

Görüntü Keskinleştirme Yöntemlerinin Nesne-Yönelimli Sınıflandırma Açısından Değerlendirilmesi

(Evaluation of Image Pan-Sharpning Methods In Terms of Object-Oriented Classification)

Mehmet ÖZDEMİR

Hava Kuvvetleri Komutanlığı, Bakanlıklar/Ankara
mozdemir17@hvkk.tsk.tr

ÖZ

Mevcut uzaktan algılama uyduları genellikle, daha düşük mekânsal çözünürlüklü multispektral ve daha yüksek mekânsal çözünürlüklü pankromatik görüntü alabilen algılayıcılara sahiptir. Düşük ve yüksek çözünürlüklü görüntüler arasındaki bu oran genellikle 4 olmasına rağmen, Landsat, Göktürk-2 gibi bazı uydularda ikidir. Uydü görüntülerinin keskinleştirilmesi ile daha yüksek mekânsal çözünürlüklü multispektral görüntüler elde edilebilmektedir. Bu durumda daha ayrıntılı arazi kullanımı ve arazi örtüsü bu görüntülerden elde edilebilmektedir. Görüntülerin keskinleştirilmesi için çeşitli yöntemler geliştirilmiştir. Bu yöntemler farklı görüntülere uygulanmış ve sonuçlar değerlendirilmiştir. Görüntülerin spektral ve mekânsal çözünürlükleri arazi kullanımı ve örtüsünün çıkarılmasını etkilerken, diğer taraftan görüntüleme uydularının çoğalmasıyla birlikte görüntülerden otomatik veya yarı otomatik yöntemlerle yeterli doğrulukta bilgilerin çıkarılması gerekmektedir. Görüntülerden yeryüzüne ait bilgilerin çıkarılmasının otomatize edilmesi görüntü sınıflandırma yöntemleri ile sağlanmaktadır. Son yıllarda yapılan araştırmalar kullanılan sınıflandırma yöntemlerinden nesne-yönelimli sınıflandırmanın, piksel tabanlı yöntemleri domine ettiğini göstermiştir. Görüntü keskinleştirme yöntemleri istatistiksel olarak ve piksel tabanlı sınıflandırma kullanılarak değerlendirilmiş başarıları karşılaştırılmıştır. Bu çalışmada en başarılı olarak değerlendirilen keskinleştirme yöntemleri nesne-yönelimli sınıflandırma açısından kıymetlendirilmiştir. Spektral ve mekânsal anlamda zenginleştirilmiş görüntülerin, en başarılı sınıflandırma yöntemi olan nesne-yönelimli sınıflandırma ile görüntü keskinleştirmenin sonuçları sınıflandırma doğrulukları açısından incelenmiştir.

Anahtar Kelimeler: Görüntü-keskinleştirme, nesne-yönelimli sınıflandırma, Gram Schmidt, IHS, PC Sharpning, Yun Zhang

ABSTRACT

Current remote sensing satellites generally have multispectral bands have lesser spatial resolution and panchromatic band has higher spatial resolution. Between panchromatic and multispectral bands resolution ratio is generally 4. But this ratio for Landsat and Gokturk-2 is 2. Pansharpening these images (panchromatic and multispectral bands) imagery has higher spatial resolution can be obtained. So more detailed land use and land classification (LULC) can be produced with pan-sharpened images. In order to sharpen images different methods have been

developed. With these methods a lot of images have been fused and fused images have been assessed in terms of spectral and spatial aspects. While pectral and spatial resolution of images effect extraction of LULC, on the other hand increasing of volume of satellite images necessitates automatic or semi-automatic methods to obtain LULC with enough accuracy. To extract information from images automatically or semi-automatically can be handled with image classification. Recent studies showed that object-oriented classification have been dominated classical methods (pixel based classification). Image pansharpening methods have been evaluated statistically and in terms of pixel based classification. In this study image pansharpening methods which is assessed successful have been evaluated in terms of object-oriented classification. Spectrally and spatially enhanced images have been analyzed in terms of classification accuracy.

Keywords: Image pan-sharpening, object-oriented classification, Gram Schmidt, IHS, PC Sharpning, Yun Zhang

1. GİRİŞ

Uzaktan algılama uyduları mimarileri gereği genellikle, daha düşük mekânsal çözünürlüklü multispektral algılayıcılar ile daha yüksek çözünürlüklü pankromatik algılayıcılardan oluşmaktadır. Multispektral ile pankromatik bandlar arasındaki mekânsal çözünürlük oranı ise genellikle 4'dür. Bazı uydularda ise bu farklılık göstermektedir. Örneğin Landsat uydusunun multispektral bandlarının çözünürlüğü 30 m. iken pankromatik bandının çözünürlüğü 15 m.'dir.

Doğru, istenilen zamanda ve sürekli güncellenen, küresel çapta mekânsal veriye ihtiyaç her geçen gün artmaktadır (Lang, 2008). İhtiyaç duyulan her alanda gereken zamanda ve doğrulukta mekânsal veri, uzaktan algılama verilerinden görüntü sınıflandırma yöntemleri kullanılarak elde edilebilir. Hızlı bilgi çıkarma ise tam veya yarı otomatik görüntü sınıflandırma ve detay çıkarma yöntemleri ile sağlanabilir. Uzaktan algılamada görüntü sınıflandırmada, geleneksel yöntemler (supervised-eğitilmiş ve unsupervised-eğitimsiz) ve nesne-yönelimli sınıflandırma yöntemleri kullanılmaktadır (Lillesand, vd., 2014).

Nesne yönelimli yöntemin başarısı piksel tabanlı yöntemlere göre epeyce ileridedir (Oruç, 2008; Yan vd., 2006). Nesne-yönelimli sınıflandırmada pikseller yerine görüntü nesnelere kullanılmaktadır. Ayrıca nesne-yönelimli sınıflandırmada analizcinin deneyimlerinin ve bilgilerinin sınıflandırmaya katılması sağlanmaktadır. Nesne yönelimli yaklaşım insanın görüntü işleminin birebir kopyalanmasıdır (Navulur, 2006). Bulanık setlerle birlikte renk, doku, şekil, boyut, komşuluk ilişkileri gibi görüntü nesnelere özelliklerinin kullanılması ile sınıflandırma başarısı oldukça artar (Özdemir, 2013). Gerekli doğrulukta ve zamanda ihtiyaç olan mekânsal verinin sağlanması için en iyi yöntemin nesne-yönelimli sınıflandırma olduğu görülmektedir. Dolayısı ile görüntü keskinleştirme yöntemlerinin nesne-yönelimli sınıflandırma açısından değerlendirilmesi faydalı olacaktır.

Uydu görüntülerinin multispektral bandları ile pankromatik bandlarının birleştirilmesi üzerine çeşitli çalışmalar yapılmış ve sonuçlar değerlendirilmiştir.

Makarau vd. çalışmalarında Landsat 7 ETM+, IKONOS ve WorldView-2 görüntülerini Brovey, yansıma şiddeti, renk tonu, doygunluk (IHS-Intensity Hue Saturation), temel bileşen analizi (PCA-Principal Component Analysis), Gram Schmidt (GS), de la résolution spatiale par injection de structures (ARSIS), General Framework for image Fusion (GFF) ve Ehlers yöntemleri ile keskinleştirerek ve Relative dimensionless global error in synthesis (ERGAS) spektral, Zero mean normalized cross-correlation (ZNCC, spectral), PC (spatial), SSIM PAN (spatial) tutarlılık ölçeklerini kullanarak görüntü keskinleştirme yöntemlerinin tutarlılıklarını incelemişlerdir (Makarau, vd., 2012).

Nikolakopoulos vd. en çok kullanıldığını değerlendirdikleri on görüntü keskinleştirme yöntemini Color Normalized (CN), Ehlers, GS, Yüksek Geçirgenli Filtreleme yöntemi (HPF-High Pass Filtering), Local Mean Matching (LMM), Local Mean and Variance Matching (LMVM), Modified IHS, PCA, dalgacık dönüşümü (wavelet transform) yöntemleri ile WorldView-2 görüntüsüne uygulamışlar ve sonuçları ERGAS ve Q ölçeklerini kullanarak karşılaştırmışlardır. Ehlers ve HPF algoritmalarının spektral anlamda en başarılı olduklarını, LMM, LMVM and Modified IHS tekniklerinin ikinci sırada kullanılmaları gerektiğini belirtmişlerdir (Nikolakopoulos ve Oikonomidis, 2015).

Jiang vd. farklı zamanlarda, farklı algılayıcılar ile alınmış görüntülerin keskinleştirilmelerini arazi örtüsü, arazi kullanımı haritalanması ve değişiklik izleme analizleri açısından değerlendirmişlerdir. En çok kullanılan keskinleştirme yöntemleri olan IHS, PCA, Brovey, dalgacık dönüşümü ve yapay sinir ağları (artificial neural networks-ANN) yöntemlerini ve bunların birlikte kullanılabilirliklerini incelemişlerdir. Ayrıca görüntülerin keskinleştirilmesinin ardından bu görüntülerin arazi kullanımı ile örtüsünün çıkarılması ve değişiklik izleme açısından incelemişlerdir (Jiang ve ark., 2013).

Zhu vd. çalışmalarında SparseFI adlı yeni bir keskinleştirme yöntemi önermişler bu yöntemle birlikte IHS, Adaptive IHS, Brovey, PCA yöntemlerini UltraCAM görüntüleri kullanarak, karesel ortalama hata (RMSE), korelasyon katsayısı (ρ), spectral angle mapper (SAM), degree of distortion (D), universal image quality index (UIQI) ölçeklerini kullanarak değerlendirmişlerdir. SparseFI yönteminin görüntü keskinleştirme için kullanılabileceği, yöntemin aynı zamanda hiperspektral görüntülerle de kullanılabileceği ifade edilmiştir (Zhu, vd., 2013).

Galiano vd. Landsat 7 ETM+ görüntülerini PC, IHS; dalgacık dönüşüm temelli (WAT), Additive Wavelet Luminance Proportional (AWLP) ve Multidirection-Multiresolution (MDMR) yöntemlerini kullanarak ve bir geostatistik yöntem olan Downscaling Cokriging (DCK) ve son olarak Bayesian yöntemlerini kullanarak keskinleştirmişlerdir. Elde edilen görüntüleri korelasyon katsayısı (CC-Correlation Coefficient), RMSE, ERGAS indekslerini kullanarak değerlendirmişlerdir. Ayrıca keskinleştirilmiş görüntüleri ISODATA sınıflandırma yöntemi ile sınıflandırmışlar ve niteliksel değerlendirmeye tabi tutmuşlardır (Rodriguez, vd., 2012).

Abdikan ve Balık, Ehler, IHS, HPF, iki boyutlu Discrete Wavelet Transformation, (DWT) ve PCA yöntemlerini kullanarak SAR ve optik görüntüleri birleştirmişlerdir. Birleştirilmiş görüntüleri nitel ve nicel olarak değerlendirmişlerdir. İstatistiksel olarak, bias, CC, varyans farkı, standart sapma farkı, UIQI indeksleri ile birleştirilmiş görüntüleri değerlendirmişlerdir. Değerlendirme çalışmaları, şehir ve kırsal alan olarak ikiye ayrılarak yapılmıştır. Bazı yöntemlerin spektral bilgiyi korurken bazılarının mekânsal bilgileri koruduğu görülmüştür. Ehlers yönteminin spektral bilgiyi en iyi koruduğu görülürken HPF yönteminin kırsal alanda en etkili yöntem olduğunu belirtmişlerdir (Abdikan, vd., 2012).

Choodarathnakara vd. en çok kullanılan keskinleştirme yöntemlerinden Brovey, Multiplicative Transform (MT) ve DWT, IHS yöntemlerini Indian Remote Sensing Satellite (IRS) görüntülerine uygulamışlar, sonuçları spatial quality indeksini kullanarak ve görsel olarak değerlendirmişlerdir. Ardından yöntemler arasında bir sıralama yapmışlardır (Choodarathnakara, vd.,2012).

Matsuoka çalışmasında Additive Wavelet Intensity (AWI), Additive Wavelet PC (AWPC), Generalized Laplacian Pyramid with Spectral Distortion Minimization, genelleştirilmiş yansıma şiddeti, renk tonu, doygunluk (GIHS-Generalized Intensity-Hue-Saturation) dönüşümü, GIHS adaptive, GS spektral keskinleştirme ve block-based synthetic variable ratio yöntemlerini ALOS görüntülerini keskinleştirmek için kullanmıştır. Keskinleştirilen görüntüleri görsel olarak, ERGAS, Q indeks ve korelasyon katsayısı istatistiksel yöntemler kullanarak değerlendirmiştir. ERGAS ve Q indeksi GIHS'nin 2 ve 3. bantlardaki spektral bilgiyi oldukça iyi koruduğunu göstermiş, GS, AWI, ve AWPC bütün bantlardaki bilgiyi iyi koruduğunu göstermiştir (Matsuoka, 2012).

Han vd. çalışmalarında en çok kullanılan görüntü keskinleştirme yöntemlerinden Brovey, PCA ve SFIM yöntemlerini ZY03 ve SPOT-5 görüntülerine uygulayarak değerlendirmişlerdir. Gradyent sapması (Gradient deviation) ve CC istatistiksel yöntemlerini kullanarak keskinleştirilmiş görüntüleri değerlendirmişlerdir. Yöntemler içerisinde spektral ve mekânsal bilgileri en iyi koruyan yöntemin SFIM olduğunu belirtmişlerdir (Han, vd., 2013).

Yuhendra vd. çalışmalarında Quickbird görüntülerini IHS, Brovey, PCA, GS ve CN-Spectral yöntemlerini kullanarak keskinleştirmiş, elde edilen keskinleştirilmiş görüntüleri CC, standart sapma istatistiksel yöntemlerini kullanarak ve eğitimli kernel Destek Vektör Makineleri (SVM-support vector machine) sınıflandırma yöntemini kullanarak değerlendirmiştir. Sınıflandırmada elde edilen genel doğruluklar; GS 0.91, PCA 89.59, CNS 87.73, IHS 86.78 ve Brovey 83.74 şeklindedir (Yuhendra, vd., 2011).

Srimani vd. çok bilinen yöntemlerden PCA, Modified-IHS, Brovey, GS, Wavelet-PCA ve Wavelet-IHS yöntemleri ile IRS-ID, LISS IV, Cartostat-1 görüntülerini keskinleştirmişler, sonuçları görsel, istatistik ve ERDAS IMAGINE 9.2'de bulunan en büyük olasılık (Maximum likelihood) eğitimli sınıflandırması ile

sınıflandırmışlar ve doğruluk değerlendirmesine tabi tutmuşlardır. Sınıflandırma doğrulukları sırası ile %70, %78, %75, %73, %85, %88'dir (Srimani ve Prasad, 2014).

Helmy vd., modified IHS, Brovey, PCA, MT, Wavelet resolution merge, HPF ve Ehlers yöntemlerini kullanarak Quickbird görüntülerini keskinleştirmişler ve Average CC, Bias in the Mean ve standard sapma, karesel ortalama hata, Average angle error, ERGAS, Quality index Q4 ölçekleri ile keskinleştirilen görüntüleri değerlendirmişlerdir. Kullanılan değerlendirme ölçekleri her bir keskinleştirme yöntemi için farklı sonuçlar üretmektedir aralarında bir tutarsızlık mevcut olduğunu ifade etmişlerdir (Helmy ve ark., 2010).

Gül vd., çalışmalarında WorldView-2 görüntülerini 16 yöntem kullanarak keskinleştirmişler ve görüntülerdeki farklı özellikteki alanlar ve farklı band kombinasyonları ile değerlendirmişler, puanlamışlar ve sıralamışlardır. HCS Kubik, IHS NN, IHS Bileneer, IHS Kubik, HPF yöntemleri en başarılı beş yöntem olarak değerlendirmişlerdir (Gül, vd., 2012).

Mevcut keskinleştirme yöntemlerinin (IHS, PCA, Wavelet) renk bozulması gibi kusurlarını gidermek üzere Yun Zhang yeni bir yöntem olan kendi ismi ile anılan yöntemi geliştirmiştir. Geliştirdiği yöntemi birçok Landsat ve IKONOS görüntüsü ile değerlendirmiş, çok iyi derecede sonuçlar elde etmiş, görüntülerde maksimum düzeyde detaylar korunmuştur. Bu yöntemle elde edilen görüntülerde diğer yöntemlerde karşılaşılan renk bozulmalarının en az seviyeye indirildiği belirtilmiştir (Zhang, 2002).

Bu çalışmada önceki çalışmalarda başarılı oldukları ifade edilen ve ticari olarak da bulunabilen PC, IHS, Gram-Schmidt, Ehlers ve Yun Zhang yöntemleri ile farklı görüntüler keskinleştirilmiş, görüntüler nesne yönelimli sınıflandırma açısından değerlendirilmişlerdir. Ayrıca elde edilen sınıflandırma sonuçları ile yer doğruluğu nesne-yönelimli değişiklik izleme yöntemi ile karşılaştırılmış bütün sınıflandırma yapılan alan için doğruluk hesaplanmıştır.

2. ÇALIŞMA ALANI, MATERYAL VE YÖNTEM

a. Çalışma Alanı

Çalışma alanı Ankara ili merkezi ile Gölbaşı ilçesi arasındaki bir bölge, Mamak ilçesinde bir bölge ve Eskişehir ili civarında bir bölgedir. Çalışma alanları Şekil 1'de görülmektedir.



Şekil 1. Çalışma Alanı

Çalışma alanı içerisinde yeşil alan, yerleşim yerleri, su alanlar ve toprak alanlar gibi farklı arazi örtüsü mevcuttur.

b. Veri

Çalışmalar için üç farklı uydu görüntüsü (Landsat-8, Kompsat-3, ve WorldView-2) kullanılmıştır.

Landsat-8 görüntüsü multispektral bantları 30 m mekânsal çözünürlüklü, pankromatik bandı ise 15 m çözünürlüklüdür. Landsat-8 görüntülerinin spektral çözünürlüğü ise oldukça yüksektir.

Kompsat-3 görüntülerinin multispektral bantları 3 m ve pankromatik bandı 70 cm mekânsal çözünürlüklüdür. Mavi, yeşil, kırmızı ve yakın kızılötesi bandlara sahiptir.

WorldView-2 görüntülerinin multispektral bantları 2 m pankromatik bandı ise 50 cm çözünürlüklüdür. Ayrıca kıyı (coastal), mavi, yeşil, sarı, kırmızı, red edge, yakın kızılötesi 1 ile 2 ve kısa dalga kızılötesi bandlara sahiptir.

c. Yöntem

Landsat-8 görüntüsü öncelikle atmosferik ve geometrik düzeltmeye tabi tutulmuştur. Worldview-2 görüntüsü atmosferik ve geometrik olarak düzeltilmiş olarak temin edildiğinden herhangi bir atmosferik düzeltme yapılmamıştır. Kompsat-3 görüntüsü de atmosferik ve geometrik düzeltmeye tabi tutulmuştur

Önceki çalışmalarda görüntü keskinleştirme algoritmalarından en başarılı olduğu belirtilenler ve ticari olarak temin edilebilen Ehlers, Gram-Schmidt, Zun Yhang, PC Sharpening ve IHS yöntemleri kullanılarak Landsat-8, Worldview-2 ve Kompsat-3 görüntüleri keskinleştirilmiştir.

Her bir keskinleştirme yöntemi ile elde edilen görüntü, nesne-yönelimli sınıflandırmaya tabi tutulmuştur. Elde edilen sınıflandırma sonuçları yer gerçekliği ile karşılaştırılarak kullanıcı, üretici, genel doğruluk ve Kappa değerleri elde edilmiştir.

Görüntülerin atmosferik ve geometrik olarak düzeltilmesi, keskinleştirilmesi için PCI Geomatica 2015, ENVI 5.3 ve ERDAS 2015 yazılımları, sınıflandırma ve elde edilen sınıflarla yer gerçekliği arasındaki değişimin elde edilmesi için eCognition 9.1 ve QGIS yazılımları kullanılmıştır.

3. GÖRÜNTÜ SINIFLANDIRMA

Görüntü sınıflandırma, nesne-yönelimli sınıflandırma yöntemleri kullanılarak gerçekleştirilmiştir. Nesne yönelimli sınıflandırmada pikseller yerine nesnelere kullanılmaktadır (Blaschke, 2010).


a. Görüntü Bölütleme

Nesne yönelimli sınıflandırmada ilk adım görüntü nesnelere oluşturulmasıdır. Görüntü nesnelere oluşturulması amacıyla, eCognition yazılımında bulunan çok çözünürlüklü bölütleme kullanılmıştır. Çok çözünürlüklü bölütleme uzaktan algılanmış görüntülerde oldukça iyi bir çözümdür (Baatz, vd., 2000).

Çok çözünürlüklü bölütleme neticesinde Ehlers yöntemi dışındaki bütün yöntemler tatmin edici sonuçlar vermiştir. Ehlers yönteminde bazı bölgelerde bölütleme Şekil-2'de görüldüğü gibi arazi örtüsünü tam anlamıyla yansıtamamıştır. (Şekil-2'de işaretli alanlarda uygun bölütleme sağlanamamıştır.)

b. Sınıflandırma

Bölütlemenin ardından her bir görüntü nesne yönelimli yöntemle bulanık setler kullanılarak sınıflandırılmıştır. Farklı yöntemlerle keskinleştirilmiş her bir görüntü için (örneğin Landsat-8 görüntüleri için) aynı kurallar ve aynı bulanık setler kullanılarak sınıflandırılmışlardır. Arazi örtüsü sınıflandırması için dört sınıf (bitki, su, çıplak toprak ve yerleşim alanları) kullanılmıştır.



Şekil 2. Ehlers bölütlemeye ilişkin örnek

Sınıflandırmada Normalize Edilmiş Bitki İndeksi (NDVI-Normalized Differenced Vegetation Index), Normalize Edilmiş Su İndeksi (NDWI-Normalized Differenced Water Index) gibi indeksler ile mavi band oranı (ratio blue band) gibi oranlar kullanılmıştır. Bu değerler bulanık kuralları ile kullanılmışlardır. Sınıflandırmaya ilişkin kurallardan bazıları Şekil-3'de görüldüğü gibidir.

Ehlers yöntemi ile elde edilen görüntüler ile sınıflandırma işlemi gerçekleştirilememiştir. Keskinleştirilmiş görüntülerde NDVI ve NDWI hesaplandığında bitki alanları ile su alanlarının birbirine karıştığı görülmüştür.

c. Doğruluk Araştırması

Sınıflandırma doğruluğunun tespitinde hata matrisi kullanılarak birçok hata ölçüsü elde edilebilir. Bunlardan en çok kullanılanları; kullanıcı doğruluğu, üretici doğruluğu ve genel doğruluktur (Yan, 2003).

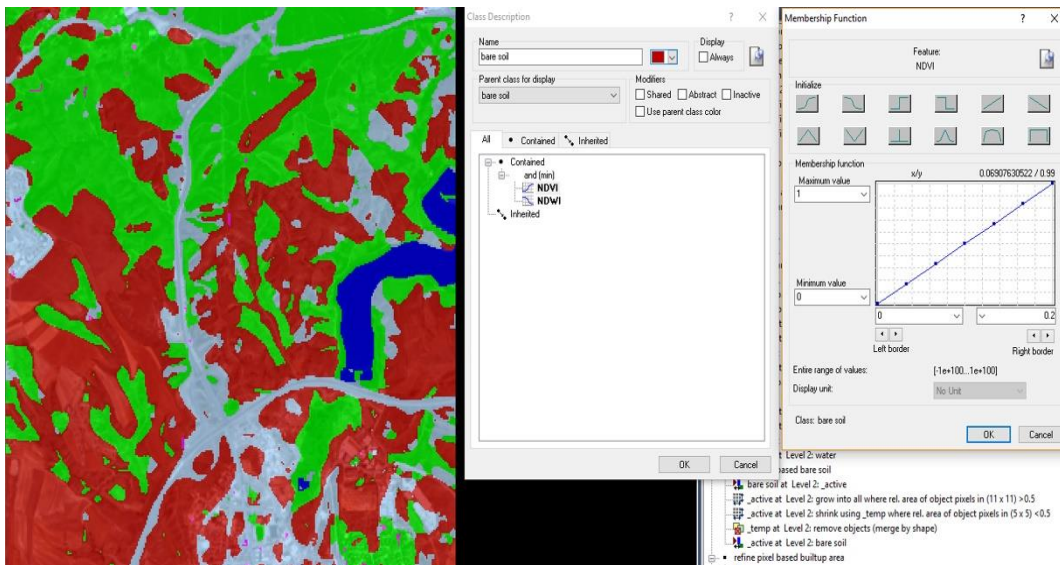
- **Kullanıcı doğruluğu (UA-User Accuracy)**, herhangi bir sınıfa atanmış pikselin gerçekte o sınıfa ait olma olasılığını temsil eder. Her bir sınıf için doğru olarak sınıflandırılmış piksel ya da nesne sayısının o kategoride sınıflandırılan toplam piksel ya da nesne sayısına (sütun toplamı) bölümü ile hesaplanır (Boyacı, 2012).

$$UA = \frac{a_{ii}}{\sum_{k=1}^n a_{ik}} \quad (1)$$

- **Üretici Doğruluğu (PA-Producer Accuracy)**, piksel ya da nesnenin gerçek değerinde sınıflandırılma olasılığını ifade eder. Her bir sınıf için doğru olarak sınıflandırılmış piksel ya da nesne sayısının, o sınıf için seçilen gerçek örtü tipi örnekleme sayısı toplamına (sütun toplamı) bölünmesiyle hesaplanır (Boyacı, 2012).

$$UA = \frac{a_{ii}}{\sum_{k=1}^n a_{ki}} \quad (2)$$

Uygulamada bu iki doğruluk değeri 100'e yakın ve birbirine ne kadar yakın ise sınıflandırma doğruluğunun o kadar iyi olduğu değerlendirilebilir. Aksi durumda yani bu iki değerden biri 100'e yakinken diğeri çok düşükse ya da iki değerde çok küçükse seçilen eğitim alanlarının ya da kullanılan algoritmanın yeniden değerlendirilmesi gerekebilir (Boyacı, 2012)



Şekil 3. Sınıflandırmaya ilişkin örnek kural

• **Genel Doğruluk (OA-Overall Accuracy)**, Her bir sınıf için doğru olarak sınıflandırılmış piksel ya da nesne sayısının, toplam referans piksel sayısına bölünmesi ile hesaplanır. Sınıfların doğruluğu hakkında genel bir değerlendirme sunar (Boyacı, 2012).

$$OA = \frac{\sum_{k=1}^N a_{kk}}{\sum_{i,k=1}^N a_{ik}} = \frac{1}{n} \sum_{k=1}^N a_{kk} \quad (3)$$

Elde edilen doğrulukların değerlendirilmesi amacı ile kullanılan diğer bir ölçüt ise hata matrisinin satır ve sütun toplamaları ile köşegen üzerindeki elemanlar kullanılarak hesaplanan kappa (k) değeridir. Kappa değeri 0 ile 1 arasında bir değer alır. Bu değer 1'e ne yakın yakınsa elde edilen sınıfın doğruluk değeri o kadar güvenilirdir (Lillesand vd., 2008).

$$k = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})} \quad (4)$$

Bu eşitlikte;

r : hata matrisindeki toplam satır sayısı,
 x_{ii} : i. satır ve sütundaki piksel sayısı,
 x_{i+} : i. satırdaki toplam piksel sayısı,
 x_{+i} : i. sütundaki toplam piksel sayısı,
 N : matrisin tamamındaki piksel sayısı;

olarak tanımlanır. Hata matrisinden ve kappa istatistiğinden elde edilen sonuçlar birbirinden

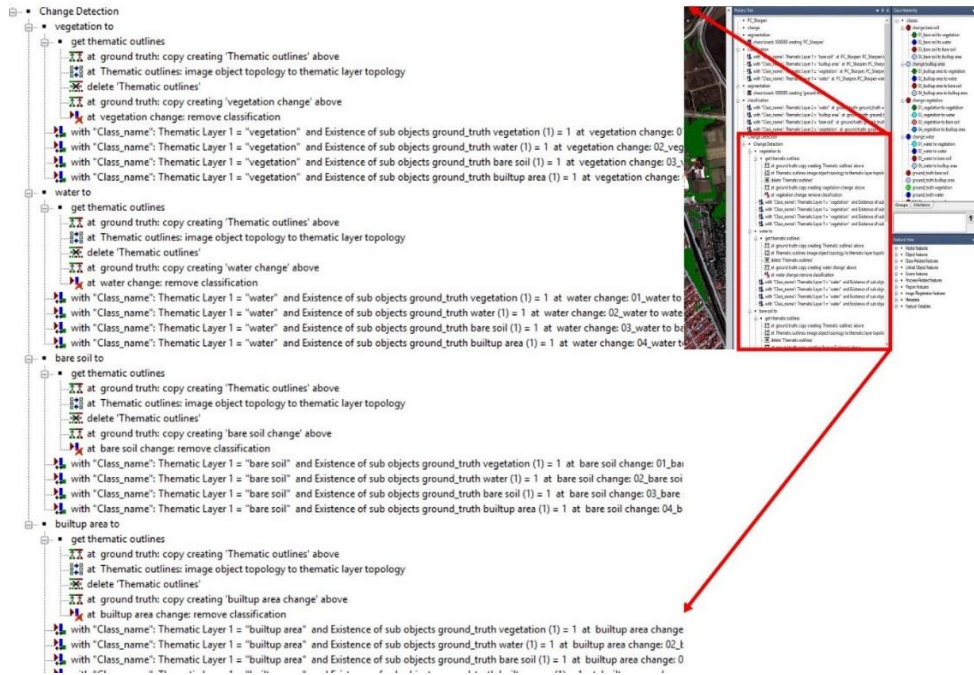
farklıdır. Çünkü her ikisinde farklı bilgiler kullanılır. Hata matrisinde sadece köşegen elemanları kullanılırken, kappa katsayısı için satır ve sütunların ağırlıklı toplamı kullanılır (Jensen, 1996).

Ayrıca kappa değerleri Tablo 1'de gösterildiği gibi yorumlanabilir (Landis vd., 1977).

Tablo 1. Kappa değerlerine ilişkin yorumlar

Kappa	Yorum
< 0	Hiç uyuşma olmaması
0.0-0.20	Önemsiz uyuşma olması
0.21-0.40	Orta derecede uyuşma olması
0.41-0.60	İyi derecede uyuşma olması
0.61-0.80	Önemli derecede uyuşma olması
0.81-1.00	Neredeyse mükemmel uyuşma olması

Keskinleştirilmiş Kompsat-3, WorldView-2 ve Landsat-8 görüntüleri kullanılarak nesne-yönelimli sınıflandırma neticesinde elde edilen sınıflar ile yer gerçekliği arasında yapılan değişiklik analizi sonucu elde edilmiştir. Değişiklik analizine ilişkin kuralları Şekil-4'de verilmiştir. Elde edilen kullanıcı, üretici doğrulukları ile genel doğruluk ve kappa indeksleri sırası ile Tablo 2, Tablo 3 ve Tablo 4'de verilmiştir.



Şekil 4. Doğruluğun değişiklik tespiti ile belirlenmesine ilişkin sınıflar ve kurallar

Tablo 2. Komsat-3 görüntüleri için elde edilen kullanıcı, üretici, genel doğruluk ve kappa değeri

	Sınıf			
	Bitki	Su	Çıplak Toprak	Yerleşim yeri
Yöntem	Gram Schmidt			
Kullanıcı Doğruluğu	0,9578	0,5865	0,9920	0,8662
Üretici Doğruluğu	0,9781	0,8370	0,9248	0,9814
Genel Doğruluk	0,9510			
Kappa	0,4491			
Yöntem	IHS			
Kullanıcı Doğruluğu	0,8676	0,4914	0,9423	0,7101
Üretici Doğruluğu	0,9566	0,4498	0,7519	0,8982
Genel Doğruluk	0,8495			
Kappa	0,4536			
Yöntem	PC			
Kullanıcı Doğruluğu	0,9375	0,5163	0,9750	0,8432
Üretici Doğruluğu	0,9594	0,7824	0,8756	0,9665
Genel Doğruluk	0,9234			
Kappa	0,4533			
Yöntem	Yun Zhang			
Kullanıcı Doğruluğu	0,9119	0,7336	0,6650	0,7791
Üretici Doğruluğu	0,9431	0,6542	0,7956	0,6937
Genel Doğruluk	0,8171			
Kappa	0,4318			

Tablo 3. WorldView-2 görüntüsü için elde edilen kullanıcı, üretici, bütün doğruluk ve kappa değeri

	Sınıf			
	Bitki	Su	Çıplak toprak	Yerleşim yeri
Yöntem	Gram Schmidt			
Kullanıcı Doğruluğu	0,9194	1	0,9977	0,6762
Üretici Doğruluğu	0,9983	0,9996	0,7364	0,9965
Genel Doğruluk	0,8574			
Kappa	0,4511			
Yöntem	IHS			
Kullanıcı Doğruluğu	0,9992	1	0,9529	0,7114
Üretici Doğruluğu	0,9586	0,9984	0,9111	0,9846
Genel Doğruluk	0,9511			

Kappa	0,4267			
Yöntem	PC			
Kullanıcı Doğruluğu	0,9896	1	0,9693	0,8396
Üretici Doğruluğu	0,8233	0,9490	0,9282	0,9889
Genel Doğruluk	0,9281			
Kappa	0,4440			
Yöntem	Yun Zhang			
Kullanıcı Doğruluğu	0,9896	1	0,9694	0,8001
Üretici Doğruluğu	0,8233	0,9490	0,9351	0,8467
Genel Doğruluk	0,8929			
Kappa	0,4594			

Tablo 4. Landsat-8 görüntüleri için elde edilen kullanıcı, üretici, genel doğruluk ve kappa değeri

	Sınıf			
	Bitki	Su	Çıplak Toprak	Yerleşim yeri
Yöntem	Gram Schmidt			
Kullanıcı Doğruluğu	0,9194	1	0,9977	0,6041
Üretici Doğruluğu	0,9162	0,9963	0,9125	0,7121
Genel Doğruluk	0,8882			
Kappa	0,4505			
Yöntem	IHS			
Kullanıcı Doğruluğu	0,9951	0,9967	0,9533	0,6194
Üretici Doğruluğu	0,9290	0,9936	0,9404	0,8028
Genel Doğruluk	0,9228			
Kappa	0,4477			
Yöntem	PC			
Kullanıcı Doğruluğu	0,9870	0,9971	0,8085	0,4792
Üretici Doğruluğu	0,9195	0,9935	0,8872	0,4429
Genel Doğruluk	0,8369			
Kappa	0,4501			
Yöntem	Yun Zhang			
Kullanıcı Doğruluğu	0,9872	0,9917	0,8907	0,4657
Üretici Doğruluğu	0,9076	0,9966	0,8930	0,6729
Genel Doğruluk	0,8792			
Kappa	0,4408			

4. SONUÇ

Landsat-8, Kompsat-3 ve WorldView-2 görüntülerinin keskinleştirilmesi sonucunda elde edilen yeni görüntüler ile nesne yönelimli sınıflandırmanın ilk aşaması olan bölütleme gerçekleştirilmiş, Ehlers dışındaki tüm yöntemlerin yeterli doğrulukta sonuçlar verdiği gözlenmiştir.

Ehlers yöntemi kullanılarak keskinleştirilen görüntülerde NDVI ve NDWI indekslerinin birbirine karışıkları gözlenmiştir. Diğer yöntemlerle keskinleştirilen görüntülerle elde edilen sınıfların kullanıcı ve üretici doğruluğu, genel doğruluğu ve Kappa indeksleri değerlendirildiğinde, Ehlers dışındaki bütün yöntemlerle nesne-yönelimli sınıflandırmanın gerçekleştirilebileceği değerlendirilmektedir.

Bütün yöntem ve görüntülerle genel doğruluk %80 üzerinde elde edilmiş ve kapa değerleri incelendiğinde uyuşmaların iyi derecede olduğu görülmüştür. Sınıflandırma doğruluklarındaki farklılıkların görüntülerin spektral çözünürlüklerinin farklılığından kaynaklı olabileceği değerlendirilmektedir.

KAYNAKLAR

- Abdikan, S., Şanlı, F. B., (2012), **Comparison of different fusion algorithms in urban and agricultural areas using sar (palsar and radarsat) and optical (spot) images**, Boletim de Ciencias Geodesicas, 18(4), 509-531.
- Baatz, M., Schape, A., (2000), **Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation**, Angewandte Geographische Informationsverarbeitung XII, 58, 12-23.
- Gül, B., Yıldırım, Ç., Değer, A., Erdoğan, M., (2013), **Görüntü Birleştirme Yöntemlerinin Spektral Değerleri Koruma Açısından Karşılaştırılması: WorldView-2 Uygulaması**, TMMOB Harita ve Kadastro Mühendisleri Odası, 14. Türkiye Harita Bilimsel ve Teknik Kurultayı, 14-17 Mayıs 2013, Ankara.
- Blaschke, T., (2010), **Object based image analysis for remote sensing**, ISPRS journal of photogrammetry and remote sensing, 65(1), 2-16.
- Boyacı, D., (2012), **CBS-uzaktan algılama entegrasyonu ve örnek uygulama: Uydu görüntülerinden detay ve otomatik Öznelik tespiti**, Ph.D. dissertation, Selçuk Üniversitesi Fen Bilimleri Enstitüsü.
- Choodarathnakara, A. L., Kumar, T. A., Koliwad, S., Patil, C. G., (2012), **Assessment of Different Fusion Methods Applied to Remote Sensing Imagery**, (IJCSIT) International Journal of Computer Science and Information Technologies, Vol. 3 (6), 2012,5447-5453
- Ehlers, M., Klonus, S., Johan Astrand, P., Rosso, P., (2010), **Multi-sensor image fusion for pansharpening in remote sensing**, International Journal of Image and Data Fusion, 1(1), 25-45.
- Han, Z., Tang, X., Gao, X., Hu, F., (2013), **Image Fusion and Image Quality Assessment of Fused Images**, International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XL-7 W, 1, 33-36.
- Helmy, A. K., Nasr, A. H., El-Taweel, G. H., (2010), **Assessment and evaluation of different data fusion techniques**, International Journal of Computers, 4(4), 107-115.
- Ehlers, M., Klonus, S., Astrand, P. J., (2008), **Quality assessment for multi-sensor multi-date image fusion**, Proc. XXIth Int. Congr. ISPRS, 499-506.
- Jeleneck, J., Kopavckova, V., Koucka, L., (2015), **Testing a New Approach for ASTER Image Data Sharpening via Using Diverse Principle Components**.
- Jensen, J. R., (1986), **Introductory digital image processing: a remote sensing perspective**.
- Jiang, D., Zhuang, D., Huang, Y., (2013), **Investigation of image fusion for remote sensing application. Remote Sensing Applications**, Image Fusion and Its Applications, 978-953.
- Landis, J. R., Koch, G. G., (1977), **The measurement of observer agreement for categorical data**, biometrics, 159-174.
- Lang, S., (2008), **Object-based image analysis for remote sensing applications: modeling reality--dealing with complexity**, Object-based image analysis (s. 3-27), Springer.
- Lillesand, T., Kiefer, R. W., Chipman, J., (2014), **Remote sensing and image interpretation**, John Wiley \ Sons.

- Ling, Y., Ehlers, M., Usery, E. L., Madden, M., (2008), **Effects of spatial resolution ratio in image fusion**, International Journal of Remote Sensing, 29(7), 2157-2167. doi:10.1080/01431160701408345
- Makarau, A., Palubinskas, G., Reinartz, P., (2012), **Analysis and selection of pansharpening assessment measures**, Journal of Applied Remote Sensing, 6(1), 63548-1.
- Matsuoka, M., (2012), **Comparison of the spectral properties of pansharpened images generated AVNIR-2 and PRISM onboard ALOS. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, 7.
- Navulur, K., (2006), **Multispectral image analysis using the object-oriented paradigm**, CRC press.
- Nikolakopoulos, K., Oikonomidis, D., (2015), **Quality assessment of ten fusion techniques applied on Worldview-2**, European Journal of Remote Sensing, 48, 141-167.
- Oruc, M. M., (2008), **Comparison of Pixel-Based and Object-Oriented Classification Approaches Using Landsat-7 ETM Spectral Bands**.
- Özdemir, M., (2013), **Uydu görüntülerinden nesne yönelimli yöntemlerle özellik çıkarımı Ph.D. dissertation**, Selçuk Üniversitesi Fen Bilimleri Enstitüsü.
- Rodriguez-Galiano, V. F., Pardolguizquiza, E., Chica-Olmo, M., Mateos, J., Rigol-Sanchez, J. P., Vega, M., (2012), **A comparative assessment of different methods for Landsat 7/ETM+ pansharpening**, International journal of remote sensing, 33(20), 6574-6599.
- Srimani, P. K., Prasad, N., (2014), **Analysis and Comparative Study of Image Fusion Techniques for Land Use and Land Cover Classification on Anthrasanthe Hobli, Karnataka-Case Study**, International Journal of Engineering Research and Technology, 3.
- Yan, G., Mas, J.-F., Maathuis, B. H., Xiangmin, Z., Van Dijk, P. M., (2006), **Comparison of pixel-based and object-oriented image classification approaches-a case study in a coal fire area, Wuda, Inner Mongolia, China**, International Journal of Remote Sensing, 27(18), 4039-4055.
- Yuhendra, J., Kuze, H., (2011), **Performance Analyzing of High Resolution Pansharpening Techniques: Increasing Image Quality for Classification using Supervised Kernel Support Vector Machine**, Research Journal of Information Technology, 8(1), 12-28.
- Zhang, Y., (2002), **Problems in the fusion of commercial high-resolution satellite as well as Landsat 7 images and initial solutions**, International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences, 34(4), 587-592.
- Zhu, X. X., Bamler, R., (2013), **A sparse image fusion algorithm with application to pansharpening**, IEEE Transactions on Geoscience and Remote Sensing, 51(5), 2827-2836.