



Uydu görüntüsü ve uzaktan algılama teknikleri ile arazi kullanım sınıflarının belirlenmesi

Sinan Bulut^{1*}

¹ Çankırı Karatekin Üniversitesi, Orman Fakültesi, Orman Amenajmanı Anabilim Dalı, 18100, Çankırı

MAKALE KÜNYESİ

Geliş Tarihi: 14/04/2023

Kabul Tarihi: 02/11/2023

<https://doi.org/10.53516/ajfr.1367416>

* Sorumlu yazar:

sbulut@karatekin.edu.tr

ÖZ

Araştırma Makalesi

Uydu sistemlerinin ve uzaktan algılama teknolojilerinin kullanım alanları oldukça genişlemektedir. Özellikle arazi kullanım sınıfları ile arazi örtü değişimlerinin belirlenmesinde sıklıkla kullanılmakta ve üretilen tematik haritalar veri kaynağı olarak sunulabilmektedir. Bu çalışmada, Landsat 8 Operational Land Imager (OLI) uydu görüntüsü kullanılarak en çok benzerlik (EÇB), destek vektör makineleri (DVM)

doğrusal fonksiyon, DVM radyal fonksiyon, DVM polinom fonksiyon, DVM sigmoid fonksiyon ve yapay sinir ağları (YSA) gibi kontrollü sınıflandırma teknikleri ile arazi kullanım sınıfları belirlenmiş ve haritalanmıştır. Bunun için Eleman Orman İşletme Şefliği seçilmiş ve referans veri olması için bu şefliğe ait meşcere haritası kullanılmıştır. Altı farklı kontrollü sınıflandırma tekniğinin performansını karşılaştırmak için hem sınıflandırma başarıları hem de McNemar testi kullanılmıştır. Bulgulara göre bütün sınıflandırma tekniklerine ait kappa ve genel doğruluk değerleri 0.80 ve %80 üzerinde bulunmuştur. En yüksek kappa (0,8488) ve genel doğruluk (%89,14) değeri ise DVM polinom fonksiyon için elde edilmiştir. McNemar test sonuçlarına göre en başarılı DVM polinom fonksiyon ve YSA metodu arasında istatistiksel olarak bir fark bulunmamıştır ($\chi^2 < 3,8414$). Kullanılan kontrollü sınıflandırma teknikleri arasında en etkili sınıflandırma yöntemlerinin DVM polinom fonksiyon ve YSA metodu olduğu bulunmuştur.

Anahtar Kelimeler: Kontrollü sınıflandırma, Landsat 8 OLI, McNemar testi, destek vektör makineleri, yapay sinir ağları

Determining land cover types with satellite image and remote sensing techniques

ABSTRACT

The usage areas of satellite systems and remote sensing technologies are considerably expanding. It is frequently used, especially in determining land use classes and land cover changes, and the thematic maps produced can be presented as a data source. In this study, land use classes were determined and mapped using supervised classification techniques such as maximum likelihood (ML), support vector machines (SVM) linear function, SVM radial function, SVM polynomial function, SVM sigmoid function and artificial neural networks (ANN) using Landsat 8 Operational Land Imager satellite images. For this purpose, Eleman Forest Planning Unit was selected, and the stand map of this area was used as reference data. Both classification success and the McNemar test were used to compare the performance of six different supervised classification techniques. According to the results, kappa and overall accuracy values of all classification techniques were found to be 0.80 and above 80%, respectively. The highest kappa (0.8488) and overall accuracy (89.14%) values were obtained for the SVM polynomial function. According to the McNemar test results, there was no statistical difference between the most successful SVM polynomial function and ANN method ($\chi^2 < 3.8414$). The SVM polynomial function and ANN approach were found to be the most effective classification methods among the employed supervised classification techniques.

Key Words: Supervised classification, Landsat 8 OLI, support vector machine, artificial neural network

Bu makaleye atf:

Bulut, S., 2023. Uydu görüntüsü ve uzaktan algılama teknikleri ile arazi kullanım sınıflarının belirlenmesi. Anadolu Orman Arařtırmaları Dergisi, 9(2), 150-156.



Content of this journal is licensed under a Creative Commons Attribution NonCommercial 4.0 International Licence.

1. Giriř

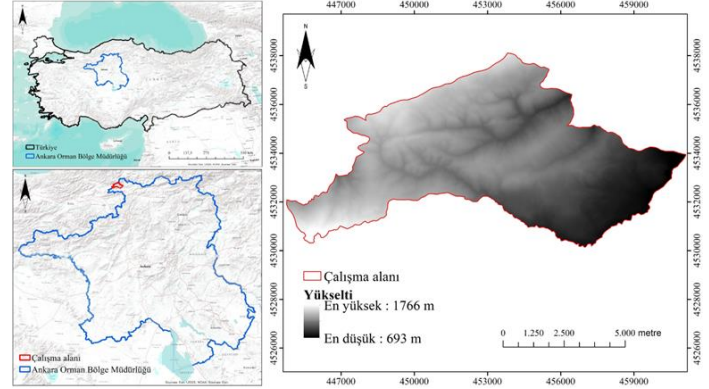
Uzaktan algılama alıřmaları geliřen teknoloji, yeni teknikler ve uydu sistemleri ile zaman iinde eřitlenmektedir. Geliřen teknoloji ile yüksek özünürlükte uydu verilerinin temini bu alıřmaların sayısının ve eřitliliğinin artmasında büyük rol oynamaktadır. Elde edilebilen bu detaylı uydu verileri yapılan alıřmalara konumsal ve spektral açıdan kapsamlı bilgiler sağlamaktadır. Ücretsiz bir şekilde elde edilebilen aktif algılama, pasif algılama ve uydu tabanlı lazer tarama sistemleri yapılan bilimsel alıřmaların daha eřitli ve kapsamlı yapılabilmesine olanak sağlamaktadır. Özellikle ormancılık alanında meřcere parametrelerinin uzaktan algılama verileri ile modellenmesi ve uydu görüntülerinin sınıflandırılması sıklıkla alıřılan konulardandır. Bu tür alıřmalarda kullanılabilcek pek ok farklı uzaktan algılama verisi ve bu veriler için kullanılabilcek farklı teknikler bulunmaktadır (Otukey and Blaschke, 2010; Jog and Dixit, 2016; Özkan and Yeřil, 2016; Saraliođlu and Vatandaşlar, 2022).

Uydu görüntülerinin sınıflandırılmasında kontrollü ve kontrolsüz sınıflandırma olmak üzere farklı uydu görüntüleri ve algoritmalar sıklıkla kullanılmaktadır. Yapılan alıřmalarda Landsat 7 ETM+ (Aksoy and Kaptan, 2021; Göl ve ark., 2018), Landsat 8 OLI (Shaharum et al., 2018, Aksoy and Kaptan, 2022), Landsat 9 OLI (Saraliođlu and Vatandaşlar, 2022), SPOT 4 (Anlar ve ark., 2015), Sentinel-2 (Bulut and Günlü, 2019; Ediř ve ark., 2022), IKONOS (Özkan and Yeřil, 2016), Quickbird (Lu et al., 2010) gibi uydu görüntüleri yoğun olarak kullanılmaktadır. Uydu görüntülerinin sınıflandırılmasında ise EB (Sisodia et al., 2014), minimum mesafe (Jog and Dixit, 2016), mahalalanobis mesafesi (Khan et al., 2015), rastgele orman (Kulkarni and Lowe, 2016), DVM (Kavzođlu and ölkesen, 2009; řatır and Berberođlu, 2012), YSA (Kavzođlu and Reis, 2008; Bulut et al. 2019) ve karar ađaçları (Otukey and Blaschke, 2010) gibi kontrollü sınıflandırma teknikleri kullanılabilir. Bu alıřmanın bařlıca amaları arazi kullanım sınıflarının EB metodu, DVM metoduna iliřkin 4 farklı kernel fonksiyon (dođrusal, radyal, polinom ve sigmoid) ve YSA metodu kullanılarak Landsat 8 OLI uydu görüntüsü ile haritalanması ve en bařarılı kontrollü sınıflandırma tekniğinin belirlenmesidir.

2. Materyal ve Yöntem

2.1 alıřma alanı

alıřma alanı Ankara Orman Bölge Müdürlüğü ierisindeki Eleman Orman İřletme řefliđidir. Planlama birimi 432499-484352 dođu boylamları ve 4523130-4544445 kuzey enlemleri (WGS 1984, UTM zon 36N) arasında yer almaktadır (řekil 1). Toplam alan 6427,58 ha olup ierisinde yayılıř gösteren ibreli ormanlar 3790,23 ha, yapraklı ormanlar 372,20 ha ve bozuk orman alanları 369,91 ha'dır. Yükselti 693 ile 1766 m arasında deđiřmektedir ve ortalama yükseltisi 1300 m'dir. alıřma alanı İ Anadolu ve Karadeniz ikliminin geiř alanı ierisinde olup ılıman ve yađıřlı bir iklime sahiptir. alıřma alanında Karaam (*Pinus nigra*), Sarıam (*Pinus silvestris*), Göknař (*Abies bormülleriana*), Kayın (*Fagus*) ve Tüylü Meře (*Quercus pubescens*) türleri yayılıř göstermektedir (Anonim, 2018).



řekil 1. alıřma alanı

2.2 Meřcere haritası ve Landsat 8 OLI uydu görüntüsü

Bu alıřmada kullanılan materyaller meřcere haritası ve Landsat 8 OLI uydu görüntüsüdür. Meřcere haritası 2018 yılı orman amenajman planından ve Landsat 8 OLI uydu görüntüsü 13 Eylül 2017 tarihi için "USGS Earth Explorer (<http://earthexplorer.usgs.gov/>)" veri portalından elde edilmiřtir (Path/Row: 178/032). Landsat 8 OLI uydusunun konumsal özünürlükleri 15, 30 ve 100 m olan toplamda 11 adet spektral bantı bulunmaktadır. Bu alıřmanın gerekleřtirilmesinde konumsal özünürlükleri 30 m olan 4 adet bant kullanılmıřtır. Bu spektral bantlar mavi (bant 2), yeřil (bant 3), kırmızı (bant 4) ve yakın kızılötesi (bant 5) bantlardır.

2.3 Kontrollü sınıflandırma teknikleri

2.3.1 En ok benzerlik

EB parametrik bir sınıflandırıcıdır ve bütün sınıflar için Gauss olasılık yoğunluk fonksiyonu modelinin ikinci derece istatistiklerine dayanmaktadır. Genellikle sınıflandırma tekniklerinin karřılařtırılmasında bir referans olarak kullanılmaktadır (Paola and Schowengerdt, 1995). EB sınıflandırıcısı bazı özellikleri geređi sıklıkla kullanılmaktadır ve bu özelliklerden bazıları řu şekildedir. Algoritma kararı en olası sonucu vermektedir. Geliřtirilmiř bir teorik temeli vardır ve matematiksel olarak izlenebilmektedir. Uzaktan algılanmıř verilerde yaygın olarak görülen oklu bađlantı verilerini kolayca uyum sađlayabilmektedir. Son olarak EB sınıflandırıcısı farklı řartlarda ve uydu sistemlerinde bařarısını kanıtlamıř bir tekniktir (Bolstad and Lillesand, 1991).

2.3.2 Destek vektör makineleri

DVM sınıflandırıcısı parametrik olmayan bir istatistiksel öđrenme yöntemidir ve yapısal risk minimizasyonu prensibine dayanmaktadır. Tasarımı ilk olarak iki sınıflı parametrik verilerin sınıflandırılması için yapılmıřtır. Sonrasında ise parametrik olmayan ve ok sınıflı verilerin birbirinden ayırımı yapabilmek için geliřtirilmiřtir. DVM sınıflandırıcısı görünmeyen örnekler üzerinde alıřmakta ve genelleme yapmaktadır (Roy and Chakraborty, 2023). DVM sınıflandırma tekniğinde ama mevcut örneklerden türetilen bir fonksiyonla en uygun hiper düzlemi oluřturarak iki sınıfı birbirinden

ayırmaktır (Vapnik, 1963; Vapnik, 1999). DVM sınıflandırıcısı için kullanılabilir farklı kernel fonksiyonları bulunmaktadır. Bu çalışmada DVM sınıflama tekniğinin uygulanmasında doğrusal, radyal, polinom ve sigmoid fonksiyonları kullanılmıştır (Hsu et al., 2003). DVM sınıflandırıcısı için kullanılan fonksiyonlar ve en yüksek başarıyı veren parametrelere ilişkin veriler Çizelge 1’de sunulmuştur.

Çizelge 1. DVM sınıflandırıcısı için kullanılan kernel fonksiyonlarına ilişkin parametre değerleri

Sınıflandırıcı	Parametre			
	d	g	h	d
DVM doğrusal fonksiyon	250			
DVM radyal fonksiyon	200	0,150		
DVM polinom fonksiyon	150	0,125	1	5
DVM sigmoid fonksiyon	200	0,125	1	

d: düzenleme parametresi (>0,01), g: gama (>0,01), h: hata (1), d: polinom derecesi (1-6)

2.3.3 Yapay sinir ağları

Yapay sinir ağları teorik olarak beyin ve zihin aktivitelerinin matematiksel bir modelidir. Yapay sinir ağları farklı işleme eleman katmanlarına sahiptir (Haykin, 1998). Yapay sinir ağlarında beyin sinapsları, nöronları ve aksonları gibi sinir ağı özelliklerine karşılık olarak girdi ağırlıkları, işleme elemanları ve çıktı yolları bulunmaktadır (Erbek et al., 2004). YSA metodu uygulamasında aktivasyon fonksiyonu olarak lojistik fonksiyon seçilmiştir. Bunun yanında eşik değer, oran, momentum ve iterasyon gibi parametreler de kullanılmaktadır. Eşik değer iç ağırlıklardaki değişiklikler, oran ağırlık ayarının boyutu, momentum ağırlık değişimlerine yön vermek ve iterasyon eğitim tekrar sayısını belirlemek için kullanılmaktadır (Knapp and Wang, 1992; Geetha et al., 2020). YSA metodu için kullanılan bu parametre değerlerine ilişkin bilgiler Çizelge 2’de sunulmuştur.

Çizelge 2. YSA metodu için uygulanan sınıflandırma işleminde kullanılan parametre değerleri

Sınıflandırıcı	Parametre			
	e	o	m	i
YSA metodu	0,2	0,2	0,9	300

e: eşik değer (0-1), o: oran (0-1), m: momentum (0-1), i: iterasyon (>0)

2.4 Görüntü sınıflandırma

Bu çalışmada yapılan kontrollü sınıflandırma işleminde eğitim ve test verisi olarak Landsat 8 OLI uydu görüntüsü ve meşcere haritası kullanılmıştır. Sınıflandırmanın ilk aşamasında Landsat 8 OLI uydu görüntüsü için sınıflandırmada kullanılan mavi (bant 2), yeşil (bant 3), kırmızı (bant 4) ve yakın kızılötesi (bant 5) bantlar ArcMap programında “Composite Bands” fonksiyonu kullanılarak birleştirilmiştir. Daha sonra uydu görüntüsü çalışma alanı sınırına göre ArcMap programında “Clip” fonksiyonu ile kırılmıştır. Çalışma alanı sınırına uygun bir şekilde oluşturulan uydu görüntüsü kontrollü sınıflandırma için hazır hale getirilmiştir. Sonraki aşamada test verisi olarak kullanılacak meşcere haritasında sınıflandırmanın yapılacağı arazi kullanım sınıfları belirlenmiştir. Bunun için ibrelî orman, yapraklı orman, bozuk orman ve diğer alanlar olmak üzere 4 farklı arazi kullanım sınıfı belirlenmiştir. İbrelî orman sınıfı iğne

yapraklı ağaçların saf ve ağırlıkta olduğu meşcerelerden, yapraklı orman sınıfı geniş yapraklı ağaçların saf ve ağırlıkta olduğu meşcerelerden, bozuk orman sınıfı kapalılığın %10 ve altında olduğu boşluklu kapalı meşcerelerden ve diğer alanlar sınıfı ise bu meşcerelerin dışında kalan yerleşim, ziraat, orman toprağı vb. alanlardan oluşmaktadır. Bu arazi kullanım sınıfları için haritalama yapılmış ve eğitim alanlarının nereden alınacağı belirlenmiştir. Eğitim ve test verisi hazır hale getirildikten sonra kontrollü sınıflandırma işlemleri ENVI 5.2 yazılımı ile gerçekleştirilmiştir. Bu işlemde EÇB, DVM doğrusal fonksiyon, DVM radyal fonksiyon, DVM polinom fonksiyon, DVM sigmoid fonksiyon ve YSA metotları sınıflandırıcı olarak kullanılmıştır. Her bir arazi kullanım sınıfı için Landsat 8 OLI uydu görüntüsü üzerinden 15 adet eğitim alanı alınmıştır. Eğitim alanlarının çalışma alanı üzerinde homojen olarak dağıtılmasına özen gösterilmiştir. Kullanılan metotlarının sınıflandırma başarılarının karşılaştırılmasında denklik probleminin olmaması için bütün tekniklerin uygulanmasında aynı eğitim alanları kullanılmıştır.

2.5 McNemar testi

Kontrollü sınıflandırma işleminde kullanılan metotların başarı düzeyleri arasında istatistiksel olarak bir fark olup olmadığı McNemar testi kullanılarak analiz edilmiştir. McNemar testi ki-kare dağılımını esas almaktadır (McNemar, 1947). Testin uygulanmasında 2x2 boyutlu bir hata matrisi için kritik değer (χ^2) hesaplanmaktadır. Daha sonra χ^2 değeri ki-kare tablosundan elde edilen %95 güven düzeyinde 3,8414 olan kritik değer ile karşılaştırılmaktadır. Hesaplanan χ^2 değerinin 3,8414’ten büyük olduğu durum karşılaştırılan iki metodun başarıları arasında istatistiksel olarak bir fark olduğunu, tersi durum ise arada bir olmadığını göstermektedir.

$$\chi^2 = \frac{(|a-b|-1)^2}{a+b} \quad (1)$$

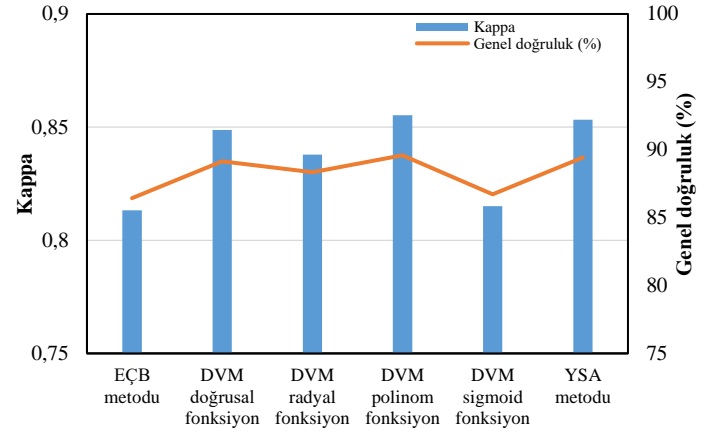
Denklemden a sadece 1. metod tarafından yanlış sınıflandırılan piksel sayısını ve b sadece 2. metod tarafından yanlış sınıflanan piksel sayısını ifade etmektedir (Dietterich, 1998).

3. Bulgular ve Tartışma

Bu çalışmada ibrelî orman, yapraklı orman, bozuk orman ve diğer alanlar (İs, Z, OT vb.) olmak üzere 4 farklı arazi kullanım sınıfı için kontrollü sınıflandırma yapılmıştır. Bu amaçla EÇB, DVM doğrusal fonksiyon, DVM radyal fonksiyon, DVM polinom fonksiyon, DVM sigmoid fonksiyon ve YSA metotları kullanılmıştır. En yüksek sınıflandırma başarısını 0,8552 kapa ve %89,5901 genel doğruluk oranı ile DVM polinom fonksiyon sağlamıştır (Şekil 2, Çizelge 3). Uygulanan sınıflandırıcılar parametrik ve parametrik olmayan olarak ayrıldığında en düşük başarıyı parametrik olan EÇB metodu göstermiştir (kappa: 0,8132 - genel doğruluk: %86,4346). DVM sınıflandırıcısı içeriğinde kullanılan 4 farklı kernel fonksiyonu içerisinde ise en düşük başarıyı sigmoid fonksiyon göstermiştir (kappa: 0,8151 - genel doğruluk: %86,7261). YSA metodu için 0,8533 kapa ve %89,4186 genel doğruluk başarısı elde edilmiştir. DVM polinom fonksiyondan sonra en yüksek doğruluk YSA metodu için elde edilmiştir.

Kontrollü sınıflandırma tekniklerinin karşılaştırılmasında EÇB metodu çoğunlukla referans olarak kullanılmaktadır. Uygulanan diğer metotların başarı ölçütleri EÇB metoduna göre kıyaslanmaktadır. Kavzoğlu ve Çölkesen (2010) Landsat ETM+ uydu görüntüsü ile arazi kullanım sınıflaması yapmıştır. EÇB metodu için elde ettikleri kapa değeri 0,89'dur. En yüksek başarıyı ise DVM Pearson VII fonksiyonu ile elde etmişlerdir (kappa: 0,94). Jog and Dixit (2016) çalışmalarında çeşitli Landsat uydu görüntüleri kullanarak arazi kullanımı için kontrollü sınıflandırma yapmışlardır. EÇB metodu için 0,85 kappa değeri elde etmişlerdir. Kullanılan DVM doğrusal ve polinom fonksiyonları için kappa değerleri sırası ile 0,8958 ve 0,9046'dır. Dash et al. (2023) yaptıkları çalışmada Landsat 8 OLI uydu görüntüsü ile arazi kullanım sınıflaması yapmışlardır. Kullandıkları EÇB ve DVM metotları için sırası ile 0,674 ve 0,789 kappa değerleri elde etmişlerdir.

Yapılan çalışmalarda çoğunlukla parametrik olmayan DVM ve YSA metotları, parametrik bir teknik olan EÇB metoduna göre daha yüksek sınıflandırma başarısı gösterebilmektedir. Fakat bazı çalışmalarda EÇB metodu için daha yüksek sınıflama başarıları elde edilmiştir. Bulut ve Günlü (2016) yaptıkları çalışmada arazi kullanım sınıfları için Landsat 8 OLI uydu görüntüsünü EÇB ve DVM metodunun 4 kernel fonksiyonu kullanarak sınıflandırmışlardır. En yüksek sınıflandırma başarısını EÇB (kappa: 0,81) ve DVM polinom fonksiyonu (kappa: 0,79) ile elde etmişlerdir. Aliabad et al. (2023) YSA teknikleri (fuzzy ARTMAP, Kohonen and Perceptron) ve EÇB metodu gibi kontrollü sınıflandırma teknikleri kullanarak arazi kullanım sınıflandırması yapmışlardır. Elde edilen sınıflandırma başarı ölçütlerine göre EÇB metodu için 0,9115 kappa değeri elde edilirken fuzzy ARTMAP, Kohonen ve Perceptron gibi YSA teknikleri için elde edilen kappa değerleri sırası ile 0,7322, 0,2119 ve 0,8049 bulunmuştur. Kumar et al. (2023) çalışmalarında 2000 ve 2017 yılları için Landsat 5 TM ve Landsat 8 OLI uydu görüntüleri ile arazi kullanım sınıflaması yapmışlardır. Kullandıkları EÇB, SVM ve YSA metotlarında 2000 yılı için sırası ile 0,89, 0,89 ve 0,86, 2017 yılı için ise 0,92, 0,93 ve 0,92 kappa değerleri bulmuşlardır. Berberoğlu and Şatır (2008) çalışmalarında Envisat MERIS ve Landsat ETM uydu görüntüleri ile doğrusal karışık etkili model ve YSA teknikleri kullanarak arazi kullanım sınıflaması yapmışlardır. Bu çalışmada çok zamanlı spektral veri ve yeterli eğitim verisi kullanmanın sınıflandırma doğruluğunu artırabileceği raporlanmıştır. Ersoy Mirici et al. (2020) yaptıkları çalışmada arazi kullanımı ve arazi örtü değişimi topoğrafya, bitki yoğunluğu ve spektral verilerin entegre edildiği hibrit bir yaklaşım ile belirlenmiştir. 2003 ve 2014 yılları için yapılan sınıflamada kappa değerleri sırası ile 0,81 ve 0,83 elde edilmiştir. Bu yaklaşımın heterojen yapıdaki baskın ağaç örtüsünü sınıflamada iyi bir performans sergilediği bulunmuştur. EÇB metodu kontrollü sınıflandırma çalışmalarında kullanılan ve başarısını kanıtlamış bir metottur. Farklı arazi yapılarına sahip ve spektral olarak birbirinden ayırt edilebilen alanlarda EÇB metodu DVM ve YSA tekniklerine göre sınıflandırma başarısı açısından daha etkili olabilmektedir (Aliabad et al., 2023; Kumar et al., 2023). Genel olarak pikseller içerisindeki karışım derecesinin düşük olduğu ve arazi deseninin karmaşık olmadığı durumlarda EÇB gibi parametrik tekniklerin kullanılabilirliği (Şatır and Berberoğlu 2012).



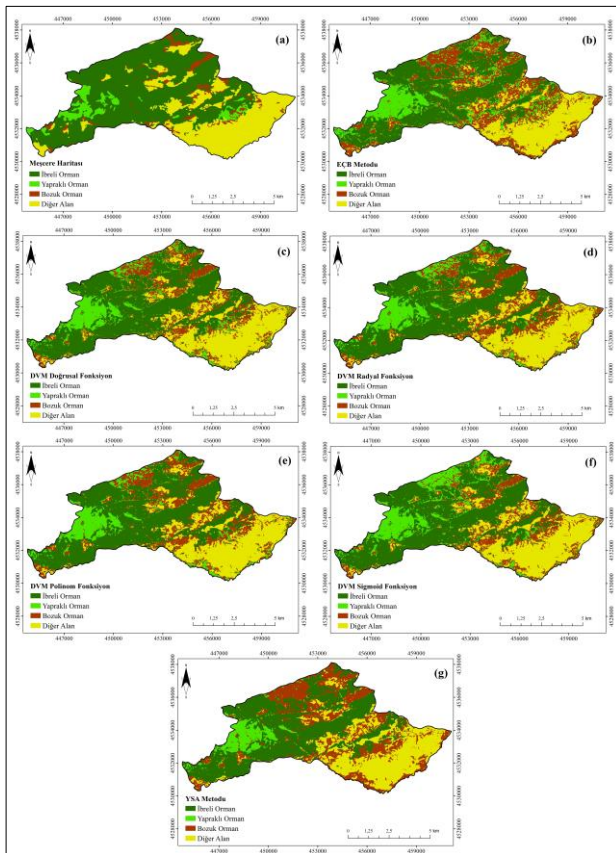
Şekil 2. Uygulanan sınıflandırma tekniklerinin kappa ve genel doğruluk (%) başarıları

Kullanılan referans meşçere haritası ve kontrollü sınıflandırma teknikleri ile oluşturulan tematik haritalar Şekil 3'de verilmiştir. Üretilen arazi kullanım sınıfları haritalarının büyük ölçüde referans harita ve birbirleri ile uyumludur. Bu uyumluluk yapılan sınıflama hataları için de geçerlidir. Özellikle çalışma alanının kuzeyinde yer alan ve çoğunluğu genç sarıçam meşcerelerinden oluşan bölge bütün sınıflandırıcılar tarafından hatalı bir şekilde sınıflanmıştır (Şekil 4). Referans alınan meşçere haritasında ibrelili ormanlardan oluşan arazi sınıfının genç meşcerelerden oluşması, o bölgenin yansıma özelliklerini de etkilemektedir. Mevcut durumda ibrelili orman olarak etiketlenmiş alanlar çoğunlukla yapraklı veya bozuk orman olarak sınıflanmıştır. Bu sonucun elde edilmesindeki temel faktör söz konusu bölgenin spektral özelliklerinin olması istenen arazi sınıfından farklı olmasıdır. Sınıflandırma, benzer spektral özelliklerdeki alanların gruplandırılmasıdır (Demirci, 2008). Bu bölgedeki yansıma özellikleri ise meşçere haritasındaki arazi kullanım sınıfını yansıtmadığından dolayı uygulanan teknikler tarafından hatalı bir şekilde sınıflanmıştır.

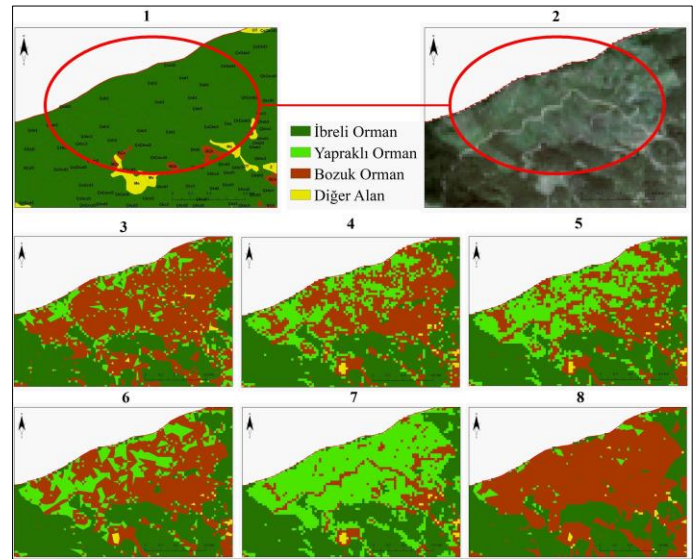
Bu çalışma kapsamında oluşturulan arazi kullanım sınıflarına ait alan bilgileri meşçere haritasından alınmış ve sınıflandırıcılar ile üretilen tematik haritalardan elde edilen alan bilgileri ile kıyaslanmıştır (Şekil 5). İbrelili orman ve diğer alan sınıfları olduğundan daha düşük tahmin edilmiştir. Yapraklı ve bozuk orman sınıfları ise referans alınan meşçere haritası verilerine göre daha yüksek tahmin edilmiştir. Tahminlerin sistematik olarak belirli sınıflar için yüksek ve düşük tahmin edilmesinin nedenlerinin en önemlisi Şekil 4'te gösterilen ve hataya neden olan bölgedeki ibrelili ormanların, yapraklı orman ve bozuk orman olarak sınıflandırılmasıdır.

Çizelge 3. Kontrollü sınıflandırma tekniklerine ilişkin hata matrisleri

EÇB metodu					DVM doğrusal fonksiyon						
Sınıf	İbrelî orman	Yapraklı orman	Bozuk orman	Diğer alan	Toplam	Sınıf	İbrelî orman	Yapraklı orman	Bozuk orman	Diğer alan	Toplam
İbrelî orman	2016	14	17	0	2047	İbrelî orman	2058	25	17	3	2103
Yapraklı orman	32	900	205	9	1146	Yapraklı orman	6	888	91	9	994
Bozuk orman	21	136	578	267	1002	Bozuk orman	5	126	581	139	851
Diğer alan	0	18	72	1546	1636	Diğer alan	0	29	183	1671	1883
Toplam	2069	1068	872	1822	5831	Toplam	2069	1068	872	1822	5831
Kappa: 0,8132 – Genel doğruluk: %86,4346					Kappa: 0,8488 – Genel doğruluk: %89,1442						
DVM radyal fonksiyon hata matrisi					DVM polinom fonksiyon						
Sınıf	İbrelî orman	Yapraklı orman	Bozuk orman	Diğer alan	Toplam	Sınıf	İbrelî orman	Yapraklı orman	Bozuk orman	Diğer alan	Toplam
İbrelî orman	2057	25	18	3	2103	İbrelî orman	2057	22	18	3	2100
Yapraklı orman	6	826	73	6	911	Yapraklı orman	7	876	54	11	948
Bozuk orman	6	189	607	152	954	Bozuk orman	5	143	628	145	921
Diğer alan	0	28	174	1661	1863	Diğer alan	0	27	172	1663	1862
Toplam	2069	1068	872	1822	5831	Toplam	2069	1068	872	1822	5831
Kappa: 0,8378 – Genel doğruluk: %88,3382					Kappa: 0,8552 – Genel doğruluk: %89,5901						
DVM sigmoid fonksiyon					YSA metodu						
Sınıf	İbrelî orman	Yapraklı orman	Bozuk orman	Diğer alan	Toplam	Sınıf	İbrelî orman	Yapraklı orman	Bozuk orman	Diğer alan	Toplam
İbrelî orman	2053	34	17	3	2107	İbrelî orman	2051	24	18	2	2095
Yapraklı orman	10	827	149	7	993	Yapraklı orman	4	793	4	0	801
Bozuk orman	6	172	514	149	841	Bozuk orman	12	231	709	159	1111
Diğer alan	0	35	192	1663	1890	Diğer alan	2	20	141	1661	1824
Toplam	2069	1068	872	1822	5831	Toplam	2069	1068	872	1822	5831
Kappa: 0,8151 – Genel doğruluk: %86,7261					Kappa: 0,8533 – Genel doğruluk: %89,4186						



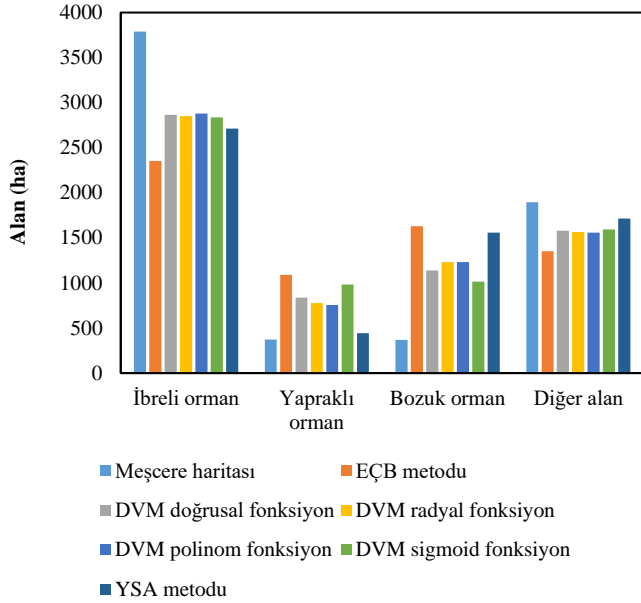
Şekil 3. Meşçere haritası ve sınıflandırma tekniklerinden üretilen arazi kullanım sınıfları haritaları (a) meşçere haritası, (b) EÇB metodu, (c) DVM doğrusal fonksiyon, (d) DVM radyal fonksiyon, (e) DVM polinom fonksiyon, (f) DVM sigmoid fonksiyon ve (g) YSA metodu



Şekil 4. Sınıflandırma işleminde en yüksek hatanın oluştuğu bölge (1) meşçere haritası, (2) Landsat 8 uydu görüntüsü, (3) EÇB metodu, (4) DVM doğrusal fonksiyon, (5) DVM radyal fonksiyon, (6) DVM polinom fonksiyon, (7) DVM sigmoid fonksiyon ve (8) YSA metodu

Bu çalışma kapsamında oluşturulan arazi kullanım sınıflarına ait alan bilgileri meşçere haritasından alınmış ve sınıflandırıcılar ile üretilen tematik haritalardan elde edilen alan bilgileri ile kıyaslanmıştır (Şekil 5). İbrelî orman ve diğer alan sınıfları olduğundan daha düşük tahmin edilmiştir. Yapraklı ve bozuk orman sınıfları ise referans alınan meşçere haritası

verilerine göre daha yüksek tahmin edilmiştir. Tahminlerin sistematik olarak belirli sınıflar için yüksek ve düşük tahmin edilmesinin nedenlerinin en önemlisi Şekil 4'te gösterilen ve hataya neden olan bölgedeki ibrelili ormanların, yapraklı orman ve bozuk orman olarak sınıflandırılmasıdır.



Şekil 5. Meşcere haritasından elde edilmiş arazi kullanım sınıflarına ilişkin alan değerlerinin uygulanan sınıflandırma tekniklerine göre karşılaştırılması

Uygulanan kontrollü sınıflandırma tekniklerinin sınıflandırma başarıları arasında bir fark olup olmadığı McNemar testi ile analiz edilmiştir (Çizelge 4). Elde edilen χ^2 değerleri incelendiğinde en yüksek başarıyı gösteren DVM polinom fonksiyon ve YSA metodu arasında %95 güven düzeyinde bir fark bulunmamıştır ($\chi^2 < 3,8414$). DVM doğrusal ve radyal fonksiyon ile EÇB metodu ve DVM sigmoid fonksiyon metodları arasında ise bir fark gözlemlenmemiştir ($\chi^2 < 3,8414$). McNemar test sonuçlarına göre bu çalışmadaki en düşük sınıflandırma başarısını EÇB metodu ve DVM sigmoid fonksiyon, en yüksek sınıflandırma başarısını ise DVM polinom fonksiyon ve YSA metodu göstermiştir.

Çizelge 4. McNemar testi için hesaplanan χ^2 değerleri

χ^2	1	2	3	4	5	6
1	0	17,5309	8,3759	24,2175	0,1847	21,5028
2		0	1,6824	5,5452	14,1301	4,2048
3			0	4,1406	6,0770	3,0601
4				0	20,1948	0,0817
5					0	17,7203
6						0

1: EÇB metodu, 2: DVM doğrusal fonksiyon, 3: DVM radyal fonksiyon, 4: DVM polinom fonksiyon, 5: DVM sigmoid fonksiyon, 6: YSA metodu

4. Sonuç ve Öneriler

Bu çalışmada arazi kullanım sınıfları Landsat 8 OLI uydu görüntüsü ve 6 farklı kontrollü sınıflandırma tekniği kullanılarak haritalanmıştır. Kullanılan sınıflandırma

tekniklerinin sınıflandırma performansları arasında bir fark olup olmadığını belirlemek için McNemar testi kullanılmıştır. Genel başarı ölçütleri ve McNemar testi sonuçları doğrultusunda uygulanan teknikler içerisinde en yüksek başarıyı DVM polinom fonksiyon ve YSA metodu göstermiştir. Bu tür çalışmalarda kullanılan optik veriler ve uygulanan teknikler elde edilen ürünlerin kalitesi ve sınıflandırmanın başarısı üzerinde büyük rol oynamaktadır. Yapılacak çalışmanın amacı doğrultusunda çözünürlük özelliklerine göre kullanılacak uydu görüntüsünün ve arazi desenine göre uygulanacak tekniklerin seçilmesi önerilmektedir.

Teşekkür

Bu çalışmada kullanılan meşcere haritasının temini için Orman Genel Müdürlüğü, Orman İdaresi ve Planlama Daire Başkanlığına teşekkür ederiz.

Kaynaklar

- Aksoy, H., Kaptan, S. 2021. Monitoring of land use/land cover changes using GIS and CA-Markov modeling techniques: A study in Northern Turkey. Environmental monitoring and assessment, 193(8), 507.
- Aksoy, H., Kaptan, S. 2022. Simulation of future forest and land use/cover changes (2019–2039) using the cellular automata-Markov model. Geocarto International, 37(4), 1183-1202.
- Aliabad, F. A., Zare, M., Solgi, R., Shojaei, S. 2023. Comparison of neural network methods (fuzzy ARTMAP, Kohonen and Perceptron) and maximum likelihood efficiency in preparation of land use map. GeoJournal, 88(2), 2199-2214.
- Anlar, H. C., Günlü, A., Keleş, S., Bulut, S. 2015. SPOT-4 uydu görüntüsü yardımıyla bazı meşcere parametreleri (gelişim çağı ve kapalılık) ve arazi kullanım sınıflarının belirlenmesi; Devrez Planlama Birimi Örneği. Anadolu Orman Arařtırmaları Dergisi, 1(1-2), 33-40.
- Anonim 2018. Ankara Orman Bölge Müdürlüğü, Eskipazar Orman İşletme Müdürlüğü, Eleman Orman İşletme Şefliği, Ekosistem Tabanlı Fonksiyonel Orman Amenajman Planı. T. C. Orman Genel Müdürlüğü, Orman İdaresi ve Planlama Dairesi Başkanlığı, Ankara.
- Berberoğlu, S., Şatır, O. 2008. Fuzzy classification of Mediterranean type forest using ENVISAT MERRIS data. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. XXXVII. Part B8, pp. 1109-1114. Beijing, China.
- Bolstad, P., Lillesand, T. M. 1991. Rapid maximum likelihood classification. Photogrammetric engineering and remote sensing, 57(1), 67-74.
- Bulut, S., Günlü, A. 2016. Arazi kullanım sınıfları için farklı kontrollü sınıflandırma algoritmalarının karşılaştırılması. Kastamonu University Journal of Forestry Faculty, 16(2), 528-535.
- Bulut, S., Günlü, A. 2019. Determination of total carbon storage using Sentinel-2 and Geographic Information Systems in mixed forests. Anadolu Orman Arařtırmaları Dergisi, 5(2), 127-135.
- Bulut, S., Günlü, A., Keleş, S. 2019. Estimation of forest development stage and crown closure using different

- classification methods and satellite images: A case study from Turkey. *Journal of Forest Science*, 65(1), 18-26.
- Dash, P., Sanders, S. L., Parajuli, P., Ouyang, Y. 2023. Improving the Accuracy of Land Use and Land Cover Classification of Landsat Data in an Agricultural Watershed. *Remote Sensing*, 15(16), 4020.
- Demirci, F. 2008. Filyos havzasındaki sediment birikim alanlarının uydu görüntü verileri ve sayısal arazi modeli ile analizi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 73 s.
- Dietterich, T. G. 1998. Approximate statistical tests for comparing supervised classification learning algorithms. *Neural computation*, 10(7), 1895-1923.
- Ediř, S., Tuttu, G., Aytas, İ., Tuttu, U., Özcan, A. U. 2022. Acıçay (Çankırı) Riparian Zonunda zamansal ve mekânsal deęişimin analizi. *AÇÜ Orman. Fak. Derg.* 23(1), 1-10.
- Erbek, F. S., Özkan, C., Taberner, M. 2004. Comparison of maximum likelihood classification method with supervised artificial neural network algorithms for land use activities. *International journal of remote sensing*, 25(9), 1733-1748.
- Ersoy Mirici, M., Şatır, O., Berberoęlu, S. 2020. Monitoring the Mediterranean type forests and land-use/cover changes using appropriate landscape metrics and hybrid classification approach in Eastern Mediterranean of Turkey. *Environmental Earth Sciences*, 79(21), 492.
- Geetha, V., Aprameya, K. S., Hinduja, D. M. 2020. Dental caries diagnosis in digital radiographs using back-propagation neural network. *Health Information Science and Systems*, 8, 1-14.
- Göl, C., Günlü, A., Ediř, S., Küçükdöngül, A. 2018. Çorum-Osmancık-Emine Deresi ve yan dere havzaları 1990-2014 yılları havza ıslah çalışmalarının arazi kullanım türü/arazi örtüsüne etkileri. *Turkish Journal of Forestry*, 19(2), 149-155.
- Haykin, S. 1998. *Neural networks: a comprehensive foundation*. Prentice Hall PTR.
- Hsu, C. W., Chang, C. C., Lin, C. J. 2003. *A practical guide to support vector classification*. Taipei, National Taiwan University, 16.
- Jog, S., Dixit, M. 2016. Supervised classification of satellite images. In *2016 Conference on Advances in Signal Processing (CASP)* (pp. 93-98). IEEE.
- Kavzoęlu, T., Reis, S., 2008, Performance Analysis of Maximum Likelihood and Artificial Neural Network Classifiers for Training Sets with Mixed Pixels, *GIScience and Remote Sensing*, 45(3), 330-342.
- Kavzoęlu T., Çölkesen I. 2009. A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, 11, 352-359.
- Kavzoęlu, T., Çölkesen, İ. 2010. Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. *Harita Dergisi*, 144(7), 73-82.
- Khan, U., Minallah, N., Junaid, A., Gul, K., Ahmad, N. 2015. Parallelepiped and Mahalanobis Distance based Classification for forestry identification in Pakistan. In *2015 International Conference on Emerging Technologies (ICET)* (pp. 1-6). IEEE.
- Knapp, G. M., Wang, H. P. 1992. Machine fault classification: a neural network approach. *International Journal of Production Research*, 30(4), 811-823.
- Kulkarni, A. D., Lowe, B. 2016. Random forest algorithm for land cover classification. *Computer Science Faculty Publications and Presentations*. Paper 1. <http://hdl.handle.net/10950/341>.
- Kumar, A., Garg, R. D., Singh, P., Shankar, A., Nayak, S. R., Diwakar, M. 2023. Monitoring the Land Use, Land Cover Changes of Roorkee Region (Uttarakhand, India) Using Machine Learning Techniques. *International Journal of Social Ecology and Sustainable Development (IJSESD)*, 14(1), 1-16.
- Lu, D., Hetrick, S., Moran, E. 2010. Land cover classification in a complex urban-rural landscape with QuickBird imagery. *Photogrammetric Engineering & Remote Sensing*, 76(10), 1159-1168.
- McNemar, Q. 1947. Note on the sampling error of the difference between correlated proportions or percentages. *Psychometrika*, 12(2), 153-157.
- Şatır, O., Berberoęlu, S. 2012. Land use/cover classification techniques using optical remotely sensed data in landscape planning. *Landscape Planning*. Rijeka: InTech, 21-54.
- Otukei, J. R., Blaschke, T. 2010. Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms. *International Journal of Applied Earth Observation and Geoinformation*, 12, S27-S31.
- Özkan, U., Yeşil, A. 2016. Forest stand delineation using Ikonos image and object based image analysis. *Journal of the Faculty of Forestry Istanbul University*, 66(2), 600-612.
- Paola, J. D., Schowengerdt, R. A. 1995. A detailed comparison of backpropagation neural network and maximum-likelihood classifiers for urban land use classification. *IEEE Transactions on Geoscience and remote sensing*, 33(4), 981-996.
- Roy, A., Chakraborty, S. 2023. Support vector machine in structural reliability analysis: A review. *Reliability Engineering & System Safety*, 109126.
- Saralioglu, E., Vatandaslar, C. 2022. Land use/land cover classification with Landsat-8 and Landsat-9 satellite images: A comparative analysis between forest-and agriculture-dominated landscapes using different machine learning methods. *Acta Geodaetica et Geophysica*, 57(4), 695-716.
- Shaharum, N. S. N., Shafri, H. Z. M., Gambo, J., Abidin, F. A. Z. 2018. Mapping of Krau Wildlife Reserve (KWR) protected area using Landsat 8 and supervised classification algorithms. *Remote Sensing Applications: Society and Environment*, 10, 24-35.
- Sisodia, P. S., Tiwari, V., Kumar, A. 2014. Analysis of supervised maximum likelihood classification for remote sensing image. In *International conference on recent advances and innovations in engineering (ICRAIE-2014)* (pp. 1-4). IEEE.
- Vapnik, V. N. 1963. Pattern recognition using generalized portrait method. *Automation and remote control*, 24(6), 774-780.
- Vapnik, V. N. 1999. *The nature of statistical learning theory*. Springer science & business media.