüntüler benzer özellikteki piksellerin daha doğru bir şekilde ayrıştırılmasına olanak sağlamaktadır. Ancak, hiperspektral görüntülerdeki bant sayısının fazla olması, özellikle istatistiksel tabanlı sınıflandırıcıların kullanıldığı

durumlarda sınıflandırma doğruluğunun istenilen düzeyde olmasını engellemektedir. Bu nedenle, günümüze kadar sınıflandırma doğruluğunu arttırmaya yönelik çeşitli sınıflandırma teknikleri ve yaklaşımların geliştirilmekte ve uygulanmasına yönelik yoğun çalışmalar yürütülmektedir (Lu and Weng, 2007). Toplu öğrenme algoritmaları son yıllarda uzaktan algılama çalışmalarında yaygın bir şekilde kullanılmaktadır. Toplu öğrenme, birden çok sınıflandırıcının eğitilmesine ve tahmin verisi üzerinde sınıflandırıcıların nihai karar birlikteliğine dayanmaktadır (Pal, 2007). Topluluk


metotları seri veya paralel olarak iki kategoriye ayrılmaktadır. Seri kombinasyonlarda, ilk sınıflandırıcıdan son sınıflandırıcıya kadar sıralı bir şekilde eğitim ve test işlemleri gerçekleştirilmektedir. Önceki sınıflandırıcılardaki yanlış sınıflar ağırlıklandırılarak sonraki sınıflandırıcının eğitim kümesi oluşturulmakta ve topluluktaki çeşitlilik sağlanmaktadır. Paralel kombinasyonlarda ise eğitim verisinde yapılan rastgele seçimler sonucunda sınıflandırıcılar arasındaki çeşitlilik sağlanmakta bu şekilde her sınıflandırıcı farklı bir şekilde eğitilmektedir. (Holloway and Mengersen, 2018). Toplu öğrenme yöntemlerinin, tek sınıflandırıcı kullanıldığı sınıflandırma yöntemlerinden çok daha etkili olduğu belirtilmektedir. Toplu öğrenme yöntemlerinde, genel doğruluk performansı ve kısa işlem süresi bakımından, temel sınıflandırıcının karar ağacı (KA) olarak seçilmesi literatürde yaygın olarak görülmektedir. (Ghimire et al., 2012). Karar ağacının temel sınıflandırıcı olarak kullanıldığı toplu öğrenme algoritmalarından en yaygın olarak kullanılanları rastgele orman (RO), rotasyon orman (RotOr), AdaBoost ve torbalama(bagging) algoritmalarıdır. Chen et al., (2017) tarafından yapılan çalışmada multispektral görüntüler kullanılmış ve Adaboost ile birlikte çeşitli temel sınıflandırıcıların görüntüler üzerinde sınıflandırma performansları değerlendirilmiştir. Çalışma sonucunda,uydu görüntüleri yardımıyla yapılaşmış alanların tespitinde, Adaboost ile C4.5 karar ağacı algoritmasının birlikte kullanılması istatistiksel sınıflandırıcılara göre daha üstün bir performans gösterdiği ifade edilmiştir. Maxwell et al., (2018), RO algoritması ve KA tabanlı hızlandırma algoritmalarının parametrik sınıflandırıcılara göre karışık özellik uzayı üzerinde güçlü etkisi olduğu belirtilmiş, hiperspektral görüntülerin sınıflandırıldığı bir çok çalışmada önemli sonuçlar elde edildiği ifade edilmiştir.

Bu çalışmada, Indian Pine (IP) ve Kennedy Space Center (KSC) hiperspektral görüntülerinin sınıflandırılmasında toplu öğrenme algoritmalarının karşılaştırılması ve sınıflandırma


performanslarının analizi edilmesi amaçlanmıştır. Bu amaç doğrultusunda, her bir görüntü RO, RotOr ve AdaBoost toplu öğrenme algoritmalarıyla sınıflandırılmıştır. Eğitim veri seti boyutunun sınıflandırma doğruluğuna etkisinin incelenmesi amacıyla, sınıflandırma işlemi için gerekli eğitim verisi her iki görüntü için mevcut olan yerdoğrulama verisinin %10,%20,%80 ve %90'ını içerecek şekilde dört farklı oranda rastgele seçilmiştir. Her bir toplu öğrenme algoritmasının aynı veri kümeleriyle eğitilmesi sağlanmıştır. Böylece eğitim örneklerinin sayısının sınıflandırma algoritmalarıyla olan ilişkisinin incelenmesi ve algoritmaların sınıflandırma performanslarının birbirleriyle karşılaştırılması amaçlanmıştır. Sınıflandırma sonuçlarının analizinde, genel doğruluk ve Kappa ölçütlerinin yanı sıra eğitim için gerekli olan işlem süreleri de analiz edilmiştir. Bununla birlikte, sınıflandırma doğruluğu arasındaki farklılıkların anlamlılığı McNemar's testi kullanılarak istatistiksel olarak analiz edilmiştir.

2. ÇALIŞMA İÇİN KULLANILAN VERİLER

Çalışmada IP ve KSC olmak üzere iki farklı hiperspektral görüntü kullanılmıştır. IP veri seti AVIRIS sensöründen elde edilmiş olup, 0.4-2.5 µm spektral aralığa sahip görüntünün su soğurma bantları hariç 200 bantı kullanılmıştır. Şekil 1'den de görüleceği üzere, IP veri setinde görüntüleme alanının 2/3'ü tarımsal alanlardan, geri kalan kısmı orman ve diğer çok yıllık bitki sınıflarından oluşmaktadır. Ayrıca görüntüye ait 16 sınıfı içeren yer doğrulama verisi mevcuttur (Şekil 1). NASA AVIRIS sensöründen elde edilen KSC verisi, 18m konumsal çözünürlüğe, 400-2500 nm arasında 10nm aralıklarla tasarımı yapılmış 176 bantta sahiptir (su soğurma ve düşük yansıtımlı bantlar hariç). İçerisinde su,çalılık çeşitli bataklık ve ağaç türlerinden oluşan 13 sınıf bulunmaktadır. Şekil 2' de KSC veri seti ve 13 arazi örtüsü sınıfını içeren doğrulama verisi verilmiştir. İki veri seti de özellik uzayında herhangi bir boyut indirgemesi yapılmadan sınıflandırma işlemleri için orijinal haliyle kullanılmıştır .



Şekil 1. IP hiperspektral veri seti ve 16 sınıfı içeren yer doğrulama verisi



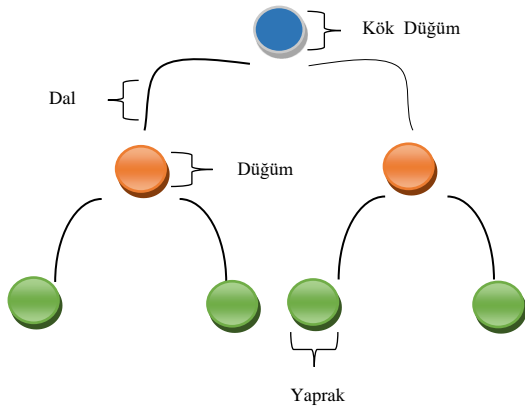
Şekil 2. KSC hiperspektral veri seti ve 13 sınıfı içeren yer doğrulama verisi

3. SINIFLANDIRMA ALGORİTMALARI

Uzaktan algılamada, uydu görüntüsü üzerinde benzer yansımaya değerlerine sahip piksellerin arazi karşılık geldiği arazi örütüsü veya arazi kullanım sınıflarının belirlenmesi işlemi sınıflandırma olarak ifade edilmektedir. Sınıflandırma sonucunda elde edilen tematik haritalar arazi örtünün yorumlanmasında büyük öneme sahiptir. Bu çalışmada, AdaBoost, RO ve RotOr sınıflandırıcı toplulukları ile birlikte temel sınıflandırıcı olarak karar ağacı algoritması kullanılmıştır.

3.1 Karar ağaçları algoritması

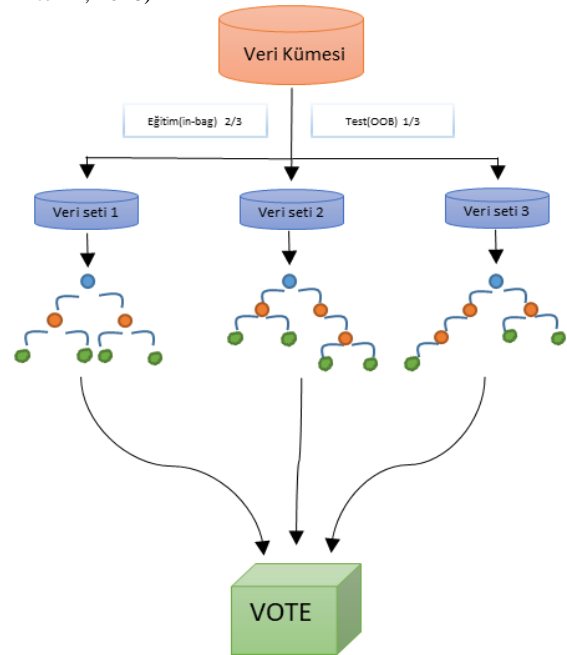
KA, matematiksel olarak kolay anlaşılması, doğruluk performansı ve kısa işlem süresi nedeniyle toplu öğrenme algoritmalarında sıklıkla tercih edilmektedir (Pal and Mather, 2003; Kavzoğlu ve Çölkesen, 2010; Çölkesen ve Ertekin; 2018). KA, adından da anlaşılacağı üzere, kök düğüm, ara düğüm, dal, yaprak gibi ağacı oluşturan unsurlara benzetilerek açıklanmaktadır (Şekil 3). Kök ve ara düğümler öznelikleri, dallar ayrılma kriterlerini, yapraklar ise sınıflandırma ile ulaşılabilecek sınıfları temsil eder. Eğitim veri kümesi ile oluşturulan bu ağaç yapıları ile bilinmeyen piksellerin sınıf atamaları gerçekleştirilir. Yapı kural tabanlı sınıflandırmaya da benzetilmektedir (Jiang et al., 2011). Ağaç oluşumunda kullanılacak özneliklerin seçimi için birçok yöntem kullanılmaktadır. Çalışmada tüm topluluk yöntemleri için CART (Classification and Regression Trees) algoritmasıyla oluşturulan KA yöntemi budamasız olarak kullanılmıştır.



Şekil 3. Basit bir karar ağacı yapısı

3.2 Rastgele orman algoritması

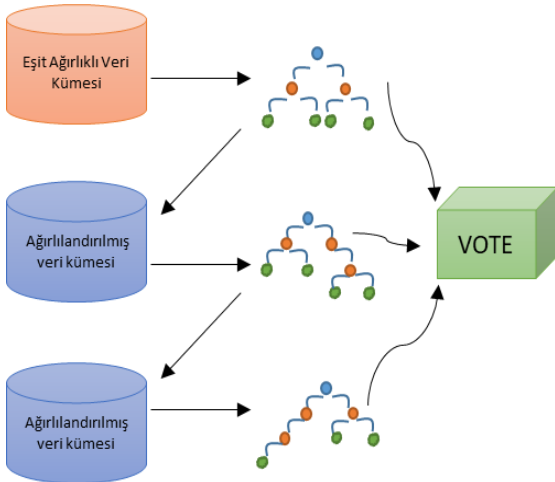
Rastgele orman (RO) algoritması, birden çok KA algoritması kullanan karar ormanı olarak adlandırılan toplu öğrenme yöntemlerinden biridir (Breiman 2001). Algoritmanın çalışma prensibi Şekil 4' te verilmiştir. Ağaçların çeşitliliği, rastgele eğitim kümesi ve belirli sayıda rastgele öznelik seçimi ile sağlanmaktadır. Yöntemin uygulanması için *Ntree* ve *Mtry* parametrelerinin tanımlanması gerekmektedir. *Mtry* parametresi her bir düğüm için seçilecek rastgele özneliklerin sayısını temsil etmektedir. *Mtry*, genellikle özellik uzayı boyutunun karekökü alınarak belirlenmektedir. *Ntree* parametresi topluluktaki kurulacak ağaç sayısını belirleyen parametredir. Çalışmaların çoğunda hatalardaki farkların önemsizleştiği 500 varsayılan değeri alınmaktadır (Belgiu and Dragut, 2016). Sınıflandırıcıların eğitimi torbalama yöntemiyle aynı şekildedir. Eğitim kümesinin 2/3 (in-bag) rastgele olarak seçilmekte, geriye kalan 1/3 (OOB) ise ağaçların kendi içinde test edilmesi ve ağaç performanslarının tespit edilmesi için kullanılmaktadır. Ağaç performanslarına göre modellerin tahminleri birleştirilerek bilinmeyen sınıflara ağırlıklı oylama ile etiketleme yapılmaktadır. (Çölkesen ve Ertekin, 2018)



Şekil 4. Rastgele Orman Algoritmasının Çalışma Prensibi

3.3 AdaBoost algoritması


Şekil 5' te de görüldüğü üzere temel sınıflandırıcıları seri yapıda kullanan AdaBoost algoritması uygulaması kolay bir yöntemdir. Topluluk boyutu dışında ayarlanması gereken bir parametresi yoktur. Başlangıç için aynı ağırlıkta seçilen eğitim kümesi ilk sınıflandırıcıya tahmin ettirilir. Yanlış olan tahminler veri seti içerisinde ağırlıklandırılır. Yeni ağırlıklandırılmış veri seti bir sonraki sınıflandırıcıyla sınıflandırma işlemine sokulur. Bu işlemler son sınıflandırıcıya kadar devam ettirilir. Böylece veri setinde sınıflandırılması güç olan verilerin üzerinde daha fazla durularak, sınıflandırma doğruluğu artırılmaya çalışılmaktadır (Freund and Schapire,1996).



Şekil 5. AdaBoost Algoritması Temel Çalışma Prensibi

3.4 Rotasyon orman algoritması

Rotasyon orman (RotOr), toplu öğrenme algoritmaları arasında yüksek performansından dolayı son zamanlarla sıklıkla kullanılan algoritmalarındandır. RotOr'ın temel çalışma prensibi sınıflandırıcıları eğitim kümesinden örnekleme yapmak yerine, eğitim kümesinin açısını değiştirerek sınıflandırıcılar arasındaki çeşitliliği sağlamaktır. Böylece veri kaybı olmaksızın eğitilen sınıflandırıcı topluluklarının daha iyi performans vermesi amaçlanmaktadır. Eğitim kümesinin açısını değiştirmek için bütün özellikler kullanıcı tarafından tanımlanacak parametreye göre rastgele seçilerek kümelendir. Daha sonra torbalama yöntemindeki gibi veri setinden belirli örneklemeler yapılır. Seçilen verilere PCA uygulanır. Böylece sınıflandırıcılar için eğitim kümesinin açısını değiştirecek rotasyon matrisler elde edilir. Sınıflandırıcıların tahmin işlemi için bilinmeyen veri sınıflandırıcıların kendine ait rotasyon matrisi ile çarpılarak tahmin ettirilir. Sınıflandırıcıların çoğunluklu oyuyla etiketleme işlemi yapılmış olur (Şekil 6) (Kuncheva, 2014).



Şekil 6. Rotasyon Orman Algoritması Temel Çalışma Prensibi

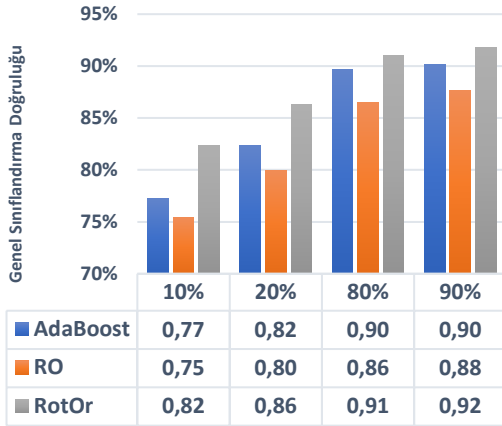
4. UYGULAMA

Sınıflandırma işleminin gerçekleştirilmesi amacıyla IP ve KSC görüntülerinin mevcut yer doğrulama verileri kullanılarak eğitim veri setleri oluşturulmuştur. Çalışma amacına uygun olarak, belirlenen 4 farklı örnekleme oranı (%10, 20, 80 ve 90) esas alınarak farklı boyutlarda eğitim veri setleri elde edilmiştir. Eğitim veri setleri oluşturulurken her bir sınıf için örnekleme oranları ayrı ayrı uygulanmıştır. Eğitim verisi seçildikten sonra ilgili sınıftan geriye kalan kısımlar test verisi olarak değerlendirilmiştir (Tablo 1). Eğitim ve test veri kümeleri bu şekilde tutulup her bir toplu öğrenme yönteminin özdeş veri kümeleriyle eğitilip test edilmesi sağlanmıştır.

Tablo 1. Indian Pine %10'luk veri kümesinin eğitim ve test verilerinin dağılımı.

Sınıflar	Eğitim-%10	Test-%90	Toplam
Alfalfa	5	41	46
Corn-notill	143	1285	1428
Corn-mintill	83	747	830
Corn	24	213	237
Grass-pasture	48	435	483
Grass-trees	73	657	730
Grass-pasture-	3	25	28
Hay-windrowed	48	430	478
Oats	2	18	20
Soybean-notill	97	875	972
Soybean-mintill	246	2209	2455
Soybean-clean	59	534	593
Wheat	21	184	205
Woods	127	1138	1265
Buildings-Grass-	39	347	386
Stone-Steel-Towers	9	84	93
Toplam	1027	9992	10249


Veri setlerinin oluşturulması, toplu öğrenme algoritmaları ile sınıflandırma işlemleri, performans analizleri, McNemar's testi ve tematik harita üretilmesinde MATLAB yazılımı kullanılmıştır. Hazırlanan eğitim verileri kullanılarak RO, AdaBoost, RotOr toplu öğrenme modellerinin oluşturulması işlemi gerçekleştirilmiştir. Uygulamada topluluk boyutu parametresini (ağaç sayısı) tespit etmek için her bir topluluktan elde edilebilecek maksimum doğruluk göz önünde bulundurulmuştur. Böylelikle her bir algoritmanın olabilecek en yüksek performansları karşılaştırılmıştır. RO yöntemi için OOB (out of bag) verilerinden yararlanılarak elde edilen kümülatif sınıflandırıcı doğrulukları sayesinde minimum hatayı veren sınıflandırıcı topluluğu sayısı bulunmuştur. En yüksek doğruluğu veren ağaç sayısı literatürde varsayılan değer olarak alınan 500 ağaç arasından seçilmiştir. Adaboost algoritması RO ile rekabet edebilen bir algoritmadır (Breiman, 2001). Bu yüzden sınıflandırıcı boyutu seçimi bu algoritma için de 500 ağaç üzerinden yapılmıştır. RotOr yöntemi, RO ve AdaBoost' a göre güçlü ve hesap yükü ağır bir yöntem olduğu için 100 ağacın içinden en yüksek performansı veren topluluk boyutu seçilmiştir. RO için diğer belirlenecek parametre olan *Mtry*, önerildiği şekilde özellik uzayı boyutunun karekökü olarak alınmıştır. RotOr algoritmasında özellik uzayının gruplandırılması için uygun görülen 3 değeri dikkate alınmıştır (Kuncheva., 2014). IP veri kümesinin RO, AdaBoost ve RotOr yöntemleri ile sınıflandırılması sonucunda örnekleme oranlarına göre elde edilen genel doğruluklar Şekil 7'de verilmiştir.



Şekil 7. IP görüntüsü için eğitim veri seti boyutuna göre sınıflandırma doğruluğundaki değişimler.

IP veri seti için bulunan sınıflandırma doğrulukları ve Kappa değerleri, dikkate alınan tüm küme oranları için RotOr' ın diğer yöntemlere olan üstünlüğünü kanıtlar niteliktedir. İkinci olarak AdaBoost algoritması yüksek sınıflandırma performansı göstermiştir. RO diğer algoritmalarla göre daha düşük sınıflandırma doğruluğu vermiştir. Düşük oranlı veri kümeleri için (örneğin; %10) RotOr ile AdaBoost arasındaki genel doğruluk farkı %5 iken büyük oranlı veri setinde (örneğin;%90) fark %2' dir. RotOr ile RO arasında aynı veri kümesi oranları için bu fark sırasıyla %7 ve %4'tür. Veri oranlarındaki artış sınıflandırıcıların doğruluklarını birbirine yaklaştırmıştır. Bunun yanında düşük eğitim oranlarındaki değişim (%10 dan %20 'ye) genel doğruluğa bakıldığında AdaBoost ve RO için %5, RotOr için %4 arttırmıştır. Kappa değerlerine bakıldığı zaman bu farklar %6 (AdaBoost), %5 (RO), %4 (RotOr) olarak görülmektedir. Büyük oranlı eğitim kümelerinde (%80 ile %90) genel doğruluklar arasında artışlar %0 (AdaBoost), %2 (RO), %1 (RotOr) iken Kappa değerlerindeki artışlar üç yöntem için de %1 dir. Doğruluk performansları ve eğitim boyutlarının doğruluklara olan

ilişkisi incelenirken sınıflandırıcıların eğitilmesi için geçen süreler de hesaplanmıştır. İşlem süreleri açısından performanslar analiz edildiğinde, RO algoritmasının tüm eğitim veriseti boyutlarında en hızlı işlem gerçekleştiren algoritma olduğu görülmüştür. Buna karşın RotOr algoritması özellikle %80-90 örnekleme oranı ile oluşturulan veri seti kullanımında RO algoritmasına göre 5 kat daha fazla işlem süresine ihtiyaç duymaktadır. AdaBoost algoritması RO ve RotOr ile karşılaştırıldığında %10-20 örnekleme oranıyla oluşturulan veri setleri için 3-5 kat, %80-90 örnekleme oranları için 10 kat ve daha fazla işlem süresine ihtiyaç duymaktadır. KSC verisi için farklı boyutlardaki eğitim kümeleriyle toplu öğrenme algoritmalarının performansı arasındaki ilişkiyi gösteren grafik Şekil 8'de gösterilmiştir. Şekil incelendiğinde, RotOr algoritmasının gerek düşük oranlı eğitim veri seti kullanımında gerekse büyük oranlı eğitim veri seti kullanımında en yüksek genel sınıflandırma doğruluğu verdiği görülmektedir. RotOr algoritmasının ardından, hesaplanan en yüksek genel doğruluk değerlerine AdaBoost algoritması kullanılarak ulaşılmıştır. RO algoritması kullanımıyla 4 farklı eğitim veri seti boyutu için diğer algoritmalarla göre daha düşük sınıflandırma doğrulukları elde edilmiştir. Düşük ve büyük oranlı eğitim veri setleri arasında en büyük doğruluk değişimi RO algoritmasında gerçekleşmiştir. Eğitim veri seti boyutu %10 olarak alındığında hesaplanan genel doğruluk 0.84 iken eğitim veri seti boyutu %90 olarak alındığında hesaplanan genel doğruluk 0.93'tür. Dolayısıyla RO algoritmasının sınıflandırma performansında eğitim veri seti boyutunun artmasıyla birlikte %9'a varan seviyede iyileşmeler olduğu gözlemlenmiştir. Diğer taraftan yer doğrulama verisinin %90 eğitim veri seti olarak kullanıldığında 3 toplu öğrenme algoritmasında benzer sınıflandırma performansı sergilediği söylenebilir. İşlem süreleri açısından performanslar analiz edildiğinde, IP veri setinde olduğu gibi RO algoritmasının tüm eğitim veriseti boyutlarında en hızlı işlem gerçekleştiren algoritma olduğu görülmüştür. Buna karşın RotOr ve AdaBoost algoritmalarının eğitim veri seti boyutundaki artışa paralel olarak gereksinim duydukları işlem sürelerinin RO algoritmasına göre oldukça fazla olduğu tespit edilmiştir.



Şekil 8. KSC görüntüsü için eğitim veri seti boyutuna göre sınıflandırma doğruluğundaki değişimler.

IP ve KSC hiperspektral görüntülerinin farklı boyutta eğitim veri setleri kullanılarak RO, AdaBoost ve RotOr algoritmaları ile sınıflandırılması sonucunda elde edilen doğruluklar arasındaki farklılıkların istatistiksel olarak anlamlılığı McNemar's testi kullanılarak analiz edilmiştir. İki sınıflandırma sonucu için hesaplanan istatistik değeri, %95

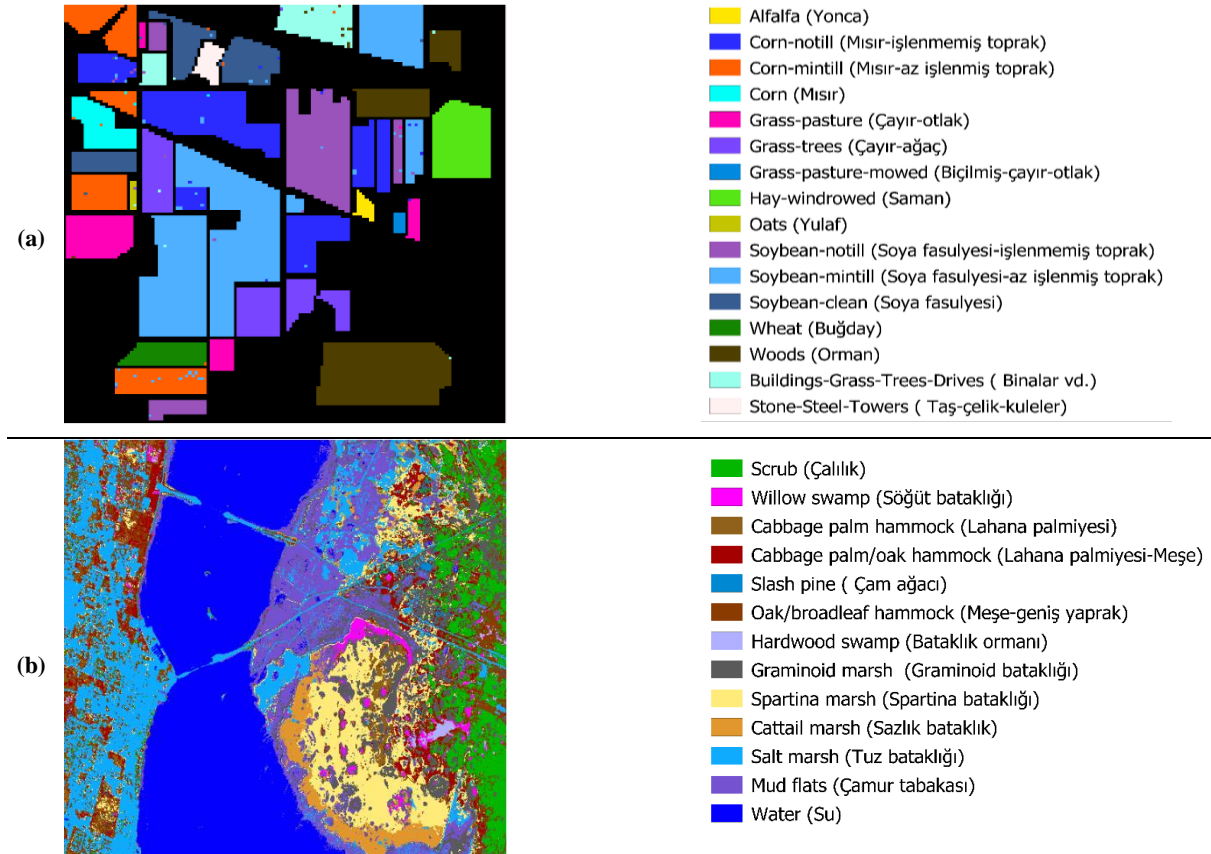
güven aralığında ki-kare tablo değerinden $\chi^2 = 3.84$ büyük olduğunda sınıflandırma doğrulukları arasındaki farkın istatistiksel olarak anlamlı bir farklılık olduğu sonucuna varılmaktadır.

IP ve KSC veri setlerinin farklı boyutta eğitim veri setleri kullanılarak RO, AdaBoost ve RotOr algoritmaları ile sınıflandırması sonucunda elde edilen doğruluklar arasındaki farklılıklara ilişkin hesaplanan istatistik değerler Tablo 2’de verilmiştir. Tablodaki değerler incelendiğinde, hesaplanan tüm düşük boyutlu eğitim kümeleri için istatistik değerlerin %95 güven aralığında tablo değerinden $\chi^2 = 3.84$ büyük olduğu görülmektedir. Dolayısıyla RotOr algoritmasının IP ve KSC veri setlerinin sınıflandırılmasında düşük boyutlu eğitim veri seti kullanımında AdaBoost ve RO algoritmalarına göre istatistiksel olarak daha yüksek doğruluklu sınıflandırma sonuçları ürettiği ifade edilebilir. Diğer taraftan, her iki hiperspektral uydu görüntüsü için RotOr ve AdaBoost algoritmaları kullanımıyla tüm farklı eğitim veri setleri için RO algoritmasına göre istatistiksel olarak daha doğru sonuçlar elde edildiği görülmektedir. KSC verisi için, yer doğrulama verisinin %90’nın eğitim veri seti olarak kullanıldığı durumda RotOr ve AdaBoost algoritmaları için hesaplanan sınıflandırma doğrulukları arasındaki farklılığın istatistiksel olarak anlamsız olduğu Tablo 2’de görülmektedir. Dolayısıyla bu iki sınıflandırıcı %90 oranıyla üretilen eğitim veri seti kullanımında aynı sınıflandırma performansını sergilediği söylenebilir.

Tablo 2. IP ve KSC veri setleri için hesaplanan McNemar’s test sonuçları.

	Veri seti boyutu	RO-AdaBoost	RO-RotOr	RotOr-AdaBoost
IP veri seti	10%	32,22	311,30	184,16
	20%	67,93	289,51	120,80
	80%	41,09	52,42	5,93
	90%	12,25	21,51	4,19
KSC veri seti	10%	73,88	215,11	60,24
	20%	46,08	63,00	4,52
	80%	13,56	16,66	1,32
	90%	7,20	7,35	0,05

Çalışmada değerlendirmeye alınan farklı boyuttaki eğitim verilerinden ve sınıflandırma algoritmalarından, örnek olarak her iki veri seti için en yüksek sınıflandırma doğruluklarına sahip tematik görüntüler şekil 9’da gösterilmiştir. IP tematik haritasında (Şekil 9a) işlenmemiş ve az işlenmiş mısır sınıfları ile binalar sınıfında diğer sınıflara oranla daha fazla hatalı sınıflandırma görülmektedir. KSC tematik haritasında (Şekil 9b) çam ağacı ve meşe-geniş yaprak sınıflarında diğer sınıflara nispeten daha fazla sınıflandırma hatası tespit edilmiştir.



Şekil 9. a) %90 IP eğitim kümesinin RotOr ile sınıflandırılması sonucunda üretilen tematik harita. **b)** %80 KSC eğitim kümesinin RotOr ile sınıflandırılması sonucunda üretilen tematik harita.

5.SONUÇLAR

Uydu görüntülerinin sınıflandırılması sonucunda üretilen tematik haritaların doğruluğu farklı kriterlere bağlı olarak değişkenlik göstermektedir. Bu çalışmada, hiperspektral görüntülerin sınıflandırılması için günümüzün gelişmiş sınıflandırıcıları olan toplu öğrenme algoritmalarından RO, AdaBoost ve RotOr algoritmaları kullanılmış ve farklı boyuttaki eğitim veri setleri için performansları analiz edilmiştir. Böylelikle hem sınıflandırıcıların, çok boyutlu görüntüler üzerindeki performansları hem de farklı boyutlu eğitim kümelerinin, doğruluk performansı üzerine olan etkilerinin incelenmesi amaçlanmıştır. İki veri seti için sonuçlar ayrı ayrı dikkate alındığında, IP eğitim kümelerinin kullanılmasından elde edilen en yüksek genel sınıflandırma doğruluğu %92 olarak bulunmuştur. %90'lık eğitim kümesinin RotOr algoritmasında kullanılmasıyla bu doğruluğa ulaşılmıştır. RotOr'ın diğer yöntemlerin doğrulukları ile olan ilişkisine bakıldığı zaman, tüm boyutlardaki veri kümeleri için en iyi doğrulukları veren algoritma olduğu görülmektedir. Özellikle düşük orandaki eğitim veri setleri (%10,%20) bu farkın daha da belirgin olduğu gözlemlenmiştir. Eğitim kümesindeki veri miktarı arttıkça toplu öğrenmeler arasındaki doğruluk farkları azalmıştır. Düşük oranlı eğitim kümeleri arasındaki doğruluk farkı incelendiğinde AdaBoost ile RO algoritmalarının RotOr'a göre veri artışına daha duyarlı olduğu görülmüştür. Büyük oranlı eğitim veri setleri (%80,%90) arasında doğruluklar sabit kalmış ya da %1-2 civarında artış göstermiştir. Bu sonuca göre sınıflandırma doğruluklarının büyük oranlı eğitim verilerinde doyuma ulaştığı görülmektedir. RO yöntemi eğitim süresi en hızlı yöntem olarak belirlenmiştir. En kısa işlem süresi olarak 11 sn kaydedilmiştir. RotOr 44 sn ile ikinci, AdaBoost 133 sn ile sonuncu olmuştur (IP %10 eğitim kümesinde). RO işlem süresi olarak RotOr'a göre 4-5 kat, AdaBoost'a göre 10 kattan fazladır. KSC verisi göz önüne alındığında, AdaBoost ve RotOr ile birlikte eğitim kümesinin %90'ının kullanıldığı durumda %96 genel doğruluk sonucuna ulaşılmıştır. Kappa değeri olarak RotOr AdaBoost'a göre %1 fazla doğruluk vererek %96 olarak hesaplanmıştır. RotOr ve AdaBoost algoritmaları için söz konusu %1'lik fark McNemar's test sonuçlarına göre istatistiksel olarak anlamsız bulunmuştur. Ayrıca %80 oranlı eğitim veri seti için genel doğruluklar arasında fark olsa da istatistiksel olarak anlamsız olduğu için bu fark kabul edilmemiştir. Düşük oranlı eğitim kümelerinde sınıflandırma doğrulukları dikkate alındığında RotOr yöntemi en iyi sonuçları vermiştir. İki eğitim kümesi arasında (%10-%20), veri sayısındaki artışın doğruluğa etkisi incelendiğinde RO'ın artıştan en fazla etkilendiği belirlenmiştir. İşlem süresi bakımından incelendiğinde RO 'ın veri kümelerinin tümünde üstün performans gösterdiği görülmektedir. RO'ın en kısa işlem süresi 6 sn sürmüştür (%10 veri kümesinde). En uzun işlem süresi 27 sn olarak görülmektedir. RotOr'dan en az 2 kat AdaBoost'tan en az 4 kat daha hızlıdır. Eğitim kümesindeki artış ile bu farklar daha da artmaktadır.

Sonuç olarak, RotOr algoritmasının özellikle sınırlı eğitim veri seti olduğu durumlarda tercih edilmesi, RO ve AdaBoost'a göre daha iyi bir sınıflandırma performansı vermektedir. Veri boyutu arttıkça algoritmaların sınıflandırma performansları birbirine yaklaşmaktadır. Bu durum RotOr yönteminin diğer yöntemlere olan üstünlüğünü azaltmaktadır. AdaBoost doğruluk performansı olarak RotOr ve RO yöntemlerinin arasında kalmakla birlikte en yavaş yöntem olarak ön plana çıkmaktadır. Büyük oranlı eğitim veri setlerinde özellikle KSC verisinde RotOr ile benzer sonuçlar yakaladığı için AdaBoost'un tercih edilmesi

değerlendirilebilir. Fakat burada zaman faktörü unutulmamalıdır. Düşük oranlı kümelerindeki veri miktarı değişiminden RO ve AdaBoost yöntemleri önemli derecede etkilenmektedir. Bu durum sınırlı eğitim verisi olduğu ve bu yöntemlerin kullanıldığı uygulamalarda doğrulama verisi miktarının bir miktar arttırılmasını desteklemektedir. RotOr'ın kullanıldığı uygulamalarda ise doğruluk üzerinde bu durumun etkisi daha az olmaktadır. Çalışma sonuçları toplu öğrenme algoritmalarının hiperspektral görüntülerin sınıflandırılmasındaki etkinliğini ortaya koyarken, kullanılan eğitim veri seti boyutunun sınıflandırma doğruluğu ile ilişkili olduğunu destekler niteliktedir.

KAYNAKLAR

Chen, Y., Dou P., Yang, X., 2017. Improving Land Use/Cover Classification with a Multiple Classifier System Using AdaBoost Integration Technique, *Remote Sensing*, 9, 1055.

Çölkesen, İ., ve Ertekin, Ö. H. 2018. Hiperspektral Görüntülerin Sınıflandırılmasında Gelişmiş Karar Ormanı Toplu Öğrenme Algoritmalarının Performans Analizi, 7. *Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZALCBS2018)*, 18-21 Eylül 2018, Eskişehir.

Freund, Y., Schapire, R.E., 1996. Experiments with a new boosting algorithm. In L. Saitta (Ed.), *ICML-96. Proceedings of the Thirteenth International Conference on Machine Learning* (pp. 148-156). Italy: Morgan Kaufmann, July 3-6.

Belgiu, M. and Dragut, L., 2016. Random forest in remote sensing: A review of applications and future directions, *ISPRS Journal of Photogrammetry and Remote Sensing*, 114:24-31.

Ghimire, B., Rogan, J., Galiano, V., R., Panday, P., Neeti, N., 2012. An Evaluation of Bagging, Boosting, and Random Forests for Land-Cover Classification in Cape Cod, *GIScience & Remote Sensing*, 49:5, 623-643

Holloway, J.; Mengersen, K. Statistical Machine Learning Methods and Remote Sensing for Sustainable Development Goals: A Review. *Remote Sens.* 2018, 10, 1365.

Jiang L., Wang W., Yang, X., Xie, N., Cheng, Y., 2011 Classification Methods of Remote Sensing Image Based on Decision Tree Technologies. *Computer and Computing Technologies in Agriculture, IV. CCTA 2010. IFIP Advances in Information and Communication Technology*, vol 344. Springer, Berlin, Heidelberg

Kavzoğlu, T., Çölkesen, İ., 2010. Karar ağaçları ile uydu görüntülerinin sınıflandırılması: Kocaeli örneği, *Harita Teknolojileri Elektronik Dergisi*, 2, pp. 36-4

Kuncheva, L.I., 2014. Combining Pattern Classifiers: Methods and Algorithms, 2nd edition, John Wiley & Sons Hoboken, New Jersey 384p.

Lu D., Weng Q., 2007. A survey of image classification methods and techniques for improving classification performance, *International Journal of Remote Sensing*, 28:5, 823-870

Maxwell, A., E., Warner, T., A., Fang, F., 2018 Implementation of machine-learning classification in remotesensing: *International Journal of Remote Sensing*, 39:9, 2784-2817,

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), pp. 554-565.

Pal, M., 2007. Ensemble Learning with Decision Tree for Remote Sensing Classification.