



Araştırma Makalesi

**İHA İLE MULTİSPEKTRAL KAMERALARDAN SAĞLANAN GÖRÜNTÜLER YARDIMIYLA
BİTKİ TÜRLERİNİN SINIFLANDIRILMASI
CLASSIFICATION OF VEGETATION SPECIES WITH MULTI-SPECTRAL CAMERA BY USING
UNMANNED AERIAL VEHICLES**

Yusuf DOĞAN*¹, Ferruh YILDIZ¹

¹Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Harita Mühendisliği Bölümü, Konya, Türkiye

Anahtar Kelimeler:

Uzaktan Algılama
İHA
Bitki Türü
Multispektral Kamera
Yonca
Soya

Keywords:

Remote sensing
UAV
Vegetation
Multispectral Camera
Clover
Soybean

ÖZ

Yeryüzündeki bitki örtüsü türlerinin ayırt edilmesi uzaktan algılama çalışmalarında yoğun olarak kullanılmaktadır. Uydu görüntüleri kullanılarak yapılan bu uzaktan algılama çalışmaları, uyduların gerek her zaman aynı yerden görüntü elde edememesi gerekse yer örnekleme aralıklarından kaynaklanan sebeplerle zamansal ve mekânsal çözünürlükleri yüksek hassasiyet ve doğruluk istenen çalışmalarda yetersiz kalmaktadır. Bu çalışmada, son zamanlarda hızla artan ve yaygınlaşan İnsansız Hava Aracı (İHA) teknolojisinin esnek hareket kabiliyetine sahip olması nedeniyle sunmuş olduğu olanaklar üzerinde bir uygulama gerçekleştirilmiştir. İHA'ların istenilen zaman ve yer örnekleme aralığına uygun yükseklikte uçurulabilmesi esnek hareket kabiliyetine sahip olmasını sağlamaktadır. İHA üzerine yerleştirilen multispektral kameradan elde edilen görüntüler ile yeryüzündeki bitki örtüsü türlerinin tespiti yapılarak sınıflandırılarak arazi kullanımlarının belirlenmesi ve ürün verimliliğinin araştırılması gibi konular uzaktan algılama çalışmalarına yeni bir bakış açısı kazandırabilir. İHA üzerine monte edilen kameranın elde ettiği yeşil, kırmızı, kırmızı-kenar ve yakın kızıl ötesi görüntüler kullanılarak yonca ve soya bitkilerinin tespit edilebilirliği incelenmiştir. Multispektral görüntülerden oluşturulan kompozit görüntüler yardımıyla tür sınıflandırması yapılmıştır.

ABSTRACT

The distinction between the types of vegetation on earth is used extensively in remote sensing studies. Remote sensing studies using satellite imagery are inadequate in the studies requiring high accuracy and precise in temporal and spatial resolutions caused by frequency of revisit time and ground sample distance. In this study, an application was performed with the opportunities offering flexible mobility of unmanned aerial vehicle (UAV) technology which is rapidly increasing and widening recently. UAVs have flexible mobility thanks to the ability to fly at an altitude proper for the desired time and ground sampling distance. The multispectral imagery acquired from a camera mounted on a UAV. Determining the land uses and researching the product efficiency by classifying the species of vegetation on earth can give a new perspective to the remote sensing studies by using the images obtained from the multispectral camera mounted on the UAV. Detectability of clover and soybean was investigated using green, red, red-edge and near-infrared imagery obtained from multispectral camera. Vegetation classification was carried out by composite imagery created from multispectral imagery.

*Sorumlu Yazar

*(yusufdogan89@gmail.com) ORCID ID 0000-0001-8564-7839
(fyildiz.ktun.edu.tr) ORCID ID 0000 - 0003 - 1248 - 8923

1. GİRİŞ

Yer sathını gözleme uydularından elde edilen multispektral görüntüler birçok soruna çözüm bulmak amacıyla uzaktan algılama çalışmaları dâhilinde kullanılmaktadır (Orhan ve Yakar, 2016; Orhan vd. 2014; Orhan vd., 2019; Kuşak ve Küçükali, 2019; Comert vd., 2019)). Son zamanlarda İHA sistemleri de multispektral görüntü elde etme amacıyla kullanılmaya başlanmıştır. İHA'lar genellikle küçük alanlarda hızlı veri toplama, yüksek doğruluklu düşük maliyetli haritalama için uygun olduğundan çeşitli uygulamalar için kullanılabilir (Ahmad vd., 2013). İHA tabanlı spektral görüntüleme kullanımı, yüksek çözünürlüklü uzaktan algılama uygulamalarında önemli avantajlar sunmaktadır. Bununla birlikte, bir İHA üzerine monte edilebilen sensörlerin sayısı sınırlıdır ve spektral bantların optimal kombinasyonunun seçilmesi karmaşıktır ancak geleneksel İHA-tabanlı çoklu-görüşlü görüntüleme sistemleri için çok önemlidir (Ishida vd., 2018). Bitki örtüsünü ayırt etme yeteneği, İHA'ların görüntü spektrumu (kamera tipi), mekansal (uçuş yüksekliği) ve zamansal (çalışma tarihi) çözünürlüklerinden önemli ölçüde etkilenmiştir. (Peña vd., 2015). Küçük termal, lazer veya spektral sensörler ile donatılmış insansız hava araçlarının kullanımı, meralar, ormanlar ve tarımsal ortamlardaki uygulamaların modellenmesi, haritalanması ve izlenmesi için umut verici bir alternatif olarak ortaya çıkmıştır (Salamí vd., 2014). Bitki örtüsü tespiti için İHA'lara monte edilen sensör sistemleri genellikle pasif sistemler olup güneşten yansıyan ışınları kullanırlar. Pasif optik sistemler ve özellikle hiperspektral sistemler genel olarak aktif SAR veya LiDAR sensör sistemlerine göre ağaç türlerinin sınıflandırılması için daha yüksek potansiyel göstermiştir (Fassnacht vd., 2016).

Somers ve Asner (2014) çalışmalarında spektral ve zamansal verileri kullanarak irdeledikleri yaklaşımları sonucunda her pikselde mevcut olan ağaç türleri arasındaki spektral ayrımı optimize edebildiklerini belirtmektedir. Bitki türlerinin spektrumlara göre ayırt edilmesi konusunda yapılan çalışmalarda kırmızı kenar spektrumunun oldukça etkili olduğu gözlemlenmiştir. Kırmızı kenar spektrumu bitki örtüsü yapı parametrelerine duyarlıdır, bitkilerin geniş yaprak ve Yaprak Alan Endeksi (LAI) bitkinin ayırt edilmesi için kırmızı kenar bölgesini iyi bir seçim haline getirmektedir (Jia vd., 2011).

Adam ve Mutanga (2009) yeşil yaprakların yakın kızılötesi ve kırmızı kenar bölgelerinde en büyük çeşitliliğe sahip olduğunu belirterek elektromanyetik spektrumun kırmızı kenar ve kızıl ötesi bölgelerinin tür tespiti ve ayırt etmedeki önemini çalışmalarında doğrulamıştır. Bitki örtüsü ayırt edilmesinde birçok sınıflandırma tekniği kullanılmaktadır. Dudley vd. (2015) bitki örtüsü fenolojisindeki mekansal ve zamansal değişimlere

bağlı olarak spektral yansımadaki değişkenlik sebebiyle doğru bitki örtüsü sınıflandırmasında oluşan sorunlara çözüm bulmak için Çoklu Son Eleman Spektral Karışım Analizi (MESMA) yöntemini kullanmışlardır. Tuz bataklıkları bitki toplulukları üzerinde yapılan bir çalışmada Doğrusal Ayırıcı Analiz (LDA) ve parametrik olmayan sınıflandırma ve regresyon ağacı (CART) tekniklerinin karşılaştırması yapılmıştır. Kahve tarlaları ve doğal bitki örtüsü arasında ayırım yapmanın zor olduğu bölgelerde yapılan bir çalışmada kontrollü sınıflandırma tekniği kullanılmıştır (Martínez-Verduzco vd., 2012). Anchang vd. (2016) uydu görüntülerinden kentsel bitki örtüsü haritalama çalışmalarında kontrolsüz sınıflandırmanın maliyetli alan çalışmasından ziyade görüntü elde etmede kaynaklara daha fazla odaklanmasını sağladığından bir avantaj sağladığını belirtmektedir. Sınıflandırma çalışmalarında bitki türlerine göre yukarıdakiler gibi çeşitli teknikler kullanılmaktadır.

2. MATERYAL VE YÖNTEM

2.1. Materyal

2.1.1. Çalışma alanı

Çalışma alanı Mersin ili Tarsus ilçesinde bulunan Alata Bahçe Kültürleri Araştırma Enstitüsü Müdürlüğüne ait arazide yapılmıştır (Şekil 1 ve 2). Arazide ekili olan soya ve yonca bitkilerinin multispektral görüntüler vasıtasıyla ayırt edilmesi amaçlanmıştır.




Şekil 1. Mersin ilçe haritası



Şekil 2. Alata Bahçe Kùltürleri Arařtırma Enstitüsü Tarsus Müdürlüğü arazisi

Bitki türlerinin sınıflandırılması amacıyla bařladığımız çalıřmamıza en az iki farklı bitki türünün, yonca ve soya bitkilerinin ekildiđi 4.5 hektarlık alanda çalıřma yapıldı (Şekil 3).



Şekil 3. Arazideki soya (a) ve yonca (b) ekinleri

2.1.2. Donanım

Ekinlere ait görüntüler Parrot Bluegrass döner kanatlı mikro-İHA'ya entegreli Parrot Sequoia multispektral kamera ile elde edilmiřtir.



Şekil 4. Parrot Bluegrass mikro-İHA

İHA'nın (Şekil 4) teknik özellikleri:

GENEL:

- Ağırlık: 1.81 kg
- Boyut: 30.48 cm x 40.64 cm in x 14 cm
- Tařıma için çıkarılabilir pervaneler

WI-FI VE SİNYAL İLETİMİ:

- Aralık: Parrot Skycontroller 2 km'ye kadar
- WiFi AC-type, 2 bi-band antennas (2,4 and 5GHz)

BATARYA KAPASİTESİ:

- Batarya süresi: 25 dakika
- 6700 mAh Lipo batarya

SENSÖRLER:

- Dâhili GPS + GLONASS
- Inertial Navigation System (INS)
- Altimetre
- Ultrason
- Optik akıřlı dikey kamera

ÖN KAMERA:

- Fotoğraf: 14MP geniř açi kamera
- Video: 1080p Full HD
- Video yayını: 360p / 720p
- Dâhili video belleđi: 32GB



Şekil 5. Araca entegre edilen kamera sistemleri

Parrot Sequoia Multispektral Kamera (Şekil 5) özellikleri:

GENEL:

- Boyut: 2.3x1.6x1.1 in
- Ağırlık: 72 gr
- Fotoğraf modu: 1 fps'ye kadar
- Dâhili hafıza: 64 GB
- Inertial measurement unit & magnetometre
- Güç: 5 W (~12 W en son)

4 KÜRESEL ÖRTÜCÜLÜ TEK-BANT KAMERA:

- Çözünürlük: 1.2 Mpx, 1280x960 piksel
- HFOV: 61.9°
- VFOV: 48.5°
- DFOV: 73.7°

4 AYRI BANT:

- Yeşil: 550nm +/- 40nm
- Kırmızı: 660nm +/- 40nm
- Kırmızı Kenar: 735nm +/- 10nm
- Yakın Kızılötesi: 790nm +/- 40nm

RGB KAMERA:

- Çözünürlük: 16 MP, 4608x3456 piksel
- HFOV: 63.9°
- VFOV: 50.1°
- DFOV: 73.5°

GÜNEŞ IŞIĞI SENSÖRÜ:


- Boyutlar: 4.57x3.81x1.78 cm
- Ağırlık: 36 gr
- 4 spektral sensör (gövde ile aynı filtreler)
- GPS
- Inertial measurement unit & magnetometre
- SD Kart girişi
- Güç: 1 W

Parrot Sequoia multispektral kamera sistemi iki parçadan oluşmaktadır. İlki dört farklı spektral bant ile RGB sensöre sahip olup eşzamanlı küresel deklanşör sistemiyle görüntüleri elde eden kamera, ikincisi ise kamerayla tamamen entegreli güneş ışığı sensörüdür. Bu sensör mevcut aydınlatma koşullarını yakalayıp kaydını tutarak mutlak bir ölçüm için kamera çıktılarını otomatik olarak kalibre eder.

2.2. Yöntem

Ekinlere ait görüntüler fotogrametri yöntemiyle elde edilip işlendi. Bu çalışmada uygulanan yöntemde İHA için gereken uçuş planı, Pix4D firması tarafından sağlanan uçuş planlayıcı mobil uygulaması ile oluşturuldu. Uçuş, belirlenen çalışma alanı içinde %80 boyuna ve enine bindirme oranında, yer örnekleme aralığı (YÖA/GSD) yaklaşık 7 cm olacak şekilde gerçekleştirildi. Bunun yanında uçuşun güneş ışınlarının en yüksek yansımaya seviyesine sahip olduğu öğle saatinde yapılmasına dikkat edildi. Uçuşa başlamadan önce ortamın

güneş ışığı yansımaya değerlerinin belirlenip görüntülerin kalibre edilmesi için spektral kalibrasyon kağıdının görüntüleri multispektral kamera ile edinildi (Şekil 6).



Şekil 6. Spektral kalibrasyon kağıdının görüntüsünün İHA'ya monteli multispektral kamera ile alınması. a) yeşil b) yakın kızıl ötesi c) kırmızı d) kırmızı-kenar görüntüleri


Saat 11.30'da uçuşa başlayan İHA seyrini yaklaşık 10 dk sürdürmüş olup multispektral görüntüleri başarılı bir şekilde edildi. Bu uçuş sonucunda toplamda 1665 adet görüntü elde edilmiştir. Yeşil, kırmızı, kırmızı-kenar, yakın kızıl ötesi ve RGB bantlarının her birinden 333 tane görüntü toplanmıştır. Bu görüntülerden RGB hariç diğer banttaki görüntüler (yeşil, kırmızı, kırmızı-kenar, yakın kızıl ötesi) işlenmek üzere Pix4D yazılımına aktarıldı. Pix4D yazılımı, Structure from Motion (SfM) algoritması ile çalışmakta ve görüntüleri ışın demetleriyle blok dengeleme yaparak işlemektedir. Bu çalışmada yazılımın multispektral görüntüleri işlenmesi için tarım uygulamalarına yönelik modülü kullanıldı. Kalibrasyon kağıtlarının görüntüleri yazılıma tanıtılarak spektral kalibrasyon yapıldıktan sonra görüntüler yöneltme işlemine tabi tutulup arazi yüzeyinin 3B modelinin tahmini şekli seyrek nokta bulutu ile oluşturuldu. Akabinde yoğun nokta bulutu oluşturulup üzerinden yüzey geçirilmiştir. Sonrasında ise her bir bant için ayrı ayrı 7.81 cm yer örnekleme aralığına sahip ortofoto üretildi.

Ortofotolar ESRI ArcGIS yazılımında işlenmek üzere (.tif) biçiminde dışarı çıkarıldı (Şekil 7).



Şekil 7. Ekin arazisine ait kızıl ötesi bandındaki ortofoto

Her bir bant ArcGIS yazılımının içine aktarıldı ve sınıflandırma çalışmalarına altlık olmak üzere birleştirilerek kompozit görüntü elde edildi. Yeşil, kırmızı, kırmızı-kenar ve yakın kızıl ötesi bantları ihtiva eden kompozit görüntü ArcToolbox modülü ile üretildi (Şekil 8).



Şekil 8. 4 bandın birleştirilmesiyle oluşan kompozit false color görüntü

Çalışmamızda 1 adet kontrolsüz ve 2 adet kontrollü sınıflandırma yapılarak doğruluk analizi yapıldı. Sınıflandırma çalışmaları aşağıdaki başlıklar altında anlatılmaktadır.

- a) Kontrolsüz Sınıflandırma
 - i) ISO data cluster
- b) Kontrollü Sınıflandırma
 - i) En Yakın Benzerlik
 - ii) Destek Vektör Makinesi


2.2.1. Kontrolsüz sınıflandırma

Kontrolsüz sınıflandırma; piksellerin, kullanıcı müdahalesi olmadan otomatik olarak kümelenmesi temeline dayanmaktadır. Bu çalışmada kontrolsüz sınıflandırma yöntemlerinden ISO data cluster kullanılmıştır.

ISO Data Cluster

ISO cluster algoritması, her aday hücreyi bir kümeye atarken minimum Öklid mesafesini hesaplamak için kullanılan iteratif bir işlemdir. Süreç, her küme için bir tane olmak üzere, yazılım tarafından atanan keyfi değerlerle başlar (tarafımızdan girilen küme sayısı ile). Her hücre, bu değerlerin en yakınına atanır. İlk iterasyondan sonra kümeye ait olan hücrelerin öznelik mesafelerine bağlı olarak her küme için yeni değerler yeniden hesaplanır.

Çalışma alanında 4 adet sınıf belirlenmiş olup bunlar soya, yonca, toprak ve yabancı ot olarak ayrılmıştır. Ancak kontrolsüz sınıflandırmada eğitim bölgeleri işaretlenmediğinden programa 5 tane sınıflandırma yapması komut verilmiştir. İşlem sonucu oluşan sınıflandırma haritası aşağıdadır (Şekil 9).



Şekil 9. ISO cluster sınıflandırma

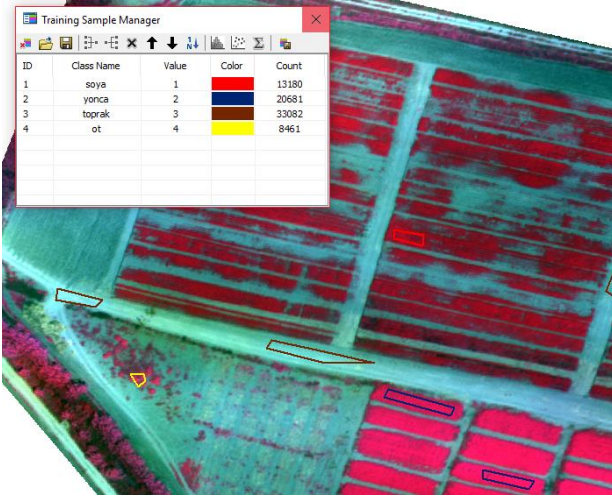
2.2.2. Kontrollü sınıflandırma

Kontrollü sınıflandırmada görüntünün hangi sınıflara ayrılacağı, ya da görüntüden hangi sınıfların elde edilmek istenildiği önceden bilinir. Bunun için görüntüden belirlenen sınıflara ait denetim alanlarının seçilmesi gerekmektedir. Bu seçim için gerektiğinde arazide yer gerçekliği yapılması zorunludur. Kontrol alanlarının seçimi sınıflandırmannın doğruluğunu etkileyen bir aşamadır.

En Yakın Benzerlik


Bu sınıflandırma algoritması her banttaki her bir sınıf için istatistiklerinin normal olarak dağıtıldığını ve belirlenmiş bir pikselin belli bir sınıfa ait olma olasılığını hesaplar. Kompozit

görüntü üzerinde niteliği bilinen alanlar algoritmaya tanıtılarak eğitildi (Şekil 10).



Şekil 10. Eğitim alanları


Bu eğitilmiş alanlara ait pikseller sayesinde diğer tüm piksellerin sınıfı tahmin edildi. Belirlenen 4 adet sınıf için eğitilen alanlar baz alınarak sınıflandırma haritası oluşturuldu (Şekil 11). ArcGIS yazılımında ArcToolbox modülü ile oluşturulan sınıflandırma haritası Şekil 10'daki gibidir.



Şekil 11. En Yakın Benzerlik sınıflandırma

Destek Vektör Makinesi

Destek Vektör Makinesi (SVM), genellikle karmaşık ve gürültülü verilerden iyi bir sınıflandırma sonucu veren istatistiksel öğrenme teorisinden türetilmiş bir denetimli sınıflandırma yöntemidir. Bu yöntemde de En Yakın Benzerlik yönteminde kullanılan eğitim alanları kullanıldı (Şekil 10). Söz konusu eğitim alanları arazi gerçeğinde niteliği bilinen ve görüntüde açıkça belirli olan kısımlardan çizildi (Şekil 12).



Şekil 12. Destek Vektör Makinesi sınıflandırma

2.3. Doğruluk Değerlendirmesi

Doğruluk değerlendirme, uzaktan algılamada, görüntü sınıflandırmasında bir piksele atanan sınıf etiketi ile gerçek değer arasındaki uygunluğun ortaya konmasıdır. Gerçek sınıf, arazide bulunan nesnelerin hava fotoğraflarından ya da mevcut harita ve planlardan doğrudan veya dolaylı olarak gözlenebilir. Gerçek sınıf arazi çalışması esnasında yapılan gözlemler yardımıyla doğrudan görüntü üzerinden belirlenmiştir.

Doğruluk değerlendirmesinde kullanılmak üzere sınıflandırılmış görüntü üzerine örneklem noktaları atılması gerekmektedir. Örneklem noktalarının adedi görüntünün toplam piksel sayısına göre hesaplandı ve en az 289 adet nokta gerektiği tespit edildi. Bu hesaplama toplamda 300 adet nokta görüntü üzerine otomatik olarak rastgele atıldı. Bu işlem ArcGIS yazılımının ArcToolbox modülü ile gerçekleştirildi. Bu modül sayesinde noktaların altlık olarak kullanılan sınıflandırma haritalarında denk geldiği piksel değeri otomatik olarak öznitelik tablosuna aktarılmıştır. Yer gerçekliği ise kompozit görüntü üzerinden öznitelik tablosuna el ile girildi. Her bir sınıf numaralandırılmış olup sırasıyla 1=soya, 2=yonca, 3=toprak ve 4=yabani ot olarak kodlandı. Örneklem noktalarının konumu aynı kalacak şekilde her bir sınıf için farklı öznitelik tablosu oluşturuldu. Öznitelik tabloları ile hata matrisleri oluşturuldu.

Maximum Likelihood sınıflandırma için oluşturulan hata matrisi Tablo 1'de olduğu gibidir.

Tablo 1. Test alanına ilişkin En Yakın Benzerlik sınıflandırma performansı; Hata Matrisi

Sınıf	Soya	Yonca	Toprak	Yabani Ot	Toplam	Kullanıcı Doğruluğu	Kappa
Soya	84	2	0	11	97	0.87	
Yonca	0	14	0	0	14	1.00	
Toprak	1	0	121	4	126	0.96	
Yabani Ot	18	0	3	42	63	0.67	
Toplam	103	16	124	57	300	0.00	
Üretici Doğruluğu	0.82	0.88	0.98	0.74	0	0.87	
Kappa							0.81

Soya, yonca, toprak ve yabancı ot sınıflarının üretici doğruluğu ve kullanıcı doğruluğunun karşılaştırması Tablo 1’de verilmiş olup ortalama doğruluk %87 olarak hesaplanmıştır. Kappa değeri ise %81 olarak hesaplanmış olup;

- 1.00 tam uyum olduğunu,
- 0.75 ve fazlası sınıflandırma performansının çok iyi olduğunu,
- 0.40’ in aşağısı ise performansın yetersiz olduğunu,
- 0.00 ise sınıflandırılmış ve referans verileri arasında uyumun olmadığını gösterir.

Bu durumda Maximum Likelihood sınıflandırma işleminin performansının çok iyi olduğu söylenebilir.

Support Vector Machine sınıflandırma işlemi için oluşturulan hata matrisi Tablo 2’de olduğu gibidir.

Tablo 2. Test alanına ilişkin Destek Vektör Makinesi sınıflandırma performansı; Hata Matrisi

Sınıf	Soya	Yonca	Toprak	Yabancı Ot	Toplam	Kullanıcı Doğruluğu	Kappa
Soya	77	0	0	8	85	0.91	0
Yonca	1	12	0	0	13	0.92	0
Toprak	2	0	123	18	143	0.86	0
Yabancı Ot	23	4	1	31	59	0.53	0
Toplam	103	16	124	57	300	0	0
Üretici Doğruluğu	0.75	0.75	0.99	0.54	0	0.81	0
Kappa	0	0	0	0	0	0	0.71

Support Vector Machine sınıflandırma performansına ilişkin hata matrisindeki toplam doğruluk %81 olup kappa değeri %71 olarak hesaplanmıştır. Buna göre sınıflandırmanın iyi bir performans sergilediği söylenebilir.

3. SONUÇ

Bu çalışmada yonca ve soya bitkilerinin ekildiği araziden multispektral görüntüler elde edildi. Görüntüler çeşitli yazılımlarda işlenerek üç farklı algoritma ile sınıflandırıldı. Bu sınıflandırma çalışmalarının doğruluğu incelendi. Yapılan sınıflandırmalarda aynı eğitim bölgeleri ve örneklem noktaları kullanıldı. Sınıflandırmalar sonucu Maximum Likelihood için doğruluk %87, Support Vector Machine için ise %81 olarak hesaplandı. Bu istatistiki bilgilere göre çalışmamız için en iyi sonucu veren sınıflandırma algoritmasının Maximum Likelihood olduğu ortaya çıkmıştır.

TEŞEKKÜR

Bu çalışmanın tamamlanması için yardımlarından dolayı Paksoy Teknik A.Ş.’ye ve Alata Bahçe Kültürleri Araştırma Enstitüsüne teşekkür ederiz.

KAYNAKÇA

Adam, E. ve Mutanga, O. (2009). Spectral discrimination of papyrus vegetation (*Cyperus papyrus* L.) in swamp wetlands using field spectrometry, *ISPRS Journal of Photogrammetry and Remote Sensing*, 64 (6), 612-620.

Ahmad, A., Tahar, K. N., Udin, W. S., Hashim, K. A., Darwin, N., Hafis, M., Room, M., Hamid, N. F. A., Azhar, N. A. M. ve Azmi, S. M. (2013). Digital aerial imagery of unmanned aerial vehicle for various applications, *Control System, Computing and Engineering (ICCSCE)*, 2013 IEEE International Conference on, 535-540.

Anchang, J. Y., Ananga, E. O. ve Pu, R. (2016). An efficient unsupervised index based approach for mapping urban vegetation from IKONOS imagery, *International Journal of Applied Earth Observation and Geoinformation*, 50, 211-220.

Çömert, R., Matcı, D., Avdan, U. (2019). Object based burned area mapping with random forest algorithm, *International Journal of Engineering and Geosciences*, 4 (2), 78-87. DOI: 10.26833/ijeg.455595

Dudley, K. L., Dennison, P. E., Roth, K. L., Roberts, D. A. ve Coates, A. R. (2015). A multi-temporal spectral library approach for mapping vegetation species across spatial and temporal phenological gradients, *Remote Sensing of Environment*, 167, 121-134.

Fassnacht, F. E., Latifi, H., Stereńczak, K., Modzelewska, A., Lefsky, M., Waser, L. T., Straub, C. ve Ghosh, A. (2016). Review of studies on tree species classification from remotely sensed data, *Remote Sensing of Environment*, 186, 64-87.

Ishida, T., Kurihara, J., Viray, F. A., Namuco, S. B., Paringit, E. C., Perez, G. J., Takahashi, Y. ve Marciano, J. J. (2018). A novel approach for vegetation classification using UAV-based hyperspectral imaging, *Computers and Electronics in Agriculture*, 144, 80-85.

- Jia, K., Wu, B., Tian, Y., Li, Q. ve Du, X. (2011). Spectral discrimination of opium poppy using field spectrometry, *IEEE Transactions on Geoscience and Remote Sensing*, 49 (9), 3414-3422.
- Kuşak, L , Küçükali, U . (2019). Outlier detection of land surface temperature: Küçükçekmece region, *International Journal of Engineering and Geosciences* , 4 (1) , 1-7 . DOI: 10.26833/ijeg.404426
- Martínez-Verduzco, G. C., Galeana-Pizaña, J. M. ve Cruz-Bello, G. M. (2012). Coupling Community Mapping and supervised classification to discriminate Shade coffee from Natural vegetation, *Applied Geography*, 34, 1-9.
- Orhan, O., Ekercin, S., & Dadaser-Celik, F. (2014). Use of landsat land surface temperature and vegetation indices for monitoring drought in the Salt Lake Basin Area, Turkey. *The Scientific World Journal*, 2014.
- Orhan, O., & Yakar, M. (2016). Investigating Land Surface Temperature Changes Using Landsat Data in Konya, Turkey. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 41, B8.
- Orhan, O , Dadaser-Celik, F , Ekercin, S . (2019). Investigating land surface temperature changes using Landsat-5 data and real-time infrared thermometer measurements at Konya closed basin in Turkey, *International Journal of Engineering and Geosciences* , 4 (1) , 16-27 . DOI: 10.26833/ijeg.417151
- Peña, J., Torres-Sánchez, J., Serrano-Pérez, A., de Castro, A. ve López-Granados, F. (2015). Quantifying Efficacy and Limits of Unmanned Aerial Vehicle (UAV) Technology for Weed Seedling Detection as Affected by Sensor Resolution, *Sensors*, 15 (3), 5609.
- Salamí, E., Barrado, C. ve Pastor, E. (2014). UAV Flight Experiments Applied to the Remote Sensing of Vegetated Areas, *Remote Sensing*, 6 (11), 11051.
- Somers, B. ve Asner, G. P. (2014). Tree species mapping in tropical forests using multi-temporal imaging spectroscopy: Wavelength adaptive spectral mixture analysis, *International Journal of Applied Earth Observation and Geoinformation*, 31, 57-66.