

PAPER DETAILS

TITLE: Tarımsal alanlarda yüksek çözünürlüklü IKONOS uydu görüntüsünden nesne-tabanlı ürün deseni tespiti

AUTHORS: Beste TAVUS,Kamil KARATAS,Mustafa TÜRKER

PAGES: 603-614

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/834934>



Tarımsal alanlarda yüksek çözünürlüklü IKONOS uydu görüntüsünden nesne-tabanlı ürün deseni tespiti

Object-based crop pattern detection from IKONOS satellite images in agricultural areas

Beste TAVUS^{1*} , Kamil KARATAŞ² , Mustafa TÜRKER³

^{1,3}Geomatik Mühendisliği Bölümü, Mühendislik Fakültesi, Hacettepe Üniversitesi, Ankara, Türkiye.
bestetavus@gmail.com, mturker@hacettepe.edu.tr

²Harita Mühendisliği Bölümü, Mühendislik Fakültesi, Aksaray Mühendisliği Bölümü, Aksaray, Türkiye.
kkaratas42@gmail.com

Geliş Tarihi/Received: 22.05.2018, Kabul Tarihi/Accepted: 28.11.2018

* Yazışılan yazar/Corresponding author

doi: 10.5505/pajes.2018.25428
Araştırma Makalesi/Research Article

Öz

Günümüzde uzaktan algılama teknolojisi ve görüntü işleme tekniklerinin gelişmesiyle birlikte, uydu görüntüleri tarımsal alanlarda ürün deseninin belirlenmesi çalışmalarında sıklıkla tercih edilir hâle gelmiştir. Bu çalışmada, yüksek konumsal çözünürlüklü IKONOS uydu görüntüsünden tarımsal alanlarda nesne-tabanlı sınıflandırma yöntemi ile ürün deseninin belirlenmesi hedeflenmiştir. Çalışma alanı, Marmara Bölgesi'nde bulunan Bursa ili, Karacabey ilçesinin güneybatısında yer almakta ve yaklaşık 9×9 km²'lik bir alanı kapsamaktadır. Domates, mısır, biber, buğday, pirinç ve şeker pancarı bölgede yetiştirilen başlıca tarım ürünleridir. Çalışmada, IKONOS uydu görüntüsü çoklu-çözünürlük segmentasyon tekniği ile segmente edilmiştir. Segmentasyon işleminde gerekli parametrelerden en önemlisi olan ölçek parametresi için en uygun değer ESP-2 (Estimation of Scale Parameter) yazılımı ile belirlenmiştir. Diğer segmentasyon parametreleri olan şekil ve bütünlük parametreleri için en uygun değerler ise, yapılan deneme analizleri neticesinde tespit edilmiştir. Sınıflandırmanın doğruluğunu artırmak için, görüntünün orijinal bantlarına ek olarak, normalize edilmiş bitki indeksi (NDVI) bantı ile homojenlik, zıtlık, farklılık, ortalama, varyans ve entropi doku bantları kullanılmıştır. Sınıflandırma işlemi, toplam 29 bantlı veri seti kullanılarak eCognition yazılımında nesne-tabanlı en yakın komşuluk tekniği ile yapılmıştır. Elde edilen sınıflandırma sonucu, 2212 adet yer gerçeği verisi kullanılarak değerlendirilmiştir. Doğruluk analizleri neticesinde, sınıflandırmanın genel doğruluğu %87.5 olarak hesaplanmıştır. Elde edilen sonuçlar, yüksek çözünürlüklü IKONOS uydu görüntüsünden tarımsal ürün deseni tespitinin nesne-tabanlı sınıflandırma yöntemiyle yüksek doğrulukta belirlenebildiğini göstermektedir.

Anahtar kelimeler: Segmentasyon, Nesne-tabanlı sınıflandırma, Doku analizi

Abstract

Nowadays, with the development of remote sensing technologies and image processing methods, satellite images have become frequently preferred in studies to determine the crop pattern in agricultural areas. In this study, it is aimed to detection the crop pattern in agricultural areas with high accuracy by using object-based classification technique from high spatial resolution IKONOS satellite images. The study area is located on the South-west of the Karacabey district of the Bursa province in the Marmara Region and covers an area of nearly 9×9 km². Tomato, corn, pepper, wheat, rice and sugar beet are the main products grown in the region. In this study, the IKONOS satellite image is segmented using multi-resolution segmentation technique. The most appropriate value for the scale parameter, which is the most important parameter in the segmentation process, has been determined by ESP-2 (Estimation of Scale Parameter) software. Various combinations have been tried for shape and compactness parameters in order to find the optimal segmentation parameters. In order to increase classification accuracy, normalized difference vegetation index (NDVI) and GLCM texture measurement methods have been used, including homogeneity, contrast, dissimilarity, mean, variance, and entropy. Using the data set from consist 29 bands, the image classification process have been performed using the object-based nearest neighbor classification technique in the eCognition software. The obtained classification results have been tested on parcel basis using 2212 ground truth data. The overall accuracy of the classification has been calculated as 87.5%. The results show that the high spatial resolution IKONOS satellite image can be used to detection high accuracy with object-based classification of agricultural crop pattern.

Keywords: Segmentation, Object-based classification, Texture analysis

1 Giriş

Uzaktan algılama, görüntü işleme ve analizi tekniklerinin geliştirilmesiyle birlikte birçok alanda tercih edilen önemli bir veri kaynağı olmuştur. Son yıllarda özellikle, tarımsal ürün deseninin yüksek doğrulukla belirlenmesi, zamansal değişimlerinin izlenmesi ve bölgesel-küresel anlamda sürdürülebilir tarım alanlarının etkin yönetimi ile ilgili çalışmalarda önemli bir veri sağlayıcısı olarak sıklıkla tercih edilmektedir [1],[2].

Uzaktan algılamada bilgi elde etmek için en yaygın kullanılan yöntemlerin başında otomatik görüntü sınıflandırma ve öznitelik çıkarımı gelmektedir. Uzaktan algılamada genel

olarak görüntü sınıflandırma yöntemleri piksel tabanlı ve nesne tabanlı yöntemler olmak üzere ikiye ayrılmaktadır. Son yıllarda uydu görüntülerinin konumsal çözünürlüklerinin artması ile piksel tabanlı sınıflandırma yöntemleri, yüksek konumsal çözünürlüğe sahip uydu görüntülerinin sınıflandırılmasında düşük doğrulukta sonuçlar vermektedir. Bunun temel nedeni, çözünürlük artışına bağlı olarak görüntülerde heterojenliğin artması ve nesnelerin spektral benzerlikleridir [3]. Nesne-tabanlı sınıflandırma fikri görüntüdeki karakteristik doku, bağlam ve konumsal ilişkilerin diğer klasik yöntemlerde ihmal edilmesinden dolayı ortaya çıkmıştır [4]. Nesne tabanlı sınıflandırma işlemi, segmentasyon (bölütleme) ve sınıflandırma olmak üzere iki temel adımdan oluşmaktadır. Segmentasyon işleminde, görüntü üzerindeki

benzer spektral özelliklere sahip pikseller gruplandırılarak segmentler (görüntü nesneleri) oluşturulur. Oluşan segmentler, bir sonraki adım olan sınıflandırma aşaması için girdi veri olarak kullanılır. Sınıflandırma işleminde nesnelere ait yapı, doku ve konumsal ilişkiler vb. özellikler tanımlanarak kullanıcı tarafından seçilen yöntem ve kurallara göre sınıflandırılmaktadır.

Yapılacak sınıflandırma sonuçlarının doğruluğunu etkileyen birçok faktör bulunmaktadır. Bunların başında; görüntünün konumsal ve spektral özellikleri, uygun bant ve yardımcı veri seçimi, kullanılan veri analizi yöntemleri, çalışma alanının boyutu ve heterojenliği gelmektedir [5]. Özellikle tarımsal ürün sınıflarının belirlendiği çalışmalarda, sınıflandırma sonuçlarının doğruluğu üzerinde, tarım ürünlerinin spektral benzerliği ve görüntü çözünürlüğünün artışına bağlı olarak oluşan piksel heterojenliği oldukça etkili olmaktadır. Bu durumun etkisini azaltmak ve tarımsal ürün sınıflarının ayırt edilebilirliğini artırmak amacıyla, birçok çalışmada, spektral bilgiye ek olarak ürün karakteristikleri ve ekim şekillerinden dolayı oluşan doku özellikleri ve bitki endeksleri gibi yardımcı veriler kullanılmıştır [2],[6]. Örneğin; Kim ve diğ. [7] tarafından yapılan çalışmada, IKONOS uydu görüntüsüne gri seviye eş-oluşum matrisi (Gray Level Co-Occurrence Matrix-GLCM) ile hesaplanan doku özellikleri eklenerek nesne tabanlı sınıflandırma yöntemi ile yaprak döken, sürekli yeşil kalan ve karışık orman sınıfları belirlenmiştir. Farklı parametreler kullanılarak yapılan segmentasyon sonuçları nesne tabanlı yöntemler ile sınıflandırılmıştır. GLCM doku özellikleri kullanılmadan yapılan nesne tabanlı sınıflandırmanın başarı oranı %79 olarak belirlenirken, GLCM doku özellikleri kullanılarak yapılan nesne tabanlı sınıflandırmanın başarı oranı ise %83'e yükselmiştir.

Nesne tabanlı sınıflandırma yöntemi ile ürün deseni tespiti kapsamında yapılan çalışmalardan Bock ve diğ. [8] tarafından yapılan çalışmada, 30m konumsal çözünürlüğe sahip Landsat ve 0.7 m konumsal çözünürlüğe sahip QuickBird uydu görüntüleri yardımcı verilerle birlikte kullanılarak nesne tabanlı sınıflandırma yöntemi ile sınıflandırılmış ve 8 adet bitki örtüsü sınıfı belirlenmiştir. QuickBird uydu görüntüsü sınıflandırma başarı oranı %81 olarak belirlenmiştir. Çalışma sonucunda, düşük doğrulukta bitki örtüsü sınıflarını belirlemek için Landsat uydu görüntüsünün yeterli olduğu, bitki örtüsü sınıflarını daha yüksek doğrulukta belirlemek için ise yüksek çözünürlüklü QuickBird uydu görüntüsünün oldukça iyi performans gösterdiği belirtilmiştir. Yu ve diğ. [9] tarafından yapılan çalışmada, DAIS uydu görüntüsü kullanılarak 43 bitki örtüsü sınıfı nesne tabanlı sınıflandırma yöntemiyle belirlenmiştir. Sayısal yükseklik modeli, eğim ve bakı gibi yardımcı veriler de sınıflandırma işleminde kullanılmıştır. Her görüntü nesnesi için, spektral, doku, topografik ve geometrik olmak üzere toplam 52 özellik tanımlanmış ve sınıflandırma işlemi en yakın komşu sınıflandırma tekniği ile yapılmıştır. Çalışma sonucunda, 43 farklı bitki örtüsü sınıfı %60 doğrulukla belirlenmiştir. Çalışma sonucunda, eğitim alanlarının büyüklüğü ve belirlenme kalitesi, sınıflandırma işleminde kullanılan yöntemler ve bitki örtüsünün konumsal dağılımının sınıflandırma doğruluğu üzerinde oldukça etkili olduğu vurgulanmıştır. Conrad ve diğ. [2] tarafından yapılan çalışmada, pan-keskinleştirilmiş SPOT-5 uydu görüntüsünün segmentasyonu ile güncel parsel sınırları elde edilmiş ve bu parsel sınırları nesne tabanlı sınıflandırma sürecine dâhil edilerek ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer) verileri ile altı adet ürün sınıfı

belirlenmiştir. Önerilen yaklaşım ile elde edilen sınıflandırma başarı oranı %80 olarak belirlenmiştir. Türker ve Özdarıcı [10] tarafından yapılan çalışmada, aynı alana ait farklı çözünürlükteki uydu görüntülerinin sınıflandırma sonuçlarına etkisi araştırılmıştır. Bu SPOT4 MS, SPOT5 MS, IKONOS MS, QuickBird MS ve QuickBird PS uydu görüntülerinin parsel (field-based) tabanlı sınıflandırmasından elde edilen tarımsal ürün haritaları karşılaştırılmıştır. Çalışma alanında belirlenen 5 sınıf için vektör formatta bulunan parsel verileri sınıflandırma sürecine dâhil edilmiştir. Ayrıca, görüntü filtre etkisini gözlemlemek amacıyla farklı boyutlarda filtreler kullanılarak sonuçlara olan etkisi analiz edilmiştir. Sonuç olarak, elde edilmek istenen sınıflandırma başarı oranı %80 civarındaysa en uygun görüntünün SPOT5 MS, %85 civarında ise IKONOS MS, QuickBird MS ve QuickBird PS görüntülerinin kullanılabileceği tespit edilmiştir. Türker ve Özdarıcı [10] tarafından yapılan çalışmadan farklı olarak bu çalışmada, nesne tabanlı sınıflandırma yaklaşımı ile görüntü önce nesnelere ayrılmış ve görüntü bu nesneler üzerinden sınıflandırılmıştır. Sınıflandırma başarısını artırmak amacıyla, GLCM'den hesaplanan yardımcı doku verileri ve üretilen NDVI bantı segmentasyon ve sınıflandırma sürecine dâhil edilmiş ve sonuçlara etkisi analiz edilmiştir. Vektör formattaki parsel sınırları verisi ise, sınıflandırma başarı oranının belirlenmesi amacıyla kullanılmıştır.

Pena-Barragan ve diğ. [11] tarafından yapılan çalışmada, ürün türlerinin mevsimlere bağlı olarak değerlendirilmesi için nesne tabanlı görüntü analizi ve karar ağacı algoritmalarını birleştiren bir yöntem önerilmiştir. Bitkilerin üç farklı büyüme evresinde elde edilen ASTER uydu görüntüsü bantlarından üretilen çeşitli bitki endeksleri ve doku özellikleri kullanılarak 13 ürün sınıfı belirlenmiştir. Sınıflandırmada özellikle doku özellikleri ve NDVI kullanımının sınıflandırma doğruluğuna önemli derecede katkıda bulunduğu belirtilmiştir. Önerilen yöntem ile yapılan sınıflandırmanın başarı oranı %79 olarak belirlenmiştir. Koutsias ve diğ. [12] tarafından yapılan çalışmada, tarımsal bir alanda IKONOS ve ASTER uydu görüntüleri kullanılarak nesne tabanlı sınıflandırma ile 8 sınıf belirlenmiştir. Segmentasyon işleminden sonra segmentler için doku ve bağlamsal özellikler tanımlanarak en yakın komşu (NN) sınıflandırması yöntemi uygulanmış ve IKONOS uydu görüntüsünün sınıflandırma başarı oranı %82 olarak hesaplanmıştır. Algancı ve diğ. [13] tarafından yapılan çalışmada, çok tarihli 2.5 m, 5 m ve 10 m konumsal çözünürlüklü Spot-5 ve 30 m konumsal çözünürlüklü Landsat-5-TM görüntüleri kullanılarak parsel seviyesinde ürün çeşitliliğini analiz etmek için piksel ve nesne tabanlı sınıflandırma yöntemleri karşılaştırılmıştır. Çoklu çözünürlük segmentasyon ve NN sınıflandırmanın kullanılarak yapılan nesne tabanlı sınıflandırmanın başarı oranı %91.83 iken, piksel tabanlı sınıflandırmada en iyi sonucu, destek vektör makinaları (DVM) sınıflandırma yöntemi %80 kappa doğruluk değeri ile vermiştir.

Yakın zamanda Li ve diğ. [14] tarafından yapılan çalışmada, tarımsal alanlarda yüksek konumsal çözünürlüklü görüntüler kullanılarak, DVM, karar ağacı, NN ve rastgele orman sınıflandırma algoritmalarının da içinde bulunduğu 7 adet farklı nesne tabanlı sınıflandırma tekniğinin, iki farklı test alanında ve farklı ölçek parametreleri de denenerek, sistematik karşılaştırması yapılmıştır. Her iki çalışma bölgesi için, rastgele orman sınıflandırıcısı kullanılan ölçeklerin hepsinde en yüksek doğruluk sağladığı ve tarımsal alanlarda yapılacak çalışmalarda kullanılabilir olduğu belirtilmiştir. Singha ve diğ. [15]


tarafından yapılan çalışmada, spektral, konumsal ve fenolojik özelliklerin birlikte kullanılması ile pirinç tarlaları için nesne tabanlı bir görüntü analiz yaklaşımı sunulmaktadır. Çoklu çözünürlük segmentasyon ile elde edilen görüntü nesneleri bitki örtüsü endeksleri kullanılarak NN algoritması ile sınıflandırılmıştır. Önerilen nesne tabanlı görüntü analizi yaklaşımı sonucunda sınıflandırmanın başarı oranı %93 olarak belirlenmiştir. Ayrıca, fenolojik özelliklerin kullanılmasının sınıflandırma doğruluğunu %2 ile %4 arasında iyileştirdiği belirtilmiştir. Zhang ve diğ. [16] tarafından yapılan çalışmada, 4 ayrı tarihte çekilmiş SPOT-5 görüntülerinden tarım alanları (3 sınıf hâlinde) nesne-tabanlı yöntemle sınıflandırılmıştır. Sınıflandırmada, SPOT-5 görüntüsünden elde edilen bitki endeksleri, jeostatistiksel semivariogram doku ve GLCM'den hesaplanan doku özelliklerini içeren, toplam 440 özellik kullanılmıştır. Segmentasyon için farklı parametreler denenerek sonuçlar analiz edilmiş ve elde edilen segmentlerin tarım parsellerini iyi bir şekilde tanımladığı belirtilmiştir. Ürünlerin olgunluk dönemi olan Ağustos ayına ait SPOT-5 görüntüsü %94 başarı oranıyla en iyi sınıflandırma sonucunu sağlamıştır.

Yapılan geçmiş çalışmalar incelendiklerinde, son yıllarda yüksek ve orta konumsal çözünürlükteki uydu görüntülerinin yardımcı veriler ile desteklenerek parsel ya da nesne tabanlı sınıflandırma yöntemleri ile analiz edildiği görülmüştür. Bu çalışmanın amacı, pan-keskinleştirilmiş IKONOS uydu görüntüsü ve bu görüntüden üretilen yardımcı verileri, hem segmentasyon hem de sınıflandırma sürecinde kullanarak, nesne tabanlı sınıflandırma yöntemiyle ürün deseni tespiti yapmaktır. Bu amaçla, Bursa ili, Karacabey ilçesinin güneybatısında yer alan bir tarım alanına ait, IKONOS uydu görüntüsü, yer gerçeği ve mevcut parsel sınır verileri kullanarak, nesne tabanlı sınıflandırma yaklaşımı ile görüntü nesnelere ayrılmış ve bu nesneler üzerinden sınıflandırılmıştır. Sınıflandırma başarısını artırmak amacıyla, GLCM'den hesaplanan yardımcı doku verileri ve üretilen NDVI bantı da segmentasyon ve sınıflandırma sürecine dâhil edilmiş ve sonuçlara etkisi analiz edilmiştir.

Nesne tabanlı sınıflandırmanın ilk aşaması olan segmentasyon işlemi, segmentasyon sonuçlarını iyileştirmek amacıyla görüntü bantlarına NDVI verisinin de eklenmesiyle elde edilen 5 bantlı veri seti kullanılarak, eCognition yazılımında çoklu çözünürlük segmentasyon algoritması ile yapılmıştır. Bu parametrelerden en önemlisi olan ölçek parametresi için en uygun değer otomatik olarak ESP-2 yazılımı ile belirlenmiştir. Diğer parametreler olan şekil ve bütünlük parametreleri için en uygun değerler ise çeşitli kombinasyonlar denenmek suretiyle belirlenmiştir. Elde edilen segmentlerin doku özelliklerinin hesaplanması amacıyla, GLCM'den hesaplanan 6 adet doku ölçüm yöntemi belirlenmiş ve IKONOS uydu görüntüsünün bantlarına uygulanmıştır. Tüm yönlerde ve 5*5 filtre boyutu kullanılarak hesaplanan doku bantlarının ortalaması alınmış ve toplamda 24 adet doku bandından oluşan yardımcı veri seti elde edilmiştir. Sınıflandırma işlemi, uydu görüntüsü mavi, yeşil, kırmızı ve yakın kızılötesi bantları, NDVI bantı ve 24 adet doku bandından oluşan toplam 29 bantlı veri seti kullanılarak, eCognition yazılımında nesne-tabanlı en yakın komşuluk tekniği ile yapılmıştır. Sınıflandırmanın doğruluğu, 2212 adet yer gerçeği ve mevcut parsel sınırları verisi kullanılarak, %87.5 olarak hesaplanmıştır.

Bu çalışmanın diğer çalışmalardan farkı, ürün deseni tespitinin nesne tabanlı yöntemlerle belirlenmesidir. Literatürdeki mevcut çalışmaların sonuçlarının, farklı alanlarda ve farklı

konumsal çözünürlüklere sahip uydu görüntülerinin farklı yöntemler ile değerlendirilmiş olmasıyla birlikte, bu çalışmanın sonuçları ile karşılaştırması Şekil 1'de verilmiştir. Şekil 1'de de görüldüğü üzere, bu çalışmanın genel başarı oranı verilen on adet geçmiş çalışmanın altısından yüksek, biriyle çok yakın ve kalan 3'ünden ise düşük olarak belirlenmiştir. Buna göre, elde edilen sonuçlar ve yapılan karşılaştırmalar, bu çalışmada önerilen yaklaşımın kabul edilebilir ve uygulanabilir olduğunu göstermektedir.



Şekil 1: Literatürde incelenen çalışmaların başarı oranları grafiği.

2 Materyal ve yöntem

2.1 Çalışma alanı

Çalışma alanı, Marmara bölgesinde bulunan Bursa ili, Karacabey ilçesinin güneybatısında yer almakta ve 9×9 km²'lik bir alanı kapsamaktadır. Alan, 40° 08' 33"-40° 13' 22" Kuzey Enlemleri ile 28° 10' 15"-28° 16' 28" Doğu Boylamları arasında bulunmaktadır (Şekil 2).



Şekil 2: Çalışma alanının konumu.

Çalışma alanında toplam 4128 adet parsel bulunmaktadır. Bölgede 1988-1992 yılları arasında arazi toplulaştırma çalışması yapıldığı için çoğu parsel dikdörtgen şeklindedir. Çalışma alanındaki tarım parsellerinin alanlarına göre dağılımı Tablo 1'de verilmiştir.

Tablo 1: Parsellerin alanlarına göre dağılımı [10].

Parsel Sayısı	Alan (da)	Yüzde (%)
929	0.074-4.9	22.5
1034	5-9.9	25.0
1850	10-49.9	44.9
216	50-99.9	5.9
99	100-479.9	2.4

Bölgede domates, mısır, biber, buğday, pirinç ve şeker pancarı yetiştirilen temel ürünler arasında yer almaktadır. Ürünlerin fenolojik özellikleri Tablo 2'de verilmektedir.

Tablo 2: Çalışma alanında yetiştirilen tarım ürünlerinin yüzey örtü oranları [10].

	Oca	Şub	Mar	Nis	May	Haz	Tem	Ağu	Eyl	Eki	Kas	Ara
Mısır												
Anız												
Domates												
Pirinç												
Ş. Pancarı												
Biber												

■ : Yoğun Bitki Örtüsü, ▨ : Seyrek Bitki Örtüsü

2.2 Yardımcı verilerin oluşturulması

Yardımcı veri setleri, yüksek çözünürlüklü uydu görüntülerinin analizinde görüntü nesnelerinin tanımlanması ve sınıflandırma sonuçlarını iyileştirilmesi amacıyla kullanılabilecek konumsal ve konumsal olmayan (öznitelik) verilerdir [16]. Bu çalışmada yardımcı veri seti olarak normalize edilmiş bitki indeksi (Normalized Difference Vegetation Index-NDVI) ve gri seviye eş-oluşum matrisi yardımıyla hesaplanan doku özellikleri kullanılmıştır. Vejetasyon indeksleri, arazi örtüsü/kullanımının belirlenmesi, ormancılık, rekolte tahmini ve ürün sağlığı ve gelişiminin izlenmesi gibi bir çok uygulamada temel veri kaynağı olarak kullanılmaktadır [11]. Farklı tarım ürünlerinin belirlenmesinde spektral ayrımın artırılması amacıyla, segmentasyon ve sınıflandırma işlemlerinde kullanılmak üzere kırmızı (K) ve yakın kızılötesi (YKÖ) bantlardan NDVI verisi oluşturulmuştur (Denklem 1).

$$NDVI = (YKÖ - KIRMIZI) / (YKÖ + KIRMIZI) \quad (1)$$

Uzaktan algılanmış görüntülerinin yorumlanmasında ve görüntü nesnelerinin tanımlanmasında kullanılan bir diğer yardımcı veri seti doku özellikleridir. Bu anlamda düzenli bir frekansta tekrar eden desen veya desen kombinasyonu olarak tanımlanan doku ilgili görüntü nesnelerin belirlenmesinde kullanılan önemli bir özelliktir [17]. Bu çalışmada doku analizleri, Haralic tarafından geliştirilen GLCM algoritması kullanılarak yapılmıştır.

GLCM, ikinci dereceden olasılık yoğunluk fonksiyonunun, $P(i, j | d, \theta)$, tahminine dayanır ve görüntüde belli bir yönde ve aralıkta bulunan ve farklı yansıtım değerlerine sahip piksellerin birbirine göre oluşum sıklıklarını veren bir kare matristir. Matristeki dağılım, pikseller arasındaki mesafe (d) ve açıya (θ) göre değişmektedir ve matrisin her bir elemanın d mesafesindeki i ve j piksel çiftinin oluşum sayısını belirtir [18]. Doku özelliklerinin hesaplama yönüne göre değişmediğini garantilemek için genellikle $\theta=0^\circ, 45^\circ, 90^\circ$ ve 135° olacak şekilde dört yönde hesaplanmaktadır. Haralick ve diğ. [17] bu dört yönde hesaplanan doku özelliklerinin ortalamasının alınmasını önermiştir. Tanımlanan bu özelliklerin seçiminde, özellikle tarımsal alanlar ile ilgili yapılan çalışmalarda en sık

kullanıldığı tespit edilenler tercih edilmiştir [5],[11],[14]. Bunlar; homojenlik, zıtlık, farklılık, entropi ortalama ve standart sapma doku ölçüm yöntemleridir. Belirlenen özellikler, 5x5 pencere boyutu ile dört farklı yönde ($0^\circ, 45^\circ, 90^\circ$ ve 135°) görüntüye uygulanmış ve her bir bant için dört farklı yönde hesaplanan doku özelliklerinin ortalamaları alınarak sınıflandırma işleminde ek bant olarak kullanılmıştır.


Çalışmada kullanılan doku ölçüm yöntemlerinden biri olan homojenlik, GLCM'nin elemanlarının köşegen (ana diyagonal) boyunca yoğunlaşma derecesini ölçmektedir. Zıtlık, görüntüde bulunan yerel değişimlerin miktarını gösterir. Homojen görüntülerde zıtlık değeri 0'a yakındır. Farklılık, zıtlığa benzer, ancak doğrusal olarak artmaktadır. İlgilenilen bölge yüksek bir zıtlık değerine sahipse, farklılık değeri de yüksektir. Entropi, görüntüdeki rastgelelik veya mevcut düzensizliğin bir ölçüsüdür. Entropi değeri, GLCM'nin tüm elemanları eşit olduğunda (homojen görüntülerde) en yüksek değerini almaktadır. GLCM ortalama, görüntü penceresindeki tüm piksel değerlerinin basit bir ortalaması değildir. Burada, piksel değerleri belirli bir komşu piksel değeri ile birlikte ortaya çıkma sıklığına bağlıdır. Standart sapma ise, matris elemanlarının dağılımlarının bir ölçüsüdür ve gri seviye değerleri ortalamadan farklı olduğunda varyans değeri artmaktadır [17].

Tablo 3'te çalışmada kullanılan yardımcı veriler, bu verilerin hangi bantlara uygulandığı ve üretilen yeni bantların kullanıldığı işlem adımları verilmiştir. Belirlenen özellikler doğrultusunda, her bir görüntü nesnesi için gerekli hesaplamaların yapılması sonucunda 29 özelliği içeren çok boyutlu bir veri seti elde edilmiştir.


Görüntüdeki gürültüyü yok etmek amacıyla, sınıflandırma öncesinde görüntünün orijinal bantlarına Denklem 2'de verilen Gauss filtresi uygulanmıştır. Ayrıca, sınıflandırma sürecine dâhil edilmek üzere Denklem 3, 4, 5, 6, 7 ve 8'de verilen, homojenlik, zıtlık, entropi, farklılık, ortalama ve varyans doku ölçüm yöntemleri IKONOS uydu görüntüsünün tüm bantlarına (M, K, Y ve YKÖ) uygulanmıştır [17]. Böylece 29 adet doku bandı elde edilmiştir. Şekil 3(a),(b),(c),(d),(e), ve (f)'de sırasıyla homojenlik, zıtlık, farklılık, entropi, ortalama ve varyans doku bantları için örnekler gösterilmektedir.

Tablo 3: Görüntü nesneleri için tanımlanan özellikler.


	Özellik	Açıklama	Kullanılan İşlem
Temel Spektral Bilgiler	NDVI Gauss Filtresi	IKONOS K ve YKÖ Bantları	Segmentasyon ve Sınıflandırma
Doku Özellikleri	Homojenlik	IKONOS Tüm Bantlar	Sınıflandırma
	Zıtlık	(Tüm yönlerde GLCM, 5x5)	
	Entropi		
	Farklılık		
	Ortalama		
	Varyans		




(a): Homojenlik (Ikono kırmızı bant).



(b): Zıtlık (Ikono kırmızı bant).



(c): Farklılık (Ikono YKÖ bant).



(d): Entropi (Ikono kırmızı bant).



(e): Ortalama (Ikono yeşil bant).



(f): Varyans (Ikono yeşil bant).

Şekil 3: Sınıflandırma işleminde yardımcı veri olarak kullanılan doku bantlarından bazı örnekler.

Eşitliklerde; i, j eş oluşum matrisinin satır ve sütun sayısını, $P_{i,j}$ eş oluşum matrisinin i, j konumunda bulunan değeri, N gri seviye sayısı, μ ve σ ise sırasıyla ortalama değer ve standart sapma değerini göstermektedir.

$$Gauss \text{ filtresi} = \frac{1}{2\pi\sigma^2} e^{-\left(\frac{x^2+y^2}{2\sigma^2}\right)} \quad (2)$$

$$Homojenlik = \sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i-j)^2} \quad (3)$$

$$Zıtlık = \sum_{i,j=0}^{N-1} P_{i,j} (i-j)^2 \quad (4)$$

$$Farklılık = \sum_{i,j=0}^{N-1} P_{i,j} |i-j| \quad (5)$$

$$Entropi = \sum_{i,j=0}^{N-1} P_{i,j} (-\ln P_{i,j}) \quad (6)$$

$$Ortalama (\mu_i) = \sum_{i,j=0}^{N-1} i (P_{ij}) \quad \mu_j = \sum_{i,j=0}^{N-1} j (P_{ij}) \quad (7)$$

$$Varyans (\sigma_{i,j}^2) = \sum_{i,j=0}^{N-1} P_{i,j} (i, j - \mu_{i,j})^2 \quad (8)$$

2.3 Çoklu çözünürlük segmentasyon

Nesne tabanlı sınıflandırma işleminin ilk ve önemli bir adımı olan görüntü segmentasyonu, IKONOS uydu görüntüsünün Mavi (M), Kırmızı (K), Yeşil (Y) ve YKÖ bantlarına NDVI bantının da eklenmesiyle toplam 5 banttan oluşan veri seti kullanılarak, eCognition yazılımının sunduğu çoklu çözünürlük segmentasyon algoritması ile yapılmıştır. Çoklu çözünürlük segmentasyon, piksel seviyesinde ya da görüntü alt nesneleri ile başlayan ve spektral ve konumsal ölçütlere göre, birbirine benzer özelliğe sahip pikselleri-alt nesneleri homojen parçalar olarak gruplandırarak bir alan birleştirme tekniğidir [19].

Çoklu çözünürlük segmentasyonda ölçek, şekil-renk ve bütünlük-yumuşaklık olmak üzere üç temel parametrenin değerlerinin kullanıcı tarafından belirlenmesi gerekmektedir [20]. Heterojenlik artışları en küçük olan nesne çiftleri kullanıcının belirlediği eşik değerine yakınsayana kadar iteratif olarak bileştirilir. Bu eşik değeri, nesnelerin heterojenliğine izin veren maksimum seviyeyi belirleyen ve nesne boyutları üzerinde doğrudan etkili olan ölçek parametresidir. Şekil-renk parametreleri, şekil ve renk özelliklerinin nesne üretiminde etkisini ifade etmektedir. Birbirini 1'e tamamlayan bu iki parametreden şekil kriterine ağırlık verilirse nesne üretiminde şekil özellikleri dikkate alınırken, spektral özellikler daha az dikkate alınmaktadır. Şekil parametresi 0'dan büyük bir ağırlık verildiğinde, bütünlük ve yumuşaklık parametrelerine farklı ağırlıklar verilerek bu parametrelerin nesne üretimine etkisi değiştirilebilir.

Bütünlük değerine ağırlık verildiğinde büyük şekillerin kompakt, küçük şekillerin düzgün sınırlara sahip olacak şekilde oluşmasını sağlamaktadır.

Bu parametrelerden en önemlisi, segmentlerin boyutu ve homojenliği üzerinde önemli derecede etkisi olan ölçek parametresidir [18],[21],[22]. Uygulamalarda, hangi ölçek parametresinin sınıflandırma doğruluğunu artıracığını tespit etmek oldukça zordur ve bunun için nicel bir ölçüt bulunmamaktadır. Ancak, son yıllarda ölçek parametresinin otomatik olarak belirlenmesini amaçlayan çalışmalar yaygınlaşmaya başlamıştır [23],[24].

Bu çalışmada, önceki benzer çalışmalarda da sıklıkla tercih edilmiş olan ölçek parametresi değerini otomatik olarak belirleyen ESP-2 yazılımı, deneme-yanılma yaklaşımıyla birlikte kullanılarak, çalışmanın amacına en uygun segmentasyon parametre değerleri belirlenmiştir. Bunun için, ESP-2 yazılımı ile en uygun ölçek parametre değeri belirlenmiştir. Belirlenen değere yakın 4 adet ölçek parametresi değeri ile 3 farklı şekil ve bütünlük parametre değerleri deneme-yanılma yaklaşımıyla değerlendirilerek bu çalışma için en uygun segmentasyon parametre değerleri belirlenmiştir.


2.3.1 ESP yöntemi ile ölçek parametresi değerinin belirlenmesi

Bu çalışmada, ölçek parametresinin otomatik olarak belirlenmesi için, Drăgut ve diğ. [25] tarafından, eCognition

Developer programının Cognition Network Language ortamında geliştirilen ESP-2 yazılımı kullanılmıştır. İteratif olarak aşağıdan-yukarıya (bottom-up) yaklaşımına göre görüntü nesnelerini üreten ESP-2 yazılımı, birçok çalışmada ölçek parametre değerini otomatik olarak belirlemek için tercih edilmiştir [26]-[28].

Bu yazılımda, heterojenlik değişimi, ölçek parametrelerine göre çizilen lokal varyans değişkeni ile yorumlanmaktadır. Lokal varyansın değişim oranlarında (rate of change) meydana gelen eşik değerleri (ani değişimler), farklı ölçek parametrelerinde anlamlı olabilecek nesnelerin yorumlanmasını sağlamaktadır. ESP-2 yazılımı, L1, L2 ve L3 olmak üzere 3 seviyeli ölçek tahmini gerçekleştirmektedir. L1 en iyi nesne ölçeğini, L2 orta seviye nesne ölçeğini, L3 ise en geniş ölçeğini temsil etmektedir ve nesne sayısı, L1'den L3'e doğru azalmaktadır. ESP-2 yazılımı ile ölçek parametresinin belirlenmesi için 12 adet değer kullanıcı tarafından yazılıma girilmesi gerekmektedir. Bu değerler; hiyerarşi kullanımı, hiyerarşi kullanım tipi, üç adet farklı ölçek parametresinin başlangıç değeri, üç adet farklı ölçek parametresinin artış değeri, şekil ve bütünlük değerlerinin ağırlığı, lokal varyans-değişim oranı grafiğinin üretimi ve döngü sayısıdır.


Bu nedenle, ilk aşamada uygun olabilecek ölçek parametrelerini belirlemek amacıyla şekil ve bütünlük parametreleri için önerilen değerler olan 0.1 ve 0.5 değerleri kabul edilmiş ve Şekil 4'te verilen lokal varyans-değişim oranı grafiği elde edilmiştir. ESP-2 sonucu elde edilen lokal varyans-değişim oranı grafiği incelendiğinde çalışma alanında bulunan ürün segmentlerini en iyi şekilde belirleyebilecek ölçek parametresi değerinin 35, 40, 45 ve 50 değerleri olabileceği sonucuna varılmıştır.



Şekil 4: Lokal varyans-değişim oranı grafiği.


2.3.2 Şekil ve bütünlük parametre değerlerinin belirlenmesi

ESP-2 yazılımında, şekil ve bütünlük parametre değerleri sırasıyla 0.1 ve 0.5 olarak alındığında, elde edilen olası ölçek parametre değerleri 35, 40, 45 ve 50 kullanılarak çoklu çözünürlük segmentasyon işlemi uygulanmıştır. Yapılan bazı segmentasyon örnekleri Şekil 5(a),(b),(c) ve (d)'de verilmiştir. Verilen segmentasyon sonuçları incelendiğinde, çalışma alanında çoğunlukla düzgün dikdörtgen şekilde olan tarımsal ürün sınırlarını iyi temsil etmeyen segment sınırlarının olduğu görülmüştür. Özellikle homojen olmayan alanlarda, şekil parametresine gerekli ağırlığın verilmemesinden dolayı oluşan segment sınırları ile ürün sınırları arasında belirgin konumsal farklılık olduğu görülmüştür. Sonuç olarak, kullanılan parametre değerleri ile görüntü nesnelerini iyi bir şekilde temsil edebilecek segmentasyon sonucuna ulaşılamamıştır.



(a): Ölçek: 35, Şekil: 0.1, bütünlük: 0.5.

(b): Ölçek: 40, Şekil: 0.1, bütünlük: 0.5.



(c): Ölçek: 45, Şekil: 0.1, bütünlük: 0.5.

(d): Ölçek: 50, Şekil: 0.1, bütünlük: 0.5.

Şekil 5: Farklı segmentasyon parametreleri ile elde edilen segmentasyon sonuçları.


Şekil parametresine gerekli ağırlığın verilmemesinden kaynaklanan bu sorunun sınıflandırma sonucunu doğrudan etkileyecek olmasından dolayı, parametre değerleri değiştirilerek sonuçlar tekrar değerlendirilmiştir.

Şekil parametresi için 0.5, 0.6 ve 0.7 değerleri ve bütünlük parametresi için de 0.3, 0.4 ve 0.5 değerleri ve belirlenen ölçek parametre değerleri kullanılarak toplam 36 adet çoklu çözünürlük segmentasyon kombinasyonu denenmek suretiyle bu çalışma için en uygun parametre değerleri belirlenmiştir. Denenen tüm parametre değerleri Tablo 4'te verilmiştir. Örneğin, Ölçek = 50, Şekil = 0.5, Bütünlük=0.5 (G) şeklindedir. Benzer biçimde bir başka kombinasyon, Ölçek = 45, Şekil = 0.7, Bütünlük = 0.5 (I) şeklindedir.

Çoklu çözünürlük segmentasyon parametre değerlerinin belirlenmesi için farklı ölçek, şekil ve bütünlük parametre değerleri kullanılarak yapılan kombinasyonlardan birkaç örnek Şekil 6'da gösterilmiştir.


Yapılan denemeler sonucunda, Şekil 6(b)'de verilen, ölçek parametresi için 40, şekil parametresi için 0.5 ve bütünlük parametresi için 0.3 değerlerinin, bu çalışmada kullanılan tarımsal alanda yer alan arazi örtüsü sınıflarını en iyi şekilde

bölütleyen parametre değerleri olduğuna karar verilmiştir. Tablo 4'te verilen segmentasyon parametre değerleri ile yapılan çoklu-çözünürlük segmentasyon denemelerinde, tarımsal alanlarda etkili olan YKÖ ve NDVI bantlarının ağırlıkları diğer bantlara göre 3 kat fazla alınmıştır.



(a): Ölçek: 35, Şekil: 0.6, bütünlük: 0.3.

(b): Ölçek: 40, Şekil: 0.5, bütünlük: 0.3.



(c): Ölçek: 45, Şekil: 0.7, bütünlük: 0.5.


(d): Ölçek: 50, Şekil: 0.5, bütünlük: 0.5.

Şekil 6: Farklı segmentasyon parametreleri ile elde edilen segmentasyon sonuçları.

Çoklu çözünürlük segmentasyon işlemi, belirlenen parametre değerleri ile yapılmış olup gerçekleştirilen segmentasyon neticesinde toplam 4917 adet görüntü nesnesi oluşmuştur. Ölçek parametresinin küçük seçilmesinden dolayı segment sayısı artmıştır. Özellikle, köy yerleşim merkezi sınırlarında bulunan büyük mera parsellerinin birden fazla segmente ayrılmasına neden olmuştur. Bu durum, söz konusu segmentler doğru sınıflandırıldığı sürece sonucu olumsuz yönde etkilemeyeceğinden yöntemin bir sonraki adımı olan nesne-tabanlı sınıflandırma işlemine elde edilen görüntü nesneleri ile devam edilmiştir. Elde edilen nihai segmentasyon sonucu Şekil 7'de gösterilmektedir. Elde edilen 4917 adet segmentten çalışma alanında bulunan yol, yerleşim merkezi, dere gibi tarım alanı dışında kalan yerler çıkarılmıştır. Sınıflandırma işlemine sadece tarım alanlarını kapsayan segmentler kullanılarak devam edilmiştir.

Tablo 4: Segmentasyon işleminde kullanılan parametre değerleri kombinasyonları.

Parametreler	Kombinasyonlar (35, 40, 45 ve 50 ölçek parametre değerlerinin her biri için)								
	A	B	C	D	E	F	G	H	I
Şekil	0.5	0.6	0.7	0.5	0.6	0.7	0.5	0.6	0.7
Bütünlük	0.3	0.3	0.3	0.4	0.4	0.4	0.5	0.5	0.5



Şekil 7: Çalışma alanını en iyi şekilde temsil eden segmentasyon sonucu.

2.4 Nesne tabanlı sınıflandırma


Bu aşamada, segmentasyon işlemi ile elde edilen görüntü nesnelerinden benzer karakteristik özelliklere sahip olanlar; homojenlik, büyüklük, doku, renk, gibi farklı parametrelerle değerlendirilerek belirlenen sınıflara atanması amaçlanmıştır. eCognition yazılımı en yakın komşu sınıflandırıcı ve bulanık üyelik (fuzzy membership) fonksiyonları olmak üzere iki temel sınıflandırıcı sağlamaktadır. En yakın komşu sınıflandırıcı, oluşan segmentler üzerinden sınıf hiyerarşisine göre belirlenen örnek nesneler yardımıyla ortaya çıkacak sınıfları tanımlarken, bulanık üyelik fonksiyonları nesnelerin ilgili sınıfa ait özelliklerin ve eş değeriyle ilgili sınıflar için oluşturulacak bir karar setinin tanımlanmasına dayanmaktadır.

Bu çalışmada en yakın komşuluk sınıflandırma algoritması kullanılmıştır. Bu yöntemde, sınıflandırma birimi olarak pikseller yerine segmentlerin kullanılması işlemlerin daha hızlı biçimde ilerlemesini sağlar [29]. Her sınıf için belirlenen eğitim alanı örneklerinin ortalama değerleri kullanılarak, en yakın komşuluk yöntemiyle ortak özelliklere sahip segmentleri gruplandırarak sınıflandırma işleminin tamamlanır.

Görüntünün nesne-tabanlı sınıflandırması için çalışma alanında yoğunlukla bulunan mısır, domates, biber, mera, pirinç, şeker pancarı ve anız olmak üzere toplam yedi adet ürün sınıfı belirlenmiştir. Çalışma alanı görsel olarak incelendiğinde, çok sayıda parselde çoklu ürün bulunduğu ve ya aynı ürünün ekili olduğu bazı tarım parsellerinin, ürünün olgunluk derecesine, sulanma durumuna veya ekim zamanına bağlı olarak farklı özelliklere sahip olduğu gözlemlenmiştir. Bu durumun sınıflandırma sonuçlarında hataya neden olmasını önlemek amacıyla, aynı sınıfa ait ve farklı özelliklere sahip olan parseller, öncelikle birkaç alt sınıf halinde düzenlenmiş ve eğitim alanları bu sınıflar için ayrı ayrı toplanmıştır. Örneğin; pirinç sınıfı için iki farklı alt sınıf (Pirinç-1 ve Pirinç-2) ve domates sınıfı için de üç farklı alt sınıf (Domates-1, Domates-2 ve Domates-3) oluşturulmuştur. Eğitim alanları örnekleri bu sınıflardan ayrı ayrı seçilmiş ve sınıflandırma sonrasında bu sınıflar birleştirilerek değerlendirilmiştir (Şekil 8).

Böylece, mera ve şeker pancarı dışında tüm sınıflar için toplam 13 adet alt sınıf oluşturulmuştur. Toplamda 15 sınıf için, bu sınıfları temsil eden homojen alanlardan eğitim alanları seçilmiş ve sonrasında yapılan nesne-tabanlı sınıflandırma işleminden sonra aynı ürüne ait alt sınıflar birleştirilerek sınıflandırılmış görüntü elde edilmiştir. Çalışmada kullanılan


arazi örtüsü sınıfları (ürün türleri) ve bu sınıflara ait alt sınıflar Şekil 9'da gösterilmektedir.



(a): Pirinç ürününe ait örnekler.

(b): Domates ürününe ait örnekler.

Şekil 8: Farklı özelliklere sahip ürün örnekleri.



Şekil 9: Çalışma alanında belirlenen sınıflar.

Her sınıf için eğitim alanları daha önce oluşturulan görüntü segmentlerinden seçilmiştir. Eğitim alanı seçiminde, seçilecek görüntü segmentlerinin ilgili sınıfı en iyi şekilde temsil ediyor olmasına ve seçilen örneklerin homojen dağılımlı olmasına dikkat edilmiştir. Eğitim alanlarının seçiminde yer gerçekleri verileri de yardımcı veriler olarak kullanılmıştır. Sınıflandırma işlemine geçilmeden önce, eğitim alanı örnekleri olarak seçilen segmentlere göre sınıfların, sınıflandırmada kullanılacak her bir banttaki histogramları ve sınıflar arasındaki spektral örtüşme durumları incelenmiştir. İncelemeler sonucunda mısır, şeker pancarı, anız ve pirinç sınıfları arasında spektral örtüşmenin fazla olmadığı görülmüştür. Ancak, özellikle domates ve biber sınıflarının tanımlanan veri setinin hemen hemen tüm bantlarında dağılımlarının benzer aralıklarda olduğu görülmüştür. Bu sınıflara ait histogramlardaki örtüşme değerleri incelendiğinde, domates ve biber sınıflarının ayrımı oldukça zor olduğundan bu iki sınıf domates/biber sınıfı altında birleştirilerek değerlendirilmiştir. Spektral örtüşmenin fazla olmasından kaynaklanan bu sorunların çözümünde yardımcı veri üretimi yoluna gidilmiştir. Bu yaklaşımın yetersiz kaldığı durumlarda, sınıflandırma işleminde çok-zamanlı (multi-temporal) uydu görüntülerinin ve/veya bilgi tabanlı algoritmaların (örneğin; ürün ekim zamanları, büyüme evreleri, çiftçilerin ekim alışkanlıkları vb.) kullanılması, sınıfların ayrılabilirliğini artırmak için kullanılabilecek yöntemler arasında yer almaktadır.

Bu işlemlerden sonra nesne-tabanlı sınıflandırma işlemine geçilmiştir. Nesne-tabanlı sınıflandırma eCognition yazılımında

yer alan en yakın komşuluk sınıflandırma algoritması kullanılarak yapılmıştır. En yakın komşuluk sınıflandırması için öncelikle sınıflandırma işleminde kullanılacak özellikler (IKONOS uydu görüntüsü bantları, NDVI bandı ve texture bantları) ve ilgili sınıflar seçilmiştir. Böylelikle en yakın komşu sınıflandırması için gereken özellik uzayı oluşturulmuş ve daha önce yapılan segmentasyon sonucu elde edilen görüntü segmentleri bu uzayda tanımlanan eğitim alanlarına göre sınıflandırılmıştır.

Sınıflandırma işleminden sonra sınıflandırılmış görüntü üzerinde genelleştirme ve yumuşatma işlemlerini içeren sınıflandırma sonrası işlemler uygulanmıştır. Bu kapsamda, çoğunluk filtresi (majority filter) ve sınır temizleme (boundary clean) işlemleri sırasıyla uygulanarak sınıflandırılmış görüntü üzerinde yer alan birkaç pikselden oluşan küçük piksel grupları (küçük segmentler) temizlenmiştir. Böylece sınıflandırılmış görüntünün tematik kalitesi artırılmıştır. Sınıflandırma sonrası işlemlerin uygulanması neticesinde elde edilen sınıflandırılmış uydu görüntüsü Şekil 10'da gösterilmektedir.

2.5 Doğruluk analizleri


Sınıflandırılmış görüntünün doğruluk analizi için ilgili sınıflara ait referans parseller seçilmiştir. İlgili ürünlerin ekili olduğu parsel sayıları doğrultusunda belirlenen referans parsellerin sayısı, domates/biber için 748, anız için 662, mısır için 603, şeker pancarı için 85, pirinç için 71 ve mera için 43 olmak üzere toplam 2212 adettir. Dolayısıyla, sınıflandırılmış görüntünün doğruluk analizleri toplam 2212 adet parsel bilgisi kullanılarak yapılmıştır.

Sınıflandırılmış görüntü ile referans veriyi karşılaştırmak amacıyla, referans veride yer alan her parselinin ağırlık merkezinde olacak şekilde bir nokta belirlenmiş ve böylece referans nokta verisi oluşturulmuştur. Doğruluk analizleri bu referans noktalar kullanılarak yapılmış ve elde edilen sonuçlar bir hata matrisi üzerinde gösterilerek sınıflandırma başarı oranı (overall accuracy), üretici doğruluğu (producer's accuracy) ve kullanıcı doğruluğu (user's accuracy) hesaplanmıştır (Tablo 5). Sınıflandırma başarı oranı, hata matrisinin tüm köşegen elemanları toplamının matrisin tüm elemanlarının toplamına oranı ile hesaplanmaktadır.

Üretici doğruluğu, bir sınıfı test etmek için belirlenen referans piksel ya da nesnenin kaç tanesinin doğru sınıflandırıldığını ifade eder ve hata matrisinde köşegen elemanlarının bulundukları sütun toplamına oranı ile hesaplanmaktadır. Kullanıcı doğruluğu, herhangi bir sınıfa atanan piksel ya da nesnenin gerçekte ilgili sınıfa ait olma olasılığını ifade eder ve hata matrisinin köşegen elemanlarının, bulundukları satır toplamına oranı ile hesaplanmaktadır [30]. Hata matrisini analiz etmek için, Denklem 9'da verilen ve istatistiksel bir yöntem olan K (kappa katsayısı) değeri kullanılmıştır [31].

$$Kappa (K) = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})} \quad (9)$$

Bu eşitlikte; r, hata matrisindeki toplam satır sayısını, x_{ii}, i. satır ve sütundaki piksel sayısını, x_{i+}, i. satırdaki toplam piksel sayısını, x_{+i}, i. sütundaki toplam piksel sayısını ve N, matrisin tamamındaki piksel sayısını temsil etmektedir.



Şekil 10: IKONOS uydu görüntüsünün nesne-tabanlı sınıflandırması sonucu elde edilen tematik harita.

Tablo 5: Hata matrisi.

Sınıflandırma	Referans Veri							Kullanıcı Doğruluğu (%)
	Mısır	Domates/Biber	Mera	Pirinç	Şeker Pancarı	Anız	Satır Toplamı	
Mısır	509	56	5	7	0	26	603	84.41
Domates/Biber	60	629	18	0	5	36	48	84.09
Mera	0	2	41	0	0	0	43	95.35
Pirinç	1	1	0	68	1	0	71	95.77
Şeker Pancarı	5	7	0	0	73	0	85	85.88
Anız	11	19	12	5	0	615	662	92.90
Satır Toplamı	586	714	76	80	79	677	2212	
Sınıflandırma başarı oranı: %87.48 Kappa (K): 0.83								
Üretici Doğruluğu (%)	86.86	88.10	53.95	85.00	92.41	90.84		

Sınıflandırma sonucunda 748 adet referans Domates/biber parselinin 629 adedi doğru sınıfa atanırken, 119 adet parselin yanlış sınıfa atanması nedeniyle kullanıcı doğruluğu %84.09 olarak belirlenmiştir. Diğer sınıflara ait 85 adet parselin Domates/biber sınıfına atanması sonucunda ise, üretici doğruluğu %88.10 olarak hesaplanmıştır. Domates/biber sınıfının, özellikle mısır ve anız sınıfı ile karıştığı görülmektedir. Domates ve biber bitkileri, yansıma karakteristikleri bakımından birbirlerine oldukça yakındır. Ayrıca, çalışmada kullanılan IKONOS uydu görüntüsü, domates ve biber ürünlerinin benzer olan olgunluk döneminde çekilmiştir. Bu iki unsur, söz konusu ürünlerin sınıflandırmada kullanılan bantlarda ayırt edilebilirliğini önemli derecede azaltmıştır. Ürünler arasında bulunan spektral örtüşme doğruluk oranını önemli derecede azalttığı için domates ve biber sınıfları birleştirilerek değerlendirilmiştir.

Çalışma alanında çoğunlukla köy yerleşim merkezleri yakınında bulunan 43 adet referans mera parselinin 41 adedinin doğru olarak sınıflandırılması sonucunda mera sınıfının kullanıcı doğruluğu %95.45 olarak belirlenmiştir. Ancak, domates/biber ve anız sınıfları ağırlıklı olmak üzere toplam 31 adet parselin hatalı olarak mera sınıfına atanmasından ve mera sınıfının parsel içi varyasyonlarının fazla olmasından dolayı mera sınıfının üretici doğruluğu %53.95 olarak belirlenmiştir.

Diğer ürünlerle spektral örtüşmesi düşük olan pirinç sınıfına ait 71 adet referans pirinç parselinin 68 tanesi doğru olarak sınıflandırılmış ve böylece en yüksek kullanıcı doğruluğu olan %95.77 oranına ulaşmıştır. Ağırlıklı olarak, olgun dönemde olan mısır parsellerinin (mısır_1) ve anız sınıfına ait 5 adet parselin hatalı olarak pirinç sınıfına atanması nedeniyle pirinç sınıfının kullanıcı doğruluğu %85.00 olarak hesaplanmıştır.

Şeker pancarı sınıfına ait 85 adet referans parselin 73 tanesinin doğru sınıflandırılması sonucunda şeker pancarı sınıfının kullanıcı doğruluğu %85.88 olarak hesaplanmıştır. Şeker pancarı ürününü domates-1 ve domates-2 sınıflarına ait ürünler ile karıştığı için 6 parsel hatalı olarak şeker pancarı sınıfına atanmış ve bu nedenle şeker pancarı sınıfının üretici doğruluğu %92.41 olarak belirlenmiştir.


Çalışma alanında bulunan anız parselleri, çoğunlukla ekili parseller olmadığı için diğer sınıflardan spektral olarak farklı ve parsel içi varyasyonları azdır. Bu nedenlerle 662 adet referans anız parselinin 615 tanesi doğru olarak sınıflandırılmış ve kullanıcı doğruluğu %92.90 oranında belirlenmiştir. Domates/biber ve mısır sınıflarından toplam 62 adet parselin

hatalı olarak anız sınıfına atanması sonucunda anız sınıfının üretici doğruluğu %90.84 olarak belirlenmiştir.

Ekran üzerinde yapılan görsel incelemeler sonucunda, aynı tarım parseli içerisinde yapılan çoklu ekimlerin, parsellerin içerisinde bulunan çeşitli yapıların (taş öbekleri ve kuyu vb.) ve parsel içi spektral varyasyonların bir parselin birkaç segment ile temsil edilmesine neden olduğu görülmüştür. Bu gibi durumlara ek olarak ölçek parametresinin küçük seçilmesi nedeniyle çalışma alanında bulunan parsel sayısından daha fazla sayıda segment elde edilmiştir. Fakat söz konusu segmentler, sınıflandırma sürecinde ve sonrasında birleştirilebileceğinden dolayı ilgili nesne sınırlarını iyi bir şekilde temsil ettiği sürece, segment sayısının fazla olmasının (over-segmented) sınıflandırma sonucuna olumsuz yönde etkisi bulunmamaktadır [25].

Belirlenen ölçek, şekil ve bütünlük parametreleriyle gerçekleştirilen denemeler sonucunda elde edilen segment sayıları incelendiğinde, ölçek parametresinin oluşturulacak segment sayısı üzerinde diğer parametrelerden daha etkili olduğu görülmektedir (Şekil 11). Bunun nedeni, ölçek parametresinin, segmentlerin heterojenlik seviyesini dolayısıyla boyutunu belirleyen temel parametre olmasıdır.

Şekil parametresine gerekenden fazla ağırlık verilmesi sonucunda, benzer özellik gösteren ürünlerin ekili olduğu ve aynı ekim dönemine ait komşu parseller belirlenememiştir. Renk parametresinin ağırlığı artırıldığında ise, spektral bilgiye ağırlık verildiği için benzer özelliklere sahip ürünlerin ekili olduğu parsellerin büyük oranda belirlendiği gözlemlenmiştir.



Şekil 11: Farklı parametre değerleri kullanılarak yapılan segmentasyon denemeleri sonucunda elde edilen segment sayıları.

3 Sonuçlar

Bu çalışmada 2004 yılına ait yüksek çözünürlüklü IKONOS uydu görüntüsü nesne-tabanlı yöntemle sınıflandırılmış ve tarımsal ürün deseni yüksek doğrulukla elde edilmiştir. Nesne tabanlı sınıflandırmanın ilk aşaması olan segmentasyon işlemi eCognition Developer yazılımı kullanılarak çoklu çözünürlük segmentasyon ile yapılmıştır. Çalışma alanını en iyi temsil edecek çoklu çözünürlük segmentasyon parametreleri ESP-2 yazılımı ve deneme-yanılma yöntemiyle beraber değerlendirilerek belirlenmiştir. Sınıflandırma aşamasında ise, nesne tabanlı en yakın komşuluk algoritması kullanılmış ve sınıflandırma performansı 2212 adet yer gerçeği verileri kullanılarak analiz edilmiştir.

Yüksek çözünürlüklü uydu görüntülerinde artan heterojenlik, nesnelerin birbirinden ayırt edilmesinde sorunlara neden olmaktadır. Aynı zamanda, tarım ürünleri arasında spektral benzerliğin fazla olması ve arazide parsel sınırlarının net bir şekilde belirgin olmaması hem segmentasyon hem de sınıflandırmanın başarısını etkileyen önemli hususlardandır. Bu sorunların çözümü için uydu görüntülerinin nesne-tabanlı sınıflandırma yöntemleri ile analizinde yardımcı veriler ile birlikte değerlendirilmesi genellikle tercih edilen bir yaklaşımdır. Bu çalışmada, sınıflandırma sürecinde kullanılmak üzere tarımsal alanlarda sıklıkla tercih edilen doku ölçüm yöntemleri belirlenmiş ve IKONOS uydu görüntüsünün orijinal bantlarına uygulanarak 24 adet doku bandı elde edilmiştir. Sınıflandırma sürecinde doku bantlarının kullanılması ve dolayısıyla bant sayısının artmasının sınıflandırma sonucuna olumlu yönde katkısı olduğu görülmüştür. Ancak, doku hesaplamaları karmaşık matematiksel işlemler içerdiğinden, bant sayısının artmasının işlem süresini oldukça uzattığı görülmüştür. Bu nedenle, çalışma alanına bağlı olarak kullanılacak doku özellikleri ve uygulanacak bantlar, çalışma amacı ve zaman açısından değerlendirilerek belirlenmelidir.

Kullanılan uydu görüntüsü ve çalışma alanı için, nesne tabanlı sınıflandırmanın başarısını etkileyen en önemli etkenlerden birisi, segmentasyon işleminin başarısıdır. Başarılı bir segmentasyon ise, kullanılacak veri seti, çalışma alanı ve belirlenmek istenen detaylara göre değişen segmentasyon parametrelerinin iyi bir şekilde belirlenmesine bağlıdır. Bu çalışmada, çoklu çözünürlük segmentasyon algoritmasının en önemli parametresi olan ölçek parametresini otomatik olarak belirlemek için ESP-2 yazılımı kullanılmıştır. Bu çalışmada, ESP-2 sonuçlarına göre uygun olabilecek dört farklı (35, 40, 45, 50) ölçek parametresi kullanılmıştır. Ölçek parametresi değeri 35 olarak alındığında, aşırı segmentasyon sonucu elde edilmiştir. Aynı koşullar altında, ölçek parametresi değeri 45 ve 50 alındığında ise, bu değerlerle belirlenebilen nesneler olmasına rağmen, çalışma alanında bulunana birçok nesne tespit edilememiştir. Bu nedenlerle, çalışma alanı ve kullanılan verilere göre nesneleri en uygun şekilde belirleyen ölçek parametresi değeri 40 olarak belirlenmiştir. Diğer parametreler olan şekil ve bütünlük parametre değerlerinin belirlenmesi için, farklı parametre denemeleri yapılmıştır. Bu denemeler sonucunda, şekil parametresinin ağırlığı artırıldığında farklı özelliklere sahip alanların (örneğin; farklı ürün türlerinin ekili olduğu tarım parselleri) belirlenmesinde olumlu etkisi olduğu tespit edilmiştir. Bütünlük parametresi belirgin farklılıkları olan bölgeleri belirlemede etkili olsa dahi, ağırlığı artırıldığında küçük varyasyonlara sahip alanlarda aşırı bölütlemeye neden olduğu görülmüştür.

En uygun segmentasyon parametrelerinin bulunması için yapılan denemeler sonucunda, özellikle ölçek parametresinin oluşan segment sayısı ve büyüklüğü üzerinde diğer parametrelerden daha fazla etkisi olduğu görülmüştür. Elde edilen sonuçlara göre, çalışma alanına ait keskinleştirilmiş IKONOS uydu görüntüsünün çoklu çözünürlük segmentasyonunda, ölçek, şekil ve bütünlük parametreleri için en uygun değerler sırasıyla 40, 0.5, 0.3 olarak belirlenmiştir.

Çalışmanın sonucu olarak, sınıflandırma başarı oranı ve kappa doğruluğu sırası ile %87.48 ve 0.837 olarak elde edilmiştir. Belirlenen yöntemle değerlendirilen IKONOS uydu görüntüsünün, ülkemiz için oldukça önemli olan ürün deseni tespiti çalışmalarında güvenilir sonuçlar verdiği ve kullanılabilir olduğu görülmüştür. İleriki çalışmalarda bölgeye ait çok zamanlı uydu görüntülerinin farklı sınıflandırma algoritmaları ile değerlendirilerek ürün deseninin daha yüksek doğrulukta belirlenmesi hedeflenmektedir.

4 Kaynaklar

- [1] Shanahan J, Schepers J, Francis D, Varvel G, Wilhelm W, Tringe J, Major D. "Use of remote-sensing imagery to estimate corn grain yield". *Agronomy Journal*, 93(3), 583-589, 2011.
- [2] Conrad C, Fritsch S, Zeidler J, Rücker G, Dech S. "Per-field irrigated crop classification in arid Central Asia using SPOT and ASTER data". *Remote Sensing*, 2(4), 1035-1056, 2010.
- [3] Antunes A, Lingnau C, Centeno J. "Object oriented analysis and semantic network for high resolution image classification". *Anais XI SBSR*, Belo Horizonte, Brazil, 05-10 April 2003.
- [4] Blaschke T. "Object based image analysis for remote sensing". *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), 2-16, 2010.
- [5] Lu D, Weng Q. "A survey of image classification methods and techniques for improving classification performance". *International Journal of Remote Sensing*, 28(5), 823-870, 2007.
- [6] Mialhe F, Gunnell Y, Ignacio J, Delbart N, Oganja J, Henry S. "Monitoring land-use change by combining participatory land-use maps with standard remote sensing techniques: Showcase from a remote forest catchment on Mindanao, Philippines". *International Journal of Applied Earth Observation and Geoinformation*, 36, 69-82, 2015.
- [7] Kim M, Madden M, Warner T. *Estimation of Optimal Image Object Size for the Segmentation of Forest Stands with Multispectral IKONOS Imagery*. Editors: Blaschke T, Lang S, Hay G. Object-Based Image Analysis, 291-307, Berlin, Heidelberg, Springer-Verlag, 2008.
- [8] Bock M, Xofis P, Mitchley J, Rossner G, Wissen M. "Object-oriented methods for habitat mapping at multiple scales-Case studies from Northern Germany and Wye Downs, UK". *Journal for Nature Conservation*, 13(2), 75-89, 2005.
- [9] Yu Q, Gong P, Clinton N, Biging, G, Kelly M. "Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery". *Photogrammetric Engineering and Remote Sensing*, 72(7), 799-811, 2006.
- [10] Türker M, Özdarıcı A. "Field-based crop classification using SPOT 4, SPOT 5, IKONOS and QuickBird imagery for agricultural areas: a comparison study". *International Journal of Remote Sensing*, 32(24), 9735-9768, 2011.

- [11] Pena-Barragan JM, Ngugi MK, Plant RE, Six J. "Object-based crop identification using multiple vegetation indices, textural features and crop phenology". *Remote Sensing of Environment*, 115(6), 1301-1306, 2011.
- [12] Koutsias N, Mallinis GG, Pleniou M, Voukelatou I, Paschali T, Dimopoulos P. "Object-based classification using a synergy of high spatial (IKONOS) and high spectral (ASTER) satellite data in a rural NATURA 2000 deltaic area". *Proceedings of the 2nd International Conference on Space Technology*, Athens, Greece, 15-17 September 2011.
- [13] Alganci U, Sertel, E, Özdoğan M, Örmeci C. "Parcel-level identification of crop types using different classification algorithms and multi-resolution imagery in Southeastern Turkey". *Photogrammetric Engineering and Remote Sensing*, 79(11), 1053-1065, 2013.
- [14] Li M, Ma L, Blaschke T, Cheng L, Tiede D. "A systematic comparison of different object-based classification techniques using high spatial resolution imagery in agricultural environments". *International Journal of Applied Earth Observation and Geoinformation*, 49, 87-98, 2016.
- [15] Singha M, Wu B, Zhang M. "An object-based paddy rice classification using multi-spectral data and crop phenology in Assam, Northeast India". *Remote Sensing*, 8(6), 479, 2016.
- [16] Zhang H, Li Q, Liu J, Du X, Dong T, McNairn H, Shang J. "Object-based crop classification using multi-temporal SPOT-5 imagery and textural features with a Random Forest classifier". *Geocarto International*, 33(10), 1-19, 2017.
- [17] Haralick RM, Shanmugam K, Dinstein I. "Textural features for image classification". *IEEE Transactions on Systems*, 3(6), 610-621, 1973.
- [18] Smith, A. "Image segmentation scale parameter optimization and land cover classification using the Random Forest algorithm". *Journal of Spatial Science*, 55(1), 69-79, 2010.
- [19] Baatz M, Schape A. *Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation*. Editors: Strobl J, Blaschke T, Griesebner G. Angewandte Geographische Informations-Verarbeitung XII, 12-23, Karlsruhe, Germany, Wichmann, 2000.
- [20] Benz UC, Hofmann P, Willhauck G, Lingenfelder I, Heynen M. "Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information". *ISPRS Journal of Photogrammetry and Remote Sensing*, 58 (3-4), 239-258, 2004.
- [21] Myint SW, Gober P, Brazel A, Grossman-Clarke S, Weng Q. "Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery". *Remote Sensing of Environment*, 115(5), 1145-1161, 2011.
- [22] Kim M, Warner TA, Madden M, Atkinson DS. "Multi-scale GEOBIA with very high spatial resolution digital aerial imagery: scale, texture and image objects". *International Journal of Remote Sensing*, 32(10), 2828-2850, 2011.
- [23] Smith GM, Morton RW. "Real world objects in GEOBIA through the exploitation of existing digital cartography and image segmentation". *Photogrammetric Engineering and Remote Sensing*, 76(2), 163-171, 2010.
- [24] Liu Y, Bian L, Meng Y, Wang H, Zhang S, Yang Y, Shao X, Wang B. "Discrepancy measures for selecting optimal combination of parameter values in object-based image analysis". *ISPRS Journal of Photogrammetry and Remote Sensing*, 68, 144-156, 2012.
- [25] Drăgut L, Csillik O, Eisank C, Tiede D. "Automated parameterisation for multi-scale image segmentation on multiple layers". *ISPRS Journal of Photogrammetry and Remote Sensing*, 26(4), 119-127, 2010.
- [26] D'Oleire-Oltmanns S, Tiede D. "Application of the estimation of scale parameter 2 (ESP-2) tool for the identification of scale levels for distinct target objects". *South-Eastern European Journal of Earth Observation and Geomatics*, 3(2), 597-584, 2014.
- [27] O'Connell J, Bradter U, Benton T. "Wide-area mapping of small-scale features in agricultural landscapes using airborne remote sensing". *ISPRS Journal of Photogrammetry and Remote Sensing*, 109, 165-177, 2015.
- [28] Drăgut L, Tiede D, Levick SR. "ESP: a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data". *International Journal of Geographical Information Science*, 24(6), 859-871, 2014.
- [29] Kavzoglu T, Yıldız M. "Parameter-Based performance analysis of object-based image analysis using aerial and QuickBird-2 images". *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 11(7), 31-37, 2014.
- [30] Mather P. *Computer Processing of Remotely-Sensed Images: An Introduction*. 3rd ed. New York, USA, Wiley, 2004.
- [31] Cohen J. "A coefficient of agreement for nominal scales". *Educational and Psychological Measurement*, 20(1), 37-46, 1960.