

GÖRÜNTÜ ZENGİNLEŞTİRME YÖNTEMLERİNİN TARIMSAL ÜRÜN SINIFLANDIRMASI ÜZERİNDEKİ ETKİLERİNİN DEĞERLENDİRİLMESİ

A. Özdarıcı^a, Z. Akyürek^b

^a ODTÜ Jeodezi ve Coğrafi Bilgi Teknolojileri EABD, Orta Doğu Teknik Üniversitesi
Ankara, Türkiye - ozdarici@metu.edu.tr

^b ODTÜ İnşaat Mühendisliği Bölümü, Orta Doğu Teknik Üniversitesi, Ankara, Türkiye - zakyurek@metu.edu.tr

ANAHTAR KELİMELER: Görüntü Zenginleştirme, Görüntü Sınıflandırması, Tarım, Doğruluk Değerlendirme, QuickBird

ÖZET

Görüntü zenginleştirme, farklı mekansal, spektral ve zamansal görüntü özellikleri biraraya getirilerek bu görüntülerden yüksek mekansal ve spektral özelliklere sahip yeni bir görüntü elde etme yöntemidir. Yöntemin ana amacı, görüntü analizlerine (görüntü sınıflandırması, bölütleme, değişim belirleme vb.) detaylı girdi sağlamaktır.

Çalışmada literatürde sıkça karşılaşılan dokuz farklı görüntü zenginleştirme yöntemi test edilmiş ve bu yöntemlerin tarımsal ürün sınıflandırması üzerindeki etkileri incelenmiştir. Çalışma alanı olarak Bursa'da yer alan Karacabey Ovası seçilmiştir. Karacabey Ovası, alanda yetiştirilen ürün çeşitliliği bakımından Türkiye'nin en verimli ovaları arasında yer almaktadır. Tarımsal alanlarda yetiştirilen ürünlerin güvenilir bir şekilde haritalanabilmesi için son yıllarda yüksek mekansal çözünürlük sağlayan uydular önem kazanmıştır. Bu çalışmada 13 Ağustos 2004 tarihli QuickBird siyah-beyaz (0.61m) ve renkli (2.44 m) görüntüleri kullanılmıştır. Hesaplamalarda kolaylık sağlamak amacıyla analizler görüntünün yaklaşık 5 km² lik bölümü üzerinde uygulanmıştır. Görüntüler üzerinde ilk olarak, Gram-Schmidt, En Küçük Kareler, Yüksek Frekans Filtreleme yöntemi, Ana Bileşenler Spektral görüntü zenginleştirme yöntemi, Renk-Doygunluk-Parlaklık dönüşümü (RDP), İyileştirilmiş Yoğunluk-Renk-Doygunluk (YoRD) dönüşümü, Brovey, Dalgaboyu tabanlı Ana Bileşenler Yöntemi ve Dalgaboyu tabanlı YoRD görüntü zenginleştirme yöntemleri uygulanmıştır. Zenginleştirilmiş görüntüler üzerinde yer alan beş ürün sınıfı (Mısır, Buğday, Anız, Domates ve Şeker Pancarı) En Büyük Olasılık Sınıflandırma yöntemi yardımıyla sınıflandırılmıştır. Görüntü zenginleştirme yöntemleri sonucunda üretilen zenginleştirilmiş görüntülerin spektral kalitesinin gerçek renkli görüntü ile karşılaştırılabilmesi için görüntüler, gerçek renkli görüntü çözünürlüğü olan 2.44 m ye dönüştürülerek sınıflandırılmıştır. Sınıflandırma süresince tüm görüntüler için aynı örnek alanlar kullanılmıştır. Sınıflandırma sonuçları gerçek renkli görüntüye ait sınıflandırma sonucu ile karşılaştırılmış ve referans harita yardımıyla değerlendirilmiştir. Kullanılan referans harita, ürün bilgilerinin alana gidilerek toplanması yoluyla üretilmiştir. Referans harita üretimi, görüntü çekim tarihiyle eş zamanlı olarak gerçekleştirilmiştir. Referans harita yardımıyla sınıflandırılmış görüntüler için hata matrisleri oluşturulmuş ve genel hata, Kappa değeri ve ürün sınıflarına ait doğruluk oranları bu matrisler yardımıyla hesaplanmıştır. Değerlendirmeler sonucunda gerçek renkli görüntüye ait en yüksek genel hata oranı %84,2 olarak hesaplanmıştır. Gram-Schmidt görüntü zenginleştirme yöntemi gerçek renkli görüntüden elde edilen sınıflandırma doğruluğunu yaklaşık %4 arttırarak %88 olarak hesaplanmıştır. Bu oranı yaklaşık %86 ile En Küçük Kareler yöntemi, Ana Bileşenler Spektral görüntü zenginleştirme yöntemi, Yüksek Frekans Filtreleme Yöntemi ve İyileştirilmiş YoRD dönüşümü yöntemleri izlemiştir. Brovey ve Dalgaboyu tabanlı YoRD dönüşümlerine ait doğruluk oranları yaklaşık %85 olarak hesaplanmış ve bu iki yönteme ait sonuçlar da kabul edilebilir bulunmuştur. Diğer taraftan Dalgaboyu tabanlı Ana Bileşenler yöntemi ve RDP yöntemlerine ait doğruluk oranlarının gerçek renkli görüntü için hesaplanan orandan düşük olduğu gözlenmiştir. Bu iki yönteme ait genel doğruluk oranları yaklaşık %81 olarak hesaplanmıştır. Elde edilen sonuçlar, Gram-Schmidt, En Küçük Kareler, Ana Bileşenler Spektral, Yüksek Frekans Filtreleme Yöntemi, İyileştirilmiş YoRD dönüşümü, Brovey dönüşümü ve Dalgaboyu tabanlı YoRD görüntü zenginleştirme yöntemlerinin tarım alanlarındaki ürün çeşitliliğinin sınıflandırılmasında sınıflandırma doğruluğunu arttırmak için kullanılabileceğini göstermiştir.

EVALUATING THE CONTRIBUTION OF IMAGE FUSION METHODS INTO THE CLASSIFICATION ACCURACIES OF AGRICULTURAL CROPS

A. Ozdarici^a, Z. Akyurek^b

^a METU Geodetic and Geographic Information Technologies Department, Middle East Technical University
Ankara, Turkey - ozdarici@metu.edu.tr

^b METU Civil Engineering Department, Middle East Technical University, Ankara, Turkey - zakyurek@metu.edu.tr

KEY WORDS: Image Fusion, Image Classification, Agriculture, Accuracy, QuickBird

ABSTRACT:

Image fusion is a process to generate a new image by integrating different spatial, spectral and/or temporal resolution images. The main goal of image fusion is to provide detail input to the later image analyses (image classification, segmentation, change detection, etc.).

This study focuses on evaluating the influence of nine different image fusion methods, mostly encountered in the literature, on the accuracies of the agricultural crop classification. The study site selected is on the Karacabey Plain, one of the most productive and valuable agricultural regions, located in Bursa in Turkey. A new trend for the agricultural crop classification is to utilize high resolution satellite products in order to extract the crop types more reliably. Therefore, a QuickBird panchromatic (0.61m) and multispectral (2.44m) images acquired on 13 August 2004 were used in this study. A small part of QuickBird (~5 km²) image was used in order to improve computational efficiency in the analyses. Nine different fusion methods, namely Gram-Schmidt, Least Square Fusion (LSF), High Pass Filter Resolution Merge (HPF), Principle Component (PC) Spectral Sharpening, Hue-Saturation-Value (HSV), Modified Intensity-Hue-Saturation (IHS) Resolution Merge, Brovey, Wavelet-based PCA (Principle Component Analysis), and Wavelet-based IHS were used to combine the panchromatic and multispectral data. The fused images were classified into number of five classes (Corn, Wheat, Residue, Tomato and Sugar beet) as a supervised manner using Maximum Likelihood Classification method. Before the classification, the fused images were resized to 2.44m, the size of the original multispectral image, in order to understand the radiometric quality of the fused products. During the classification the same training areas were used for each image. The classification results were then compared with the classification of the original multispectral image. The accuracies of the classified thematic maps were tested using a reference map. The reference map was produced by collecting information about crop types from the study area. Producing reference map and image acquisition were performed simultaneously. Based on the reference map, the overall accuracy, overall kappa and individual class accuracies were computed using error matrices. The overall accuracy of the original multispectral image, was computed as 84,2%. The classified images fused by the Gram-Schmidt method provided the highest overall accuracy of about 88%. The Gram-Schmidt method was followed by the methods of LSF, PC Spectral Sharpening, HPF, and Modified IHS Resolution Merge and their accuracies were computed around 86%. The accuracies of Brovey and Wavelet IHS Resolution Merge also revealed acceptable result, which was around 85%. On the other hand, the results obtained from the Wavelet PCA and HSV methods were found lower than the accuracy of the classified original image. The accuracies of these methods were computed as around 81%. The results revealed that the methods of the Gram-Schmidt, LSF, PC Spectral Sharpening, HPF, and Modified IHS Resolution Merge, Brovey, and Wavelet IHS Resolution Merge can be used to fuse the images before the classification of the agricultural crops to increase the classification accuracy.

1. GİRİŞ

Uzaktan Algılama, araştırmacılara mekansal, spektral ve zamansal çözünürlükte çeşitli ürünler sağlayarak elektromanyetik spektrumun büyük bir bölümüne ait bilgi çıkarımına katkıda bulunmaktadır. Uzaktan algılama teknolojisinin sağladığı bu geniş çaplı veri, bir takım problemleri de beraberinde getirmektedir. Bu problemlerden başlıcaları; verilerin birbirleri ile kombinasyonu, yüksek kalitede bilgi elde etmek ve gereksiz bilgilerin ayıklanması olarak sayılabilir. En önemli problemlerden bir tanesi, renkli görüntüye ait spektral bilgi ile siyah-beyaz görüntüye ait mekansal bilginin nasıl etkili bir şekilde kullanılacağına yöneliktir. Bu problemlerin çözümünde kullanılan en etkili yöntem 'görüntü zenginleştirme' olarak adlandırılmaktadır. Görüntü zenginleştirme, farklı mekansal, spektral ve zamansal çözünürlükteki görüntülerin birleştirilmesi ve bu sayede yüksek spektral ve mekansal özelliklerde yeni bir görüntü elde edilmesi işlemi olarak tanımlanabilir. Daha genel bir ifade ile görüntü zenginleştirme, farklı kaynaklardan elde edilen uydu verilerinin birleşimi, korelasyonu ve kombinasyonu olarak ifade edilebilir. Bu yaklaşım sadece görsel yönden kaliteli görüntüler üretmekle kalmaz daha sonra görüntü üzerine uygulanacak analizlere de detaylı girdi sağlar. Pohl ve van Genderen tarafından 1998 yılında görüntü zenginleştirme yöntemlerinin değerlendirilmesine yönelik geniş çaplı bir çalışma yapılmıştır. Çalışmada, görüntü zenginleştirme yöntemleri; piksel tabanlı, nesne tabanlı ve karar ağacı düzeyinde olmak üzere 3 gruba ayrılmaktadır. Piksel düzeyinde gerçekleştirilen yöntemler veriyi oluşturan en küçük nesnelere (piksel) üzerinde uygulanmaktadır. Nesne düzeyinde uygulanan yöntemler,

görüntüyü oluşturan nesnelere zenginleştirilmesine yönelik olarak yapılmaktadır. Karar ağacı düzeyinde gerçekleştirilen zenginleştirme yöntemlerinde görüntüler üzerinde zenginleştirme işlemi gerçekleştirecek uygun kuralların (kararların) belirlenmesi gerekmektedir (Pohl ve van Genderen, 1998). Bu çalışmada piksel düzeyinde uygulanan görüntü zenginleştirme yöntemlerine yer verilecektir. Görüntü zenginleştirme yöntemleri ile ilgili problemler ve kısıtlamalar bugüne kadar bir çok araştırmacı tarafından incelenmiştir (Chavez vd., 1991, Pellemans vd., 1993, Zhang, 2002). Bu araştırmacılardan Zhang (2002), görüntü zenginleştirme yöntemlerine ait sorunları Landsat 7 ve IKONOS görüntüleri üzerinde inceleyerek bu problemlere neden olan aksaklıkların belirlenmesi için çeşitli tespitlerde bulunmuştur. Colditz vd. (2006) Landsat 7 görüntüsü üzerinde 5 farklı görüntü zenginleştirme yöntemi uygulamış ve sonuçları 3 farklı sınıflandırma yöntemi yardımıyla sınıflandırılarak değerlendirmiştir. Elde edilen bulgular, Brovey ve RDP dönüşümlerinin görüntülerin zenginleştirilmesi ve daha sonra bu görüntülere uygulanacak sınıflandırma işlemi için uygun yöntemler olmadığını göstermiştir. Benzer bir çalışma Karathanassi vd. tarafından gerçekleştirilmiştir (Karathanassi vd., 2007). Çalışmada görüntü zenginleştirme yöntemlerini incelemek amacıyla çeşitli değerlendirme yöntemleri kullanılmıştır. Değerlendirmeler sonucunda en yüksek sonuçların Lokal Ortalama ve Dağılım Uyuşması, En Küçük Kareler ve Gram-Schmidt görüntü zenginleştirme yöntemlerinin sağladığı gözlenmiştir. Yukarıda sözü edilen çalışmalara benzer bir diğer çalışma Konstantinos (2008) tarafından gerçekleştirilmiştir. Çalışmada zenginleştirme yöntemi uygulanmış görüntüler görsel ve istatistiksel olarak


değerlendirildikten sonra kontrolsüz bir sınıflandırma yöntemi kullanılarak yöntemlerin sınıflandırma doğruluğu üzerindeki etkileri incelenmiştir.

Bu çalışmada dokuz (9) farklı görüntü zenginleştirme yöntemi sonucu üretilmiş görüntüler kontrollü bir sınıflandırma yöntemi yardımıyla sınıflandırılarak görüntü zenginleştirme yöntemlerinin ürün sınıflandırması üzerindeki etkileri incelenmiştir. Analizler 13 Ağustos 2004 tarihli QuickBird renkli (2.44m) ve siyah-beyaz (0.60m) görüntüleri üzerinde uygulanmıştır. İlk olarak Gram-Schmidt, En Küçük Kareler, Yüksek Frekans Filtreleme yöntemi, Ana Bileşenler Spektral görüntü zenginleştirme yöntemi, Renk-Doygunluk-Parlaklık dönüşümü (RDP), İyileştirilmiş Yoğunluk-Renk-Doygunluk (YoRD) dönüşümü, Brovey, Dalgaboyu tabanlı Ana Bileşenler Yöntemi ve Dalgaboyu tabanlı YoRD görüntü zenginleştirme yöntemleri kullanılarak QuickBird görüntüleri zenginleştirilmiştir. Yukarıda sayılan yöntemler yoluyla üretilen görüntüler beş (5) farklı istatistiksel değerlendirme yöntemi yardımıyla değerlendirilerek üretilen yüksek çözünürlükteki görüntülerin gerçek renkli görüntüye ait spektral değerlere yakınlığı ölçülmüştür. Bu amaç için kullanılan değerlendirme yöntemleri; *Görelî Ortalama ve Varyans farkları, Korelasyon, En Yüksek Sinyal Hata Oranı ve Genel Kalite İndeksi*dir. Zenginleştirilmiş görüntülerin istatistiksel ve görsel olarak değerlendirilmelerinin ardından görüntüler üzerinde yer alan beş (5) farklı ürün sınıfı (mısır, domates/biber, buğday, anız ve şeker pancarı) *En Büyük Olasılık* sınıflandırma yöntemi yardımıyla sınıflandırılmıştır. Sınıflandırmalarda kullanılan örnek alanlar gerçek renkli görüntü üzerinden toplanmış ve aynı alanlar zenginleştirilmiş ve gerçek renkli görüntülerin sınıflandırılmasında kullanılmıştır. Sınıflandırma sonrasında tematik haritalar üzerinde Sieve filtresi uygulanmış ve belli bir eşik değerinin altında kalan poligonları oluşturan pikseller birbirine komşu olan en yakın poligonların içine düşen piksel değerine atanmıştır. Elde edilen sonuçlar hata matrisleri yardımıyla değerlendirilmiş ve genel hata oranları, kappa değerleri ve ürünlere ait doğruluklar hesaplanarak sonuçlar gerçek renkli görüntüden elde edilen sınıflandırma sonucu ile karşılaştırılmıştır.

2. ÇALIŞMA ALANI VE VERİ SETİ

2.1 Çalışma Alanı

Analizleri gerçekleştirmek için seçilen çalışma alanı, Türkiye'nin kuzeybatısında bulunan Marmara bölgesindeki Bursa ilinde yer almaktadır (Şekil 1). Karacabey Ovası olarak bilinen alan, ikliminin üretime elverişli olması ve zengin ürün çeşitliliği bakımından Türkiye'nin en verimli ve en değerli ovaları arasında yer almaktadır. Alanda yetiştirilen başlıca ürünler; mısır, domates, biber, soğan, pirinç, şeker pancarı, buğday ve bezelye olarak sayılabilir (Özdarıcı, 2005).



Şekil 1. Çalışma alanı


2.2 Veri Seti

Çalışmada uydu görüntüsü ve referans veri olmak üzere iki farklı veri tipi kullanılmıştır. Görüntü zenginleştirme yöntemleri, 0.61 m siyah-beyaz ve 2.44 m renkli QuickBird uydu görüntüleri üzerinde uygulanmıştır (Şekil 2). Kullanılan QuickBird görüntüleri ürün dağılımının ve gelişiminin en üst düzeyde olduğu Ağustos 2004 tarihinde elde edilmiştir. Görüntüler, standart ürün formatındadır. Standart ürün formatına sahip olan görüntülerde sensör ile ilgili düzeltmeler yapılmış, radyometrik ve geometrik hatalar düzeltilmiş ve görüntüler kartografik projeksiyon sistemine uygun hale getirilmiştir. Hesaplamalarda kolaylık sağlamak için 8 bitlik QuickBird görüntüsünün yaklaşık 5 km² lik bir bölümü kullanılmıştır. Renkli QuickBird görüntüsü mavi, yeşil, kırmızı ve yakın kızıl ötesi olmak üzere dört banttan oluşmaktadır. Çalışmada kullanılan Brovey, RDP, İyileştirilmiş YoRD dönüşümü, Dalgaboyu tabanlı YoRD dönüşümü yöntemleri üç bant ile sınırlıdır. Bu nedenle karşılaştırma işlemi için çalışmada yeşil, kırmızı ve yakın kızıl ötesi bantları kullanılmıştır. Kullanılan yeşil, kırmızı ve yakın kızıl ötesi bantlar alandaki ürün çeşitliliğini açıklamada mavi banttan daha etkilidir (Özdarıcı, 2005).

Analizlerde kullanılan bir diğer veri alanda yetiştirilen ürünlere ait parsel bilgilerini içeren vektör veridir. Vektör veri 2002 yılında Arıkan tarafından yapılan bir çalışma sonucunda kadastral bilgileri kullanılarak üretilmiş ve 2005 yılında Özdarıcı tarafından yapılan bir çalışma ile güncellenerek bu çalışmaya girdi sağlamıştır (Arıkan, 2003; Özdarıcı, 2005). Sözü edilen çalışmalar yoluyla elde edilen vektör veri çalışmanın görüntü sınıflandırması ve doğruluk analizi aşamasında kullanılmıştır.



(a)



(b)

Şekil 2. (a) 13 Ağustos 2004 tarihine ait siyah-beyaz (a) ve renkli (b) QuickBird görüntüleri

3. YÖNTEM

Bu bölümde çalışmada kullanılan yöntemler açıklanmıştır. İlk bölümde görüntü zenginleştirme yöntemleri incelenecektir. İkinci bölümde, zenginleştirilmiş görüntüler üzerinde uygulanan görüntü sınıflandırma yöntemi anlatılacaktır. Son olarak sınıflandırma işlemi sonunda üretilen tematik haritalara ait sonuçlar ortaya koyulacaktır.

3.1 Görüntü Zenginleştirme Yöntemleri

Başarılı bir görüntü zenginleştirme, görüntülerin birbirine göre geometrik olarak hassas bir şekilde yönelimlerini gerektirir. Analizlerde kullanılan QuickBird görüntüleri birbirlerine göre düzeltilmiş olarak elde edilmiştir. Görüntüler aynı tarihte ve zamanda çekildikleri için iki veri arasında zaman farkı yoktur. Çalışmada literatürde sıkça karşılaşılan Renk-Doygunluk-Parlaklık dönüşümü (RDP), Brovey, İyileştirilmiş Yoğunluk-Renk-Doygunluk (YoRD) dönüşümü, Ana Bileşenler Spektral görüntü zenginleştirme yöntemi, Gram-Schmidt, En Küçük Kareler, Yüksek Frekans Filtreleme yöntemi, Dalgaboyu tabanlı Ana Bileşenler Yöntemi ve Dalgaboyu tabanlı YoRD görüntü zenginleştirme yöntemleri değerlendirilmiştir. Yöntemlere ait açıklamalar aşağıda yer almaktadır.

3.1.1 Renk-Doygunluk-Parlaklık (RDP) Dönüşümü

RDP dönüşümü Yoğunluk-Renk-Doygunluk (YoRD) dönüşümü ile benzer özellikler göstermektedir. Yöntem, Kırmızı-Mavi-Yeşil (KMY) uzayının RDP uzayına dönüştürülmesi ile başlar. Bu dönüşüm, görüntü zenginleştirme sürecinde renkler üzerinde yüksek kontrol olanağı sağlar. Dönüşümü, parlaklık (P) ve yüksek mekansal çözünürlüğe sahip bantların yer değiştirmesi izler. Bu işlem, renk (R) ve Doygunluk (D) bantlarına ait piksellerin yüksek mekansal çözünürlüğe dönüştürülmesi (resampling) ile devam eder. Son aşamada, RDP uzayı RGB uzayına tekrar dönüştürülerek görüntü zenginleştirme işlemi tamamlanır (ENVI kılavuzu). RDP dönüşümü 3 banta sahip görüntüler üzerinde uygulanabilmektedir.

3.1.2 Brovey Dönüşümü

Brovey dönüşümünde yüksek ve düşük mekansal çözünürlüklü veri özellikleri biraraya getirilerek bu görüntülerden yeni bir görüntü elde etmek için basit bir oran kullanılır. Bu oran, düşük mekansal çözünürlüğe sahip bantların yüksek mekansal çözünürlüğe sahip bant ile çarpılması ve sonucun düşük mekansal çözünürlüklü bantların toplamına bölünmesi şeklinde olmaktadır (Eşitlik 1). Bu işlem düşük mekansal çözünürlüklü bantların uygun bir yeniden örnekleme yöntemi (örn. En yakın komşuluk, bilinear, cubic convolution) yardımıyla yüksek mekansal çözünürlüğe dönüştürülmesi ile son bulmaktadır (ENVI kılavuzu). Brovey dönüşümü 3 bant ile sınırlıdır.

$$DN_{fused_i} = \frac{DN_i \times DN_{pan}}{\sum_{i=1}^N DN_i} \quad (1)$$

eşitlikte;

DN_i renkli görüntüye ait bantların piksel değerleri ($i=1,2,3$), DN_{pan} yüksek mekansal çözünürlüklü veriye ait piksel değeri; N renkli görüntüdeki bant sayısı ($Bant1+Bant2+Bant3$).

3.1.3 İyileştirilmiş YoRD Dönüşümü

YoRD dönüşümü, zenginleştirme işlemi uygulanacak görüntüleri RGB uzayından YoRD uzayına dönüştürerek bantlar arasındaki mekansal korelasyonu algılamada kolaylık sağlar. YoRD uzayını oluşturan yoğunluk değeri; parlaklığı, renk değeri baskın olan rengi, doyumluk ise gri değere göre olan saflığı ifade eder (Lillesand, 2005). Renkli görüntünün YoRD uzayına dönüştürülmesini dönüşüm sonucunda elde edilen yoğunluk değeri ile yüksek mekansal çözünürlüklü görüntünün yer değiştirmesi takip eder. Ardından renk ve doyumluk, siyah-beyaz görüntünün sahip olduğu mekansal çözünürlüğe dönüştürülür. Bu işlemi YoRD uzayından KYM uzayına geçmeyi sağlayan ters dönüşüm işlemi takip eder ve zenginleştirme işlemi tamamlanır (Siddiqui, 2003).

YoRD dönüşümü, yüksek mekansal çözünürlüğe sahip görüntüye ait detayların korunmasında etkili bir yöntem olmasına rağmen bu yöntem ile üretilen zenginleştirilmiş görüntüler sadece siyah-beyaz görüntü ile yoğunluk değerinin benzerlik gösterdiği durumlarda geçerlidir. Fakat renkli görüntüye ait yoğunluk değeri her zaman yüksek mekansal çözünürlüklü görüntüler ile benzer özellikler göstermeyebilir. Bu nedenle daha güvenilir sonuçlar elde etmek için alternatif olarak iyileştirilmiş YoRD dönüşümü geliştirilmiştir.

İyileştirilmiş YoRD dönüşümünde amaç görüntünün KYM uzayına dönüştürülmesinden önce yüksek mekansal çözünürlüklü görüntüye ait istenmeyen piksellerin filtelenmesidir. Yöntem, basit bir oran hesabına dayanır. Amaç, yüksek mekansal çözünürlüklü görüntünün renkli görüntüye ait yoğunluk değerine benzetilmesidir (Eşitlik 2) (ERDAS Kılavuzu). İyileştirilmiş YoRD dönüşümü 3 banta sahip görüntüler üzerinde uygulanabilmektedir.

$$r_l = \frac{\alpha_r d_r + \alpha_g d_g + \alpha_b d_b}{\sum_j \beta_j d_j} \quad (2)$$

eşitlikte

r_l = yoğunluk iyileştirme oranı
 α_r = kırmızı banttaki piksel değerine ait katsayı payı
 d_r = kırmızı banta ait piksel değeri
 α_g = yeşil banttaki piksel değerine ait katsayı payı
 d_g = yeşil banta ait piksel değeri
 α_b = mavi banttaki piksel değerine ait katsayı payı
 d_b = mavi banta ait piksel değeri
 β_i = j bantındaki piksel değerine ait katsayı payı
 d_j = j bantına ait piksel değeri

j bantı, yüksek mekansal çözünürlüğe sahip verinin kapsadığı spektral aralığı temsil eden düşük mekansal çözünürlüklü bantları ifade eder.

3.1.4 Ana Bileşenler Görüntü Zenginleştirme Yöntemi

Renkli görüntülere ait bantlar birbirlerine göre genellikle benzer bilgiler içerir. Ana Bileşenler görüntü zenginleştirme yönteminin amacı, bu bantlardan birbirinden bağımsız doğrusal kombinasyonlar üretmek ve bu sayede bantlar arasında tekrarlanan bilgiyi en aza indirmektir. Bu dönüşüm sonucunda birbirine dik akslar üretilir. İşlem, görüntünün gerçek uzayına (RGB uzayı) dönüştürülmesi ile son erer.

Ana Bileşenler görüntü zenginleştirme yöntemi, düşük ve yüksek mekansal çözünürlüklü görüntülerin zenginleştirilmesi için kullanılan etkili bir yöntemdir. İlk olarak, görüntüye Ana Bileşenler dönüşümü uygulanır. Bir sonraki işlem, bu dönüşüm sonucunda üretilen ilk bandın (Ana Bileşen 1) yüksek mekansal çözünürlüklü veri ile yer değiştirmesidir. Bu aşamada, üretilen ilk ana bileşenin yüksek mekansal çözünürlüklü veri özelliklerine yakın olduğu varsayımından yola çıkılır. Bu işlemi, spektral bilgi üzerinde olabilecek hataları önlemek amacıyla siyah-beyaz görüntünün ilk ana bileşen bandına göre ölçeklenmesi takip eder. Ardından ters dönüşüm uygulanarak görüntü gerçekte bulunduğu uzaya (KYM) dönüştürülür. Son aşama, renkli görüntüye ait bantların yüksek mekansal çözünürlüğe dönüştürülmesi işlemidir (ENVI Kılavuzu). Ana Bileşenler görüntü zenginleştirme yöntemi 3 ve 3'ten fazla banta sahip görüntüler için uygulanabilmektedir.

3.1.5 En Küçük Kareler Görüntü Zenginleştirme Yöntemi

En Küçük Kareler görüntü zenginleştirme yöntemi iki temel problemi çözmeyi hedeflemiştir. Bu problemlerden biri renk bozulmaları, diğeri kullanıcı ve veri bağımlılığıdır. Diğer görüntü zenginleştirme yöntemlerinde olduğu gibi En Küçük Kareler görüntü zenginleştirme yöntemi de gerçek renkli görüntü ve zenginleştirilmiş görüntü arasında en iyi etkileşimi kurmayı hedefler. Bu amaç doğrultusunda görüntü zenginleştirme işlemi standart ve otomatik hale getirmek için bir takım istatistiksel yöntemlere başvurur. En Küçük Kareler görüntü zenginleştirme yönteminin uygulanmasında kullanılan istatistiksel yöntemlere ilişkin literatürde net bir bilgi bulunmamaktadır (PCI Geomatica Kılavuzu). Gram-Schmidt görüntü zenginleştirme yöntemi 3 ve daha fazla banta sahip görüntüler üzerinde uygulanabilmektedir.

3.1.6 Gram-Schmidt Görüntü Zenginleştirme Yöntemi

Gram-Schmidt görüntü zenginleştirme yöntemi ismini matematik biliminde sıkça karşılaşılan Gram-Schmidt teoreminden almıştır. Gram-Schmidt, doğrusal cebirde kullanılan önemli bir yöntemdir ve bir uzayı oluşturan vektörlerin birbirine göre dik hale getirilmesi için kullanılır. Bu işlem, veri üzerinde daha fazla kontrol imkanı sağlar.

Yöntemde ilk olarak, yüksek mekansal çözünürlüğe sahip veriyi düşük mekansal çözünürlüğe dönüştürmek için siyah-beyaz görüntünün simülasyonu yapılır. Ardından simülasyon işlemi uygulanmış siyah-beyaz veriye ve renkli görüntüye ait spektral bantlara Gram-Schmidt dönüşümü uygulanır. Bu dönüşümde simülasyon işlemi uygulanmış yüksek çözünürlüklü bant, sıralamada ilk sırada yer alır. Gerçek yüksek mekansal çözünürlüklü banta ait istatistikler Gram-Schmidt dönüşümü uygulanmış ilk banta adapte edilir ve gerçek yüksek mekansal çözünürlüklü bant Gram-Schmidt dönüşümü sonucu elde edilen ilk bantın yerini alır. Yüksek mekansal çözünürlüğe sahip yeni

bantlar üretmek için ters dönüşüm işlemi uygulanarak zenginleştirme işlemi tamamlanır (Laben ve ark. 2000; ENVI Kılavuzu).

3.1.7 Yüksek Frekans Filtreleme Yöntemi

Yüksek Frekans Filtreleme yöntemi yüksek ve düşük mekansal çözünürlüklü görüntüleri filtreleme tekniği yardımıyla zenginleştirmektedir. Yöntem, görüntüleri oluşturan piksellerin okunması ve R değerinin hesaplanması ile başlar. R değeri, renkli görüntüdeki piksel boyutunun siyah-beyaz görüntüdeki piksel boyutuna oranıdır. Bu oran QuickBird görüntüsü için 4 olarak hesaplanmıştır. R değeri hesaplandıktan sonra filtre boyutu belirlenerek yüksek mekansal çözünürlüğe sahip görüntü filtrelenir. Çalışmada kullanılan QuickBird görüntüsü için görüntü özellikleri ve R değeri dikkate alınarak 9×9 boyutunda bir filtre kullanılmıştır. Renkli görüntüye ait piksel boyutunun filtrelenmiş görüntünün piksel boyutuna dönüştürülmesi için renkli görüntü üzerinde yeniden örnekleme işlemi uygulanır. Ardından filtrelenmiş görüntü renkli görüntüye ait bantlara eklenir. İşlem, üretilen görüntünün gerçek renkli görüntüye ait istatistiksel değerlere benzetilmesi ile sona erer (ERDAS Kılavuzu). Yöntem, 3 ve daha fazla banta sahip görüntüler üzerinde uygulanabilmektedir.

3.1.8 Dalgaboyu Tabanlı Görüntü Zenginleştirme Yöntemi

Dalgaboyu tabanlı görüntü zenginleştirme yöntemi, Fourier dönüşümü ile benzer özellikler göstermektedir. Fourier dönüşümünde uzun dalga boyları (sinüs ve kosinüs) kullanılırken dalgaboyu tabanlı dönüşümlerde birbirinden farklı kısa dalgaboyları kullanılmaktadır. Bu nedenle yöntem, daha lokal işlemler üzerinde uygulanabilmektedir. Yöntemin en önemli noktalarından bir tanesi, temel dalga boylarının belirlenmesi aşamasıdır. Dönüşüme giridi olacak sinyale (görüntü) birbirinin ardı sıra filtreleme işlemi uygulanır ve önemli parçalar belirlenerek görüntü temsil edilir. Bu işlem sayesinde farklı çözünürlükte birden fazla görüntü elde edilmektedir. Üretilen görüntülerdeki farklılıklar görüntüye ait detayları temsil eder. Çoklu mekansal çözünürlüğe sahip görüntüler KYM uzayına dönüştürülerek gerçek renkli görüntü elde edilebilir (Ranchin vd., 2003; ERDAS Manual). Aşağıda dalgaboyu tabanlı iki farklı görüntü zenginleştirme yöntemi açıklanmaktadır.

3.1.8.1 Dalgaboyu tabanlı YoRD Dönüşümü

Dalgaboyu tabanlı YoRD dönüşümü, görüntünün KYM uzayından YoRD uzayına dönüştürülmesi ve yoğunluk değerinin elde edilmesi ile başlar. Bu aşamayı, yüksek mekansal çözünürlüğe sahip görüntüye dalgaboyu dönüşümünün uygulanması takip eder. Dalgaboyu dönüşümü uygulanmış görüntü daha sonra yoğunluk bantı ile yer değiştirir. Son olarak ters dönüşüm işlemi uygulanarak görüntü KYM uzayına getirilir. Dalgaboyu tabanlı YoRD dönüşümü üç bant ile sınırlıdır.

3.1.8.2 Dalgaboyu tabanlı Ana Bileşenler Görüntü Zenginleştirme Yöntemi

Dalgaboyu tabanlı ana bileşenler görüntü zenginleştirme yönteminde görüntüye ilk olarak Ana Bileşenler dönüşümü uygulanır. Ana Bileşenler görüntü zenginleştirme yöntemi sonucunda üretilen ilk bileşen yüksek mekansal çözünürlüğe sahip görüntü ile yer değiştirir ve KYM uzayına geri dönüşüm gerçekleştirilir. Ana Bileşenler yöntemi üç ve daha fazla banta sahip görüntüler üzerinde uygulanabilmektedir.

Yukarıda açıklanan görüntü zenginleştirme yöntemleri yoluyla üretilen görüntüler *Görelî Ortalama ve Varyans Farkları, Korelasyon, En Yüksek Sinyal Hata Oranı ve Genel Kalite İndeksi* yardımıyla incelenmiştir. Değerlendirme yöntemleri zenginleştirilmiş görüntü çözünürlüğü olan 2.44m ye düşürülerek gerçekleştirilmiştir (Özdarıcı ve Akyürek, 2008).

3.2 Görüntü Sınıflandırması

Görüntü zenginleştirme yöntemlerinin ana amacı, görüntü üzerinde uygulanacak analizlere detaylı girdi sağlamak ve bu sayede güvenilir bilgi elde etmektir.

Bu aşamada, görüntü zenginleştirme yöntemi sonucunda elde edilen yüksek mekansal çözünürlüğe sahip renkli görüntüler gerçek renkli görüntü çözünürlüğü olan 2.44 m ye dönüştürülerek En Büyük Olasılık sınıflandırma yöntemi yardımıyla sınıflandırılmıştır. Görüntü zenginleştirme işlemi sonucunda elde edilen çözünürlük olan 0.60 m nin gerçek renkli görüntü çözünürlüğüne dönüştürülmesinin nedeni üretilen görüntülerin spektral olarak gerçek renkli görüntü ile karşılaştırılabilmesi ve bu sayede zenginleştirilmiş görüntüler üzerindeki spektral hataların bulunabilmesidir. Görüntülerin sınıflandırılmasında kullanılan yöntem, *En Büyük Olasılık* sınıflandırma yöntemi, görüntü üzerindeki bilinmeyen pikselleri bilgisayara tanıtılan örnek alanlara bağlı kalarak varyans ve kovaryans değerlerine göre gruplandırmaktadır (Lillesand et.al, 2004). *En Büyük Olasılık* sınıflandırma yöntemi yardımıyla mısır, buğday, anız, domates ve şeker pancarı olmak üzere beş ürün türü sınıflandırılmıştır. Sınıflandırma öncesinde uygun bir eşik değeri (2 piksel) atanarak parsel kenarlarına düşen pikseller gerçek renkli ve zenginleştirilmiş görüntülerden çıkarılmıştır. Parsel kenarlarına düşen piksellerin görüntülerden çıkarılmasının ardından sınıflandırma işlemi için gerçek renkli görüntü üzerinde örnek alanlar belirlenmiştir. Örnek alan seçimi homojen parseller üzerinden yapılmıştır. Bu alanların seçiminde görüntü üzerindeki spektral farklılıklar ve fenolojik olaylar dikkate alınmıştır. Toplanan alanlar, ayrılabilirlik indeksleri yardımıyla değerlendirilmiştir. Bu incelemeler sonucunda domates ve biberin ayrılma oranlarının düşük olduğu gözlenmiş ve bu iki ürün, domates sınıfı altında birleştirilmiştir. Sınıflandırma işlemi tamamlandıktan sonra bu görüntüler üzerinde Sieve filtresi uygulanmış ve bu sayede tematik haritalama sonucu ortaya çıkan istenmeyen büyüklükteki piksellerden oluşan poligonlar elimine edilmiştir. Filtre büyüklüğü bu çalışma için 20 piksel olarak belirlenmiştir. Filtreleme işleminin ardından tematik haritalar üzerinde doğruluk analizi yapılarak sonuçlar değerlendirilmiştir.

3.3 Doğruluk Analizi

Üretilen tematik haritaların gerçeğe yakın olup olmadığı hata matrisleri yardımıyla değerlendirilmiştir. Hata matrisi oluşturmak için alanın görüntü çekim tarihi ile eş zamanlı olarak elde edilen parsel bilgisini içeren referans veriden yararlanılmıştır. Sonuçlar üzerinde olabilecek önyargıyı önlemek için sınıflandırma işlemi için toplanan örnek alanlar

doğruluk analizine dahil edilmemiştir. Sınıflandırılmış görüntülerin doğruluklarını test etmek için alan üzerinde rastgele örnekleme yöntemi kullanılarak (*simple random sampling*) 557 nokta belirlenmiştir. Bu noktalar referans verideki gerçek bilgiler ile karşılaştırılarak hata matrisleri oluşturulmuştur. Doğruluk analizleri için belirlenen nokta sayısı, aşağıda verilen eşitliğe dayanmaktadır (Eşitlik 3) (Jensen, 2005).

$$N = \frac{B \prod_i (1 - \prod_i)}{b_i^2} \quad (3)$$

Eşitlikte yer alan;

N : örnek boyutu

\prod_i : alanda bulunan k sınıf içinde toplam alanın %50'sini

kapsamaya en yakın olan i sınıfının tüm alana oranını

b_i : i sınıfı için hedeflenen hassasiyet düzeyini (örn. %5),

B: 1 serbestlik derecesinde ve $(\alpha / k) \times 100$ formülüyle hesaplanan Ki kare (χ^2) tablosundaki değeri,

k : alanda bulunan toplam sınıf sayısını göstermektedir.

Rastgele örnekleme işlemi doğruluk analizi için on defa tekrarlanmış ve tüm görüntüler için aynı örnek noktalar kullanılmıştır. Bu sayede doğruluk analizi üzerinde olabilecek ön yargı en aza indirilmeye çalışılmıştır. Doğruluk analizleri sonucunda tematik haritalara ait genel hata ve kappa oranları ve ürünlere ait doğruluklar elde edilmiştir.

4. TARTIŞMA

Üretilen tematik haritalar için hata matrisleri oluşturulmuş, en küçük ve en büyük genel hata ve kappa oranları ile sınıflara ait doğruluk oranları hesaplanmıştır. Hata matrisleri sonucu ulaşılan genel hata ve Kappa sonuçlarına ait ortalama değerler tablo 2 de verilmektedir. Tablo 2 de verilen değerler Kappa sonuçlarına göre büyükten küçüğe doğru sıralanmıştır.

Sınıflandırma sonuçları Gram-Schmidt, İyileştirilmiş YoRD dönüşümü, Dalgaboyu tabanlı YoRD dönüşümü, En Küçük Kareler yöntemi, Ana Bileşenler Spektral görüntü zenginleştirme yöntemi, Yüksek Frekans Filtreleme yöntemi, Brovey dönüşümü ve Dalgaboyu tabanlı Ana Bileşen dönüşümünün gerçek renkli görüntüye ait sınıflandırma doğruluğunu arttırdığını göstermiştir. Buna karşılık RDP yönteminin gerçek renkli görüntüye ait sınıflandırma sonucunu yaklaşık %3 oranında düşürdüğü gözlenmiştir. Sınıflandırma sonuçlarına ait en yüksek oran, %83.4 genel doğruluk ve %79,2 Kappa değerleri ile Gram-Schmidt görüntü zenginleştirme yöntemi tarafından sağlanmıştır. Gram-Schmidt görüntü zenginleştirme yöntemi, gerçek renkli görüntüye ait sınıflandırma doğruluğunu yaklaşık %3 oranında arttırmıştır. Gram-Schmidt yöntemine en yakın sonucu %83,4 genel doğruluk ve %79,14 Kappa oranları ile İyileştirilmiş YoRD dönüşümü sağlamıştır. Bu yöntemleri, gerçek renkli görüntü sonucuna yaklaşık %2 lik artış sağlayan Dalgaboyu tabanlı YoRD dönüşümü, En Küçük Kareler yöntemi, Ana Bileşenler Spektral görüntü zenginleştirme yöntemi, Yüksek Frekans Filtreleme yöntemi ve Brovey dönüşümleri izlemiştir. Dalgaboyu tabanlı Ana Bileşenler görüntü zenginleştirme yöntemi %79,69 genel doğruluk ve % 77,49 Kappa sonucuyla

gerçek renkli görüntü sonucunu yaklaşık %1 oranında arttırmıştır.

görüntü için %76,57 doğruluk ile şeker pancarı tarafından sağlanmıştır.

Table 2. Görüntü sınıflandırması sonuçları

Image Classification Methods	Avg. Overall Accuracy (%)	Avg. Overall Kappa (%)
Gram Schmidt	83,4	79,2
İyileştirilmiş YoRD dönüşümü	83,4	79,14
Dalgaboyu tabanlı YoRD dönüşümü	82,99	78,63
En Küçük Kareler	82,95	78,55
Ana Bileşenler Spektral	82,84	78,36
Yüksek Frekans Filtreleme y.	82,41	77,9
Brovey	82,77	78,3
Dalgaboyu tabanlı PCA	79,69	77,49
Renkli QuickBird görüntüsü	81,03	76,2
RDP	78,97	73,35

Ürnlere ait en yüksek hata oranları şekil 3 de verilmektedir. Şekil 3a da yer alan siyah kutucuklar, görüntüler üzerinden toplanan örnek alanları göstermektedir. Gerçek renkli görüntüye ait sonuçlar, en düşük üretici doğruluğunun %78,26 ile mısır bitkisi tarafından sağlandığını göstermektedir. Diğer taraftan en düşük kullanıcı doğruluğu yaklaşık %75 ile domates ve şeker pancarı bitkileri için hesaplanmıştır.



Genel Doğruluk Oranı		84.2%
Genel Kappa Oranı		80.2%
	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)
Anız	81.65	92.70
Buğday	92	86.79
Mısır	78.26	91.52
Domates	89.28	75.18
Ş.Pancarı	81.63	76.92

(a)

Gram-Schmidt görüntü zenginleştirme yöntemi bütün ürünler için %80 in üzerinde üretici doğruluğu ortaya koymuştur. En düşük kullanıcı doğruluğu bu yöntem ile sınıflandırılmış



Genel Doğruluk Oranı		87.61%
Genel Kappa Oranı		84.5%
	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)
Anız	82.59	95.74
Buğday	94	89.52
Mısır	85.50	91.47
Domates	90.17	85.59
Ş.Pancarı	86.73	76.57

(b)

En Küçük Kareler yöntemi de Gram-Schmidt yöntemine yakın sonuçlar göstermiştir. En düşük üretici ve kullanıcı doğrulukları bu yöntem için %79,16 ile şeker pancarı bitkisi için hesaplanmıştır.



Genel Doğruluk Oranı		86.35%
Genel Kappa Oranı		82.8%
	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)
Anız	84.69	95.40
Buğday	87.37	87.37
Mısır	85.29	89.23
Domates	93.54	82.27

(c)

Ana Bileşenler görüntü zenginleştirme yöntemine ait üretici ve kullanıcı doğrulukları incelendiğinde bu yöntemine ait en düşük üretici doğruluğunun %67,70 ile şeker pancarı bitkisi tarafından sağlandığı görülmektedir. Yönteme ait en düşük kullanıcı doğruluğu %75,32 ile domates bitkisi için hesaplanmıştır.



Genel Doğruluk Oranı	86.35%	
Genel Kappa Oranı	82.8%	
	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)
Anız	84.69	93.25
Buğday	91.26	86.23
Mısır	90.44	91.79
Domates	93.54	75.32
Ş.Pancarı	67.70	91.54

(d)

Yüksek Frekans Filtreleme yöntemi yardımıyla üretilen görüntüler için bulunan sonuçlar, mısır ve şeker pancarı bitkisine ait üretici doğruluklarının yaklaşık %79 ile en düşük seviyede olduğunu göstermiştir. Bu ürünler için bulunan kullanıcı doğrulukları yaklaşık %90 olarak hesaplanmıştır. En düşük kullanıcı doğruluğu %74,51 ile domates bitkisi tarafından sağlanmıştır.



Genel Doğruluk Oranı	86.17%	
Genel Kappa Oranı	82.6%	
	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)
Anız	91.83	92.78
Buğday	89.32	86.79
Mısır	79.41	90.75
Domates	91.93	74.51
Ş.Pancarı	79.16	92.68

(e)

İyileştirilmiş YoRD dönüşümü kullanılarak elde edilen sonuçlar en düşük üretici ve kullanıcı doğruluklarının şeker pancarı bitkisi için yaklaşık %75 olarak hesaplanmıştır.



Genel Doğruluk Oranı	85.99%	
Genel Kappa Oranı	82.4%	
	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)
Anız	90.81	90.81
Buğday	86.40	91.75
Mısır	88.23	93.75
Domates	87.09	80.59
Ş.Pancarı	76.04	73

(f)

Brovey dönüşümü sonucu elde edilen görüntü üzerinde uygulanan doğruluk analizi sonuçları, en düşük üretici doğruluğunun %65,93 doğruluk payı ile anız için, en düşük kullanıcı doğruluğunun ise %79,03 ile buğday bitkisi için hesaplandığını göstermiştir. Brovey dönüşümü sonucunda elde edilmiş bulgular, bu yöntem ile elde edilmiş görüntünün diğer yöntemlerden farklı sınıflandırma sonuçları olduğunu ortaya koymuştur.



Genel Doğruluk Oranı	85.4%	
Genel Kappa Oranı	81.7%	
	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)
Anız	65.93	96.77
Buğday	87.50	79.03
Mısır	86.89	86.89
Domates	92.79	83.06
Ş.Pancarı	90.81	87.25

(g)

Dalgaboyu tabanlı görüntü zenginleştirme yöntemi de üretici doğrulukları açısından Brovey dönüşümü ile benzer özellikler göstermiştir. Bu yöntem sonucu üretilen en düşük üretici doğruluğu %65,93 ile anız bitkisi için hesaplanmıştır. Diğer taraftan en düşük kullanıcı doğruluğu %72,32 ile şeker pancarı bitkisi tarafından sağlanmıştır.



Genel Doğruluk Oranı	85.1%	
Genel Kappa Oranı	81.3%	
	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)
Anız	79.09	93.54
Buğday	89.65	82.97
Mısır	83.80	90.84
Domates	88.61	85.82
Ş.Pancarı	85.26	72.32

(h)

Genel doğruluk oranları incelendiğinde Dalgaboyu tabanlı Ana Bileşenler görüntü zenginleştirme yönteminin gerçek renkli görüntüye ait sınıflandırma sonucunu yaklaşık %1 (genel hata) oranında düşürdüğü gözlenmiştir. Bu yöntem sonucunda üretilen tematik haritanın genel Kappa oranı gerçek renkli görüntü sonucunu aynı oranda arttırmıştır. En küçük üretici ve kullanıcı doğrulukları bu yöntem için sırasıyla 70,33% ve 77,93% olarak anız ve mısır ürünleri için hesaplanmıştır. En düşük kullanıcı doğruluğu gerçek renkli görüntü ile benzerlik gösterecek şekilde %75 olarak domates ve şeker pancarı bitkilerinden elde edilmiştir.



Genel Doğruluk Oranı	82.22%	
Genel Kappa Oranı	77.6%	
	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)
Anız	70.33	98.46
Buğday	89.28	81.96
Mısır	77.93	86.26
Domates	88.28	74.24
Ş.Pancarı	84.69	77.57

(i)

En düşük sınıflandırma sonuçları RDP dönüşümü uygulanmış görüntüden elde edilmiştir. RDP dönüşümü uygulanan görüntüye ait en düşük üretici doğrulukları sırasıyla %72,47 ve %63 ile anız ve buğday bitkileri için hesaplanmıştır. En düşük kullanıcı doğruluğu yaklaşık %75 doğruluk payı ile buğday ve mısır bitkilerinden sağlanmıştır.



Genel Doğruluk Oranı		81.6%
Genel Kappa Oranı		76.9%
	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)
Anız	72.47	90.80
Buğday	63	75.90
Mısır	90.58	73.09
Domates	91.96	83.06
Ş.Pancarı	86.73	92.39

(j)

Figure 6 (a) Renkli QuickBird görüntüsü (b) Gram-Schmidt, (c) En Küçük Kareler, (d) Ana Bileşenler Spektral, (e) Yüksek Frekans Filtreleme, (f) İyileştirilmiş YoRD, (g) Brovey, (h) Dalgaboyu tabanlı YoRD, (i) Dalgaboyu tabanlı Ana Bileşenler, (j) RDP dönüşümü

Sonuçlar, Brovey ve RDP dönüşümleri dışında kalan görüntü zenginleştirme yöntemlerinin alanda yetiştirilen ürünleri güvenilir bir şekilde ayırdığını göstermiştir. En düşük ayrılabilirlik domates ve şeker pancarı ürünleri arasında gözlenmiştir. Diğer taraftan, gerçek renkli görüntü ile Brovey ve RDP dönüşümleri sonucu üretilen görüntüler arasında spektral açıdan farklılıklar olması bu yöntemler sonucunda üretilen görüntüler üzerine düşen örnek alanların diğer görüntülerden farklı olmasına ve ürünlerin farklı sınıflara atanmasına yol açmıştır.

QuickBird görüntülerine uygulanan zenginleştirme yöntemlerinden, Brovey, RDP, Dalgaboyu tabanlı YoRD ve İyileştirilmiş YoRD dönüşümleri 3 bant ile sınırlıdır. Bu özellik, görüntü zenginleştirme yöntemlerine katkı sağlayacak bilgi miktarını kısıtlamakta ve zenginleştirme sonrasında uygulanacak analizlerin performansını olumsuz yönde etkilemektedir. Bunun nedeni geniş spektral aralığa sahip olan görüntülerin dar aralığa sahip olanlardan daha fazla bilgi sunma kapasitesine sahip olmasıdır.

Ana Bileşenler Spektral ve Dalgaboyu tabanlı Ana Bileşenler görüntü zenginleştirme yöntemleri görüntülere Ana Bileşen dönüşümünün uygulanması ile gerçekleştirilebilmektedir. Fakat görüntüye Ana Bileşen dönüşümünün uygulanması bir takım problemleri de beraberinde getirmektedir. Ana Bileşen dönüşümünün doğrusallık mantığı ile çalışması ve Gaussian

dağılımını esas alması bu dağılıma uymayan çoklu moda sahip veriler üzerinde güvenilir sonuçlar ortaya koymada olumsuz yönde etkili olabilmektedir. Bu nedenle yöntemin uygulanacağı görüntü özelliklerinin dikkate alınması gerekmektedir.

5. SONUÇLAR

Çalışmada 9 farklı görüntü zenginleştirme yöntemi incelenmiş ve bu yöntemlerin görüntü sınıflandırması üzerindeki etkileri değerlendirilmiştir. Kullanılan görüntü zenginleştirme yöntemleri; Gram-Schmidt, En Küçük Kareler, RDP, Brovey, İyileştirilmiş YoRD, Ana Bileşenler Spektral, Yüksek Frekans Filtreleme Yöntemi, Dalgaboyu tabanlı YoRD dönüşümü ve Dalgaboyu tabanlı Ana Bileşenler görüntü zenginleştirme yöntemleridir. Yöntemler, hesaplamalarda kolaylık sağlamak amacıyla yaklaşık 5 km² lik QuickBird görüntüleri üzerinde uygulanmıştır. Analizlerde siyah-beyaz ve yeşil, kırmızı ve yakın kızıl ötesi bantlarından oluşan QuickBird renkli görüntüleri kullanılmıştır. Zenginleştirilmiş görüntüler, *Görel Ortalama ve Varyans Farkları, Korelasyon, En Yüksek Sinyal Hata Oranı ve Genel Kalite İndeksi* kullanılarak spektral açıdan değerlendirilmiştir. Sonuçların istatistiksel olarak değerlendirilmesinin ardından gerçek renkli görüntü ve zenginleştirilmiş görüntüler En Büyük Olasılık sınıflandırma yöntemi yardımıyla sınıflandırılmıştır. Görüntü sınıflandırması için gerekli örnek alanlar renkli QuickBird görüntüsü üzerinden toplanmıştır. Üretilen zenginleştirilmiş görüntüler ve renkli QuickBird görüntüsü daha sonra örnek alanlar yardımıyla sınıflandırılmış ve sonuçlar hata matrisleri yardımıyla değerlendirilmiştir. Hata matrisleri sonucunda hesaplanan kappa değerleri %79,2 doğrulukla en yüksek doğruluğu Gram-Schmidt görüntü zenginleştirme yönteminin sağladığını göstermiştir. Gram-Schmidt yöntemi, gerçek renkli görüntünün sınıflandırılması sonucu üretilen tematik haritanın doğruluğunu yaklaşık %3 oranında arttırmıştır. İyileştirilmiş YoRD dönüşümü, Dalgaboyu tabanlı YoRD dönüşümü, En Küçük Kareler, Ana Bileşenler Spektral, Keskinleştirilmiş Filtreleme Yöntemi, Brovey ve Dalgaboyu tabanlı Ana Bileşenler yöntemlerinin de gerçek renkli görüntüye ait tematik harita doğruluğunu belli oranlarda arttırdığı gözlenmiştir. Diğer taraftan RDP dönüşümü kullanılarak üretilen tematik harita doğruluğu gerçek renkli görüntüye ait doğruluğu %1 oranında düşürmüştür.

Sonuçlar Gram-Schmidt, İyileştirilmiş YoRD dönüşümü, Dalgaboyu tabanlı YoRD ve Ana Bileşenler Zenginleştirme yöntemi, En Küçük Kareler, Ana Bileşenler Spektral, Yüksek Frekans Filtreleme Yöntemi ve Brovey dönüşümü kullanılarak elde edilmiş görüntülerin tarımsal alanlarda yetiştirilen ürün çeşitliliğini ayırmada etkili olduğunu göstermiştir. Görüntü zenginleştirme yöntemlerinin tarım alanlarında yetiştirilen ürün deseninin tesbit edilmesine olan katkısının belirlenebilmesi için yöntemlerin ürün çeşitliliğinin temsil edildiği farklı çalışma bölgelerine uygulanması yapılan çalışmanın güvenilirliğini arttıracaktır.

Kaynaklar

Ankan, M., 2003, A multitemporal masking classification method for field-based agricultural crop mapping. *Yüksek Lisans Tezi, Jeodezi ve Coğrafi Bilgi Teknolojileri EABD, Orta Doğu Teknik Üniversitesi, Ankara, Türkiye.*

Chavez, P. S., Sides, S. C., Anderson, J. A., 1991, Comparison of three different methods to merge multiresolution and multispectral data: Landsat TM and SPOT panchromatic, *Photogrammetric Engineering & Remote Sensing*, Vol. 57, pp. 295-303.

Colditz, R. R., Wehrmann, T., bachmann, M., Steinnocher, K., Schmidt, M., Strunz, G., and Dech, S., 2006, Influence of image fusion approaches on classification accuracy: a case study, *International Journal of Remote Sensing*, Vol. 27, pp. 3311-3335.

ENVI Kılavuzu v. 4.4

ERDAS Klavuzu v. 9.1

Jensen, J., 2005, "Introductory Digital Image Processing: A Remote Sensing Perspective", University of South Carolina, p. 501.

Karathanassi, V., Kolokousis, P., and Ioannidou, S., A comparison study on fusion methods using evaluation indicators, *International Journal of Remote Sensing*, Vol. 28, pp. 2309-2341.

Konstantinos, G. N., 2008, Comparison of nine fusion techniques for very high resolution data, *Photogrammetric Engineering & Remote Sensing*, Vol. 74, pp. 647-659.

Laben, E.A., 2000, Process for enhancing the spatial resolution of multispectral imagery using pan-sharpening (Gram-Schmidt). US Patent: USA, Eastman Kodak Company.

Lillesand, M., Kiefer, R. W., Chipman, J. W., 2004, Remote Sensing and Image Interpretation, *Fifth Edition*, John Wiley and Sons, Inc., USA.

Ozdarici, A., 2005, Comparison of Different Spatial Resolution Images for Polygon-Based Crop Mapping, *Yüksek Lisans Tezi, Jeodezi ve Coğrafi Bilgi Teknolojileri EABD, Orta Doğu Teknik Üniversitesi, Ankara, Türkiye.*

Özdarıcı ve Akyürek, 2008, Tarım Alanlarının Uydu Görüntülerinden Görsel Belirlenmesinde Görüntü Zenginleştirme Yöntemlerinin Etkileri, *Uzaktan Algılama ve Çğrefî Bilgi Sistemleri (UZAL CBS) Sempozyumu*, 13-15 Ekim, Kayseri, Türkiye.

PCI Geomatica Kılavuzu v. 10.1.3

Pellemans, A., Jordans, R., Allewijn, R., 1993, Merging multispectral and panchromatic SPOT images with respect to the radiometric properties of the sensor, *Photogrammetric Engineering & Remote Sensing*, Vol. 59, pp. 81-87.

Pohl, C., and Van Genderen, J. L., 1998, Multisensor image fusion in remote sensing: concepts, methods and applications, *International Journal of Remote Sensing*, Vol. 19, pp. 823-854.

Ranchin, T., Aiazzi, B., Alparone, L., Baronti, S., Wald, L., 2003, Image fusion-the ARSIS concept and some successful implementation schemes, *ISPRS Journal of Photogrammetry&Remote Sensing*, V. 58, pp. 4-18.

Siddiqui, Y., 2003, The modified IHS method for fusing satellite imagery, *ASPRS Annual Conference Proceedings*, Anchorage, Alaska.

Zhang, Y., 2002, Problems in the fusion of commercial high-resolution satellite as well as Landsat7 images and initial solutions, *Symposium on Geospatial Theory, Processing and Applications*, Ottawa.