

Pankromatik Bandın Piksel Tabanlı Sınıflandırmaya Etkisi The Effect of Panchromatic Band on Pixel-Based Classification

Ekrem Saraloğlu^{1*} 

¹Artvin Çoruh Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü 08100 Seyitler, Artvin/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Ekrem Saraloğlu
ekremsaralioglu@artvin.edu.tr

doi: 10.48123/rsgis.852055

Yayın süreci

Geliş tarihi: 01.01.2021
Kabul tarihi: 21.02.2021
Basım tarihi: 13.03.2021

Özet

Bu çalışmada, pankromatik bandın çok bantlı uydu görüntülerinin piksel tabanlı sınıflandırma doğruluğuna etkisi deneysel olarak araştırılmıştır. Çok yüksek uzamsal çözünürlüklü multispektral uydu görüntüleri multispektral bantlar yanında daha yüksek uzamsal çözünürlükte bir pankromatik bant içermektedir. Bu nedenle sınıflandırma aşamasında çeşitli seçenekler oluşmaktadır. Örneğin, sınıflandırma yapıldığında bu bant kullanılmalı mı? Kullanılacaksa nasıl kullanılmalı? Sınıflandırma doğrulukları arasında ne kadar fark olur? Pankromatik bandın sınıflandırma sonuçlarına etkisini incelemek amacıyla 4 adet senaryo oluşturulmuştur. İlk senaryoda pankromatik bant görüntü kaynaştırma yapılarak sınıflandırmada kullanılmıştır. İkinci senaryoda sadece multispektral bantlar üzerinden sınıflandırma yapılmıştır. Üçüncü senaryoda, multispektral bantların boyutu en yakın komşuluk algoritması kullanılarak pankromatik bant boyutuna getirilmiştir. Daha sonra tüm bantların arkasına pankromatik bant eklenerek sınıflandırma yapılmıştır. Son senaryoda ise sadece pankromatik bant sınıflandırılmıştır. En yüksek sınıflandırma doğruluğu pan-keskinleştirme yapılan görüntülerde elde edilmiştir. WorldView-2 görüntüsünün kendi pankromatik bandı ile kaynaştırılması sonucu elde edilen görüntünün destek vektör makineleri ve rastgele orman ile sınıflandırma sonuçları sırasıyla %78 ve %75 olarak bulunmuştur. IKONOS görüntüsü için pan-keskinleştirme yapılmış görüntüde sınıflandırma doğrulukları ise aynı sırada %70 ve %66 olarak bulunmuştur.

Anahtar kelimeler: Multispektral uydu görüntüleri, Görüntü sınıflandırma, Pan-keskinleştirme

Abstract

In this study, the effect of panchromatic band on pixel-based classification accuracy of multispectral satellite images was investigated experimentally. Very high spatial resolution multispectral satellite images contain not only multispectral bands but also a higher resolution panchromatic band, which offers a couple of options in the classification phase. For example, should this band be used within classification? If so, how should it be used? What is the difference in the classification accuracies? In order to examine the effect of the panchromatic band on classification results 4 scenarios were created. In the first scenario, panchromatic band was used in classification by pansharpening. In the second scenario, classification was conducted using only the multispectral bands. In the third scenario, the size of the multispectral bands was brought to that of the panchromatic band using the nearest neighborhood algorithm. Then, the classification was made by combining the panchromatic band with all the multispectral bands. In the last scenario, only the panchromatic band was classified. The highest classification accuracy was obtained with pansharpened images. The support vector machines and random forest classification accuracies of the image obtained by pansharpening the WorldView-2 image with its own panchromatic band were found to be 78% and 75%, respectively. The IKONOS pansharpened image resulted in classification accuracies of 70% and 66% in the same order.

Keywords: Multispectral satellite images, Image classification, Pan-sharpening


1. Giriş

Uzaktan algılanmış uydu görüntüleri, Dünya yüzeyine ait eşsiz bilgiler sağlamaktadır. Bu veriler uygun maliyet ve coğrafi kapsamı nedeniyle arazi kullanımı / arazi örtüsü haritalaması için en önemli veri kaynaklarından biri olarak kabul edilmektedir (Zhang vd., 2016). Uzaktan algılanmış görüntülerin sınıflandırılması, bu görüntüleri kullanılabilir ürünlere dönüştüren bir süreçtir. Geleneksel uzaktan algılama (UA) veri sınıflandırma yöntemleri; maksimum benzerlik sınıflandırıcısı (Abou EL-Magd, 2003), uzaklık ölçüsü (Du ve Chang, 2001) ve kümeleme (Kal-Yi, 2002) gibi yöntemleri içermektedir. Son yirmi yılda, K-en yakın komşuluk (k-NN) (Samaniago vd., 2008), rastgele orman (RO) (Breiman, 2001), sinir ağları (Civco, 1993) ve destek vektör makineleri (DVM) (Melgani and Bruzzone, 2004) gibi daha ileri yöntemler arazi örtüsü sınıflandırmada yoğun olarak kullanılmıştır (Carranza-García vd., 2019). Khatami vd. tarafından uydu görüntülerinin sınıflandırılması üzerine yapılan kapsamlı literatür araştırmasında DVM, K-NN ve RO'nun genellikle diğer geleneksel denetimli sınıflandırıcılardan daha iyi performans sağladığı gösterilmiştir.

Uzaktan algılama teknolojisindeki hızlı ilerlemeler ve görüntüleme maliyetlerinin azalması sayesinde, Dünya'nın birçok yerine ait uydu görüntüsü kolayca elde edilmektedir. Uydulardan veya uçaklardan elde edilen çeşitli uzamsal, spektral, radyometrik ve zamansal çözünürlüğe sahip bu veriler birbirlerinden farklılık göstermektedir. Modern uydu sensör teknolojisi sayesinde uzaydan elde edilen görüntüler uzamsal çözünürlük bakımından hava fotoğraflarıyla rekabet edebilmektedir. IKONOS, QuickBird, GeoEye-1 ve WorldView-2 (WV-2) gibi uydu sensörleri, yeryüzünün incelenmesinde gereken ince ayrıntıları yakalayabilen çok yüksek uzamsal çözünürlüklü MS görüntülere örnek oluşturmaktadır. Çok yüksek çözünürlüklü multispektral (MS) görüntüler sayesinde bina, yol, ağaç gibi ayrıntılı özellikler sınıflandırma ile tespit edilebilmektedir. Bu görüntüler genellikle MS bantların yanında daha yüksek uzamsal çözünürlüğe sahip bir pankromatik (PAN) bant da bulundurmaktadır. PAN bandın piksel tabanlı sınıflandırmaya etkisi bu çalışmada incelenmiştir. Pan-keskinleştirme işlemi ile PAN ve MS bantlar birlikte kullanılabilir. Literatürde çok çeşitli pan-keskinleştirme yöntemleri önerilmiştir (Yılmaz, 2020; Wady vd., 2020; Yıldırım ve Güngör, 2012). İyi uzamsal çözünürlük elde etmek genellikle spektral tutarlılığı tehlikeye atar ve bunun tersi de geçerli olmaktadır. Spektral tutarlılık, spektral bozulmadan dolayı önemli bir özelliktir. Keskinleştirilmiş verilerin sınıflandırılmasını ele alan az sayıda makale vardır. Bununla birlikte pan-keskinleştirme görüntüyü görsel olarak iyileştirmek için sıklıkla kullanılmaktadır. Pan-keskinleştirmenin dışında PAN bandın sınıflandırmaya etkisini gözlemleyebilmek amacıyla, PAN bantlar IKONOS ve WV-2 MS batlarının arkasına eklenerek oluşturulan görüntülerde sınıflandırma yapılmıştır. Son olarak sadece spektral bantlarda ve sadece PAN batlarda sınıflandırma yapılmıştır. Yapılan çalışmada iki görüntü içinde en yüksek sınıflandırma doğruluklarının pan-keskinleştirilmiş görüntülerde olduğu görülmüştür.

2. Çalışma Bölgesi ve Veriler

Çalışma kapsamında WV-2 ve IKONOS görüntüleri kullanılmıştır. IKONOS görüntüsü kentsel bir alana ait çekilmiş bir görüntüyü oluştururken WV-2 görüntüsü Trabzon ili Sürmene ilçesinde bir köye ait görüntüdür. Şekil 1'de çalışma bölgelerine ait IKONOS ve WV-2 görüntüleri gösterilmektedir.



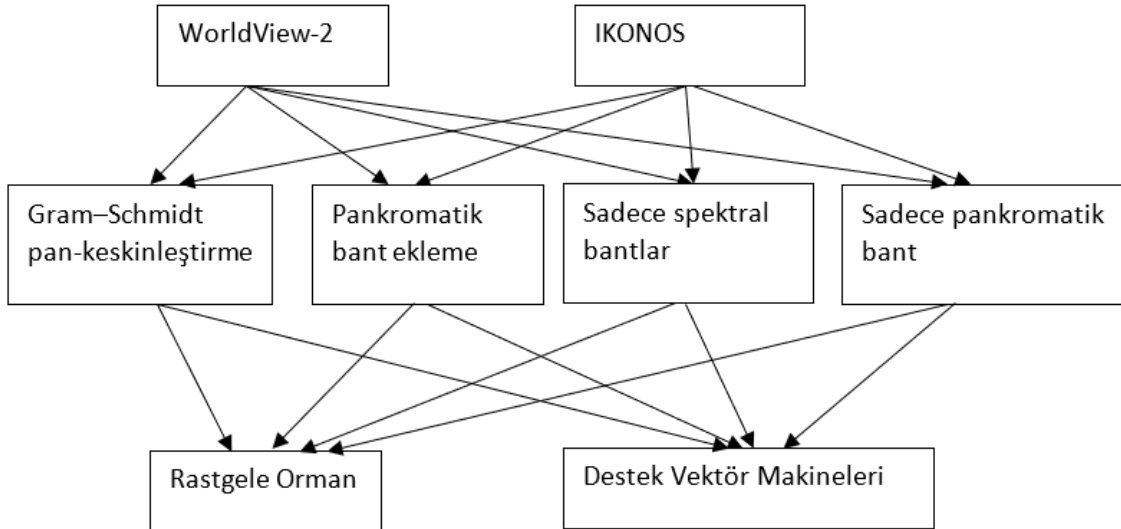
Şekil 1. Çalışma bölgesi uydu görüntüleri: (a) IKONOS görüntüsü, (b) VW-2 görüntüsü

IKONOS görüntüsü 450-900 nm spektral aralığı kapsayan her biri 4 m uzamsal çözünürlükte 4 MS bant ve 1 m uzamsal çözünürlükte PAN bant içermektedir. WV-2 görüntüsü ise bir PAN bant (0,5 m uzamsal çözünürlük) ve 400-1050 nm spektral aralığı kapsayan her biri 2 m uzamsal çözünürlüğe sahip 8 MS bant içermektedir. Spektral aralığı 400-1050 nm arasındaki bu 8 banttan 4'ü standart bantları (kırmızı, yeşil, mavi ve yakın kızılötesi-1(NIR1)) ve geri kalan diğer 4'ü kıyı (coastal), sarı, kırmızı kenar (Red Edge) ve yakın kızılötesi-2 (NIR2)) ek bantları oluşmaktadır (Saraliođlu ve Gungor, 2020). MS görüntüler, sahip oldukları ek bantlar sayesinde insan görüşünün ötesinde önemli özelliklerin çıkarılmasını sağlayabilmektedir. Tablo 1'de IKONOS ve WV-2 görüntülerinin bant özellikleri gösterilmektedir.

Tablo 1. IKONOS ve WorldView-2 görüntü özellikleri

Sensör	Bantlar	Dalga boyu (nm)	Uzamsal Çözünürlük (m)
IKONOS	Mavi	455-516	4
	Yeşil	506-595	4
	Kırmızı	632-698	4
	Yakın kızıl ötesi	757-853	4
	PAN	450-900	1
WorldView-2	Kıyı Mavisi	396-458	2
	Mavi	442-515	2
	Yeşil	506-586	2
	Sarı	584-632	2
	Kırmızı	624-694	2
	Kırmızı Kenar	699-749	2
	Yakın kızıl ötesi-1	765-901	2
	Yakın kızıl ötesi-2	856-1043	2
	PAN	450-800	0.5

Çalışma kapsamında yapılan işlemler Şekil 2'de gösterilmektedir.



Şekil 2. İş-akış şeması

Şekil 2' de görüldüğü gibi WV-2 ve IKONOS görüntüleri üzerinde sadece MS bantlarda, MS ve PAN bandın kaynaştırılması ile oluşturulan görüntülerde, MS'ye PAN band eklenerek oluşturulan görüntülerde ve sadece PAN bantların sınıflandırılması yapılmıştır. Sınıflandırma çalışmaları DVM ve RO algoritmaları ile gerçekleştirilmiştir.

3. Pan-keskinleştirme

Pan-keskinleştirme ile PAN bantın yüksek uzamsal çözünürlüğü ile MS görüntülerin yüksek spektral çözünürlüğünü birleştirerek yüksek uzamsal çözünürlüklü keskinleştirilmiş MS görüntü oluşturulmaktadır. Bu çalışmada WV-2 ve IKONOS görüntülerinde Gram-Schmidt (GS) yöntemi kullanılarak pan-keskinleştirme yapılmıştır. GS yönteminde, daha düşük uzamsal çözünürlüklü spektral bantlardan bir PAN bant simüle edilir. Genel olarak bu işlem multispektral bantların ağırlıklı ortalaması alınarak elde edilmektedir. Bir sonraki adımda simüle edilen PAN bant MS görüntünün ilk bantı olarak kullanılır. Oluşturulan yeni görüntüye GS dönüşümü uygulanır. Daha sonra yüksek çözünürlüklü PAN bant ile GS dönüşümü sonucu elde edilen görüntünün ilk bantı değiştirilir. Son olarak elde edilen görüntüye ters GS dönüşümü uygulanarak pan-keskinleştirilmiş görüntü elde edilir (Laben ve Brower, 2000). Bu yöntemin iki önemli avantajı olmaktadır. Bu yöntemin en önemli avantajlarından biri tek seferde işlenebilecek bant sayısında bir sınır olmamasıdır. Diğer bir avantajı da orijinal MS verilerinin spektral özellikleri kaynaşmış görüntüde korunmaktadır (Li vd., 2004). Bu şekilde WV-2 görüntüsünün MS ve PAN bantları kaynaştırılarak 0,5 m uzamsal çözünürlükte kaynaşmış renkli görüntü elde edilmiştir. Aynı şekilde 1 m uzamsal çözünürlükte kaynaştırılmış IKONOS görüntüsü elde edilmiştir. Şekil 3'de IKONOS ve WV-2 görüntülerine ait küçük bir alanda kaynaştırma sonrası oluşturulan görüntüler gösterilmektedir.




Şekil 3. (a) İKONOS PAN bant; (b) İKONOS doğru renk gösterimde MS bantları; (c) İKONOS GS ile kaynaştırılmış görüntü (d) WV-2 PAN bant; (e) WV-2 doğru renk gösterimde MS bantları; (f) WV-2 GS ile kaynaştırılmış görüntü

4. Sınıflandırma ve Doğruluk Değerlendirme

Tüm sınıflandırma senaryoları, RO ve DVM ile gerçekleştirilmiştir. RO her ağacın giriş vektöründen bağımsız olarak örneklenen rastgele bir vektör kullanılarak üretildiği ve her giriş örneğinde en uygun sınıf için bir birim oyu verdiği karar ağacı tabanlı sınıflandırma yöntemidir (Breiman, 2001). Gürültüye veya aşırı eğitime karşı duyarsızlık ve dengesiz veri kümelerini işleyebilme gibi önemli özelliklere sahiptir (Gomariz-Castillo vd., 2017). Ayrıca az parametre, az manuel müdahale gerektirirken yüksek sınıflandırma doğruluğu sağlamaktadır (Zheng vd., 2017). Yüksek boyutlu verilerden yönetilebilir ve hızlı bir şekilde sınıflandırma sonuçları elde edilmektedir.

RO'nun, sınıflandırma doğruluđu, hesaplama karmaşıklığı ve parametre seçimi açısından k-NN ve yapay sinir ađları (YSA) gibi diđer parametrik olmayan sınıflandırıcılarla karşılaştırıldığında etkili olduđu gösterilmektedir. RO'da en uygun sınıflandırma sonuçlarını elde etmek için, iki anahtar parametrenin önceden tanımlanması gerekmektedir. Bunlar bir ađacı oluşturmak için her düđümde kullanılan özelliklerin sayısı ve oluşturulacak ađaç sayısıdır (Pedergrana, 2012). RO'daki en uygun ađaç sayısını belirlemek için sırasıyla 20, 50, 100, 150 parametreleri denenmiştir. Çalışma bölgesi için sınıflandırma performansının 100'ün üzerinde olduđuunda artık ađaç sayısına duyarlı olmadığı görülmüştür. Sonuç olarak, ađaç sayısı 100 ve özellik sayısı da sınıflandırma doğruluđu ve hesaplama etkinliği dikkate alınarak ađaç sayısına eşit olarak belirlenmiştir.

Bu çalışmada kullanılan diđer bir sınıflandırma yöntemi olan DVM uzaktan algılama alanında arazi örtüsü tespiti çalışmalarında başarıyla kullanılmış bir yöntemdir. RO, k-NN, YSA gibi güçlü sınıflandırma yöntemleri ile karşılaştırıldığında daha iyi sınıflandırma sonuçları verdiđini gösteren çalışmalar literatürde mevcuttur (Thanh ve Kappas, 2018; Khatami vd., 2016). Bu sınıflandırma yöntemi, veriyi daha yüksek bir boyuta dönüştürerek oluşturacağı bir hiperdüzlem ile iki sınıfı birbirinden ayırma prensibine dayanmaktadır. Yüksek boyuta dönüşüm aşamasında deđişik özelliklere sahip fonksiyonlar kullanılmaktadır. Bu fonksiyonlar kernel fonksiyonları olarak adlandırılmaktadır. Bu çalışmada, çekirdek işlevi olarak Radyal Temel Fonksiyonu (Radial Basis Function (RBF) kullanılmıştır. RBF çekirdeđi genellikle az sayıda parametre tanımlamayı gerektirdiđinden ve genel olarak iyi sonuçlar verdiđi bilinen bir yöntem olduđundan seçilmiştir (Huang vd., 2018; Petropoulos vd., 2012). Şekil 4'de bu çalışma kapsamında kullanılan eğitim pikselleri ve Tablo 2' de de bu sınıflara ait piksel sayıları gösterilmektedir.



Şekil 4. a) WV-2 eğitim pikselleri, b) IKONOS eğitim pikselleri

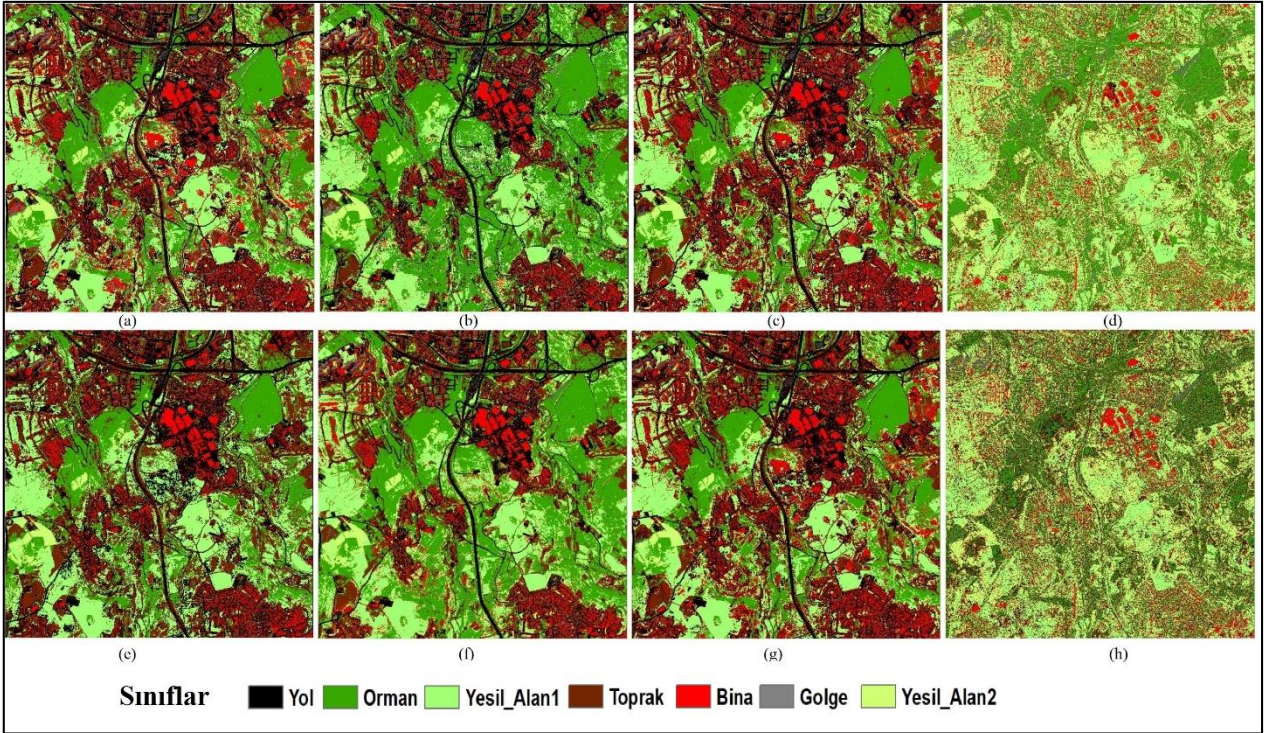
Tablo 2. IKONOS ve WV-2 eğitim sınıfları ve piksel sayıları

IKONOS			WorldView-2		
Sınıf	Renk	Toplam piksel sayısı	Sınıf	Renk	Toplam piksel Sayısı
Bina	Red	24775	Bina	Red	24602
Gölge	Grey	2657	Gölge	Grey	5415
Orman	Green	35156	Orman	Green	11059
Toprak	Brown	11628	Toprak	Brown	9333
Yesil_Alan_1	Light Green	21821	Yesil_Alan	Light Green	47432
Yesil_Alan_2	Yellow Green	10198	Deniz	Blue	382149
Yol	Black	62513	Yol	Black	50774

Sınıflandırma sonrası doğruluk değerlendirme kısmı, yaklaşık aynı boyutlu görüntüler üzerine rastgele atılan 500 adet referans nokta ile sağlanmıştır. Referans noktaların sınıf değerlerinin tespit edilmesi için PAN görüntüler, kaynaştırılmış görüntüler ve Google Earth görüntülerinden faydalanılmıştır. Sınıflandırma aşamasında kullanılan sınıflar ve bu sınıflara ait piksel sayıları Tablo 2’de gösterilmektedir.

5. Bulgular ve İrdeleme


IKONOS görüntüleri üzerinden yapılan tüm sınıflandırma çalışmaları Şekil 5’de gösterilmektedir. Şekilde görüldüğü gibi en kötü sınıflandırma sonuçları sadece PAN bandın sınıflandırılmasında ortaya çıkmıştır. Hem DVM hem de RO yöntemlerinde sınıfların birbirine çok fazla karışmış olması nedeniyle ortaya çıkan çok düşük sınıflandırma doğruluğundaki görüntülerin herhangi bir tematik haritalama çalışmasında kullanılmayacak kadar kötü olduğu görülmektedir. Piksel tabanlı sınıflandırmada sadece PAN bandın kullanıldığı durumda iyi sınıflandırma yöntemleri kullanılmasına rağmen çok düşük sınıflandırma doğrulukları üretebileceği görülmektedir. Tablo 3’de gösterilen sınıflandırma doğrulukları incelendiğinde IKONOS görüntüsü için en iyi sonuçlara pan-keskinleştirilmiş görüntülerde ulaşıldığı görülmüştür. Pan-keskinleştirilmiş görüntünün DVM ile olan sınıflandırma doğruluğunun, kendine en yakın olan MS’ye PAN band eklenerek oluşturulan görüntünün sınıflandırma sonucundan %6’ daha başarılı olduğu görülmektedir. Bunun dışında MS’ye PAN eklenmesi sonucu yapılan sınıflandırma sonucu sadece MS sınıflandırma sonucundan daha iyi olsa bile bu sonuç %2 gibi çok küçük bir değer olduğu görülmüştür. RO ile sınıflandırma sonuçları incelendiğinde sonuçların üç sınıflandırma için birbirlerine çok yakın olduğu görülmektedir.



Şekil 5. IKONOS sınıflandırılmış görüntüler: (a) DVM ile MS sınıflandırma; (b) DVM ile pan-keskinleştirilmiş sınıflandırma; (c) DVM ile PAN bant eklenmiş görüntü sınıflandırma; (d) DVM ile PAN bant sınıflandırma; (e) RO ile MS sınıflandırma; (f) RO pan-keskinleştirilmiş sınıflandırma; (g) RO ile PAN bant eklenmiş görüntü sınıflandırma; (h) RO ile PAN bant sınıflandırma

WorldView-2 görüntüleri üzerinden yapılan tüm sınıflandırma çalışmaları Şekil 6’ da gösterilmektedir. Görüldüğü gibi en kötü sınıflandırma sonuçlarının IKONOS görüntüsünde olduğu gibi sadece PAN bandın sınıflandırılmasında ortaya çıktığı görülmüştür. Tablo 3’de gösterilen DVM ile sınıflandırma doğrulukları incelendiğinde WV-2 görüntüsü için en iyi sonuçlara yine %78 genel doğruluk ile pan-keskinleştirilmiş görüntülerde ulaşıldığı görülmektedir. Daha sonra %73 ile MS’ye PAN bandın eklenerek oluşturulan görüntüde ve %69 ile sadece MS görüntülerinin sınıflandırılması gelmektedir. Pan-keskinleştirilmiş görüntünün DVM ile olan sınıflandırma doğruluğuna en yakın olan pan bant ekleme ile yapılan sınıflandırma olmaktadır. Bu sınıflandırma sonucunun pan-kenskinleştirilmiş görüntünün DVM ile sınıflandırılmasından %5’ daha başarılı sonuç verdiği görülmektedir.

Bunun dışında MS görüntülerinin arkasına PAN band eklenerek oluşturulan görüntünün sınıflandırma sonucunun sadece MS sınıflandırma sonucundan biraz daha iyi olduğu görülmektedir. Bu sonuç %2 gibi çok küçük bir değer olmaktadır. RO ile sınıflandırma sonuçları incelendiğinde ise yine üç sınıflandırma sonuçlarının birbirlerine çok yakın olduğu görülmektedir.



Şekil 6. WV-2 sınıflandırılmış görüntüler: (a) DVM ile MS sınıflandırma; (b) DVM ile pan-keskinleştirilmiş sınıflandırma; (c) DVM ile PAN bant eklenmiş görüntü sınıflandırma; (d) DVM ile PAN bant sınıflandırma; (e) RO ile MS sınıflandırma; (f) RO ile pan-keskinleştirilmiş sınıflandırma; (g) RO ile PAN bant eklenmiş görüntü sınıflandırma; (h) RO ile PAN bant sınıflandırma

Tablo 3. Sınıflandırma doğrulukları

	WV-2		IKONOS	
		Genel doğruluk		Genel doğruluk
DVM ile sınıflandırma	Kaynaştırılmış	0.78	Kaynaştırılmış	0.70
	MS	0.69	MS	0.62
	PAN eklenmiş	0.73	PAN eklenmiş	0.64
	PAN	0.57	PAN	0.34
RO ile sınıflandırma	Kaynaştırılmış	0.75	Kaynaştırılmış	0.66
	MS	0.72	MS	0.65
	PAN eklenmiş	0.75	PAN eklenmiş	0.63
	PAN	0.46	PAN	0.33

Genel anlamda DVM ile yapılan sınıflandırma doğruluklarının RO'ya göre biraz daha iyi olduğu fakat sadece MS görüntülerin sınıflandırılmasında RO'un iki görüntüde de DVM'den biraz daha iyi olduğu görülmektedir. Ayrıca WV-2 görüntüsünde IKONOS'a göre daha iyi sınıflandırma sonuçlarına ulaşıldığı görülmektedir.

Fakat çalışma bölgesinin iki görüntü için aynı olmaması nedeniyle karşılaştırma yapmak doğru olmasa da yapılan çalışmada piksel tabanlı sınıflandırma kullanıldığı için ve WV-2 görüntüsünde de daha fazla MS bandının olması nedeniyle de bu etki olabilir. VW-2 görüntüsünün IKONOS'a göre spektral çözünürlüğünün daha iyi olması sınıflandırma açısından bir avantajdır.

Bunun dışında sınıflandırma çalışmalarında en yüksek doğrulukların iki farklı görüntü ve sınıflandırma yöntemi içinde GS ile kaynaştırılmış görüntülerde olduğu görülmüştür. Kaynaştırılmış görüntüler genel olarak sınıflandırma performansını geliştirmek amacıyla kullanılmamasına rağmen GS gibi çok bantlı görüntünün spektral yapısına fazla zarar vermeden uzamsal detayı arttırmada başarılı olan bir görüntü kaynaştırma yönteminin sınıflandırma doğruluğunu arttırabileceği görülmektedir.

6. Sonuç

Bu çalışmada MS bantların yanında daha yüksek uzamsal çözünürlüğe sahip PAN bandının sınıflandırmaya etkisi incelenmiştir. Çalışma bölgesinde kullanılan iki farklı yüksek çözünürlüklü uydu görüntüsünde de en iyi sınıflandırma sonuçlarının GS yöntemi ile kaynaştırılmış görüntülerden elde edildiği görülmüştür. Kaynaştırılmış WV-2'de sınıflandırma sonrası genel doğruluk değerleri DVM ile %78 olurken RO'da %75 olarak bulunmuştur. Kaynaştırılmış IKONOS görüntüsünde ise bu sonuçlar yine aynı sıralamada %70 ve %66 olarak bulunmuştur. Bu durum, GS görüntü kaynaştırma yönteminin uygulandığı görüntünün MS bantlarından daha yüksek uzamsal çözünürlüğe sahip renkli bir görüntü oluşturma avantajının yanında bu görüntünün sınıflandırma sonuçlarında da başarılı olabileceğini göstermektedir. Yapılan çalışma bölgesinde genel anlamda DVM ile yapılan sınıflandırma doğruluklarının RO'ya göre biraz daha iyi sonuç üretebildiği görülmüştür. Tematik ürün olarak kullanılamayacak kadar düşük sonuçlar ise sadece PAN bantlarının sınıflandırılmasında elde edilmiştir. WV-2 ve IKONOS görüntüleri üzerinde yapılan tüm sınıflandırma çalışmalarda VW-2 görüntüsü üzerinde daha yüksek sınıflandırma doğruluklarına ulaşıldığı görülmüştür.

Teşekkür

Çalışma kapsamında kullanılan uydu görüntülerinin sağlanmasında Karadeniz Teknik Üniversitesi, Harita Mühendisliği Bölümüne ve Avrupa Uzay Ajansına katkılarından dolayı teşekkürü borç bilirim.

Kaynaklar

- Abou EL-Magd, I., & Tanton, T. W. (2003). Improvements in land use mapping for irrigated agriculture from satellite sensor data using a multi-stage maximum likelihood classification. *International Journal of Remote Sensing*, 24(21), 4197-4206.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- Carranza-García, M., García-Gutiérrez, J., & Riquelme, J. C. (2019). A framework for evaluating land use and land cover classification using convolutional neural networks. *Remote Sensing*, 11(3), 274.
- Civco, D. L. (1993). Artificial neural networks for land-cover classification and mapping. *International journal of geographical information science*, 7(2), 173-186.
- Du, Q., & Chang, C. I. (2001). A linear constrained distance-based discriminant analysis for hyperspectral image classification. *Pattern Recognition*, 34(2), 361-373.
- Gomariz-Castillo, F., Alonso-Sarría, F., & Cánovas-García, F. (2017). Improving classification accuracy of multi-temporal Landsat Images by Assessing the Use of different algorithms, textural and ancillary information for a mediterranean semiarid area from 2000 to 2015. *Remote Sensing*, 9(10), 1058.
- Huang, X., Wang, C., & Li, Z. (2018). A near real-time flood-mapping approach by integrating social media and post-event satellite imagery. *Annals of GIS*, 24(2), 113-123.
- Khatami, R., Mountrakis, G., & Stehman, S.V. (2016). A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: General guidelines for practitioners and future research. *Remote Sensing of Environment*, 177, 89-100.
- Laben, C.A., & Brower, B.V., (2000). Process for enhancing the spatial resolution of multispectral imagery using pan-sharpening, United States Eastman Kodak Company (Rochester, NY). US Patent 6011875.
- Li, C., Liu, L., Wang, J., Zhao, C., & Wang, R. (2004, September). Comparison of two methods of the fusion of remote sensing images with fidelity of spectral information. In *IGARSS 2004. 2004 IEEE International Geoscience and Remote Sensing Symposium* (Vol. 4, pp. 2561-2564). IEEE.
- Melgani, F., & Bruzzone, L. (2004). Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on geoscience and remote sensing*, 42(8), 1778-1790.

- Pedernana, M., Marpu, P. R., Dalla Mura, M., Benediktsson, J. A., & Bruzzone, L. (2012). Classification of remote sensing optical and LiDAR data using extended attribute profiles. *IEEE Journal of Selected Topics in Signal Processing*, 6(7), 856-865.
- Petropoulos, G.P., Kalaitzidis, C., & Vadrevu, K. P. (2012). Support vector machines and object-based classification for obtaining land-use/cover cartography from Hyperion hyperspectral imagery. *Computers & Geosciences*, 41, 99-107
- Samaniego, L., Bárdossy, A., & Schulz, K. (2008). Supervised classification of remotely sensed imagery using a modified k-NN technique. *IEEE Transactions on Geoscience and Remote Sensing*, 46(7), 2112-2125.
- Saraliođlu, E., & Gungor, O. (2020). Semantic segmentation of land cover from high resolution multispectral satellite images by spectral-spatial convolutional neural network. *Geocarto International*, 1-21.
- Thanh Noi, P., & Kappas, M. (2018). Comparison of random forest, k-nearest neighbor, and support vector machine classifiers for land cover classification using Sentinel-2 imagery. *Sensors*, 18(1), 18.
- Wady, S.M.A., Bentoutou, Y., Bengermikh, A., Bounoua, A., & Taleb, N. (2020). A new IHS and wavelet based pansharpener algorithm for high spatial resolution satellite imagery. *Advances in Space Research*, 66(7), 1507-1521.
- Yıldırım, D., & Güngör, O. (2012). A novel image fusion method using IKONOS satellite images. *Journal of Geodesy and Geoinformation*, 1(1), 75-83.
- Yılmaz, V. (2020). Metasezgisel Guguk Kuşu Arama Algoritması ile Görüntü Kaynaştırma. *Türk Uzaktan Algılama ve CBS Dergisi*, 1(1), 1-12.
- Zhang, L., Zhang, L., & Du, B. (2016). Deep learning for remote sensing data: A technical tutorial on the state of the art. *IEEE Geoscience and Remote Sensing Magazine*, 4(2), 22-40.
- Zheng, H., Du, P., Chen, J., Xia, J., Li, E., Xu, Z., ... & Yokoya, N. (2017). Performance evaluation of downscaling Sentinel-2 imagery for land use and land cover classification by spectral-spatial features. *Remote Sensing*, 9(12), 1274.