



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



**Hava LiDAR Verilerinden Tarımsal Alan
Sınırlarının Otomatik Tespiti**

Mehmet Fatih GÜRBÜZ

DOKTORA TEZİ

Harita Mühendisliği Anabilim Dalı

Nisan-2024
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Mehmet Fatih GÜRBÜZ tarafından hazırlanan “Hava LiDAR Verilerinden Tarımsal Alan Sınırlarının Otomatik Tespiti” adlı tez çalışması 15.02.2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Harita Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Ferruh YILDIZ

.....

Üye

Prof. Dr. Hakan KARABÖRK

.....

Üye

Prof. Dr. Murat UYSAL

.....

Üye

Doç. Dr. Osman ORHAN

.....

Üye

Dr. Öğr. Üyesi Ali SAĞLAM

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Mehmet Fatih GÜRBÜZ

Tarih:

ÖZET

DOKTORA TEZİ

Hava LiDAR Verilerinden Tarımsal Alan Sınırlarının Otomatik Tespiti

Mehmet Fatih GÜRBÜZ

**Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Harita Mühendisliği Anabilim Dalı**

**Danışman: Prof. Dr. Hakan KARABÖRK
2.Danışman: Doç. Dr. Nurdan BAYKAN**

2024, 97 Sayfa

Jüri

**Prof. Dr. Ferruh YILDIZ
Prof. Dr. Hakan KARABÖRK
Prof. Dr. Murat UYSAL
Doç. Dr. Osman ORHAN
Dr. Öğr. Üyesi Ali SAĞLAM**

Uydu görüntüleri, hava fotoğrafları ve LiDAR verilerinden nesne (obje) tespiti son yıllarda popüler hale gelen çalışmalar arasında yer almaktadır. Bu çalışmalar arasında özellikle son yıllarda önemi daha da artan gıda arzı ve bu arz nedeniyle yaşanan üretim sorunları düşünüldüğünde tarımsal alanların otomatik tespiti ve sınıflandırılması oldukça önemlidir. Son yıllarda sıklıkla kullanılan LiDAR teknolojisi sayesinde 3B nokta koordinatları elde edilebilmektedir. Bu 3B noktalar arazi ile arazi üzerindeki nesnelerin koordinatlarını da içermektedir. Bu nedenle çalışmada LiDAR verisi tercih edilmiştir. Çalışma kapsamında LiDAR verileri U.S. National Science Foundation, Intergovernmental Committee on Surveying and Mapping ve NOAA Office For Coastal Management isimli online kaynaklardan ve Körfez Haritacılık Planlama şirketinden offline bir şekilde ücretsiz olarak temin edilmiştir. LiDAR sisteminden elde edilen 3B nokta bulutu verisi ile 10 adet veri seti oluşturulmuştur. Daha sonra 3B nokta bulutu verisinden elde edilen görüntüler kullanılarak, tarımsal alandaki parsel sınırları tespit edilmiştir. Bu amaçla yapılan uygulamada öncelikle nokta bulutu verisinden elde edilen yoğunluk (intensity) görüntüleri belirli filtrelerden geçirilerek K-Ortalamalar, Bulanık C-Ortalamalar ve Ortalama Kaydırma kümeleme algoritmaları ile Canny, Sobel, Roberts ve Prewitt kenar bulma algoritmaları uygulanmış ve performans analizi yapılmıştır. Bu algoritmalar için en uygun parametre değerleri tespit edildikten sonra kümeleme ve kenar bulma algoritmalarının başarısı karşılaştırılmıştır. Doğruluk analizleri için F-Skor, Yüksek Sinyal Gürültü Oranı (YSGO), Sinyal Gürültü Oranı (SGO), Ortalama Karesel Hata (OKH), Yapısal Benzerlik İndeks Ölçümü (YBİÖ) ve Korelasyon Katsayısı (KK) ölçütleri kullanılmıştır. Elde edilen sonuçlarda F-Skor değerinde ortalama % 86 oranında başarı elde edildiği görülmüştür.

Anahtar Kelimeler: Kenar Bulma, Kümeleme, Nokta Bulutu, Parsel Sınırlarının Tespiti

ABSTRACT

PhD THESIS

Automatic Detection of Agricultural Field Boundaries from Aerial LiDAR Data

Mehmet Fatih GÜRBÜZ

**Konya Technical University
Institute of Graduate Studies
Department of Geomatics Engineering**

**Advisor: Prof. Dr. Hakan KARABÖRK
2nd Advisor: Assoc. Prof. Dr. Nurdan BAYKAN**

2024, 97 Pages

Jury

**Prof. Dr. Ferruh YILDIZ
Prof. Dr. Hakan KARABÖRK
Prof. Dr. Murat UYSAL
Assoc. Prof. Dr. Osman ORHAN
Asst. Prof. Dr. Ali SAĞLAM**

Object detection from satellite images, aerial photographs and LiDAR data has become popular in recent years. Especially considering that the food supply and the production problems which has become increasingly important in recent years, automatic detection and classification of agricultural areas is very important. By means of LiDAR technology, which has been used frequently in recent years, 3D point coordinates can be obtained. 3D points contain coordinates terrain and terrain objects. For this reason, LiDAR data was preferred in the study. Within the scope of the study, LiDAR data was obtained freely from the online sources that National Science Foundation, Intergovernmental Committee on Surveying and Mapping and NOAA Office for Coastal Management and also from the Körfez Mapping Planning Company in Turkey as offline data. Initially 10 data sets were generated with 3D point cloud data. Afterwards, using images obtained from 3D point cloud data, parcel boundaries in the agricultural area were determined. In the study, Firstly the intensity images were obtained from the point cloud data were passed through the specific filters. After that K-Means, Fuzzy C-Means and Meanshift clustering algorithms and Canny, Sobel, Roberts, Prewitt edge detection algorithms were applied to the intensity images and the most appropriate parameter values for these algorithms have been determined. Then, the success of clustering and edge detection algorithms was compared. Accuracy analyzes were conducted with reference data sets. The effect and performance of the accuracy criteria that F-Score, Peak Signal to Noise Ratio, Signal to Noise Ratio, Mean Squared Error, Structural Similarity Index Measure and Correlation Coefficient were tested on the results. The results showed that an average success rate of 86 % was achieved in the F-Score value.

Keywords: Clustering, Edge Detection, Parcel Boundaries Detection, Point Clouds

ÖNSÖZ

Tez çalışmasına önemli katkılar sunan başta danışmanım Sayın Prof. Dr. Hakan KARABÖRK olmak üzere, Sayın Prof. Dr. Ferruh YILDIZ'a, Sayın Doç. Dr. Nurdan BAYKAN'a, Sayın Dr. Öğr. Üyesi Ali SAĞLAM'a ve eşim Derya GÜRBÜZ'e teşekkürlerimi sunarım.

Mehmet Fatih GÜRBÜZ
KONYA-2024



İÇİNDEKİLER

ÖZET	iv
ABSTRACT	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR.....	ix
1. GİRİŞ.....	1
2. KAYNAK ARAŞTIRMASI	5
2.1. Uydu Görüntüleri Kullanılarak Yapılan Çalışmalar	5
2.2. Nokta Bulutu Verisi Kullanılarak Yapılan Çalışmalar.....	7
2.3. Hibrit Çalışmalar.....	9
3. MATERYAL VE METOT	11
3.1. LiDAR	11
3.2. Yoğunluk Görüntüsü	12
3.3. Filtreleme	12
3.4. Kümeleme	14
3.6. Kenar Bulma Operatörleri.....	22
3.6.1. Canny kenar bulma operatörü.....	25
3.6.2. Prewitt kenar bulma operatörü.....	31
3.6.3. Sobel kenar bulma operatörü.....	32
3.6.4. Roberts kenar bulma operatörü.....	33
3.7. Doğruluk Analizi Ölçütleri.....	33
3.7.5. Yüksek Sinyal Gürültü Oranı (YSGO)	35
3.7.6. Sinyal Gürültü Oranı (SGO).....	36
3.7.7. Ortalama Karesel Hata (OKH)	36
3.7.8. Yapısal Benzerlik İndeks Ölçümü (YBİÖ)	37
3.7.9. Korelasyon Katsayısı (KK)	37
3.8. Çalışma Alanı.....	38
3.9. Kullanılan Veriler	40
3.10. Metot	42
4. TEZ KAPSAMINDA YAPILAN UYGULAMA	43
4.1. Nokta Bulutu Verisinden Yoğunluk Görüntüsü Elde Edilmesi	43
4.2. Filtreleme İşlemleri.....	44
4.3. Doğruluk Analizleri İçin Referans Veri Seti Oluşturulması	45
4.4. Uygulanan Yaklaşımlar	46
4.4.1. Kenar bulma algoritmalarıyla sınırların tespiti.....	47
4.4.2. K-Ortalamlar kümeleme ile sınırların tespiti	48
4.4.3. Bulanık C-Ortalamlar kümeleme ile sınırların tespiti	50

4.4.4. Ortalama Kaydırma kümeleme ile sınırların tespiti.....	51
5. BULGULAR.....	55
5.1. Kenar Bulma Algoritmaları ile Elde Edilen Sonuçlar.....	55
5.2. K-Ortalamalar Kümeleme ile Elde Edilen Sonuçlar	60
5.3. Bulanık C-Ortalamalar Kümeleme ile Elde Edilen Sonuçlar	66
5.4. Ortalama Kaydırma Kümeleme ile Elde Edilen Sonuçlar	70
5.5. Yaklaşım ve Kenar Bulma Algoritmaları Bazında Sınır Tespitlerinin Karşılaştırılması;	74
5.5.1. F-Skor değerlerinin karşılaştırılması.....	74
5.5.2. YSGO, SGO, OKH, YBİÖ ve KK değerlerinin karşılaştırılması.....	75
5.5.3. Kenar bulma algoritmaları bazında F-Skor değerlerinin karşılaştırılması	79
5.5.4. Kenar bulma ve kümeleme algoritmaları bazında parametre değerlerinin karşılaştırılması	79
5.6. Nokta Yoğunluğu ve Yükseklik Değişimi Bazında Sınır Tespitlerinin Karşılaştırılması;	83
5.6.1. Nokta yoğunluğu bazında sınır tespitlerinin karşılaştırılması;	83
5.6.2. Yükseklik değişimi bazında sınır tespitlerinin karşılaştırılması;.....	84
6. SONUÇLAR VE ÖNERİLER	86
KAYNAKLAR	88
EKLER	98

SİMGELER VE KISALTMALAR

Kısaltmalar

CBS	:	Coğrafi Bilgi Sistemi (GIS - Geographic Information System)
ID	:	Kimlik (Identity)
İÖÜ	:	İnertiyel Ölçme Ünitesi (IMU – Inertial Measurement Unit)
KK	:	Korelasyon Katsayısı (CC – Correlation Coefficient)
KKS	:	Küresel Konumlama Sistemi (GPS – Global Positioning System)
KYM	:	Kırmızı, Yeşil, Mavi (RGB)
LiDAR	:	Işık Tespiti ve Uzaklık Tayini (Light Detection and Ranging)
NEFBÖ	:	Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI – Normalised Difference Vegetation Index)
OKH	:	Ortalama Karesel Hata (MSE – Mean Squared Error)
RÖK	:	Rastgele Örnek Konsensüsü (RANSAC – Random Sample and Consensus)
SGO	:	Sinyal Gürültü Oranı (SNR – Signal to Noise Ratio)
TBA	:	Temel Bileşenler Analizi (PCA – Principal Component Analysis)
YBiÖ	:	Yapısal Benzerlik İndeksi Ölçümü (SSIM – Structural Similarity Index Measure)
YSGO	:	En Yüksek Sinyal Gürültü Oranı (PSNR – Peak Signal to Noise Ratio)
2B	:	2 Boyutlu
3B	:	3 Boyutlu

1. GİRİŞ

Teknoloji ve bilginin çok hızlı bir şekilde geliştiği günümüzde, uluslararası standart ve kuralların önem kazandığı ve küreselleşmenin artmakta olduğu görülmektedir. Bu gelişmelere paralel olarak her alanda üretim ve verimin hızlı ve doğru bir şekilde arttırılması için sayısal sistemlere geçilmesi vazgeçilmez olarak görülmektedir.

Özellikle son yıllarda fotogrametri ve uzaktan algılama alanlarındaki gelişmelere paralel olarak özellikle algılayıcıların çözünürlüklerinin artması sebebiyle yüksek çözünürlüklü görüntülerin kullanımı artmıştır ve bu görüntüler araştırmacılara önemli bilgiler sunmaktadır. Fotogrametri ya da uzaktan algılama yöntemleri ile elde edilen verilerinden görüntü işleme teknikleri ile nesne tespitine yönelik çalışmalar son yıllarda önemli bir araştırma konusu haline gelmiş ve bu hususta tıp, bilgisayar, elektronik, inşaat, mimarlık, harita vb. birçok meslek disiplininin ilgilendiği bir alan olarak karşımıza çıkmaktadır. Doğrudan görüntü yada nokta bulutu verilerine kenar bulma algoritmaları, filtreleme, segmentasyon ve sınıflandırma yöntemleri gibi yaklaşımlar uygulanarak bu verilerden nesne (obje) belirleme çalışmaları güncel bilimsel çalışmalar arasında yer almaktadır.

Görüntülerden nesne tespiti ve bu nesnelerin sınıflandırılması haritacılık sektöründe özellikle kentsel değişim ve gelişimin görüntülenmesinde, gayrimenkul değerlendirme, şehir planlaması ve modellemesi, deformasyon analizleri, enerji sektörü, ormancılık, tarım ve afet yönetimi gibi birçok alanda kullanılmaktadır. Bu alanda yapılan çalışmalarda özellikle görüntü işleme analizleri de önemli bir yer tutmaktadır. (Kamara ve Doğan, 2019; Joshi ve ark., 2020; Kurnaz ve ark., 2020; Liu ve ark., 2020; Ramírez-Arias ve ark., 2020; Munawar ve ark., 2021; Jintasuttisak ve ark., 2022; Moon ve ark., 2022; Treccani ve Adami, 2023).

Son yıllarda önemi daha da artan gıda arzı ve bu arz nedeniyle yaşanan üretim sorunları düşünüldüğünde tarımsal alanların tespiti, sınıflandırılması, vb. amacıyla yapılan çalışmaların oldukça önemli olduğu bir gerçektir. Bunun yanında düzgün geometrik bir şekle sahip olan bina, yol gibi detayların çıkarımı görece olarak arazi sınırlarının tespitine göre daha kolay olmaktadır. Çünkü arazi sınırlarının belirli bir geometrik şekli ve yapısı bulunmamaktadır. Bu nedenle bu sınırların otomatik yöntemler ile tespitine yönelik algoritma geliştirmek nispeten daha zordur.

Optik sensör teknolojilerindeki gelişmeler neticesinde yüksek çözünürlüğe sahip sayısal görüntülerden doku ve renk bilgisi gibi 2 boyutlu bilgiler elde edilmesine rağmen görüntü çözünürlüğünün artması ile nesneleri birbirinden ayırma zorluğu da artmaktadır. Zira görüntülerde farklı nesneler farklı koşullarda benzer spektral imzaya yada aynı tip nesneler farklı spektral imzaya sahip olabilir. Yine bu tür görüntülerde istenmeyen gölge gibi detay bilgisi de bulunabilmektedir. Ayrıca görüntülerden üç boyutlu bilgi elde edilmesi daha karmaşık bir işlem olmaktadır (Chen ve ark., 2012).

Bununla birlikte iki boyutlu görüntüler kullanılarak 3B veri (nokta bulutu) üretmek için fotoğrafların görüntü alımı işlemi sırasında çekilen ardışık fotoğraflar arasındaki ortak alanın miktarını ifade eden bindirmeli olması gerekmektedir. Ancak bu yöntemlerle yüksek doğrulukta 3B veri elde etmek her zaman mümkün olmayabilmektedir. Bunun yerine LiDAR teknolojisinin kullanılması doğruluk, hız ve üretkenlik açısından daha etkili bir yöntem olduğu görülmektedir (Canaz ve Habib, 2013).

LiDAR verileri yeryüzüne ait üç boyutlu sayısal modellerin üretilmesinde kullanılan sistemlerdir. LiDAR sistemi saniyede binlerce lazer sinyali kullanır ve elde edilen yüksek doğrulukta 3B nokta verisi sayesinde objelere ilişkin çeşitli modeller, analizler ve sınıflandırmalar yapılabilmektedir. LiDAR verileri sağladığı hız, yüksek doğruluk ve maliyet gibi avantajlardan dolayı klasik yöntemlere göre tercih edilmekte olup kentsel alanlar, bitki örtüsü, iletim hatları vb. gibi objelerin tespitinde LiDAR verileri ön plana çıkmaktadır. LiDAR ile ilgili araştırmalar, 3 boyutlu bina modelleme ve değişim belirleme gibi uygulamalar üzerine yoğunlaşmıştır (Liu, 2008).

Farklı türdeki nesnelerin modellemesi ve analizi için değişik yöntemlerin kullanılması gerekmektedir. Bunun için LiDAR verisi doğru bir şekilde sınıflandırılmalıdır. LiDAR verisi çok sayıda nokta bulutundan oluştuğundan operatör yardımıyla (manuel) sınıflandırma yapılması pahalı ve zaman alıcı olmaktadır. Bu nedenle, yarı otomatik ya da otomatik yaklaşımlar kullanarak sınıflandırma yapılması güncel araştırma konuları arasındadır.

Bu alanda yapılan çalışmalar incelendiğinde; uydu görüntüleri ile LiDAR verisini kullanarak NEFBÖ (NDVI) ile bitki örtüsünün tespit edildiği (Sohn ve Dowman, 2007), skolyoz diye anılan bel iskelet eğriliğinin görüntülendiği (Habib ve ark., 2010), göl alan sınırlarının çıkarıldığı (Canaz ve ark., 2015), orman alanlarından ağaç hacim hesabının yapıldığı (Giannico ve ark., 2016), enerji nakil hatlarını çıkarıldığı

(Sevgen ve Canaz, 2016), tek sokak ağaçlarının elde edildiği (Çetin ve Yastıklı, 2022) görülmektedir.

Uydu görüntüleri ya da nokta bulutu verileri kullanılarak bina sınırlarının tespitine yönelik çalışmaların yoğun olduğu anlaşılmaktadır (San ve Türker, 2007; Uzar ve Yastıklı, 2011; Marangoz ve Alkış, 2012; Demir, 2015; Aroni ve Ioannidis, 2018; Bool ve ark., 2018; Güler, 2018; Elsayed ve ark., 2019; Park ve Guldmann, 2019; Gamal ve ark., 2020; Hui ve ark., 2021; Li ve ark., 2020; Han ve ark., 2021; Feng ve ark., 2022; Li ve ark., 2022; Benchabana ve ark., 2023 ve Dey ve ark., 2023).

Ayrıca, uydu görüntüleri ya da hava fotoğraflarından tarımsal arazilerin sınırlarının tespitine yönelik çok sayıda çalışma bulunduğu görülmektedir (Rahımzadeganasl, 2015; Garcia-Pedrero ve ark., 2017; North ve ark., 2018; Wassie ve ark., 2018; Ghaffarian ve Turker, 2019; Robb ve ark., 2020; Wagner ve Oppelt, 2020; Waldner ve Diakogiannis, 2020; Hong ve ark., 2021; Taravat ve ark., 2021; Zhang ve ark., 2021; Sharifi ve ark., 2022 ve Lavanya ve ark., 2023).

Bununla birlikte LiDAR nokta bulutu verilerinden parsel sınırlarının tespitine yönelik bir takım çalışmalar bulunmasına karşın bu alandaki çalışmaların sınırlı olduğu ve yapılan çalışmalarda ise kümeleme algoritmalarının çok tercih edilmediği ya da bu algoritmaların yeterince test edilmediği tespit edilmiştir (Mathews ve Jensen, 2012; Luo ve ark., 2017 ve Borowiec ve Marmol, 2022).

Bu çalışmada yersel ölçüm metotlarına karşın tarımsal alanların tespiti amacıyla nokta bulutu verilerinden yararlanılarak elde edilen görüntülerinin bu amaçla kullanılıp kullanılamayacağı, özellikle sabit tesislere sahip arazi sınırlarının otomatik nesne tespiti yöntemleri ile istenilen doğrulukta elde edilip edilemeyeceği hususlarının araştırılması amaçlanmıştır.

Çalışma kapsamında, nokta bulutu verisi kullanılarak elde edilen görüntülere filtreleme, kenar bulma ve kümeleme algoritmaları uygulanarak görüntülerdeki parsel sınırları tespit edilmiştir. Yine kenar bulma ve kümeleme algoritmaları içerisinde yer alan ve tez içeriğinde detayları belirtilen parametre değerleri de test edilerek en uygun parametre değerleri bulunmuştur. Ayrıca çalışma kapsamında kenar bulma ve kümeleme algoritmaları ile doğruluk ölçütleri karşılaştırılarak bu algoritmaların ve ölçütlerin birbirine göre avantaj ve dezavantajları belirlenmiştir. Bu kapsamda literatürde en sık kullanılan Canny, Sobel, Roberts ve Prewitt kenar bulma algoritmaları ile K-Ortalamalar, Bulanık C-Ortalamalar ve Ortalama Kaydırma kümeleme algoritmaları örnek veriler üzerinde test edilerek karşılaştırılmış ve en iyi sonucu veren

algoritma belirlenmiştir. Bununla birlikte farklı doğruluk analizlerine imkân sağlayan F-Skor, Yüksek Sinyal Gürültü Oranı (YSGO), Sinyal Gürültü Oranı (SGO), Ortalama Karesel Hata (OKH), Yapısal Benzerlik İndeks Ölçümü (YBİÖ) ve Korelasyon Katsayısı (KK) ölçütleri de elde edilen sonuçlar üzerinden test edilmiştir.

Böylece bu tür çalışmalardan elde edilecek sonuçlar ile tarımsal araziler üzerinde yapılan çalışmalarda etkinliği ve verimliliği artırmak, zaman ve maliyet açısından kazanımlar elde etmek, kaynak israfının önlenmesi, üretim aşamalarında insan kaynaklı hataların asgari düzeye indirgenmesi, en son teknolojilerin kurumsal çalışmalarda kullanılması öngörülmektedir.



2. KAYNAK ARAŞTIRMASI

2.1. Uydu Görüntüleri Kullanılarak Yapılan Çalışmalar

Torre ve Radeva (2000), hava görüntülerinden tarım alanı sınırlarının yarı otomatik olarak çıkarılmasını sağlayan, alan büyütme ve snake tekniklerini birleştirerek bölge rekabeti yaklaşımı olarak adlandırılan bir yaklaşım geliştirmiştir. Ortalama 30 parsel içeren 20 farklı hava fotoğrafında algoritma test edilmiş ve % 70 oranında başarı elde edilmiştir.

Rydberg ve Borgefors (2001), multispektral uydu görüntülerinden tarım alanlarının sınırlarının belirlenmesi için bütünleşmiş bir yöntem önermiştir. Çalışmada radyan kenar detektöründen gelen multispektral kenar bilgisi ile ISODATA sınıflandırıcısından elde edilen segmentasyon verisi entegre edilerek sonuçlar değerlendirilmiştir. Çalışma sonucunda uydu görüntüsünde yaklaşık % 87 oranında parsel kenarları tespit edilmiştir.

Özdarıcı ve Ok (2007), uydu görüntülerindeki tarımsal alanların tespiti için Ortalama Kaydırma algoritması destekli “En Büyük Olasılık” sınıflandırma yaklaşımı geliştirmiş ve doğruluk analizleri yardımıyla test edilen görüntülerde % 78 oranında doğruluk elde etmişlerdir.

San ve Türker (2007), uydu görüntülerinden binaların otomatik olarak tespiti için bir yaklaşım önermişlerdir. Çalışmada bina sınırlarının belirlenmesi amacıyla Canny Kenar Bulma Algoritması, Hough Dönüşümü ve Algısal Gruplama teknikleri kullanılmış olup bina sınırlarının tespitinde başarılı sonuçlar elde edilmiştir.

Büyüksalih ve ark. (2009), IKONOS ve Orb View-3 uydu görüntülerinden topografik harita yapımının mümkün olabileceğini belirtmişlerdir.

Marangoz (2009), uydu görüntülerinden bina ve yollar gibi kentsel detayları çıkarmıştır. Çalışmada, görüntülerin geometrik ve semantik içeriğinden yararlanarak 1/5000 ölçekli haritaların yapımı ve güncelleştirilmesi için uydu görüntülerinin kullanılabilirliği değerlendirilmiştir.

Marangoz ve Alkış (2012), uydu görüntülerindeki bina ve yollar gibi kentsel detayları nesne tabanlı sınıflandırma yaklaşımı kullanarak çıkarmışlardır. Elde edilen ürünler, referans vektör veriler ile karşılaştırılmış ve sonuçlar CBS ortamında analiz edilmiştir.

Ezeomede ve Igbokwe (2013), uydu görüntüleriyle haritalama, arazi kullanımı ve değişim analizleri için yaklaşım geliştirmiştir.

Turker ve Kok (2013), uzaktan algılama görüntülerinden tarımsal arazilerin alt sınırlarının Gestalt'ın yakınlık, devamlılık, simetri, benzerlik, kapanma vb. yasalarını içeren algısal gruplama algoritması kullanarak otomatik olarak çıkarılması için bir yaklaşım sunmuşlardır. Kullanılan SPOT5 ve SPOT4 görüntülerinde tarımsal arazilerin sınırlarına ait kenarların genel eşleşme yüzdeleri sırasıyla % 82,6 ve % 76,2 olarak hesaplanmıştır.

Nacar (2015), Konya, Adana ve Şanlıurfa'da seçilen 3 pilot bölgede ortofoto ve vektör haritalar kullanılarak parsellerin alanlarını belirlemiştir. Elde edilen sonuçlar ışığında, güncelleme kadastrosunda ortofoto görüntülerinin kullanılabileceği sonucuna varılmıştır.

Rahimzadeganasl (2015), uydu görüntülerinden tarımsal parsel sınırlarını çıkarmak için Havza Algoritmasının genişletilmesine dayalı Parsel-Tabanlı segmentasyon yaklaşımı önermektedir. Geliştirilen yöntem ile genel doğruluk oranlarının Spot5, IKONOS, QuickBird ve keskinleştirilmiş QuickBird görüntüleri için sırasıyla % 80.34, % 89.72, % 83.24 ve % 78.88 olduğu görülmüştür.

Ok (2016), çalışmada uydu görüntülerinden kentsel alanlardaki bina ve yol objelerin tespiti için bir yöntem sunmuştur. Sunulan yaklaşım ile bina ve yol gibi detayların görüntülerden belirlenebileceğini göstermiştir.

Wassie ve ark. (2018), uydu görüntülerindeki doğal ve insan yapımı kadastral sınırların Ortalama Kaydırma Algoritması ile tespit etmeyi amaçlamıştır.

Xia ve ark. (2018), yüksek çözünürlüklü uydu görüntülerindeki tarımsal arazilerdeki ekili alanların çıkarılması için derin öğrenme metotları uygulanan bir yöntem önermiştir. Elde edilen sonuçlar, derin öğrenme tabanlı yöntemlerin tarımsal alanların tespitinde büyük bir potansiyel olduğunu göstermiştir.

Ghaffarian ve Turker (2019), yüksek çözünürlüklü uydu görüntülerinden parsel alt sınırlarının tespiti için geliştirilmiş küme tabanlı bir snake modeli önermiştir. Çalışmada Bulanık C-Ortalamlar kümeleme ile geliştirilmiş snake modeli test edilmiştir. 20 test alanından elde edilen sonuçlara göre en yüksek genel doğruluk % 93,61 ile IKONOS XS görüntüsüne ait olup QuickBird XS ve QuickBird PS görüntüleri için genel doğruluk sırasıyla % 84,96 ve % 88,78 olarak elde edilmiştir.

Kumar ve ark. (2020), makine öğrenme teknikleri kullanarak kıyı şeridi değişikliğinin haritalamasını amaçlamıştır. Landsat görüntüleri başta Sobel ve Canny

olmak üzere kenar algılama filtreleri kullanılarak analiz edilmiştir. Modelin performansı karşılaştırılmış ve yapay sinir ağı modelinin % 86,2 doğrulukla k-en yakın komşu ve destek vektör makinesi modelinden daha iyi performans gösterdiği gözlemlenmiştir.

Wagner ve Oppelt (2020), derin öğrenme metotları yardımıyla uydu görüntülerinden parsel sınırlarının elde edilmesini amaçlamıştır. Genel doğruluk düzeyi % 88 olarak elde edilmiştir.

Sharifi ve ark. (2022), uzaktan algılama görüntüleri kullanarak çok görevli bir segmentasyon modeline dayalı olarak görüntülerden alan sınırlarının algılanmasını amaçlamıştır. Bunun için çalışmada evrimsel bir sinir ağı metodu kullanılmıştır. Diğer tüm yöntemlerle karşılaştırıldığında % 85,60 genel doğruluk elde edilmiştir.

Lavanya ve ark. (2023), Landsat 7 multispektral uydu görüntülerini kullanarak binalar, bitki örtüsü, su kütleleri vb. gibi arazi kullanımı/arazi örtüsü (LULC) türlerinin tespitini amaçlamıştır. Çalışmada Maksimum/Minimum olabilirlik sınıflandırması ile nesne tabanlı görüntü sınıflandırması kullanılmış ve % 70 - 80 aralığında başarı oranı elde edilmiştir.

2.2. Nokta Bulutu Verisi Kullanılarak Yapılan Çalışmalar

Vosselman ve ark. (2005), kentsel alanlarda 3 boyutlu haritaların üretimi ve değişim tespitinde LiDAR'ın kullanımını araştırmışlardır. Bu amaçla LiDAR verisi çok çözünürlüklü bölge bazlı segmentasyon kullanarak ayrıştırılmış ve bina ve diğer objeler olarak ayrı sınıflara atanmış ve elde edilen sonuçlar değerlendirilmiştir.

Zhang ve ark. (2006), LiDAR verisinden binaların zemin oturumlarını otomatik olarak çıkarmaya çalışmışlardır. Çalışmada morfolojik filtreler kullanılarak nokta bulutu verisi sınıflandırılmıştır. Daha sonra düzlem yerleştirme yöntemine dayalı olan bölge büyütme metodu ile zemine ait olmayan noktalardan binalar tespit edilmiştir.

Saeedi ve ark. (2009), kentsel alanlarda LiDAR verilerinden nesne çıkarımı için K-Ortalamalar Algoritması ile Yapay Arı Kolonisi Algoritmasını entegre ederek sağlam ve verimli bir kümeleme yöntemi önermiştir.

Aktaruzzaman ve Schmitt (2010), kentsel alanlarda sel olaylarının kontrolü amacıyla yaptıkları çalışma kapsamında LiDAR verisinden elde edilen nokta bulutundaki bina ve yol detaylarını çıkarmak için yarı otomatik bir yaklaşım geliştirmiştir.

Mathews ve Jensen (2012), LiDAR verilerinden normalize edilmiş sayısal yüzey modeli oluşturmuş, sınıflandırma işlemi için ISODATA algoritması kullanmıştır. Sonuç olarak parsel alanlarının ortalama doğruluğu % 88.79 olarak tespit edilmiştir.

Torun ve Düzgün (2013), LiDAR nokta bulutundan mekânsal veri madenciliği ve hesaplamalı geometri tekniklerinden oluşan karma bir yöntem sunan DAPHNE yaklaşımı ile kentsel alanlarda bina çatılarının geometrisinin oluşturulması amaçlı çalışma yapmışlardır.

Zhang ve ark. (2013), nesne tabanlı nokta bulutu analizi ile LiDAR nokta bulutlarından bilgi elde etmeyi amaçlamıştır. Çalışmada kentsel alanlarda LiDAR nokta bulutlarını sınıflandırmak için nesneye dayalı bir sınıflandırma yöntemi önerilmiştir. Sınıflandırma sürecinde, nokta bulutlarının kümelenmesini sağlamak için Yüzey Büyütme Algoritması ve Destek Vektör Makinesi kullanılmıştır. Deneyler, önerilen yöntemin kentsel nokta bulutlarını genel olarak sınıflandırabileceğini göstermektedir.

Demir (2015), Sayısal Yükseklik Modeli, Sayısal Arazi Modeli ve LiDAR verisinin de kullanıldığı dört farklı yöntem uygulanarak görüntülerden bina tespiti yapmıştır. Çalışmada, yöntemlerin özelliklerine, avantaj ve dezavantajlarına bağlı olarak % 94 ve % 92 oranlarında doğruluk değerlerine ulaşılmıştır.

Luo ve ark. (2017), hava LiDAR verisinden kadastral parsel sınırlarının tespiti için yarı otomatik bir yöntem geliştirmiştir. Çalışmada, nokta bulutu verisi yardımıyla bina, yol, bitki örtüsü, elektrik hatları, çit gibi araziye ait detayların tespiti amaçlanmıştır. Canny, α -şekil, bağlantılı bileşen, iskelet (α -shape, connected component, skeleton) segmentasyon algoritmaları belirlenen iş akışı içerisinde test edilmiştir. Geliştirilen iş akışının sonucunda, kadastral parsel sınırlarının yaklaşık % 50'sinin başarıyla çıkarıldığı görülmüştür.

Ma ve ark. (2017), LiDAR verisini kullanarak Rastgele Orman Algoritması (Random Forest Classifier) ile binaları, ağaçları, tarlaları ve zemini sınıflandırmıştır.

Zhang ve Zhang (2017), kentsel alana ait 3 boyutlu nokta bulutlarının derin öğrenme çerçevesi içinde 3B evrişimsel sinir ağı, derin Q ağı ile tekrarlayan sinir ağı yöntemlerini bütünleşmiş bir şekilde kullanarak noktaların ayrıştırılması ve bina, bitki örtüsü, yapay objeler vb. nesnelerin tespitini amaçlamıştır.

Bool ve ark. (2018), belirli bir bölgedeki binaların şeklini, sayısını ve dağılımını ve yerini belirlemeyi amaçlamıştır. Çalışmada sınıflandırılmış LiDAR nokta bulutundan elde edilen veri kümesini işlemek için RANSAC algoritması kullanılmıştır.

Güler (2018), LiDAR verisinden otomatik bina çatı düzlemlerinin çıkarılması amaçlamıştır. Çalışmada Bölge Büyüme Segmentasyon, RANSAC, DBSCAN ve Douglas-Peucker algoritmaları uygulanarak bina çatıları otomatik olarak tespit edilmiştir.

Park ve Guldman (2019), LiDAR noktalarını sınıflandırarak bina alanlarını tahmin etmeyi amaçlamıştır. Yöntem olarak Makine Öğrenme yaklaşımı olan Rastgele Orman Algoritması kullanılmış ve çatı, duvar, zemin ve yüksek aykırı değer olmak üzere 4 sınıf oluşturularak sonuçlar test edilmiştir.

Sevgen (2019), kentsel alana ait LiDAR verisini kullanarak Rastgele Orman Algoritması ile bina, bitki örtüsü, asfalt yol ve zemin noktalarını sınıflandırmıştır.

Bayaslı (2021), LiDAR verisini, denetimsiz bir yapay sinir ağı yöntemi olan Kendini Düzenleyen Haritalar, denetimli bir makine öğrenmesi yöntemi olan Rastgele Orman Algoritması ve denetimli bir yapay sinir ağı yöntemi olan Derin Öğrenme ile sınıflandırmış, uydu görüntüleri ve sokak görüntüleri kullanılarak oluşturulan referans veri seti ile doğruluk analizlerini yapmıştır.

Borowiec ve Marmol (2022), tarım arazilerinin sınırlarını belirlemek için LiDAR verilerine Temel Bileşenler Analizi (PCA) ve Hough Dönüşüm algoritmasını uygulamıştır.

Gürbüz ve ark. (2023), nokta bulutu verisine Canny, Sobel, Roberts ve Prewitt kenar bulma algoritmaları uygulayarak parsel sınırlarını tespit etmişler ve bu sınırların kenar bulma algoritmalarıyla başarılı bir şekilde tespitinin mümkün olduğunu belirtmişlerdir.

2.3. Hibrit Çalışmalar

Rottensteiner ve ark. (2003), LiDAR ve multispektral görüntüler kullanarak otomatik bina tespitine yönelik çalışma yapmışlardır. Çalışmada LiDAR verisinin ilk ve son dönüş noktaları, ortofoto görüntüler, NEFBÖ, bağlı bileşenler analizi ve morfolojik filtreler kullanılmıştır.

Kabolizade ve ark. (2010), renkli hava görüntülerinden ve LiDAR verilerinden bina çıkarımına odaklanan gelişmiş bir snake modeli önermektedir. Önerilen snake modeli, yükseklik benzerlik ve bölgesel benzerlik enerji faktörü ile gradyan vektör akışını içermektedir. Geleneksel snake modeliyle karşılaştırıldığında, uygulanan

algoritmanın, özellikle karmaşık kentsel ortamlarda gerçek bina hatlarına daha hızlı ve daha kararlı bir şekilde tespit ettiği belirtilmiştir.

Uzar ve Yastıklı (2011), LiDAR ve hava fotoğraflarının füzyonu ile nesne tabanlı sınıflandırma yöntemini kullanarak, otomatik bina tespiti için bir yaklaşım önermiştir. Çalışmada, Bulanık Mantiğa Dayalı Sınıflandırma, NEFBÖ ve Hough Dönüşümü kullanılmış ve analizler için kural setleri geliştirilmiştir.

Giampouras ve ark. (2013), Yapay Sinir Ağları metodu ile hiperspektral görüntüsü ve LiDAR verisi entegre edilerek arazi örtüsünün sınıflandırılmasını gerçekleştirmişlerdir. Çalışmada hiperspektral görüntüden özellik çıkarma işlemleri için Temel Bileşenler Analizi (PCA) uygulanmıştır.

Zhang ve ark. (2017), LiDAR verileri, yüksek çözünürlüklü ortofoto ve Google Street View görüntülerini kullanarak Rastgele Orman Algoritması ile parsel bazlı arazi kullanım sınıflandırmasının performansını test etmiştir. Çalışmada konut ve ticari binalara ait parsellerin diğer arazi kullanım parsellerinden ayrılmasında Google Street View görüntülerinin kullanımı araştırılmıştır.

Elsayed ve ark. (2019), binaların sayısal hava görüntülerinden ve LiDAR verilerinden otomatik olarak çıkarılması için bir yaklaşım önermiştir. Destek Vektör Makineleri ve Yapay Sinir Ağları sınıflandırıcıları uygulanmış yaklaşık % 87 oranında genel doğruluk oranı gözlenmiştir.


Ojogbane ve ark. (2021), Derin Sinir Ağı yöntemi ile LiDAR ve Çok Yüksek Çözünürlüklü Hava Görüntüleri birlikte kullanılarak otomatik bina tespitine ilişkin yaklaşım önermişlerdir. Yöntemin genel doğruluğu % 80'den büyük olduğu görülmüştür.

Azad ve Farnood (2022), LiDAR verileri ve görüntüler kullanılarak öz nitelik algılama için yarı otomatik bir yöntem önermiştir. Bu yaklaşımda, önerilen yöntemin kentsel özellikleri (bitki örtüsü, yol ve bina dahil) farklı şekillerde başarılı bir şekilde tespit edebildiğini göstermiştir. Bitki örtüsünün genel doğruluğu, kappa katsayısı, üretici doğruluğu ve kullanıcı doğruluğu sırasıyla % 97, % 92, % 96 ve % 94, bina sınıfına ilişkin üreticinin doğruluğu, kullanıcının doğruluğu ve kappa katsayısının sırasıyla % 94, % 95 ve % 91, Yol sınıfı hakkında ise bu parametrelerin % 95, % 89 ve % 91 doğrulukta tespit edildiği görülmüştür.

3. MATERYAL VE METOT

3.1. LiDAR

1960'lı yıllarda ortaya çıkan LiDAR (Light Detection and Ranging) lazer tarayıcı algılama sistemidir. Bu sistem ile yüksek doğruluklu konumsal veri elde edilebilmektedir. LiDAR'ın temel çalışma prensibi gönderilen lazer sinyali ile objeden yansıyan sinyalin alıcıya geri dönme süresinin ölçülmesine dayalıdır (Petrie ve Toth, 2009). Bunun için Küresel Konumlama Sistemi (KKS) (GPS- Küresel Konumlama Sistemi) ve İnertiyel Ölçme Ünitesi (İÖÜ) (IMU- Inertial Measurement Unit) kullanılır. GPS/IMU sistemi ile lazer sinyalinin gönderildiği esnadaki konum ve dönüklük bilgileri ölçülerek objenin X, Y, Z koordinatları elde edilir. Şekil 3.1'de LiDAR sisteminin temel prensibi temsil edilmiştir.



Şekil 3.1. LiDAR sisteminin temel prensibi (Beek, 2015).

800 ila 1550 nm aralığında yakın kızılötesi dalga boyu kullanan LiDAR sayesinde nesnelere ait geometrik bilgiler ile yer yüzeyinin yansıtma karakteristiğinin elde edilmesi sağlanır (Höfle ve Pfeifer, 2007).

Amerika Fotogrametri ve Uzaktan Algılama Birliği tarafından ikili (binary) sistemde “.las” formatı geliştirilmiş olup LiDAR verileri bu formatta depolanmaktadır. Her bir las dosyasında ölçülen noktaya ait; dönen sinyalin şiddeti (Intensity), dönüş

sayısı ve kaçınıcı dönüş olduğu, nokta koordinatları (x, y, z) ve uçuş hattı, yüzey kategorisi gibi bazı öznitelik bilgileri bulunmaktadır. (Yıldız, 2022).

3.2. Yoğunluk Görüntüsü

Sayısal görüntüler cisimlerden yansıyan elektromanyetik enerjinin piksel bazında parlaklık değerlerinin ölçülmesi ile oluşmaktadır. Matematiksel anlamda sayısal görüntü x, y koordinatlarındaki piksellerin parlaklık değerini üreten bir fonksiyondur. Objenin yansıtma özelliğine göre değişen yoğunluk (intensity) değeri LiDAR sistemlerinde lazer sinyalinin dönüş gücünden her nokta ölçülerek elde edilmektedir. Lazer sinyalinde yoğunluk bilgisi ayrıca kaydedilerek “intensity görüntü” oluşmaktadır. Yoğunluk görüntüsü LiDAR verilerinin sınıflandırmasında öznitelik belirleme ve nesne tespiti işlemlerinde ya da hava fotoğrafları yerine kullanılmaktadır (Höfle ve Pfeifer, 2007).

LiDAR gibi üç boyutlu nokta bulutu verilerinden nesne tespiti elde edilebilmesi amacıyla yapılan çalışmalarda bu noktaların sınıflandırılarak anlamlı hale getirilmesi amaçlanmaktadır. Hedef nesnenin türüne göre sınıflandırma metotları değişebilmektedir. Tez çalışmamızda olduğu üzere özellikle belirgin bir geometrik şekli bulunmayan parsel sınırlarının tespitinde nokta bulutu verisini direk kullanmak yerine görüntü formatına çevirerek sınıflandırma yapmak daha etkili bir yöntem olup çalışmada nesne tespiti amacıyla nokta bulutu verisi yoğunluk görüntüsüne çevrilmiştir.

3.3. Filtreleme


Görüntülerin kaydedilmesi sırasında oluşan gürültü (noise) gibi bozucu etkiler istenmeyen görüntü içerikleridir. Filtreleme ile istenmeyen bu gibi gürültülerin görüntülerden temizlenmesi amaçlanmaktadır. Ayrıca kenar tespiti, görüntü keskinleştirme, bulanıklaştırma ve görüntü yumuşatma gibi bazı detayların öne çıkarılması ya da bastırılması için de filtreler kullanılmaktadır. Bu sayede görüntünün görsel olarak yorumlanması kolaylaşmaktadır. Filtreleme işlemi için çeşitli sayısal filtre operatörleri bulunmaktadır. Filtreler, matris formatında olup boyutları kullanım amacına göre değişebilmektedir.

Yumuşatma işlemi görüntüdeki piksel değerlerinin bir öncekinden bir sonrakine ani artış ya da azalış şeklinde keskin geçişleri önlemek amacıyla yapılmaktadır. Diğer

bir deyişle, bir piksel ile komşuları arasındaki deęişim miktarı azaltılmaktadır. Yaygın olarak kullanılan yumuřatma filtreleri arasında Ortalama, Medyan ve Gauss filtreleri yer almaktadır.

Tez alıřmasında filtreleme iřlemi iin Ortalama (Mean), Medyan (Ortanca-Median) ve Gauss filtreleri kullanılmıř olup elde edilen sonuların birbirine yakın olduęu grlmřtr. Bu filtrelerin arasında daha iyi sonu veren Medyan filtresi grntlere uygulanmıřtır.

Medyan filtresi; resimdeki grlty azaltmak iin kullanılan bir filtredir. Medyan filtresinde matris boyutuna denk gelen grntdeki piksel deęerleri ncelikle kkten byęe sıralanır ve sıralamada ortada bulunan sayının deęeri grntnn bulunduęu matrisin ilgili pikseline atanır (Gonzalez ve ark., 2008). Medyan filtresi genellikle tuz ve biber (salt and pepper) adı verilen etkinin giderilmesi iin kullanılır (Blackledge, 2005). řekil 3.2’de grlt bulunan bir grntye uygulanmıř Medyan filtresi ıktısı grlmektedir.



řekil 3.2. a) Grlt bulunan grnt, **b)** 3x3 boyutunda Medyan filtresi uygulanmıř grnt (Gonzalez ve ark., 2008).

Medyan filtreleme iřlemini aıklamak iin, F grntsndeki bir $F(k, l)$ pikseli ve bu pikselin sekiz komřu piksellerin gri deęerleri ařaęıda grlmektedir (řekil 3.3). $F(k, l)$ pikselinin, yatay ynde $(k+1, l)$, $(k-1, l)$, dřey ynde $(k, l+1)$, ve $(k, l-1)$, křegenlerde ise $(k-1, l-1)$, $(k-1, l+1)$, $(k+1, l-1)$, ve $(k+1, l+1)$, olmak zere toplam sekiz adet komřu pikseller bulunmaktadır. Bu komřuluklar řekil 3.3’te (a) ve (b) ile gsterilmiřtir (Ghit, 2022).

	$(k, l-1)$		$(k+1, l-1)$	$(k, l-1)$	$(k-1, l-1)$
$(k+1, l)$	k, l	$(k-1, l)$	$(k+1, l)$	k, l	$(k-1, l)$
	$(k, l+1)$		$(k+1, l+1)$	$(k, l+1)$	$(k-1, l+1)$
(a)			(b)		

Şekil 3.3. (a) 4- Komşuluk ilişkili, (b) 8- Komşuluk ilişkili

Örneğin, (10, 10, 20, 20, 15, 20, 20, 25, 50) değerlerine sahip bir görüntüye 3x3 boyutunda bir Medyan filtresi uygulandığında öncelikle bu değerler (10, 10, 15, 20, 20, 20, 20, 25, 50) şeklinde küçükten büyüğe sıralanır. Sıranın ortasındaki değer olan 20 değeri görüntünün Medyan değerini oluşturur. Şekil 3.3’de (k, l) olarak yeniden tanımlanan piksel değeri örnek matrisinde 15 değerine sahip piksel olduğu varsayıldığında, bu piksele Medyan filtresi uygulandığında 20 değerini alacaktır. Bu işlem tüm pikseller boyunca adım adım uygulanır.

Tez çalışmasında kenar tespiti işlemlerinden önce yoğunluk görüntülerindeki gürültüleri azaltmak amacıyla Medyan filtresi her bir test alanında uygulanmış ve sonraki işlem adımlarında Medyan filtresi uygulanmış sonuç görüntüsü kullanılmıştır.

3.4. Kümeleme

Kümeleme verilerin benzerlik özelliklerinden yararlanılarak gruplama işlemidir. Kümeleme işleminde ana problem nesneleri ortak özelliklerine dikkat ederek ayrı gruplara ayırmaktır. Nesnelerin aynı kümeye atanabilmesi için herhangi bir şekilde nesnelerin birbirine daha benzer olması gerekmektedir. Böylelikle aynı küme içindeki elemanların özellikleri benzer iken, farklı kümelerdeki elemanların özelliklerinin farklı olması istenir. Başlıca kümeleme metotları şunlardır (Saeedi ve ark., 2009);

a- Yoğunluk Temelli Yöntemler (Density-Based Methods)

b- Hiyerarşik Tabanlı Yöntemler (Connectivity-based Clustering)

c- Centroid Tabanlı (Centroid-based) veya Bölümleme Tabanlı (Partitioning Methods) Yöntemler: K-Ortalamalar, Bulanık C-Ortalamalar ve Ortalama Kaydırma kümeleme algoritmaları bu grupta yer almaktadır.

d- Grid Tabanlı Yöntemler (Grid-based Methods)

e- Model Tabanlı Yöntemler (Model-Based Methods)

Tez çalışması kapsamında LiDAR nokta bulutu verisinden elde edilen filtre uygulanmış yoğunluk görüntülerine K-Ortalamlar, Bulanık C-Ortalamlar ve Ortalama Kaydırma kümeleme algoritmaları uygulanmıştır.

K-Ortalamlar Kümeleme Yöntemi (K-Means): İlk olarak 1967 yılında James MacQueen tarafından geliştirilen bu yöntem, piksel tabanlı eğitimsiz bir sınıflandırma işlemi olup bilimsel çalışmalarda sıklıkla tercih edilmektedir. K-Ortalamlar kümeleme algoritmasında amaç "n" adet nesneden oluşan bir veri setini "k" adet kümeye gruplamaktır. Kümeleme işleminde; kümeler arası benzerlik oranının düşük, küme içi benzerlik oranının ise yüksek olması beklenir. Kümeleme işleminde benzerlik oranı kümedeki diğer nesneler ile kümenin ağırlık merkezi olarak kabul edilen bir nesne arasındaki uzaklıkların ortalama değeri ile belirlenmektedir (Han ve Kamber, 2001).

K-Ortalamlar kümeleme yönteminde ilk olarak küme merkezleri seçilir ve her bir piksel rastgele ortalama vektörüne en yakın olan kümeye atanır. Daha sonra her bir küme için ortalama vektörler tekrar hesaplanır. Bu işlem döngü (iterasyon) adı verilen ve belirlenen bir işlem tekrar sayısında ortalama vektörlerin konumlarındaki bir değişim gözlenmeyene kadar devam eder (Lillesand ve ark., 2008).

K-Ortalamlar yönteminin işlem adımları şu şekildedir (Demiralay ve Çamurcu, 2005);

1. Küme merkezleri belirlenir. Burada küme merkezleri iki farklı yoldan elde edilebilir. Birincisi rastgele "k" adet küme merkezi seçilmesidir. İkinci yol ise merkez noktaların tüm nesnelerin ortalaması alınarak belirlenmesidir.

2. Her nesnenin seçilen merkez noktalara olan uzaklığı hesaplanır ve sonuçlara göre tüm nesneler "k" adet kümeden kendilerine en yakın olan kümeye atanır.

3. Oluşan kümelerin yeni merkez noktaları, o kümedeki tüm nesnelerin ortalama konumuna göre tekrar belirlenir.

4. Merkez noktalar değişmeyene kadar 2. ve 3. adımlar tekrarlanır.

K-Ortalamlar yönteminde nesnelerin merkez noktalara olan mesafesini ölçmek için kullanılan temel olarak 4 farklı algoritma bulunmaktadır (MacQueen, 1967).

- Öklit Uzaklığı (Euclidean Distance)
- Öklit Uzaklığının Karesi (Squared Euclidean Distance)
- City-Block Uzaklık Formülü (City-Block (Manhattan) Distance)
- Chebychev Uzaklığı (Chebychev Distance)

K-Ortalamlar kümeleme yöntemi karesel hata kriterini kullanan bir algoritma olup karesel hatayı en küçük yapacak olan "k" adet kümeyi tespit etmeyi amaçlamaktadır. K-Ortalamlar kümeleme yönteminde her bir veri nesnesi ile küme merkezleri arasındaki uzaklığı hesaplamak için Öklit uzaklığı en sık kullanılan algoritmadır. Denklem 3.1'deki formül tüm nesnelerin karesel hatalarının toplamını belirlemek için kullanılmaktadır.

x : hedef nesne,

x_i : C_i kümesinin ortalama değeri,

k : küme sayısı,

E : Verideki tüm nesnelerin karesel hatalarının toplamı,

olmak üzere;


$$E = \sum_{i=1}^k \sum_{x \in C_i} |x - x_i|^2 \quad (3.1)$$

Bir nesne ile küme merkezi arasındaki Öklid uzaklığı $x = (x_1, x_2 \dots x_n)$ vektörü ve başka bir $y = (y_1, y_2 \dots y_n)$ vektörü olmak üzere Öklid uzaklığı $d(x_i, y_i)$ ise Denklem 3.2'deki formül ile hesaplanmaktadır.

$$d(x_i, y_i) = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (3.2)$$

Öklid uzaklığı değerinin yüksek ya da düşük çıkması nesnelerin bulundukları küme merkezlerine olan konumları ile ilişkilidir. Bu değer düşük olması nesnelerin küme merkezlerine yakın olduğunu, yüksek olması ise nesnelerin uzak olduklarını gösterir. Birbirine benzer yani yakın nesneler içeren kümeler elde etmek amaçlandığından en düşük değere sahip kümeleme en iyi sonucu vermektedir.

Şekil 3.4'te K-Ortalamlar kümeleme yöntemiyle elde edilmiş bir örnek görülmektedir.



Şekil 3.4. K-Ortalamlar kümeleme tekniğiyle kümeleme örneği (Özekes, 2010).

K-Ortalamlar kümeleme algoritması uygulaması kolay olduğundan yaygın olarak kullanılan bir algoritmadır. Fakat algoritmanın bazı zayıf yönleride bulunmaktadır (Büyükköz, 2010):

- Veri setinin küçük olduğu durumlarda yerel minimumlar oluşabilir. Başlangıç değerleri kümeleme sonuçlarını oldukça etkilemektedir.
- "k" küme sayısı parametresinin kümelemeden önce belirlenme koşulu dezavantajdır.
- Veri sayısı fazlalığında aynı veriler farklı düzende işlem gördüğünde farklı kümeler üretebilmekte olup bu durumda gerçek küme sayısı bilinmemektedir.
- Her bir değişkenin modelde eşit ağırlıkta olduğu varsayılması nedeniyle kümeleme sürecine hangi değişkenin daha çok katkısı olduğu bilinmemektedir.
- Veride aykırı nesnelerin varlığı halinde aritmetik ortalamanın kullanılması bazı hatalara sebep olabilmektedir.


K-Ortalamlar kümeleme yönteminde küme sayısı, maksimum döngü sayısı ve tolerans değeri olmak üzere üç adet parametre değeri bulunmaktadır.

Bulanık C-Ortalamlar Kümeleme Yöntemi (Fuzzy C-Means): Bu yöntem nesne tabanlı bir sınıflandırma işlemidir. Görüntülerde spektral olarak aynı nesneler yakın yansıma değerlerine sahiptir. Bunun yanında, görüntülerdeki büyük ve karışık piksel gruplarının sadece bir sınıfa ait olduğunun belirlenmesi zordur. Bulanık mantık işlemi bir pikselin birden fazla sınıfa aidiyetliğine imkân sağlar. Bu aidiyetlik, pikselin bir sınıfta bulunabilme ihtimalini gösteren “üyelik değeri” ile belirlenir. Sonuçta piksel,

en yüksek üyelik değeri veren sınıfa atanır. Böylece veri daha iyi şekilde temsil edilebilir (Bardossy ve Samaniego, 2002).

Bu yöntem ile temel olarak doğru/yanlış, evet/hayır, yüksek/alçak gibi değerler gibi kesin değerler arasındaki geçiş değerleri de dikkate alınmaktadır (Hellman, 2001). Bulanık mantık fikri yeryüzündeki birçok detayın bulanık olduğu düşüncesinden yola çıkmaktadır. Zira bir arazi örtüsünden başka bir arazi örtüsüne geçişte kesin sınırlar net değildir. Bu nedenle daha gerçekçi bir sınıflandırma gereklidir.

Bulanık C-Ortalamlar kümeleme yönteminde arazi sınıfları bulanık setler, pikseller ise bu setlere ait elemanları ifade etmektedir. Sınıflara ait pikseller için 0 ile 1 aralığında bir üyelik derecesi söz konusudur. Bu sayede birden çok sınıfa üyelik mümkündür (Gao, 2009). Bu durum aşağıda Şekil 3.5’de gösterilmektedir. Burada, bir kümenin merkezine yakın olan bir veri noktası, o kümeye yüksek derecede üyeliğe sahip olacak ve kümenin merkezinden uzakta bulunan başka bir veri noktası, o kümeye düşük derecede üyeliğe sahip olacaktır.



Bulanık kümelemenin bazı özellikleri şunlardır (Næs ve Mevik, 1999):

- Üyelik değerleri yorumlama açısından kolaydır.
- Uzaklık kullanımı hususunda esnek bir yapıdadır.
- Bazı üyelik değerleri bilindiğinde sayısal optimizasyonla birleştirilebilir.

Bulanık C-Ortalamlar algoritması Denklem 3.3’de verilen fonksiyonun minimizasyonuna dayalı bir metottur.

$$J_m = \sum_{i=1}^D \sum_{j=1}^N \mu_{ij}^m \|x_i - c_j\|^2 \quad (3.3)$$

Denklem 3.3'te; D nokta sayısı, N ise küme sayısıdır. m, bulanık örtüşme derecesini kontrol etmek için bulanık bölüm matrisi üssüdür. Bulanık örtüşme, kümeler arasındaki sınırların ne kadar bulanık olduğunu, yani birden fazla kümede önemli üyeliği olan veri noktalarının sayısını ifade eder. x_i , i. veri noktasıdır. c_j , j. kümenin merkezidir. μ_{ij} , x_i 'nin j. kümedeki üyelik derecesidir. Belirli bir veri noktası için x_i , bütün kümenin üyelik değerlerinin toplamı 1'e eşittir.

Kümeleme algoritması şu şekilde çalışmaktadır (Peizhuang, 1983)

- 1- Küme üyelik değerleri (μ_{ij}) rastgele başlatılır.
- 2- Küme merkezleri Denklem 3.4'e göre hesaplanır.

$$C_j = \frac{\sum_{i=1}^D \mu_{ij}^m x_i}{\sum_{i=1}^D \mu_{ij}^m} \quad (3.4)$$

- 3- μ_{ij} Denklem 3.5'e göre güncellenir.

$$\mu_{ij} = \frac{1}{\sum_{k=1}^N \left(\frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{\frac{2}{m-1}}} \quad (3.5)$$

- 4- Denklem 3.3'e göre J_m fonksiyonu hesaplanır.
- 5- J_m belirli bir tolerans değerine ya da küme merkezleri değişmeyene kadar 2, 3 ve 4. adımlar tekrarlanır.

Bulanık C-Ortalamlar kümeleme yönteminde küme sayısı (c), bulanıklık üssü (m), maksimum döngü sayısı ve tolerans değeri olmak üzere dört adet parametre değeri bulunmaktadır. Bulanıklık üssünün tipik değerleri 1.5 ila 2.5 aralığındadır.

Ortalama Kaydırma Kümeleme Yöntemi (Meanshift): Bu yöntem parametrik olmayan bir kümeleme yöntemidir. Amaç nokta dağılımının en yoğun olduğu bölgeleri tespit etmektir. Bu yöntem ilk olarak 1975 tarihinde Fukunaga ve Hostetler tarafından önerilmiş ve daha sonra Comanicu tarafından geliştirilmiştir (Derpanis, 2005). Bu

yöntem olasılığa dayalı bir yöntem olup olasılık dağılımının maksimum noktasını tespit etmek için yoğunluk farkının tahmini hesaplanır (Dandan, 2010).

Bu algoritmanın fonksiyonu yani matematiksel olarak genel hatlarıyla incelendiğinde (Şeyma ve Şanlı, 2022);

Denklem 3.6, d boyutlu bir öklit uzayında R^d rastgele dağılmış n nokta içinde $x(i)$ vektörü ($i=1, 2, \dots, n$) verilsin. x 'i hesaplamak için öncelikle çekirdek (kernel) yoğunluk fonksiyonu hesaplanır. x kullanılan K çekirdeğinin merkez noktası, k ise kullanılan çekirdeğin boyutunu yani yarıçapını (bandwith) tanımlamaktadır. Tez çalışmasında yarıçap değeri "r" olarak tanımlanmıştır.

$$f(x) = \frac{1}{nh^d} \sum_{i=1}^n K\left(\frac{x - x_i}{k}\right) \quad (3.6)$$

Çekirdeğin tahmin kalitesi, yoğunluk ve tahmin edilen yoğunluk arasındaki karesel hatanın ortalaması ile ölçülür. $f(x)$ yoğunluk fonksiyonu ile tanımlanan nitelik uzayında öncelikle olarak modlar belirlenir. Modlar, gradyanların sıfır oldukları noktalarda vardır. Bu sonuçlara bakarak Ortalama Kaydırma ile bu değerler aranır.

$$G(x) = c_{g,d} g(|x|^2) \quad (3.7)$$


$$m_{h,G}(x) = \frac{1}{2} h^2 c \frac{\nabla f_{h,k}(x)}{f_{h,G}(x)} \quad (3.8)$$

Ortalama Kaydırma prosedürü iki basamaklı bir döngü (iterasyon) olarak yazılabilir:

- 1) $m_{h,G}(x)$ ortalama kayma vektörünün hesaplanması (Denklem 3.8)
- 2) Çekirdek $G(x)$ 'in ortalama kayma vektörü ile tekrar hesaplanması (Denklem 3.7)


Ortalama Kaydırma, veri kümesi üzerindeki veri dağılımının en yüksek olduğu yeri bulmayı sağlar. Ortalama Kaydırma, yakınsamaya ulaşana yani küme merkezleri değişmeyene kadar her adımda çekirdeğin döngüsel (iteratif) olarak daha yüksek yoğunluklu bir bölgeye kaydırılmasını (sliding window) hedefleyen bir tepe tırmanma (hill-climbing) algoritmasıdır. Her bir döngüde, pencere daha yüksek yoğunluklu bölgelere merkez noktasını noktaların ortalamasına kaydırılır (shifting). Bu işlemler,

tüm noktalar bir pencere içinde kalana kadar yapılır ve en çok noktayı içeren pencere korunur. Veri noktaları daha sonra içinde bulundukları pencereye göre kümelenir (Şeyma ve Şanlı, 2022).



Şekil 3.6. Ortalama kaydırma algoritması gösterimi (Ankurtripathi, 2022)

Şekil 3.6'da görüldüğü üzere Ortalama Kaydırma penceresi görüntüdeki maksimum değerlerin olduğu veriye kayarak yoğunlaşmanın olduğu yeri bulmaktadır. Yoğunlaşmanın en yoğun olduğu alan bulunduktan sonra bu alanların sınırları belirlenir. Bu yöntemde küme sayısının önceden belirtilmesi zorunlu değildir. Şekil 3.7'de gösterildiği üzere "Küme" olarak saptanan aslında veri içindeki tüm yoğunluk bölgelerinin merkezleridir.



Şekil 3.7. Ortalama Kaydırma kümeleme yöntemi

Ortalama Kaydırma kümeleme yönteminde çekirdek yarıçapı (r), maksimum döngü sayısı ve tolerans değeri olmak üzere üç adet parametre değeri bulunmaktadır.

3.6. Kenar Bulma Operatörleri

Kenar belirleme algoritmaları, görüntülerdeki piksellerin renk değerlerinin farklılığını esas alarak nesneleri tespit ve özelliklerini belirlemek amacıyla kullanılmaktadır. Bu işleme filtreleme işlemleri de denilmektedir. Farklı boyutlarda filtreleme matrisleri görüntü üzerinde gezdirilerek matematiksel bir fonksiyon aracılığı ile yeni görüntüler elde edilir.

Görüntüdeki bir nesnenin yüzey yoğunluğundaki değişimi ile nesnenin kenarı tespit edilebilir. Görüntü analizlerinde kenar tespiti oldukça önemli bir yer tutmaktadır. Zira objelerin ne olduğu hususunda önemli ipuçları bu sayede elde edilmektedir. Literatürde en sık kullanılan kenar filtreleri Canny, Prewitt, Sobel, Roberts ve Laplacian of Gaussian filtreleridir (Fidan, 2010).

Yoğunluk değerindeki ani değişimler genellikle iki bölge arasındaki sınırlarda ya da gürültü bulunan piksellerde bulunmaktadır. Bölgeler arasındaki geçişler çoğunlukla nesnelerin kenarlarını göstermektedir. Gradyan hesabı ile görüntüdeki yoğunluğun değişim miktarı ve yönü anlaşılabilmektedir. Denklem 3.9'da bir "f" görüntüsünün (x, y) konumundaki ayırıt (kenar) büyüklüğü ve yönünü bulmak için gradyan vektörü x ve y yönlerindeki (yatay ve düşey yönlerdeki) iki boyutlu vektör olarak kısmi türevlerinin alınmasıyla hesaplanır (Değirmenci ve Demirci, 2018).

$$\nabla f = \text{grad}(f) = \begin{bmatrix} g_x \\ g_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (3.9)$$

Bu vektör f'in (x, y) konumundaki en büyük değişim oranını gösteren önemli bir geometrik özelliğe sahiptir. Bir yöndeki gradyan ve vektörünün değişim oranı değeri olan ve M(x,y) olarak ifade edilen ∇f vektörünün büyüklüğü Denklem 3.10'daki eşitlikteki gibi verilir (Gonzalez ve Woods, 2014).


$$M(x, y) = \text{mag}(\nabla f) = \sqrt{g_x^2 + g_y^2} \quad (3.10)$$

Gradyanın büyüklüğü Denklem 3.10'daki eşitlik ile hesaplanmakta ve değişimin miktarını vermektedir. Yoğunluğu değişmeyen bölgelerde gradyan büyüklüğü sıfıra yakın yani siyah renge yakın pikseller iken yoğunluk değerindeki değişim miktarı

arttıkça gradyan büyüklüğünde daha büyük değerler almakta ve beyaz renge yakın pikseller oluşmaktadır (Değirmenci ve Demirci, 2018).

$$\alpha(x, y) = \tan^{-1} \left[\frac{g_y}{g_x} \right] \quad (3.11)$$

Denklem 3.11’de $\alpha(x, y)$, g_y görüntüsünün g_x görüntüsü ile vektörel bölmesi sonucu elde edilmiş orijinali ile aynı boyutlardaki bir görüntüdür. Herhangi bir (x, y) noktasındaki bir ayrıtın yönü bu noktadaki gradyan vektörünün yönü $\alpha(x, y)$ ’ye diktir (Gonzalez ve Woods, 2014).



Şekil 3.8. Gradyan vektörü ve yönü

Şekil 3.8’de her bir kare bir piksele karşılık gelmektedir. Siyah çerçeve ile belirtilen noktadaki ayrıtın büyüklüğü ve yönünün elde edilmesi istenmektedir. Gri pikseller "0" yani siyah, beyaz pikseller "1" değerine sahiptir. Bir noktaya merkezlenmiş 3x3 bir komşuluğu kullanarak x ve y yönlerindeki türevleri hesaplamak amacıyla öncelikle, aranan pikselin x yönündeki kısmi türevi elde etmek için o pikselin alt satırdaki piksellerden üst satırdaki komşu pikseller çıkarılmaktadır. Benzer şekilde y yönündeki kısmi türevi elde etmek için yine ilgili pikselin sağ sütundaki piksellerden sol sütundaki pikseller çıkarılır (Gonzalez ve Woods, 2014).

Şekil 3.8’deki siyah çerçevelenmiş nokta için Denklem 3.12’deki ifade yazılabilir.

$$\nabla f = \begin{bmatrix} g_x \\ g_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} = \begin{bmatrix} -2 \\ +2 \end{bmatrix} \quad (3.12)$$

Denklem 3.12’de $M(x, y) = 2\sqrt{2}$ olarak elde edilir. Benzer şekilde aynı noktadaki gradyan vektörü yönü $\alpha(x, y) = -45^\circ$ ‘dir. Bu değer x eksenine göre pozitif yönde ölçülen 135° ile aynıdır. Böylece Şekil 3.8’deki ayrıtın yön açısı $\alpha - 90^\circ = 45^\circ$ olarak bulunur. Bir görüntünün gradyanı görüntüdeki her piksel konumunda kısmi türevlerin hesaplanması ile elde edilir. Burada sayısal büyüklüklerle ilgilenildiğinden, bir noktanın komşu pikselleri ile arasındaki kısmi türevleri için Denklem 3.13’deki sayısal yaklaşım kullanılır (Gonzalez ve Woods, 2014).

$$g_x = \frac{\partial f(x, y)}{\partial x} = f(x+1, y) - f(x, y) \quad (3.13)$$

$$g_y = \frac{\partial f(x, y)}{\partial y} = f(x, y+1) - f(x, y)$$

Denklem 3.13’deki eşitlikleri sağlamak için kullanılan 1 boyutlu maskeler Şekil 3.9’da verilmiştir.

-1	-1	1
1		

Şekil 3.9. Bir boyutlu maskeler

Bu maskeler ile $f(x, y)$ süzgeçlenerek ilgili bütün x ve y değerleri için Denklem 3.10’daki iki eşitlik gerçekleştirilir. Diyagonal ayrıtlar için iki boyutlu maskeye ihtiyaç vardır. 2x2 boyutlarındaki maskeler kavramsal olarak basittirler fakat maskelerin simetrik olma koşulunu sağlamadıklarından dolayı ayrıt yönünü hesaplamada kullanışlı değildirler. Uygulamalarda genelde 3x3 boyutundaki maske, merkez noktası etrafında simetrik olabilecek en küçük maske olması nedeniyle ayrıt yönünü hesaplamada kullanılır. 3x3 boyutlarındaki maskeleri kullanarak kısmi türevlere en basit yaklaşımlar Denklem 3.14’deki gibi ifade edilebilirler (Gonzalez ve Woods, 2014).

$$g_x = \frac{\partial f}{\partial x} = (Z_7 + Z_8 + Z_9) - (Z_1 + Z_2 + Z_3) \quad (3.14)$$

$$g_y = \frac{\partial f}{\partial y} = (Z_3 + Z_6 + Z_9) - (Z_1 + Z_4 + Z_7)$$

Denklem 3.14’de, “Z” ile temsil edilen terimler 3x3 boyutlu filtre matrisinin satır ve sütun elemanları olup matrisin üçüncü ve birinci satırları arasındaki fark x-

yönündeki türevi, üçüncü ve birinci sütunları arasındaki fark da y-yönündeki türevi verirler. Burada tartışılan maskeler, görüntüdeki her bir piksel konumunda g_x ve g_y gradyan bileşenlerini elde etmek için kullanılırlar. Bu iki kısmi türev, ayırıt büyüklüğü ve yönünü kestirmek için kullanılır (Gonzalez ve Woods, 2014).

Literatürde en sık kullanılan kenar bulma operatörleri Canny, Prewitt, Sobel ve Roberts filtreleri olup tez çalışması kapsamında LiDAR nokta bulutu verisinden elde edilen filtre uygulanmış yoğunluk görüntülerine bu kenar filtreleri uygulanmıştır.

3.6.1. Canny kenar bulma operatörü

Canny filtresi, 1986 tarihinde John F. Canny tarafından geliştirilmiştir (Canny, 1986). Kenarları inceltip eşikleme (threshold) değeri ile doğru şekilde ayarladığı için en iyi kenar filtresi olduğu kabul edilir (Qidwai ve Chen, 2009).

Canny'nin yaklaşımı 3 temel hedefe dayanır (Gonzalez ve Woods, 2014).

1- Düşük hata oranı. Bütün ayırıtlar (kenarlar) bulunabilir ve yapay ayırıtlar yoktur.

2- Ayırıt konumları mümkün olduğunca gerçek ayırıtlara yakındır. Yani gerçek kenar pikselleri ile tespit edilen kenar pikselleri arasındaki fark minimize edilmiştir.

3- Her bir gerçek kenar noktası için yalnızca tek bir kenar noktası bulabilmesi. Bu algılayıcının sadece bir tek kenar noktası işaretlemesi, çoklu işaretleme yapmaması yani birden fazla pikselleri tanımlamaması demektir.

Canny algoritması aşağıdaki temel adımları içerir (Gonzalez ve Woods, 2014).

- a. Görüntünün yumuşatılması (Noise Reduction).
- b. Gradyan büyüklüğünün ve yönünün hesaplanması (Gradient Calculation).
- c. Gradyan vektörü yönünde zayıf kenar noktalarını baskılama (Non-Maximum Suppression).
- ç. İkili eşik değeri yöntemi ile kenarların birleştirilmesi (Double threshold).
- d. Bağlılık analizleri (Edge Tracking by Hysteresis).


3.6.1.1. Görüntü yumuşatma ve gradyan hesabı (noise reduction ve gradient calculation)

Canny algoritması, Gauss filtresi kullanarak görüntüyü yumuşatma yani gürültüyü giderme işlemi gerçekleştirir. İki boyutlu Gauss fonksiyonu Denklem 3.15'te verilmiştir. Burada ' σ ' işareti standart sapmayı göstermekte olup kullanıcı tarafından belirlenmektedir. Standart sapma veri değerlerinin ortalamaya olan uzaklığı olarak tanımlanabilir. Gauss filtresinin çıktısı komşu piksellerin ağırlıklı ortalamaları alınarak elde edilmektedir. Gauss filtresindeki ' σ ' değeri arttığında görüntüdeki bulanıklaşma miktarı artmaktadır. Gauss filtre maskesindeki katsayılar merkez piksele olan uzaklığa ve standart sapma değerine bağlı olarak değişmektedir (Değirmenci ve Demirci, 2018).

$$G(x, y) = e^{-\frac{x^2 + y^2}{2\sigma^2}} \quad (3.15)$$

Şayet $f(x, y)$ fonksiyonunu giriş görüntüsü olarak adlandıırırsak $G(x, y)$ Gauss filtresi fonksiyonudur. Denklem 3.16'daki fonksiyon ile giriş görüntüsüne Gauss filtresi uyguladığımızda $f_s(x, y)$ olarak isimlendirilen yumuşatılmış görüntü elde edilir. Şekil 3.10'da yumuşatma işlemi uygulanmış örnek görüntü görülmektedir.

$$f_s(x, y) = G(x, y) * f(x, y) \quad (3.16)$$



Şekil 3.10. (a) Orijinal görüntü (b) Gauss filtresi uygulanmış görüntü (Sofiane, 2019)


Daha sonra yumuşatılmış görüntüye Gauss fonksiyonun x ve y doğrultusunda birinci derece türevi uygulanması yani “konvolüsyon” adı verilen işlem ile gradyan büyüklüğü ve yönü hesaplanır.

Gradyan büyüklüğü için Denklem 3.17, gradyan yönü için Denklem 3.18’deki fonksiyonlar kullanılmaktadır.

$$M(x, y) = \sqrt{g_x^2 + g_y^2} \quad (3.17)$$

$$\alpha(x, y) = \tan^{-1} \left[\frac{g_y}{g_x} \right] \quad (3.18)$$

Şekil 3.11’de gradyan hesaplama işleminden sonra elde edilen örnek görüntü gösterilmiştir.




Şekil 3.11. (a) Gauss filtresi uygulanmış görüntü (b) Gradyan görüntüsü (Sofiane, 2019)

3.6.1.2. Gradyan vektörü yönünde zayıf kenar noktalarını baskılama (non-maximum suppression)


Gradyan kullanılarak elde edilmesi nedeniyle $M(x, y)$ tipik olarak yerel maksimum etrafında büyük tepeler ihtiva eder. Bir sonraki adım bu tepeleri inceltmek olacaktır. Bunun için bir yaklaşım maksimum olmayanları bastırmadır. Yaklaşımın temeli belirli sayıdaki ayırık diklerinin (gradyan vektörleri) ayırık biçimlerini ve kenar yönlerinde maksimum değere sahip pikselleri belirlemektir (Gonzalez ve Woods, 2014).

Bu işlem için önceki adımda bulunan α açısı 8 temel yönü içeren 4 ana bölgeye indirgenir. Yani açı değeri en yakın 45 dereceye yuvarlanarak ait olduğu bölge tespit edilir. Daha sonra geçerli pikselin değeri o bölgenin negatif ve pozitif yönündeki piksellerle karşılaştırılır. Eğer en büyük değer geçerli pikselin ise herhangi bir değişiklik söz konusu olmaz aksi takdirde geçerli piksel silinir (Tekin, 2018).



Şekil 3.12. Maksimum değere sahip piksellerin bulunması (Sofiane, 2019)

Şekil 3.12’de sol üst köşedeki kırmızı kutu Gradyan matrisini temsil etmektedir. Karşılık gelen kenar yönü, $-\pi$ radyan ($\pm 180^\circ$) derece açılı turuncu okla temsil edilir (Sofiane, 2019).




Şekil 3.13. Piksel kenar yönü tespiti (Sofiane, 2019)

Şekil 3.13’de kenar yönü, soldan sağa doğru turuncu noktalı çizgidir. Yöntemin amacı, aynı yöndeki piksellerin işlenenlerden daha mı fazla yoksa daha mı az yoğun olduğunu denetlemektir. Şekil 3.13’de (i,j) numaralı piksel işlenmektedir. (i,j-1) ve (i,j+1) numaralı aynı yöndeki pikseller mavi ile işaretlenmiştir. Bu iki pikselden biri

işlenenden daha yoğunsa, yalnızca daha yoğun olan korunur. $(i, j-1)$ pikseli beyaz renkte (255) daha yoğun olduğundan, (i, j) numaralı pikselin yoğunluk değeri "0" olarak atanır. Kenar yönünde daha yoğun değerlere sahip piksel yoksa, mevcut pikselin değeri korunur (Sofiane, 2019).

Şekil 3.14'de bu işlemler sonucunda elde edilen daha ince kenarlı görüntü görülmektedir. Ancak yine de kenarların yoğunluğuyla ilgili bazı farklılıklar oluşabilmektedir. Bazı pikseller diğerlerinden daha parlak görünebildiğinden bu eksikliğin sonraki adımdaki işlemlerle giderilmesi gerekmektedir (Sofiane, 2019).




Şekil 3.14. Maksimum olmayan bastırma uygulanmış çıktı görüntüsü (Sofiane, 2019)

3.6.1.3. Çift eşik (double threshold)

Hatalı ayırt noktalarını azaltmak amacıyla yapılacak son işlem eşik uygulamaktır. Eşik değeri daha düşük bir seviyeye ayarlanırsa bazı hatalı ayırtlar bulunabilir. Eşik çok yüksek değere ayarlanırsa geçerli ayırt noktaları yok olabilmektedir. Canny algoritması " T_L " alt eşiği ve " T_H " üst eşiği gibi iki eşik seviyesi kullanılmasına benzer şekilde histerez (iki seviyeli) eşik kullanır (Gonzalez ve Woods, 2014).

Gradyan vektörünün büyüklük değeri yüksek eşik değerinden fazla olan pikseller güçlü yani kesin kenar pikseli olarak kabul edilirken gradyan vektörünün büyüklük değeri düşük eşik değerinden daha küçük olan pikseller de zayıf yani kesin kenar olmayan piksel olarak kabul edilir (Tekin, 2018).


Başka bir ifade ile Şekil 3.15'te görüldüğü üzere güçlü pikselleri tanımlamak için yüksek eşik, alakasız pikselleri tanımlamak için düşük eşik kullanılır. İki eşik değeri arasında yoğunluğa sahip tüm pikseller ise zayıf olarak işaretlenir (Sofiane, 2019).



Şekil 3.15. (a) Maksimum olmayan bastırma uygulanmış çıktı görüntüsü (b) Gri renkte zayıf pikseller ve beyaz renkte güçlü pikseller (Sofiane, 2019)

3.6.1.4. Histerezis ile kenar izleme (edge tracking by hysteresis)


Eşik sonuçlarına göre, histerezis, ancak ve ancak işlenmekte olan pikselin etrafındaki piksellerden en az birinin güçlü olması durumunda, zayıf piksellerin güçlü piksellere dönüştürülmesinden oluşur (Şekil 3.16) (Sofiane, 2019).



Şekil 3.16. Zayıf piksellerin güçlü piksellere dönüşümü (Sofiane, 2019)

Gradyan vektörünün büyüklük değeri iki eşik değeri arasında kalan piksellerin her biri için komşusu olan 8 yöne de bakılır. En az bir tane güçlü piksel bulunursa geçerli piksel de güçlü kabul edilir yoksa silinir (Tekin, 2018).

Maksimum olmayan bastırma uygulamasından sonra kalan kenar pikselleri, gerçek kenarları daha doğru temsil eder. Ancak, gürültü ve renk çeşitliliği sebebiyle bazı kenar pikseller kalmaktadır. Bu durumu hesaba katmak için, yüksek ve düşük eşik değerleri seçilerek zayıf gradyan değeri olan kenar piksellerini filtrelemek ve yüksek gradyan değeri bulunan kenar piksellerini korumak esastır (Şekil 3.17) (Sofiane, 2019).



Şekil 3.17. Hysteresis uygulanmış çıktı görüntüsü (Sofiane, 2019)

3.6.2. Prewitt kenar bulma operatörü

Bu filtre türev alma işlemi ile görüntüdeki kenarların tespitini amaçlamaktadır. Filtre boyutu genelde 3x3'lük olup yatay ve düşey yönde ayrı ayrı uygulanır (Qidwai ve Chen, 2009). Prewitt operatörleri Denklem 3.19'da görüldüğü üzere diyagonal farkları uygulamaya dayalı olup "Z" ile temsil edilen terimler 3x3 boyutlu filtre matrisininin satır ve sütun elemanlarıdır.

$$g_x = \frac{\partial f}{\partial x} = (Z_7 + Z_8 + Z_9) - (Z_1 + Z_2 + Z_3) \quad (3.19)$$

$$g_y = \frac{\partial f}{\partial y} = (Z_3 + Z_6 + Z_9) - (Z_1 + Z_4 + Z_7)$$

-1	-1	-1
0	0	0
1	1	1

(R_x)

-1	0	1
-1	0	1
-1	0	1

(R_y)

R_x ve R_y ; yatay ve düşey yönde uygulanacak Prewitt filtreleri olup x ; y 'deki piksel değeri Denklem 3.20'de görülmektedir.

$$R(x, y) = \sqrt{R_x^2 + R_y^2} \quad (3.20)$$

3.6.3. Sobel kenar bulma operatörü

Bu yöntem kenar tespitini amaçlayan türev almaya dayalı bir filtredir. Öznitelik tespiti ve çıkarımı gibi amaçla kullanılan Sobel filtresi kenar bulma algoritmaları arasında sıklıkla kullanılan bir yöntemdir. Prewitt operatörünün biraz daha geliştirilmiş hali olarak düşünülebilir. Prewitt operatöründen farklı olarak maskelerdeki katsayı farklılıkları ile bu filtre ayrışmaktadır. Bu filtrede amaç kenar değeri hesaplanacak piksel ile aynı doğrultuda bulunan komşu çiftlerine daha fazla ağırlık verilmesidir (Önal, 2018).

Görüntüye uygulanacak filtre boyutu genellikle 3x3'lük olup yatay ve düşey yönde ayrı ayrı uygulanır (Qidwai ve Chen, 2009). Sobel operatörleri Denklem 3.21'de görüldüğü üzere diyagonal farkları uygulamaya dayalı olup "Z" ile temsil edilen terimler 3x3 boyutlu filtre matrisininin satır ve sütun elemanlarıdır.

$$g_x = \frac{\partial f}{\partial x} = (Z_7 + Z_8 + Z_9) - (Z_1 + Z_2 + Z_3) \quad (3.21)$$

$$g_y = \frac{\partial f}{\partial y} = (Z_3 + Z_6 + Z_9) - (Z_1 + Z_4 + Z_7)$$

$$R_{x, y} = \begin{bmatrix} x, y & x, y+1 & x, y+2 \\ x+1, y & x+1, y+1 & x+1, y+2 \\ x+2, y & x+2, y+1 & x+2, y+2 \end{bmatrix} \text{ görüntü üzerindeki koordinatlar olmak üzere,}$$

-1	-2	-1
0	0	0
1	2	1

(R_x)

-1	0	1
-2	0	2
-1	0	1

(R_y)

R_x ve R_y ; yatay ve düşey yönde uygulanacak Sobel filtreleri olup x ; y 'deki piksel değeri Denklem 3.22'de görülmektedir.

$$R(x, y) = \sqrt{R_x^2 + R_y^2} \quad (3.22)$$

3.6.4. Roberts kenar bulma operatörü

Lawrence Roberts tarafından 1963 yılında ortaya çıkan Roberts filtresi ilk kenar tespit yöntemlerinden biridir. Bu yöntem basitliği, küçük boyutlu ve sadece tam sayı değeri alan maske yapısına sahip olması yönüyle avantajlıdır. Ancak gürültüden kolay etkilenmektedir (Davis, 1975).

Bu yöntemde diğerlerinde olduğu üzere türev almaya dayalıdır. Sobel ve Prewitt filtrelerinde olduğu üzere kullanım amacı aynıdır fakat filtresi farklıdır. Roberts operatörleri Denklem 3.23’de görüldüğü üzere diyagonal farkları uygulamaya dayalı olup “Z” ile temsil edilen terimler 3x3 boyutlu filtre matrisinin satır ve sütun elemanlarıdır.

$$g_x = \frac{\partial f}{\partial x} = (Z_9) - (Z_5) \quad (3.23)$$

$$g_y = \frac{\partial f}{\partial y} = (Z_8) - (Z_6)$$

-1	0	0	-1
0	1	1	0
(R _x)		(R _y)	

R_x ve R_y; yatay ve düşey yönde uygulanacak Roberts filtreleri olup x; y’deki piksel değeri Denklem 3.24’de görülmektedir.

$$R(x, y) = \sqrt{R_x^2 + R_y^2} \quad (3.24)$$

3.7. Doğruluk Analizi Ölçütleri

Modelin başarısını değerlendirirken hata oranı, kesinlik, duyarlılık ve F-Skor gibi temel kavramlar kullanılmaktadır. Modelin başarısı, doğru ve yanlış sınıflara atanan örnek sayısı ile ve karışıklık matrisi ile ifade edilebilir. Karışıklık (Konfüzyon) matrisinde satırlar test kümesindeki örneklere ait gerçek sayıları, sütunlar ise tahmin edilen sayıları ifade edecek olursa Şekil 3.18’deki bir tablo elde edilir (Coşkun ve Baykal, 2011).

		Tahmin Edilen Sınıf	
		Sınıf = 1	Sınıf = 0
Gerçek Sınıf	Sınıf = 1	(TP)	(FN)
	Sınıf = 0	(FP)	(TN)

Şekil 3.18. Karışıklık matrisi

Bu tabloda TP (True Positive) yani Doğru Pozitif, doğru sınıflandırılmış pozitif örnekleri (doğruya doğru demek); TN (True Negatif) yani Doğru Negatif ise doğru sınıflandırılmış yanlış örnekleri (yanlışla yanlış demek) ifade etmektedir. Bu iki değer, kullanılan yöntemin ne kadar doğru çalıştığını belirlemektedir. FP (False Positive) yani Yanlış Pozitif değeri, yöntemin gerçekte yanlış olan bir değeri doğru olarak etiketlemesi iken; FN (False Negatif) yani Yanlış Negatif değeri ise yöntemin gerçekte doğru olan bir değeri yanlış olarak etiketlemesidir.

3.7.1. Doğruluk

Doğruluk oranı modelin başarısının ölçülmesinde kullanılır. Doğru sınıflandırılmış örnek sayısının (TP + TN), toplam örnek sayısına (TP + TN + FP + FN) oranı modelin doğruluk oranını (accuracy) verir. Hata oranı (error rate) ise doğruluk oranının 1'e tamamlayan kısmını ifade eder. Yani hata oranı yanlış sınıflandırılmış örnek sayısının (FP + FN), toplam örnek sayısına (TP + TN + FP + FN) oranıdır. Denklem 3.25 ve 3.26'da doğruluk ve hata oranı hesabına ilişkin formüller gösterilmiştir (Coşkun ve Baykal, 2011).

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.25)$$

$$\text{Hata Oranı} = \frac{FP + FN}{TP + TN + FP + FN} \quad (3.26)$$

3.7.2. Kesinlik

Kesinlik, sınıfı 1 olarak tahminlenmiş örnek sayısının (TP), sınıfı 1 olarak tahminlenmiş tüm örnek sayısına (TP + FP) oranıdır. Denklem 3.27’de kesinlik hesabına ilişkin formüller gösterilmiştir (Coşkun ve Baykal, 2011).

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (3.27)$$

3.7.3. Duyarlılık

Doğru sınıflandırılmış pozitif örnek sayısının (TP), toplam pozitif örnek sayısına (TP + FN) oranıdır. Denklem 3.28’de duyarlılık hesabına ilişkin formüller gösterilmiştir (Coşkun ve Baykal, 2011).

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (3.28)$$

3.7.4. F-Skor

Kesinlik ve duyarlılık ölçütleri tek başına anlamlı bir karşılaştırma yapmak için yetersizdir. Her iki ölçütün beraber değerlendirilmesi gerekmekte olup bunun için kesinlik ve duyarlılığın harmonik ortalaması olan F-Skor tanımlanmıştır. Denklem 3.29’da F-Skor hesabına ilişkin formüller gösterilmiştir (Coşkun ve Baykal, 2011).

$$\text{F-Skor} = \frac{2 \times \text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (3.29)$$

3.7.5. Yüksek Sinyal Gürültü Oranı (YSGO)

Yüksek Sinyal Gürültü Oranı (YSGO) (PSNR - Peak Signal to Noise Ratio), gürültü görüntü kalitesini bozan önemli bir faktör olarak karşımıza çıkmaktadır. YSGO’nın değeri yükseldikçe görüntünün kalitesi artmakla birlikte gürültü oranı azalmaktadır. Giriş görüntüsü ile referans bir çıkış görüntüsünü karşılaştırmak suretiyle gürültü seviyesini ölçmek için YSGO kullanılmaktadır. Bir görüntünün YSGO fonksiyonu Denklem 3.30’da gösterilmektedir (Javaid ve ark., 2013).

$$YSGO = 20 \times \log_{10} \left(\frac{255}{\sqrt{OKH(I, I_0)}} \right) \quad (3.30)$$

Denklem 3.30'daki I ve I_0 sırasıyla giriş ve çıkış görüntülerini, OKH ise Ortalama Karesel Hatayı göstermektedir.

3.7.6. Sinyal Gürültü Oranı (SGO)

Sinyal Gürültü Oranı (SGO) (SNR - Signal to Noise Ratio) değeri sinyal gürültü oranıdır. Bu değerin yüksek olması görüntünün kalitesinin yüksek olduğu anlamına gelmektedir. SGO değeri düşük olan görüntülerin kalitesi ise kötüdür. Sinyalin seviyesini arka plan gürültü seviyesi ile karşılaştırmak suretiyle bu oran elde edilmektedir. SGO oranı sinyal gücünün gürültü gücüne oranıdır ve genellikle desibel cinsinden ifade edilmektedir (Konez, 2022).

$$SGO = \frac{\mu}{\sigma} \quad (3.31)$$

Denklem 3.31'de ' σ ' işareti standart sapmayı, ' μ ' işareti ise ortalama değeri temsil etmektedir.

3.7.7. Ortalama Karesel Hata (OKH)

Ortalama Karesel Hata (OKH) (MSE - Mean Squared Error), noktalardan regresyon çizgisine kadar olan mesafeleri hesaplamak suretiyle bir regresyon çizgisinin bir dizi noktaya ne kadar yakın olduğunu gösterir. OKH değeri Denklem 3.32'de verilen fonksiyon ile hesaplanır. $M \times N$ tüm veri piksel sayısını temsil etmekte olup düşük OKH değeri, görüntü kalitesinin yüksek olduğu anlamına gelmektedir. Denklemdeki I ve I_0 sırasıyla giriş ve çıkış görüntülerini göstermektedir (Kaş, 2016).

$$OKH(I, I_0) = \frac{1}{M \times N} * \sum_{y=1}^n \sum_{x=1}^N [I - I_0]^2 \quad (3.32)$$

3.7.8. Yapısal Benzerlik İndeks Ölçümü (YBİÖ)

Yapısal Benzerlik İndeks Ölçümü (YBİÖ) (SSIM - Structural Similarity Index Measure) iki çerçeve arasındaki yapısal bir benzerliği ölçer. Bu yöntem, algısal görüntü kalitesinin değerlendirilmesinde kullanılan alternatif bir yöntemdir (Shahid ve ark., 2011).

Bu yöntem, iki çerçeve arasındaki yapısal bilginin değişimindeki değişiklikleri algıladığı için çerçevelerdeki kalite bozulmasını dikkate almaktadır. YBİÖ değeri, Denklem 3.33'deki fonksiyon ile hesaplanmaktadır (Javaid ve ark., 2013).

$$YBİÖ(n) = \frac{[2 \mu_{I_R}(n) \mu_{I_D}(n) + c_1] [2 \sigma_{I_R I_D}(n) + c_2]}{[\mu_{I_R}^2(n) + \mu_{I_D}^2(n) + c_1] [\sigma_{I_R}^2(n) + \sigma_{I_D}^2(n) + c_2]} \quad (3.33)$$

Denklem 3.31'deki $\mu_{I_R}(n)$ ve $\mu_{I_D}(n)$ işaretleri, referans I_R ve bozuk I_D görüntü dizisinin n.çerçevesinin ortalamasını ifade eder. $\sigma_{I_R}(n)$ ve $\sigma_{I_D}(n)$ işaretleri ise referans I_R ve bozuk I_D görüntü dizisinin n.çerçevesinin standart sapmasıdır. c_1 ve c_2 sabit değişkenlerdir (Kaş, 2016).

3.7.9. Korelasyon Katsayısı (KK)

Korelasyon Katsayısı (KK) (CC - Correlation Coefficient), görüntülere ait histogram değerlerinin (ortalama ve standart sapma) orijinal görüntü değerleri ile karşılaştırılması sonucunda elde edilmektedir. Korelasyon iki ya da daha çok değişken arasında ilişki olup olmadığını, ilişki varsa yönünü ve gücünü tespit etmemize yardımcı olmaktadır. Korelasyon katsayıları +1 ile -1 aralığında değerlere sahiptir ve +1 olarak bulunan korelasyon katsayısı her iki görüntü birebir ilişkiyi ortaya koymaktadır (Balçık ve Göksel, 2010).

$$KK_{XY} = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y} \quad (3.34)$$

Denklem 3.34'de Korelasyon Katsayısının hesabına ilişkin fonksiyon gösterilmiştir. Denklemde 'σ' işareti standart sapmayı, "cov" işareti ise kovaryans değerini temsil etmektedir.

3.8. Çalışma Alanı

Çalışmada kullanılan veri Şekil 3.19’da dünya haritasında gösterilen 4 ayrı bölgeye ait LiDAR verileridir.




Şekil 3.19. 4 Farklı bölgeye ait çalışma alanları

1.Bölge Amerika kıtasında Ohio Eyaletinin bulunduğu bölgede yer almaktadır (Şekil 3.20).




Şekil 3.20. 1.Bölgeye ait çalışma alanı

2.Bölge Türkiye, İstanbul ili Büyükçekmece ilçesinin bulunduğu bölgedir (Şekil 3.21).



Şekil 3.21. 2.Bölgeye ait çalışma alanı

3.Bölge Okyanusya kıtasında Yeni Zelanda ülkesinde Canterbury bölgesinde yer almaktadır (Şekil 3.22).



Şekil 3.22. 3.Bölgeye ait çalışma alanı

4.Bölge Okyanusya kıtasında Avusturalya ülkesinde Yeni Güney Galler bölgesinde yer almaktadır (Şekil 3.23).



Şekil 3.23. 4.Bölgeye ait çalışma alanı

1, 3 ve 4.bölgelere ait LiDAR verileri U.S. National Science Foundation, Intergovernmental Committee on Surveying and Mapping ve NOAA Office For Coastal Management isimli online kaynaklardan, 2.bölgeye ait LiDAR verileri ise Körfez Haritacılık Planlama şirketinden offline bir şekilde temin edilmiştir. Bu verilerin ücretsiz temin edilmesi, bu bölgedeki tarımsal alanların sınırlarının belirgin olması ve ayrıca yükseklik değişim sıklığının az olması bu bölgelerin tercih edilme sebebi olarak gösterilebilir.

3.9. Kullanılan Veriler

Çalışmada kullanılan LiDAR verileri “.las” formatında olup seçilen bölgelerden 10 adet test verisi oluşturulmuştur. Test alanları belirlenirken sınırları sabit nitelikli olmasına özen gösterilmiştir. Test alanlarına ilişkin veri setlerinin özellikleri Çizelge 3.1’de özet olarak gösterilmektedir.

Çizelge 3.1. Veri seti özellikleri

Test Alanı	Nokta Sayısı	Nokta Yoğunluğu (m ²)	Kapladığı Alan (km ²)	Projeksiyon Bilgileri	Min. Yükseklik (m)	Max. Yükseklik (m)	Bölge
1	2263982	1.94	1.28	New Zealand Transverse Mercator 2000	76.51	129.42	3
2	2752077	3.99	0.74	MGA (Map Grid of Australia) / GDA94	133.48	137.92	4
3	2602276	1.49	2.80	WGS84 UTM Zone 16N	222.57	259.51	1
4	1631388	3.50	0.60	WGS84 UTM Zone 17N	164.98	196.44	1
5	2196053	4.05	0.75	WGS84 UTM Zone 17N	165.19	193.85	1
6	3493388	5.69	0.67	New Zealand Transverse Mercator 2000	212.30	231.05	3
7	6818698	5.04	1.47	New Zealand Transverse Mercator 2000	251.74	265.58	3
8	6020238	11.05	0.64	New Zealand Transverse Mercator 2000	313.45	361.02	3
9	1880272	4.26	0.58	WGS84 UTM Zone 17N	149.85	227.59	1
10	1193476	13.42	0.09	Transverse Mercator / WGS84	10.13	29.97	2

Şekil 3.24 ve Şekil 3.25’de 1.test alanına ait nokta bulutu verisi görülmektedir.



Şekil 3.24. 1.test alanına ait nokta bulutu verisi (üstten görünüş), **(a)** Görüntü, **(b)** Nokta bulutu



Şekil 3.25. 1.test alanına ait nokta bulutu verisi (yandan görünüş)

Şekil 3.26’da 1.test alanına ait LiDAR verisine ilişkin istatistiksel bilgiler görülmekte olup tabloda toplam nokta sayısı, geri dönüş nokta sayısı bilgileri (first, second, last vb.) sınıf bilgileri, minimum yükseklik, maksimum yükseklik ve yoğunluk (Zmin, Zmax ve Intensity) bilgileri bulunmaktadır. Geriye kalan 9 adet test alanına ilişkin istatistiksel bilgilerde bu şekilde mevcut olup burada örnek teşkil etmesi bakımından sadece 1.test alanına ilişkin bilgiler verilmiştir.


Returns						Attributes		
Return	Point Count	%	Z Min	Z Max		Name	Min	Max
All Returns	2,263,982	100.00	76.51	129.42		Return No.	1	4
Unknown	0	0.00	0.00	0.00		Intensity	0	720
First	2,249,757	99.37	76.51	129.42		Class Code	1	2
Second	11,963	0.53	77.72	126.64		Scan Angle	-11.00	11.00
Last	2,247,068	99.25	76.51	129.42		User Data	0	0
Single	2,235,701	98.75	76.51	129.42		Point Source	19	22
First-of-Many	14,056	0.62	80.81	129.22				

Classification Codes									
Classification	Point Count	%	Z Min	Z Max	Min Intensity	Max Intensity	Synthetic	Withheld	Model Key
1 - Unclassified	111,158	4.91	77.12	129.42	0	720	0	0	0
2 - Ground	2,152,824	95.09	76.51	91.91	0	660	0	0	0

Şekil 3.26. 1.test alanına ait nokta bulutu verisine ilişkin istatistiksel bilgiler

3.10. Metot

Bu tez çalışması 5 ana aşamadan oluşmaktadır (Şekil 3.27). Bu aşamalar şunlardır; 1- Nokta bulutu verisinden yoğunluk görüntüsü (Intensity image) elde edilmesi, 2- Filtreleme, 3- Kümeleme, 4- Kenar bulma, 5- Doğruluk analizleri. Ana iş akışı içerisinde çalışma kapsamında 4 farklı yaklaşım belirlenmiştir. Nokta bulutu verisinden yoğunluk görüntüsü oluşturmak için açık kaynak kodlu SagaGIS yazılımı, diğer ana işlemler için kodlama yapılmak suretiyle MATLAB yazılımı, referans veri seti oluşturmak için ArcGIS yazılımı, bazı ara işlemler için Global Mapper yazılımı kullanılmıştır.




Şekil 3.27. İş akışı diyagramı

4. TEZ KAPSAMINDA YAPILAN UYGULAMA

Tez çalışması kapsamında 5 aşamalı ana iş akışı içerisinde belirlenen 10 adet test alanına 4 farklı yaklaşım uygulanmıştır. Belirlenen yaklaşımlara ait işlemlere geçilmeden önce öncelikle nokta bulutu verisinden yoğunluk görüntüsü elde edilmesi, filtreleme ve doğruluk analizleri için referans veri seti oluşturma işlemleri tüm veri setleri için oluşturulmuştur. Bu işlemlere ilişkin uygulama adımları aşağıda belirtilmiştir. Ancak bu işlemlerden öncelikle çalışmada kullandığımız “.las” uzantılı nokta bulutu verilerinin genel yapısına değinmekte fayda vardır.

Bu formatta her bir noktaya ait konumsal bilgilerin (X, Y, Z) yanı sıra KKS zamanı, yoğunluk, tarama açısı, geri dönüş sayısı, sınıf bilgileri, KYM ve nokta kimliği (GPS-time, Intensity, scan angle, number of the return, classification, RGB ve point source ID) gibi öznelik bilgileri de kayıtlıdır. Aşağıda Şekil 4.1’de 1.test alanına ait veride bu durum örnek olarak gösterilmiştir.




Attribute	Value
ELEVATION	86.73
CLASS	1
INTENSITY	40
SCAN_ANGLE	9.0
RETURN_CNT	1
RETURN_NUM	1
GPS_TIME	88740499.722420
SOURCE_ID	20
DENSITY	1.399 samples / m ²

Şekil 4.1. Nokta bulutu veri yapısı

4.1. Nokta Bulutu Verisinden Yoğunluk Görüntüsü Elde Edilmesi

Bu işlem için açık kaynak kodlu SagaGIS (System for Automated Geoscientific Analyses) version 7.7.0 yazılımı kullanılmıştır. Öncelikle test alanlarına ait “.las” uzantılı nokta bulutu verisi SagaGIS yazılımı ile açılmıştır. Olaya ve Conrad (2009) tarafından programa eklenmiş olan “Point Cloud to Grid” fonksiyonunda nokta

bulutuna ait bütün öznitelikler dahil edilerek ve piksel size "1" (piksel boyutu: 1m x 1m) olacak şekilde nokta bulutu grid formatına dönüştürülmüştür (Şekil 4.2).



Şekil 4.2. SagaGIS yazılımı Point Cloud to Grid fonksiyonu

Nokta bulutu verisinin grid formatına dönüşmesi ile birlikte “.las” formatı ile gelen bütün öznitelikler ayrı bir tabakada kaydedilmiş olup bu tabakalardan Intensity tabakası “.tif” uzantılı olacak şekilde kaydedilmiştir. Bu şekilde kaydedilen 1.test alanına ait yoğunluk görüntüsünün yapısına incelendiğinde X, Y ve 10 ila 50 değerleri arasında değişen yoğunluk değerleri olmak üzere toplam 3 adet öznitelik bilgisinin bu görüntülerde yer aldığı görülmektedir. Diğer test alanları içinde aynı işlemler sırasıyla uygulanmıştır.


4.2. Filtreleme İşlemleri

Filtreleme işlemi ile görüntüdeki gürültüyü azaltmak ve görüntüyü iyileştirmek amaçlanmıştır. Bu işlem için MATLAB ortamında “Median Filtering” fonksiyonu kullanılmıştır. Bu filtre görüntülere uygulanan 3x3 boyutlu bir filtreleme aracıdır.

Daha önceki işlem adımı her bir test alanı için elde edilen yoğunluk görüntülerine bu filtre uygulanmış ve görüntülerdeki gürültülerin azaldığı ve bu durumun sonuçlara olumlu yansıdığı görülmüştür.


4.3. Doğruluk Analizleri İçin Referans Veri Seti Oluşturulması

Referans veri seti her bir test alanı için ayrı ayrı olacak şekilde ArcGIS yazılımı aracılığıyla yoğunluk görüntülerindeki tüm sınırlar operatör yardımıyla (manuel) sayısallaştırılmıştır. Yani raster görüntüsünde görünen sınırlar vektör yapıya yani “çizgi (line)” yapısına dönüştürülmüştür.



Şekil 4.3. ArcGIS Polyline to Raster fonksiyonu


Bir sonraki aşamada ise ArcGIS “Polyline to Raster” fonksiyonu ile çizgi yani vektör yapıdaki veri raster formatına dönüştürülmüştür (Şekil 4.3).



Şekil 4.4. ArcGIS Reclassify fonksiyonu

Son olarak ArcGIS “Reclassify” fonksiyonu ile raster yapıdaki referans veri piksel değeri 2 sınıftan oluşacak şekilde binary görüntüye dönüştürülerek “.tif” uzantılı

olarak kaydedilmiştir (Şekil 4.4). Şekil 4.5'te 2.test alanına ait yoğunluk görüntüsü ile bu görüntüye ait oluşturulan referans veri görülmektedir. [1 9] test alanlarında referans veri setleri bu şekilde oluşturulmuş olmakla birlikte 10.test alanına ait LiDAR verisi ile aynı alana ait ortofoto görüntüsü de mevcut olduğundan referans veri seti mevcut ortofotodan benzer şekilde oluşturulmuştur.



Şekil 4.5. 2.test alanına ait; (a) Yoğunluk görüntüsü, (b) Referans veri

4.4. Uygulanan Yaklaşımlar

Tez çalışmasında test alanlarına aşağıda belirtilen 4 farklı yaklaşım uygulanmış ve parsel sınırları tespit edilmiştir.

1. Kenar bulma algoritmalarıyla sınırların tespiti
2. K-Ortalamlar kümeleme ile sınırların tespiti
3. Bulanık C-Ortalamlar kümeleme ile sınırların tespiti
4. Ortalama Kaydırma kümeleme ile sınırların tespiti

Birinci yaklaşımda; Canny, Sobel, Prewitt ve Roberts, diğer yaklaşımlarda; sadece Canny filtresi ile kümeleme işlemleri için K-Ortalamlar, Bulanık C-Ortalamlar ve Ortalama Kaydırma algoritmaları belirlenen 10 farklı test alanında uygulanmıştır. Birinci yaklaşımda, Canny algoritması parametresi olan gradient threshold parametresi belirleyici olduğu tespit edildiğinden diğer parametre olan operatör scale parametre değeri değıştikçe sonuçlarda belirgin bir değışim görölmediğı elde edilen sonuçlardan anlaşıldığından diğer yaklaşımlarda Operator Scale değeri "0.5" olarak sabit seçilerek parametre testleri gerçekleştirilmiştir. Ayrıca birinci yaklaşımda test alanlarında

uygulanen Canny dışında diğer kenar bulma operatörleri olan Sobel, Prewitt ve Roberts operatörlerinden elde edilen sonuçlar incelendiğinde (Bkz: Çizelge 5.7) bu operatörler ile kümeleme yapıldığında, bu kenar bulma algoritmaları için sonucun çok etkilenmediği görülmüştür. Bu nedenle diğer yaklaşımlarda sadece Canny filtresi uygulanmıştır.

4.4.1. Kenar bulma algoritmalarıyla sınırların tespiti

Daha önceden Medyan filtresi uygulanmış Intensity görüntülerinde öncelikle Canny kenar bulma algoritması ile parsel sınırları tespit edilmiştir. Canny algoritması içerisinde yer alan “Gradient Threshold” ve “Operator Scale (Sigma)” parametreleri için en uygun değerlerin tespiti yapılmıştır. Bu parametre değerleri [0, 1] arasında değişen değerler olup bu aralıkta 0.1 artış miktarları olacak şekilde parametre testi gerçekleştirilmiştir.

Uygulamada ilk olarak Gradient Threshold parametresi 0.9 değerine karşılık sigma parametre değeri 0.1 artış miktarı ile [0.1 0.9] aralığında değiştirilerek kenar bulma operatörleri ve doğruluk ölçütleri bazında elde edilen sonuç değerleri elde edilmiştir. Daha sonra Gradient Threshold parametre değeri 0.1 azaltılarak bu kez 0.8 parametre değeri ile aynı işlem uygulanmıştır. Bu şekilde Gradient Threshold ve sigma parametre değeri [0.1 0.9] aralığında bu işlemler her bir test alanında tekrarlanmıştır **(Ek-1)**. Ek-1’de verilen tablolarda sadeleşme yapmak amacıyla elde edilen sonuçlar Min, Max ve Ortalama değerler şeklinde gösterilmiştir.

10 adet test alanı için bu işlemler sonucunda elde edilen F-Skor değerleri baz alınarak Çizelge 4.1’de görülen en uygun parametre değerleri tespit edilmiştir.

Çizelge 4.1. F-Skor değeri bazında en uygun Canny parametre değerleri

Test Alan No	Gradient Threshold	Operator Scale (Sigma)
Test_1	0.1	0.5
Test_2	0.1	0.7
Test_3	0.1	0.2
Test_4	0.1	0.4
Test_5	0.1	0.2
Test_6	0.4	0.8
Test_7	0.5	0.9
Test_8	0.2	0.7
Test_9	0.2	0.5
Test_10	0.3	0.6

Canny algoritmasından sonra diğer kenar bulma operatörleri olan Sobel, Roberts ve Prewitt kenar bulma algoritmaları için de bu operatörlerin yatay (horizontal), dikey (vertical) ve iki yönlü (both) olmak üzere 3 ayrı parametre değerine göre en uygun parametre testi her bir veri seti için benzer şekilde uygulanmıştır.

Her bir test alanında kenar bulma operatörleri aracılığıyla elde edilen kenar görüntüsü ile referans veri seti karşılaştırılarak F-Skor, YSGO, SGO, OKH, YBİÖ ve KK ölçütleri yardımıyla doğruluk analizleri yapılmıştır.

Bu testler için gerekli olan kenar bulma işlemi ile test ile referans verileri karşılaştırılarak oluşturulan doğruluk analizleri MATLAB ortamında yapılmıştır. Örnek kodlama sayfası Şekil 4.6'da gösterilmiştir.

```
clc;
clear all;
close all;
A = imread('...load filtered test Image');
img = im2gray(A);
edge_Image = edge ( img ,'Canny','Gradient
Threshold','Operator Scale') ;
ref = imread('...load referans Image');
img3 = im2gray(ref);
BWref = imbinarize(img3);
Z = imsubtract(BWref,edge_Image);
similarity = bfscore(BWref, edge_Image);
```

Şekil 4.6. Canny kenar bulma algoritması MATLAB çıktısı

4.4.2. K-Ortalamlar kümeleme ile sınırların tespiti

Daha önceden Medyan filtresi uygulanmış yoğunluk görüntülerine K-Ortalamlar kümeleme ve Canny kenar bulma işlemi uygulanmış ve parsel sınırları tespit edilmiştir. Kenar Bulma Algoritmalarıyla Sınırların Tespiti yaklaşımında olduğu üzere Canny algoritması içerisinde yer alan “Gradient Threshold” ve “Operator Scale” parametreleri için en uygun değer in tespiti yapılmıştır. Operator Scale değeri "0.5" olarak sabit alındığından Gradient Threshold değeri [0.1 0.9] arasında 0.1 artış miktarları olacak şekilde parametre testi gerçekleştirilmiştir.

Bununla birlikte K-Ortalamlar kümeleme algoritması içerisinde bulunan ve küme sayısını ifade eden "k" parametre değeri için de en uygun parametre belirleme

işlemi yapılmıştır. Test alanlarından elde edilen sonuçlara göre "k" değeri [2 10] olarak belirlenmiş ve bu değerler test edilmiştir. K-Ortalamlar kümeleme algoritmasında yer alan döngü (iterasyon) sayısı "10" olarak belirlenmiştir. Bu yaklaşımda K-Ortalamlar kümeleme işleminden sonra uygulanan kenar bulma işlemi ile elde edilen görüntüler referans veri ile karşılaştırılarak doğruluk analizleri yapılmıştır

Bu yaklaşımda K-Ortalamlar kümeleme, kenar bulma işlemleri ile doğruluk analizleri MATLAB yazılımında hazırlanmıştır. Tüm bu işlemlere ait sonuç çıktıları **Ek-2'**de sunulmuştur. Ek-2'de verilen tablolarda sadeleşme yapmak amacıyla elde edilen sonuçlar Min, Max değerleri ve $k = 2$ ila 10 arasındaki sonuçların ortalaması olarak gösterilmiştir. Örnek kodlama sayfası Şekil 4.7'de gösterilmiştir.

```
% Read the image
img = imread('...load filtered test Image');
% Convert the image to double precision for k-means
img_double = double(img);
% Reshape the image into a 2D array of pixels
pixels = reshape(img_double, [], size(img_double, 3));
% Define the number of clusters (k)
k = 4;
% Apply k-means clustering
% kmeans(data, k, 'Start', initMethod, 'MaxIter', maxIter, 'Tol',
tolerance);
% initMethod = 'kmeans++'; % Initialization method
% maxIter = 10; % Maximum number of iterations
% tolerance = 1e-4; % Tolerance for convergence
[idx, centers] = kmeans(pixels, k);
% Reshape the clustered indices back to the original image size
clustered_img = reshape(idx, size(img, 1), size(img, 2));
figure, imshow(clustered_img, []);
```

Şekil 4.7. K-Ortalamlar kümeleme algoritması MATLAB çıktısı

10 adet test alanı için tekrarlanan bu test işlemi neticesinde her bir test alanı için F-Skor değeri baz alınarak Çizelge 4.2'de görülen en uygun parametre değerleri tespit edilmiştir.

Çizelge 4.2. F-Skor değeri bazında en uygun Canny ve K-Ortalamalar parametre değerleri

Test Alan No	Gradient Threshold	Operator Scale (Sigma)	K-Ortalamalar (k) Parametresi
Test_1	0.5	0.5	6
Test_2	0.2	0.5	9
Test_3	0.3	0.5	9
Test_4	0.2	0.5	8
Test_5	0.1	0.5	10
Test_6	0.4	0.5	8
Test_7	0.4	0.5	3
Test_8	0.4	0.5	5
Test_9	0.3	0.5	7
Test_10	0.4	0.5	4

4.4.3. Bulanık C-Ortalamalar kümeleme ile sınırların tespiti

Daha önceden Medyan filtresi uygulanmış yoğunluk görüntülerine Bulanık C-Ortalamalar kümeleme ve Canny kenar bulma işlemi uygulanmış ve parsel sınırları tespit edilmiştir. Bu yaklaşımda Canny algoritması içerisinde yer alan “Gradient Threshold” ve “Operator Scale” parametreleri için K-Ortalamalar kümeleme sonuçlarından elde edilen en yüksek doğruluk sonucunu veren Canny parametre değerleri esas alınmıştır.

Ayrıca Bulanık C-Ortalamalar kümeleme algoritması içerisinde bulunan ve küme sayısını ifade eden "k" parametre değeri için de en uygun parametre belirleme işlemi yapılmıştır. Test alanlarından elde edilen sonuçlara göre "k" değeri [2 10] aralığında 1'er artışla ve “max_number_iteration” değeri ise K-Ortalamalar kümeleme algoritmasında olduğu üzere "10" olarak belirlenmiş ve her bir test alanı için bu parametreler test edilmiştir. Bulanık C-Ortalamalar kümeleme algoritmasının çalışma prensibi gereğince her bir parametre testi yeterli sayıda olacak şekilde (10 kez) tekrarlanmış ve elde edilen sonuçların ortalaması esas alınmıştır. Bu yaklaşımda Bulanık C-Ortalamalar kümeleme işleminden sonra uygulanan kenar bulma işlemi ile elde edilen görüntüler referans veri ile karşılaştırılarak doğruluk analizleri yapılmıştır.

Bu yaklaşımda Bulanık C-Ortalamalar kümeleme, kenar bulma işlemleri ile doğruluk analizleri MATLAB yazılımında hazırlanmıştır. Tüm bu işlemlere ait sonuç çıktıları **Ek-3**'de sunulmuştur. Örnek kodlama sayfası Şekil 4.8'de gösterilmiştir.

```

% Read the image
img = imread('...load filtered test Image');
% Convert the image to double precision for FCM
img_double = double(img);
% Reshape the image into a 2D array of pixels
pixels = reshape(img_double, [], size(img_double, 3));
% Define the number of clusters (c)
c = 4;
% Apply Fuzzy C-Means clustering
options = [2.0, 10, 1e-5, true]; % [Exponent, Maximum number of iterations, Tolerance,
Display progress]
[centers, U, objFcn] = fcm(pixels, c, options);
% Find the cluster with the maximum membership for each pixel
[~, cluster_idx] = max(U, [], 1);
% Reshape the clustered indices back to the original image size
clustered_img = reshape(cluster_idx, size(img, 1), size(img, 2));
figure, imshow(clustered_img, []); % segmented image

```

Şekil 4.8. Bulanık C-Ortalamlar kümeleme algoritması MATLAB çıktısı

10 adet test alanı için tekrarlanan bu test işlemi neticesinde her bir test alanı için F-Skor değeri baz alınarak Çizelge 4.3’de görülen en uygun parametre değerleri tespit edilmiştir.

Çizelge 4.3. F-Skor değeri bazında en uygun Bulanık C-Ortalamlar parametre değerleri

Test Alan No	k (küme sayısı)	Maximum tekrar sayısı
Test_1	2	10
Test_2	4	10
Test_3	2	10
Test_4	3	10
Test_5	2	10
Test_6	6	10
Test_7	3	10
Test_8	3	10
Test_9	2	10
Test_10	2	10

4.4.4. Ortalama Kaydırma kümeleme ile sınırların tespiti

Medyan filtresi uygulanmış yoğunluk görüntülerine Ortalama Kaydırma kümeleme ve Canny kenar bulma işlemi uygulanmış ve parsel sınırları tespit edilmiştir. Bu yaklaşımda Canny algoritması içerisinde yer alan “Gradient Threshold” ve

“Operator Scale” parametreleri için K-Ortalamalar kümeleme sonuçlarından elde edilen en yüksek doğruluk sonucunu veren Canny parametre değerleri esas alınmıştır.

Bununla birlikte Ortalama Kaydırma kümeleme algoritmasında pencere boyutunu ifade eden "r" yarıçap (bandwidth) parametre değeri için en uygun parametre belirleme işlemi yapılmıştır. Test alanlarından elde edilen sonuçlara göre "r" değeri [2 10] değerleri arasında olacak şekilde 1'er artışla her bir test alanı için test edilmiştir. Ortalama Kaydırma kümeleme işleminden sonra uygulanan kenar bulma işlemi ile elde edilen görüntüler referans veri ile karşılaştırılarak doğruluk analizleri yapılmıştır.

Bu yaklaşımda Ortalama Kaydırma kümeleme, kenar bulma işlemleri ile doğruluk analizleri MATLAB yazılımında hazırlanmıştır. Tüm bu işlemlere ait sonuç çıktıları **Ek-4**'de sunulmuştur. Örnek kodlama sayfası Şekil 4.9'da gösterilmiştir.

```
function [clustCent,data2cluster,cluster2dataCell] =
MeanShiftCluster(dataPts,bandWidth,plotFlag);
if nargin < 2
    error('no bandwidth specified')
end
if nargin < 3
    plotFlag = true;
    plotFlag = false;
end
[numDim,numPts] = size(dataPts);
numClust = 0;
bandSq = bandWidth^2;
initPtInds = 1:numPts;
maxPos = max(dataPts,[],2);
minPos = min(dataPts,[],2);
boundBox = maxPos-minPos;
sizeSpace = norm(boundBox);
stopThresh = 1e-3*bandWidth;
clustCent = [];
beenVisitedFlag = zeros(1,numPts,'uint8');
numInitPts = numPts;
clusterVotes = zeros(1,numPts,'uint16');
while numInitPts
    tempInd = ceil( (numInitPts-1e-6)*rand);
    stInd = initPtInds(tempInd);
    myMean = dataPts(:,stInd);
```

```

myMembers    = [];
thisClusterVotes = zeros(1,numPts,'uint16');
while 1
    sqDistToAll = sum(( repmat(myMean,1,numPts) - dataPts).^2);
    inInds      = find(sqDistToAll < bandSq);
    thisClusterVotes(inInds) = thisClusterVotes(inInds)+1;
    myOldMean   = myMean;
    myMean      = mean(dataPts(:,inInds),2);
    myMembers   = [myMembers inInds];
    beenVisitedFlag(myMembers) = 1;
    if plotFlag
        figure(12345),clf,hold on
        if numDim == 2
            plot(dataPts(1,:),dataPts(2,:),'.')
            plot(dataPts(1,myMembers),dataPts(2,myMembers),'ys')
            plot(myMean(1),myMean(2),'go')
            plot(myOldMean(1),myOldMean(2),'rd')
            pause
        end
    end
    if norm(myMean-myOldMean) < stopThresh
        mergeWith = 0;
        for cN = 1:numClust
            distToOther = norm(myMean-clustCent(:,cN));
            if distToOther < bandWidth/2
                mergeWith = cN;
                break;
            end
        end
        if mergeWith > 0
            clustCent(:,mergeWith) = 0.5*(myMean+clustCent(:,mergeWith));
            %clustMembsCell{mergeWith} = unique([clustMembsCell{mergeWith}
myMembers]);
            clusterVotes(mergeWith,:) = clusterVotes(mergeWith,:) + thisClusterVotes;
        else
            numClust = numClust+1;
            clustCent(:,numClust) = myMean;
            %clustMembsCell{numClust} = myMembers;
            clusterVotes(numClust,:) = thisClusterVotes;
        end
    end
end

```

```

        break;
    end
end
initPtInds    = find(beenVisitedFlag == 0);
numInitPts    = length(initPtInds);
end
[val,data2cluster] = max(clusterVotes,[],1);
if nargout > 2
    cluster2dataCell = cell(numClust,1);
    for cN = 1:numClust
        myMembers = find(data2cluster == cN);
        cluster2dataCell{cN} = myMembers;
    end
end
end

```

Şekil 4.9. Ortalama Kaydırma kümeleme algoritması MATLAB çıktısı (Mean Shift Clustering, 2021)

10 adet test alanı için tekrarlanan bu test işlemi neticesinde her bir test alanı için F-Skor değeri baz alınarak Çizelge 4.4’de görülen en uygun parametre değerleri tespit edilmiştir.

Çizelge 4.4. F-Skor değeri bazında en uygun Ortalama Kaydırma parametre değerleri

Test Alan No	r (yarıçap)
Test_1	6
Test_2	2
Test_3	9
Test_4	4
Test_5	5
Test_6	2
Test_7	2
Test_8	6
Test_9	5
Test_10	5

5. BULGULAR

Farklı yaklaşımların kullanıldığı çalışmadan elde edilen bulgulara ait sonuçların yer aldığı çizelge ve tablolarda "k" parametre değeri K-Ortalamlar ve Bulanık C-Ortalamlar kümeleme algoritmaları içerisinde bulunan küme sayısını, "r" parametre değeri Ortalama Kaydırma kümeleme algoritmasındaki yarıçap değerini, Canny filtresinde geçen ve [0.1 0.9] aralığında değişen değerler ise sırasıyla “Gradient Threshold” ve “Operator Scale” değerlerini ifade etmektedir. F-Skor, YSGO, SGO, OKH, YBİÖ ve KK değerleri ise doğruluk ölçütlerine ait sonuç değerlerini göstermektedir.

5.1. Kenar Bulma Algoritmaları ile Elde Edilen Sonuçlar








Çizelge 5.1’de 10 adet test alanına ait 4 farklı kenar bulma operatöründen elde edilen doğruluk ölçütlerine göre en iyi sonuçlar gösterilmektedir. Ayrıca Canny algoritması içerisinde yer alan “Gradient Threshold” ve “Operator Scale” parametreleri için tüm sonuç değerleri ile diğer kenar bulma operatörlerine ait sonuç değerler **Ek-1’de** görülmektedir.

Çizelge 5.1. Elde edilen en iyi F-Skor değerleri ve diğer doğruluk ölçütlerinin sonuçları










Test Alan No	Kenar Filtreleri (Gradient Threshold_Operator Scale)	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
Test_1	Canny (0.1_0.5)	0.8898	63.9464	-1.4098	0.0262	0.9992	0.2180
	Sobel	0.8830	64.6055	-0.7506	0.0225	0.9992	0.2160
	Prewitt	0.8828	64.6146	-0.7416	0.0225	0.9992	0.2164
	Roberts	0.8876	64.5078	-0.8483	0.0230	0.9992	0.2240
Test_2	Canny (0.1_0.7)	0.9499	64.4316	-3.4363	0.0234	0.9991	0.1115
	Sobel	0.9448	65.1175	-2.7503	0.0200	0.9992	0.1046
	Prewitt	0.9445	65.1290	-2.7389	0.0200	0.9992	0.1044
	Roberts	0.9487	64.7052	-3.1627	0.0220	0.9991	0.1148
Test_3	Canny (0.1_0.2)	0.7914	63.2052	-3.3850	0.0311	0.9988	0.0857
	Sobel	0.7313	63.9815	-2.6087	0.0260	0.9989	0.0611
	Prewitt	0.7158	63.7824	-2.8078	0.0272	0.9988	0.0604
	Roberts	0.7267	64.5714	-2.0188	0.0227	0.9990	0.0565
Test_4	Canny (0.1_0.4)	0.8043	62.6675	-1.7693	0.0352	0.9987	0.1969
	Sobel	0.6714	63.5053	-0.9315	0.0290	0.9987	0.1470
	Prewitt	0.6666	63.5146	-0.9223	0.0289	0.9987	0.1468
	Roberts	0.6725	63.5503	-0.8865	0.0287	0.9987	0.1503
Test_5	Canny (0.1_0.2)	0.8233	61.8705	-1.8084	0.0423	0.9984	0.1413
	Sobel	0.7279	62.8744	-0.8045	0.0335	0.9985	0.1004
	Prewitt	0.7133	62.8831	-0.7959	0.0335	0.9985	0.0985
	Roberts	0.7240	62.6156	-1.0634	0.0356	0.9985	0.0795
Test_6	Canny (0.4_0.8)	0.9896	66.5866	-0.5094	0.0143	0.9995	0.3049
	Sobel	0.7522	64.5110	-2.5850	0.0230	0.9992	0.2065
	Prewitt	0.7580	64.5710	-2.5250	0.0227	0.9993	0.2042
	Roberts	0.8169	64.3373	-2.7587	0.0240	0.9992	0.2264
Test_7	Canny (0.5_0.9)	0.8495	67.6180	-1.1305	0.0113	0.9995	0.0714
	Sobel	0.5947	64.8918	-3.8567	0.0211	0.9992	0.0728
	Prewitt	0.5947	64.9049	-3.8436	0.0210	0.9992	0.0731
	Roberts	0.6609	64.7487	-3.9997	0.0218	0.9991	0.1020
Test_8	Canny (0.2_0.7)	0.9607	64.5565	-1.0572	0.0228	0.9993	0.2737
	Sobel	0.9507	64.7784	-0.8353	0.0216	0.9993	0.2141
	Prewitt	0.9504	64.7903	-0.8234	0.0216	0.9992	0.2142
	Roberts	0.9647	65.0869	-0.5268	0.0202	0.9992	0.2618
Test_9	Canny (0.2_0.5)	0.8319	62.5828	-2.6147	0.0359	0.9987	0.0875
	Sobel	0.8294	63.1269	-2.0706	0.0317	0.9989	0.0650
	Prewitt	0.8238	63.1549	-2.0425	0.0314	0.9989	0.0631
	Roberts	0.8565	62.9154	-2.2821	0.0332	0.9988	0.1037
Test_10	Canny (0.3_0.6)	0.7202	61.4449	-2.0810	0.0466	0.9982	0.1849
	Sobel	0.6854	61.5897	-1.9362	0.0451	0.9984	0.1447
	Prewitt	0.6859	61.6146	-1.9113	0.0448	0.9984	0.1436
	Roberts	0.7190	61.6173	-1.9085	0.0448	0.9983	0.1865

Çizelge 5.2’de test alanlarına ilişkin girdi görüntüler ile en yüksek F-Skor değerine sahip Canny algoritmasından elde edilen kenar (çıktı) görüntüleri görülmektedir.










Çizelge 5.2. Test alanları ve kenar bulma algoritmaları ile elde edilen sonuçlar

Test_1				
	Görüntü	Filtre Uygulanmış Yoğunluk Görüntüsü	Referans Veri	Kenar Görüntüsü (Canny_0.1_0.5) F-Skor: 0.89
Test_2				
	Görüntü	Filtre Uygulanmış Yoğunluk Görüntüsü	Referans Veri	Kenar Görüntüsü (Canny_0.1_0.7) F-Skor: 0.95
Test_3				
	Görüntü	Filtre Uygulanmış Yoğunluk Görüntüsü	Referans Veri	Kenar Görüntüsü (Canny_0.1_0.2) F-Skor: 0.79




Çizelge 5.2. Test alanları ve kenar bulma algoritmaları ile elde edilen sonuçlar (devamı)

Test_4				
	Görüntü	Filtre Uygulanmış Yoğunluk Görüntüsü	Referans Veri	Kenar Görüntüsü (Canny_0.1_0.4) F-Skor: 0.80
Test_5				
	Görüntü	Filtre Uygulanmış Yoğunluk Görüntüsü	Referans Veri	Kenar Görüntüsü (Canny_0.1_0.2) F-Skor: 0.82
Test_6				
	Görüntü	Filtre Uygulanmış Yoğunluk Görüntüsü	Referans Veri	Kenar Görüntüsü (Canny_0.4_0.8) F-Skor: 0.99

Çizelge 5.2. Test alanları ve kenar bulma algoritmaları ile elde edilen sonuçlar (devamı)

Test_7				
	Görüntü	Filtre Uygulanmış Yoğunluk Görüntüsü	Referans Veri	Kenar Görüntüsü (Canny_0.5_0.9) F-Skor: 0.85
Test_8				
	Görüntü	Filtre Uygulanmış Yoğunluk Görüntüsü	Referans Veri	Kenar Görüntüsü (Canny_0.2_0.7) F-Skor: 0.96
Test_9				
	Görüntü	Filtre Uygulanmış Yoğunluk Görüntüsü	Referans Veri	Kenar Görüntüsü (Canny_0.2_0.5) F-Skor: 0.83

Çizelge 5.2. Test alanları ve kenar bulma algoritmaları ile elde edilen sonuçlar (devamı)

Test10				
	Görüntü	Filtre Uygulanmış Yoğunluk Görüntüsü	Referans Veri	Kenar Görüntüsü (Canny_0.3_0.6) F-Skor: 0.72

5.2. K-Ortalamlar Kümeleme ile Elde Edilen Sonuçlar







Çizelge 5.3’de 10 adet test alanına ait Canny operatöründen elde edilen doğruluk ölçütlerine göre en iyi sonuçlar gösterilmektedir. Ayrıca Canny algoritması içerisinde yer alan “Gradient Threshold” ve “Operator Scale” parametreleri için tüm sonuç değerleri ile diğer kenar bulma operatörlerine ait sonuç değerler **Ek-2’de** görülmektedir.

Çizelge 5.3. K-Ortalamlar kümeleme ile elde edilen en iyi F-Skor değerleri ve diğer doğruluk ölçütlerinin sonuçları







Test Alan No	Küme Sayısı (k)	Kenar Filtreleri (Gradient Threshold_Operator Scale)	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
Test 1	6	Canny (0.5_0.5)	0.8297	64.4001	-0.9560	0.0236	0.9992	0.1953
Test 2	9	Canny (0.2_0.5)	0.9427	64.5702	-3.2976	0.0227	0.9991	0.1112
Test 3	9	Canny (0.3_0.5)	0.7828	62.7335	-3.8567	0.0347	0.9985	0.0749
Test 4	8	Canny (0.2_0.5)	0.7063	62.7207	-1.7161	0.0348	0.9986	0.1450
Test 5	10	Canny (0.1_0.5)	0.7807	61.3762	-2.3028	0.0474	0.9982	0.1092
Test 6	8	Canny (0.4_0.5)	0.9934	66.0018	-1.0942	0.0163	0.9994	0.2446
Test 7	3	Canny (0.4_0.5)	0.8047	68.0862	-0.6623	0.0101	0.9996	0.1130
Test 8	5	Canny (0.4_0.5)	0.9608	64.8368	-0.7769	0.0213	0.9992	0.2688
Test 9	7	Canny (0.3_0.5)	0.8478	63.2841	-1.9133	0.0305	0.9989	0.0819
Test 10	4	Canny (0.4_0.5)	0.7336	62.3917	-1.1342	0.0375	0.9986	0.2059

Çizelge 5.4’de test alanlarına ilişkin girdi görüntüler, K-Ortalamlar kümeleme görüntüleri ile en yüksek F-Skor değerine sahip Canny algoritmasından elde edilen kenar (çıktı) görüntüleri görülmektedir.







Çizelge 5.4. Test alanları ve K-Ortalamlar kümeleme ile elde edilen sonuçlar

Test_1			
	Referans Veri ve Filtre Uygulanmış Yoğunluk Görüntüsü	Kümeleme Uygulanmış Görüntü (k = 6)	Kenar Görüntüsü (Canny_0.5_0.5) F-Skor: 0.83
Test_2			
	Referans Veri ve Filtre Uygulanmış Yoğunluk Görüntüsü	Kümeleme Uygulanmış Görüntü (k = 9)	Kenar Görüntüsü (Canny_0.2_0.5) F-Skor: 0.94







Çizelge 5.4. Test alanları ve K-Ortalamalar kümeleme ile elde edilen sonuçlar (devamı)

Test_3			
	Referans Veri ve Filtre Uygulanmış Yoğunluk Görüntüsü	Kümeleme Uygulanmış Görüntü (k = 9)	Kenar Görüntüsü (Canny_0.3_0.5) F-Skor: 0.78
Test_4			
	Referans Veri ve Filtre Uygulanmış Yoğunluk Görüntüsü	Kümeleme Uygulanmış Görüntü (k = 8)	Kenar Görüntüsü (Canny_0.2_0.5) F-Skor: 0.71






Çizelge 5.4. Test alanları ve K-Ortalamalar kümeleme ile elde edilen sonuçlar (devamı)

Test_5			
	Referans Veri ve Filtre Uygulanmış Yoğunluk Görüntüsü	Kümeleme Uygulanmış Görüntü (k = 10)	Kenar Görüntüsü (Canny_0.1_0.5) F-Skor: 0.78
Test_6			
	Referans Veri ve Filtre Uygulanmış Yoğunluk Görüntüsü	Kümeleme Uygulanmış Görüntü (k = 8)	Kenar Görüntüsü (Canny_0.4_0.5) F-Skor: 0.99

Çizelge 5.4. Test alanları ve K-Ortalamlar kümeleme ile elde edilen sonuçlar (devamı)

Test_7			
	Referans Veri ve Filtre Uygulanmış Yoğunluk Görüntüsü	Kümeleme Uygulanmış Görüntü (k = 3)	Kenar Görüntüsü (Canny_0.4_0.5) F-Skor: 0.80
Test_8			
	Referans Veri ve Filtre Uygulanmış Yoğunluk Görüntüsü	Kümeleme Uygulanmış Görüntü (k = 5)	Kenar Görüntüsü (Canny_0.4_0.5) F-Skor: 0.96

Çizelge 5.4. Test alanları ve K-Ortalamalar kümeleme ile elde edilen sonuçlar (devamı)

Test_9			
	Referans Veri ve Filtre Uygulanmış Yoğunluk Görüntüsü	Kümeleme Uygulanmış Görüntü (k = 7)	Kenar Görüntüsü (Canny_0.3_0.5) F-Skor: 0.85
Test_10			
	Referans Veri ve Filtre Uygulanmış Yoğunluk Görüntüsü	Kümeleme Uygulanmış Görüntü (k = 4)	Kenar Görüntüsü (Canny_0.4_0.5) F-Skor: 0.73

5.3. Bulanık C-Ortalamlar Kümeleme ile Elde Edilen Sonuçlar



Çizelge 5.5’de 10 adet test alanına ait Canny operatöründen elde edilen doğruluk ölçütlerine göre en iyi sonuçlar gösterilmektedir. Ayrıca Bulanık C-Ortalamlar algoritmasına ait tüm sonuç değerleri **Ek-3**’de görülmektedir.

Çizelge 5.5. Bulanık C-Ortalamlar kümeleme ile elde edilen en iyi F-Skor değerleri ve diğer doğruluk ölçütlerinin sonuçları





Test Alan No	Küme Sayısı (k)	Kenar Filtreleri (Gradient Threshold_Operator Scale)	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
Test 1	2	Canny (0.5_0.5)	0.7184	63.6733	-1.6828	0.0279	0.9989	0.1817
Test 2	4	Canny (0.2_0.5)	0.8817	63.5778	-4.2901	0.0289	0.9987	0.1084
Test 3	2	Canny (0.3_0.5)	0.6853	62.9251	-3.6651	0.0332	0.9985	0.0619
Test 4	3	Canny (0.2_0.5)	0.5574	60.7327	-3.7041	0.0551	0.9976	0.0963
Test 5	2	Canny (0.1_0.5)	0.7238	61.6080	-2.0710	0.0450	0.9981	0.1058
Test 6	6	Canny (0.4_0.5)	0.7370	64.1342	-2.9619	0.0256	0.9990	0.1732
Test 7	3	Canny (0.4_0.5)	0.5607	64.9240	-3.8245	0.0209	0.9991	0.0663
Test 8	3	Canny (0.4_0.5)	0.9296	64.7195	-0.8942	0.0220	0.9992	0.2609
Test 9	2	Canny (0.3_0.5)	0.7245	63.1023	-2.0952	0.0318	0.9987	0.0779
Test 10	2	Canny (0.4_0.5)	0.6353	62.9297	-0.5961	0.0331	0.9986	0.1825

Çizelge 5.6’da test alanlarına ilişkin Bulanık C-Ortalamlar kümeleme görüntüleri ile en yüksek F-Skor değerine sahip Canny algoritmasından elde edilen kenar (çıktı) görüntüleri görülmektedir.






Çizelge 5.6. Test alanları ve Bulanık C-Ortalamlar kümeleme ile elde edilen sonuçlar

Test_1		
	Kümeleme Uygulanmış Görüntü (k = 2)	Kenar Görüntüsü (Canny_0.5_0.5) F-Skor: 0.72



Çizelge 5.6. Test alanları ve Bulanık C-Ortalamalar kümeleme ile elde edilen sonuçlar (devamı)

Test_2		
	Kümeleme Uygulanmış Görüntü (k = 4)	Kenar Görüntüsü (Canny_0.2_0.5) F-Skor: 0.88
Test_3		
	Kümeleme Uygulanmış Görüntü (k = 2)	Kenar Görüntüsü (Canny_0.3_0.5) F-Skor: 0.69
Test_4		
	Kümeleme Uygulanmış Görüntü (k = 3)	Kenar Görüntüsü (Canny_0.2_0.5) F-Skor: 0.56

Çizelge 5.6. Test alanları ve Bulanık C-Ortalamalar kümeleme ile elde edilen sonuçlar (devamı)

Test_5		
	Kümeleme Uygulanmış Görüntü (k = 2)	Kenar Görüntüsü (Canny_0.1_0.5) F-Skor: 0.72
Test_6		
	Kümeleme Uygulanmış Görüntü (k = 6)	Kenar Görüntüsü (Canny_0.4_0.5) F-Skor: 0.74
Test_7		
	Kümeleme Uygulanmış Görüntü (k = 3)	Kenar Görüntüsü (Canny_0.4_0.5) F-Skor: 0.56

Çizelge 5.6. Test alanları ve Bulanık C-Ortalamalar kümeleme ile elde edilen sonuçlar (devamı)

Test_8		
	Kümeleme Uygulanmış Görüntü (k = 3)	Kenar Görüntüsü (Canny_0.4_0.5) F-Skor: 0.93
Test_9		
	Kümeleme Uygulanmış Görüntü (k = 2)	Kenar Görüntüsü (Canny_0.3_0.5) F-Skor: 0.72
Test_10		
	Kümeleme Uygulanmış Görüntü (k = 2)	Kenar Görüntüsü (Canny_0.4_0.5) F-Skor: 0.64

5.4. Ortalama Kaydırma Kümeleme ile Elde Edilen Sonuçlar



Çizelge 5.7’de 10 adet test alanına ait Canny operatöründen elde edilen doğruluk ölçütlerine göre en iyi sonuçlar gösterilmektedir. Ayrıca Ortalama Kaydırma algoritması ile elde edilen tüm sonuç değerleri ile diğer kenar bulma operatörlerine ait sonuç değerler **Ek-4’**de görülmektedir.

Çizelge 5.7. Ortalama Kaydırma kümeleme ile elde edilen en iyi F-Skor değerleri ve diğer doğruluk ölçütlerinin sonuçları







Test Alan No	Yarıçap (r)	Kenar Filtreleri (Gradient Threshold_Operator Scale)	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
Test 1	6	Canny (0.5_0.5)	0.6138	65.0334	-0.3228	0.0204	0.9992	0.1597
Test 2	2	Canny (0.2_0.5)	0.9316	65.0013	-2.8665	0.0206	0.9992	0.1088
Test 3	9	Canny (0.3_0.5)	0.7183	64.1266	-2.4635	0.0251	0.9989	0.0638
Test 4	4	Canny (0.2_0.5)	0.7420	63.3368	-1.1000	0.0302	0.9988	0.1877
Test 5	5	Canny (0.1_0.5)	0.8206	61.8923	-1.7867	0.0421	0.9984	0.1401
Test 6	2	Canny (0.4_0.5)	0.9885	66.6454	-0.4506	0.0141	0.9995	0.3059
Test 7	2	Canny (0.4_0.5)	0.8448	67.4875	-1.2610	0.0116	0.9995	0.0758
Test 8	6	Canny (0.4_0.5)	0.9563	64.8046	-0.8091	0.0215	0.9992	0.2742
Test 9	5	Canny (0.3_0.5)	0.8087	63.2451	-1.9524	0.0308	0.9988	0.0598
Test 10	5	Canny (0.4_0.5)	0.6974	62.8597	-0.6661	0.0337	0.9986	0.2156

Çizelge 5.8’de test alanlarına ilişkin girdi görüntüler, Ortalama Kaydırma kümeleme görüntüleri ile en yüksek F-Skor değerine sahip Canny algoritmasından elde edilen kenar (çıkı) görüntüleri görülmektedir.






Çizelge 5.8. Test alanları ve Ortalama Kaydırma kümeleme ile elde edilen sonuçlar

Test_1		
	Kümeleme Uygulanmış Görüntü (r = 6)	Kenar Görüntüsü (Canny_0.5_0.5) F-Skor: 0.61






Çizelge 5.8. Test alanları ve Ortalama Kaydırma kümeleme ile elde edilen sonuçlar (devamı)

Test_2		
	Kümeleme Uygulanmış Görüntü (r = 2)	Kenar Görüntüsü (Canny_0.2_0.5) F-Skor: 0.93
Test_3		
	Kümeleme Uygulanmış Görüntü (r = 9)	Kenar Görüntüsü (Canny_0.3_0.5) F-Skor: 0.72
Test_4		
	Kümeleme Uygulanmış Görüntü (r = 4)	Kenar Görüntüsü (Canny_0.2_0.5) F-Skor: 0.74

Çizelge 5.8. Test alanları ve Ortalama Kaydırma kümeleme ile elde edilen sonuçlar (devamı)

Test_5		
	Kümeleme Uygulanmış Görüntü (r = 5)	Kenar Görüntüsü (Canny_0.1_0.5) F-Skor: 0.82
Test_6		
	Kümeleme Uygulanmış Görüntü (r = 2)	Kenar Görüntüsü (Canny_0.4_0.5) F-Skor: 0.99
Test_7		
	Kümeleme Uygulanmış Görüntü (r = 2)	Kenar Görüntüsü (Canny_0.4_0.5) F-Skor: 0.84

Çizelge 5.8. Test alanları ve Ortalama Kaydırma kümeleme ile elde edilen sonuçlar (devamı)


Test_8		
	Kümeleme Uygulanmış Görüntü (r = 6)	Kenar Görüntüsü (Canny_0.4_0.5) F-Skor: 0.96
Test_9		
	Kümeleme Uygulanmış Görüntü (r = 5)	Kenar Görüntüsü (Canny_0.3_0.5) F-Skor: 0.81
Test_10		
	Kümeleme Uygulanmış Görüntü (r = 5)	Kenar Görüntüsü (Canny_0.4_0.5) F-Skor: 0.70

5.5. Yaklaşım ve Kenar Bulma Algoritmaları Bazında Sınır Tespitlerinin Karşılaştırılması;

Kenar bulma ve kümeleme algoritmaları ile elde edilen sonuç değerleri yaklaşım bazında ve kenar bulma algoritmaları bazında karşılaştırılarak elde edilen sonuçlar değerlendirilmiştir.

5.5.1. F-Skor değerlerinin karşılaştırılması

Kenar bulma ve kümeleme algoritmaları ile elde edilen sonuçlar değerlendirilmiş elde edilen en iyi F-Skor değerleri Şekil 5.1’de gösterilmiştir.



Şekil 5.1. Kenar bulma ve kümeleme algoritmaları bazında F-Skor değerlerinin karşılaştırılması

Canny kenar bulma algoritması ve kümeleme algoritmaları içerisinde en yüksek F-Skor değerlerine ilişkin elde edilen sonuçlar Çizelge 5.9’da gösterilmiştir.


Çizelge 5.9. Uygulanan algoritmalarla göre elde edilen en yüksek F-Skor değeri

Test Alan No	Kenar Filtreleri (1.Yaklaşım)	K-Ortalamlar Kümeleme (2.Yaklaşım)	Bulanık C-Ortalamlar Kümeleme (3.Yaklaşım)	Ortalama Kaydırma Kümeleme (4.Yaklaşım)
Test 1	0.8898	0.8297	0.7184	0.6138
Test 2	0.9499	0.9427	0.8817	0.9316
Test 3	0.7914	0.7828	0.6853	0.7183
Test 4	0.8043	0.7063	0.5574	0.7420
Test 5	0.8233	0.7807	0.7238	0.8206
Test 6	0.9896	0.9934	0.7370	0.9885
Test 7	0.8495	0.8047	0.5607	0.8448
Test 8	0.9607	0.9608	0.9296	0.9563
Test 9	0.8319	0.8478	0.7245	0.8087
Test 10	0.7202	0.7336	0.6353	0.6974


Şekil 5.1 ve Çizelge 5.9'daki şekil ve tablolar incelendiğinde; kümeleme algoritması kullanılmayıp sadece kenar bulma algoritması uygulanan yaklaşımın diğer yaklaşımlara nazaran F-Skor değerlerinin genel anlamda daha iyi sonuç verdiği görülmüştür. 1, 2, 3, 4, 5 ve 7 nolu test alanlarında kenar bulma algoritması; 6, 8, 9 ve 10 nolu test alanlarında ise K-Ortalamlar kümeleme algoritmasının daha başarılı olduğu anlaşılmaktadır. K-Ortalamlar, Bulanık C-Ortalamlar ve Ortalama Kaydırma kümeleme algoritmaları karşılaştırıldığında ise; 1, 2, 3, 6, 8, 9 ve 10 nolu test alanlarında K-Ortalamlar, 4, 5 ve 7 nolu test alanlarında ise Ortalama Kaydırma algoritmasının daha başarılı olduğu görülmüştür. Bununla birlikte Bulanık C-Ortalamlar metodu bulanık mantık algoritması ile çalışmakta olup test alanlarında 10 kez uygulanan döngü ile elde edilen sonuçların ortalaması alınarak doğruluk analizleri yapılmıştır. Elde edilen ortalama değerler Çizelge 5.9'da görülmektedir. Bulanık C-Ortalamlar algoritmasına ait tüm sonuç verileri incelendiğinde **(Ek-3)**; 2.test alanında 0.95, 6.test alanında 0.94 ve 7.test alanında 0.91 oranında F-Skor değerleri gibi yüksek sonuçların olduğu görülmüş olup bu yönüyle algoritmanın diğerlerine göre üstünlük sağladığı anlaşılmaktadır.

5.5.2. YSGO, SGO, OKH, YBİÖ ve KK değerlerinin karşılaştırılması


Canny kenar bulma algoritması ve uygulanan kümeleme algoritmaları ile elde edilen sonuçlara göre en iyi YSGO, SGO, OKH, YBİÖ ve KK değerleri Şekil 5.2 ile 5.6'da gösterilmiştir.




Şekil 5.2. YSGO değerlerinin karşılaştırılması




Şekil 5.3. SGO değerlerinin karşılaştırılması



Şekil 5.4. OKH değerlerinin karşılaştırılması



Şekil 5.5. YBiÖ değerlerinin karşılaştırılması



Şekil 5.6. KK değerlerinin karşılaştırılması


Şekil 5.2 ve 5.3'deki YSGO ve SGO değerleri karşılaştırıldığında; Canny kenar bulma algoritması, K-Ortalamlar ve Ortalama Kaydırma kümeleme algoritmalarından elde edilen değerlerin birbirine yakın olduğu görülmekle birlikte Ortalama Kaydırma kümeleme algoritmasından elde edilen YSGO ve SGO değerlerinin diğer yaklaşımlara göre daha yüksek çıktığı görülmektedir.

Şekil 5.4 ve 5.5'deki OKH ve YBİÖ değerleri karşılaştırıldığında; Canny kenar bulma algoritması, K-Ortalamlar ve Ortalama Kaydırma kümeleme algoritmalarından elde edilen değerlerin birbirine yakın olduğu görülmekle birlikte Bulanık C-Ortalamlar algoritmasından elde edilen OKH değerlerinin diğer yaklaşımlara göre daha yüksek, YBİÖ değerlerinin ise diğer yaklaşımlara göre daha düşük olduğu görülmektedir.

Şekil 5.6'daki KK değerleri karşılaştırıldığında; 1, 2, 3, 8, 9 ve 10 nolu test alanlarında tüm yaklaşımlardan elde edilen değerlerin birbirine yakın olduğu, 4, 5, 6 ve 7 nolu test alanlarında ise bu değerlerin farklılaştığı görülmekle birlikte kenar bulma algoritmasından elde edilen sonuçların diğer yaklaşımlara nazaran genel anlamda daha yüksek olduğu görülmüştür.

5.5.3. Kenar bulma algoritmaları bazında F-Skor değerlerinin karşılaştırılması

Canny, Sobel, Prewitt ve Roberts kenar bulma algoritmaları karşılaştırılmış olup elde edilen en iyi F-Skor değerleri Şekil 5.7’de gösterilmiştir.




Şekil 5.7. Kenar bulma algoritmaları ile elde edilen F-Skor değerlerinin karşılaştırılması


Şekil 5.7’de kenar bulma algoritmaları bazında F-Skor değerleri karşılaştırıldığında Canny algoritmasından elde edilen sonuçların diğer kenar bulma algoritmaları olan Sobel, Prewitt ve Roberts algoritmalarına göre kısmen daha iyi sonuç verdiği anlaşılmakla birlikte 4 kenar bulma algoritmasındaki sonuçların genel anlamda birbirine yakın olduğu görülmüştür.

5.5.4. Kenar bulma ve kümeleme algoritmaları bazında parametre değerlerinin karşılaştırılması


Canny kenar bulma algoritması içerisinde yer alan “Gradient Threshold” parametre değeri, K-Ortalamlar ve Bulanık C-Ortalamlar yaklaşımları içerisinde yer alan "k" (küme sayısı) parametre değeri ile ve Ortalama Kaydırma kümeleme yaklaşımında bulunan "r" (yarıçap) parametre değeri değişiminin sonuçlara doğruluk ölçütleri bazında etkisi Şekil 5.8 ila 5.13’de gösterilmiştir.




Şekil 5.8. Parametre değerlerinin F-Skor değerine etkisi




Şekil 5.9. Parametre değerlerinin YSGO değerine etkisi




Şekil 5.10. Parametre değerlerinin SGO değerine etkisi



Şekil 5.11. Parametre değerlerinin OKH değerine etkisi



Şekil 5.12. Parametre değerlerinin YBİÖ değerine etkisi



Şekil 5.13. Parametre değerlerinin KK değerine etkisi

Canny kenar bulma algoritmasında yer alan “Gradient Threshold” parametre değeri ile K-Ortalamlar ve Bulanık C-Ortalamlar kümeleme yaklaşımlarındaki "k" parametre değeri ile Ortalama Kaydırma kümeleme yaklaşımındaki "r" parametre değerlerinin değişiminin sonuçlara etkisini gösteren Şekil 5.8 ila 5.13 nolu grafikler incelendiğinde;

Canny filtresi içerisinde bulunan “Gradient Threshold” parametre değeri azaltıldıkça F-Skor değerinin artış gösterdiği, K-Ortalamlar kümeleme algoritmasında "k" küme sayısı artışının sonuçları çok etkilemediği, Bulanık C-Ortalamlar kümeleme algoritmasında "k" küme sayısı arttıkça F-Skor değerinin kısmen azaldığı, Ortalama Kaydırma kümeleme algoritmasında ise "r" yarıçap değerinin sonuçlara etki etmediği görülmüş (Şekil 5.8) olup Ortalama Kaydırma kümeleme algoritmasının diğer kümeleme algoritmalarına nazaran bu yönüyle daha iyi olduğu söylenebilir.

Canny filtresi içerisinde bulunan “Gradient Threshold” parametre değeri azaltıldıkça YSGO ve SGO değerinin de azaldığı, K-Ortalamlar kümeleme algoritmasında "k" küme sayısı artışının sonuçları çok etkilemediği, Bulanık C-Ortalamlar kümeleme algoritmasında "k" küme sayısı arttıkça YSGO ve SGO değerinin de azaldığı, Ortalama Kaydırma kümeleme algoritmasında ise "r" yarıçap değerinin sonuçlara etki etmediği görülmüştür (Şekil 5.9 ve 5.10).

Canny filtresi içerisinde bulunan “Gradient Threshold” parametre değeri azaltıldıkça OKH değerinin de arttığı, K-Ortalamlar ve Ortalama Kaydırma kümeleme algoritmalarında "r" yarıçap değerinin artışının sonuçları çok etkilemediği, Bulanık C-Ortalamlar kümeleme algoritmasında "k" küme sayısı arttıkça OKH değerinin de arttığı görülmüştür (Şekil 5.11).

Canny filtresi içerisinde bulunan “Gradient Threshold” parametre değeri azaltıldıkça YBİÖ değerinin değişmediği sadece 10.test alanında kısmen azalma görüldüğü, K-Ortalamlar ve Ortalama Kaydırma kümeleme algoritmalarında "k" küme sayısı ve "r" yarıçap değeri artışının sonuçları çok etkilemediği, Bulanık C-Ortalamlar kümeleme algoritmasında "k" küme sayısı arttıkça YBİÖ değerinin de azaldığı görülmüştür (Şekil 5.12).

Canny filtresi içerisinde bulunan “Gradient Threshold” parametre değeri azaltıldıkça KK değerinin arttığı, K-Ortalamlar ve Bulanık C-Ortalamlar kümeleme algoritmalarında "k" küme sayısı ile Ortalama Kaydırma kümeleme algoritmasındaki "r" yarıçap değeri artışının sonuçları çok etkilemediği görülmekle birlikte KK değerinin kısmen azaldığı görülmüştür (Şekil 5.13).

5.6. Nokta Yoğunluğu ve Yükseklik Değişimi Bazında Sınır Tespitlerinin Karşılaştırılması;

Çizelge 3.1’de test alanlarına ilişkin veri setlerinin özellikleri belirtilmiş olup bu çizelgede test alanları bazında LiDAR verisine ait m²’ye düşen nokta yoğunlukları gösterilmiştir. Yine test alanlarına ait LiDAR verisindeki nokta yükseklik bilgileri her bir veri seti içerisinde mevcuttur. Nokta yoğunluğu ve yükseklik değişiminin F-Skor değerine etkisini incelemek için bu veriler ile Çizelge 5.9’da yaklaşım bazında tespit edilen Canny kenar bulma algoritması ile elde edilen en yüksek F-Skor değerleri karşılaştırılmıştır.


5.6.1. Nokta yoğunluğu bazında sınır tespitlerinin karşılaştırılması;

Çizelge 3.1’deki nokta yoğunlukları en düşükten en yükseğe olacak şekilde sıralanmış ve 4 farklı yaklaşımdan elde edilen en yüksek F-Skor değerleri Çizelge 5.10’da gösterilmiştir.

Çizelge 5.10. Canny kenar bulma algoritması ile elde edilen en yüksek F-Skor değerlerinin nokta yoğunluğuna göre sıralanması

Test Alan No	Kenar Filtreleri (1.Yaklaşım)	K-Ortalamalar Kümeleme (2.Yaklaşım)	Bulanık C-Ortalamalar Kümeleme (3.Yaklaşım)	Ortalama Kaydırma Kümeleme (4.Yaklaşım)	Nokta Yoğunluğu (m ²)
Test 3	0.7914	0.7828	0.6853	0.7183	1.49
Test 1	0.8898	0.8297	0.7184	0.6138	1.97
Test 4	0.8043	0.7063	0.5574	0.7420	3.50
Test 2	0.9499	0.9427	0.8817	0.9316	3.99
Test 5	0.8233	0.7807	0.7238	0.8206	4.05
Test 9	0.8319	0.8478	0.7245	0.8087	4.26
Test 7	0.8495	0.8047	0.5607	0.8448	5.04
Test 6	0.9896	0.9934	0.7370	0.9885	5.69
Test 8	0.9607	0.9608	0.9296	0.9563	11.05
Test 10	0.7202	0.7336	0.6353	0.6974	13.42

Çizelge 5.10’daki F-Skor değerleri ile nokta yoğunlukları karşılaştırılmış ve Şekil 5.14’deki grafik elde edilmiştir. Bu grafikten anlaşılabacağı üzere test alanlarına ait nokta yoğunluk değerinin artışının F-Skor değerine etkisinin olmadığı tespit edilmiştir.



Şekil 5.14. Nokta yoğunluğunun F-Skor değerine etkisi


5.6.2. Yükseklik değişimi bazında sınır tespitlerinin karşılaştırılması;

Test alanlarına ait LiDAR verisindeki nokta yükseklik bilgileri kullanılarak her bir test alanı için standart sapma değerleri hesaplanmıştır. Daha sonra hesaplanan standart sapma değerleri en düşükten en yükseğe olacak şekilde sıralanmış ve 4 farklı yaklaşımdan elde edilen en yüksek F-Skor değerleri Çizelge 5.11’de gösterilmiştir.

Çizelge 5.11. Canny kenar bulma algoritması ile elde edilen en yüksek F-Skor değerleri ile standart sapma bazında yükseklik değişimi

Test Alan No	Kenar Filtreleri (1.Yaklaşım)	K-Ortalamlar Kümeleme (2.Yaklaşım)	Bulanık C-Ortalamlar Kümeleme (3.Yaklaşım)	Ortalama Kaydırma Kümeleme (4.Yaklaşım)	Standart Sapma (Yükseklik Verisi)
Test 2	0.9499	0.9427	0.8817	0.9316	0.40
Test 3	0.7914	0.7828	0.6853	0.7183	1.34
Test 4	0.8043	0.7063	0.5574	0.7420	1.48
Test 7	0.8495	0.8047	0.5607	0.8448	1.71
Test 6	0.9896	0.9934	0.7370	0.9885	2.13
Test 5	0.8233	0.7807	0.7238	0.8206	2.35
Test 10	0.7202	0.7336	0.6353	0.6974	2.63
Test 9	0.8319	0.8478	0.7245	0.8087	2.89
Test 1	0.8898	0.8297	0.7184	0.6138	3.59
Test 8	0.9607	0.9608	0.9296	0.9563	3.89

Çizelge 5.11’deki F-Skor değerleri ile standart sapma bazında yükseklik değişimi karşılaştırılmış ve Şekil 5.15’deki grafik elde edilmiştir. Bu grafikten anlaşılacağı üzere tez çalışmasında kullanılan veri setlerindeki yükseklik farklarının F-Skor değerine etkisinin olmadığı tespit edilmiştir.



Şekil 5.15. Yükseklik değişiminin F-Skor değerine etkisi

6. SONUÇLAR VE ÖNERİLER

Çalışma kapsamında nokta bulutu verisi kullanılarak elde edilen görüntülere filtreleme, kenar bulma ve kümeleme algoritmaları uygulanarak görüntülerdeki parsel sınırları tespit edilmiştir. Ayrıca kenar bulma ve kümeleme algoritmaları içerisinde yer alan ve tez içeriğinde detayları belirtilen parametre değerleri de test edilerek en uygun parametre değerleri bulunmuştur. Kenar bulma algoritmaları olarak birinci yaklaşımda Canny, Sobel, Prewitt ve Roberts, diğer yaklaşımlarda sadece Canny filtresi, kümeleme işlemleri için ise K-Ortalamlar, Bulanık C-Ortalamlar ve Ortalama Kaydırma algoritmaları belirlenen 10 farklı test alanında uygulanmış ve sonuçlar değerlendirilmiştir. Ayrıca çalışma kapsamında kenar bulma ve kümeleme algoritmaları ile doğruluk ölçütleri karşılaştırılarak bu algoritmaların ve ölçütlerin birbirine göre avantaj ve dezavantajları belirlenmiştir.

Test alanlarına ait bazı görüntülerde parazitlenmelerin olduğu, özellikle kümeleme işlemi uygulandığında bu parazitlenmelerin daha da arttığı ve buna bağlı olarak doğruluk oranının azaldığı anlaşılmaktadır. Söz konusu parazitlenmeler açılma ve kapanma gibi morfolojik filtreler uygulanarak giderilmeye çalışılmış ise de bu filtreler uygulandığında çok ciddi veri kaybı olduğu görüldüğünden söz konusu parazitlenmeleri yok etmek için farklı yöntemlerin sonraki çalışmalarda kullanılabileceği önerilmektedir.

Test alanlarından elde edilen sonuçlara göre en düşük doğruluk oranının (F-Skor değeri) 10.test alanında olduğu anlaşılmaktadır. Bu durumun test alanındaki bitki örtüsünün sıklığından kaynaklı olduğu değerlendirilmiştir. O nedenle çalışma alanının seçimi doğruluk oranını etkileyen en önemli faktör olarak karşımıza çıktığından, bu tür çalışmalarda bu hususa dikkat edilmesi gerekmektedir.

Şekil 5.14 ve Şekil 5.15'deki grafikler incelendiğinde; tez çalışmasında kullanılan test alanlarındaki verilere göre m^2 'ye düşen nokta yoğunlukları ile yükseklik değişiminin F-Skor değeri bazında doğruluk oranına etkisinin olmadığı anlaşılmaktadır. Ancak yöntemler ve F-Skor sonuçları arasında belirli bir ilişkinin yani korelasyonun bulunduğu da görülmüştür. Her iki grafikte de yöntemler bazında ortalama F-Skor değerlerinin Canny, K-Ortalamlar, Ortalama Kaydırma ve Bulanık C-Ortalamlar şeklinde sıralandığı tespit edilmiş olup bu yönüyle nokta yoğunlukları ile yükseklik değişiminin yöntemler bazında benzer ilişkiye sahip oldukları anlaşılmıştır.

Çalışmada iş akışı içerisinde otomatik tespit edilen tarımsal arazi sınırları ile referans veri setlerindeki sınırlar karşılaştırıldığında ortalama F-Skor değeri % 86 olup bu anlamda elde edilen sonuçların oldukça başarılı olduğu görülmektedir. Hatta 1, 2, 6 ve 8 numaralı test alanlarında bu oranın % 95'lerin üzerinde olduğu görülmektedir. Uydu yada hava fotoğrafları kullanılarak görüntülerden nesne tespitine yönelik son yıllarda yapılan çalışmalar incelendiğinde F-Skor değeri bazında genel başarı ortalamasının % 80 - 90 aralığında olduğu görülmüş olup bu çalışmadan elde edilen sonuçlara göre nokta bulutu verisinin de bu alanda iyi bir potansiyele sahip olduğu anlaşılmaktadır. Yapılan bu çalışma sadece uydu ve hava fotoğrafları değil nokta bulutu verilerinden de tarımsal arazilerin sınırlarının başarılı bir şekilde tespitinin mümkün olduğunu göstermektedir.

Elde edilen kenar görüntüleri yardımıyla özellikle tarımsal alanlarda ürün farklılıklarının sınırlarının tespiti, hali hazır harita yapımı, kadastro çalışmalarında sınırların tespiti vb. çalışmalarda bu verilerin kullanılabilmesi mümkün olup bu alanda faaliyet gösteren farklı kurum ve kuruluşların ihtiyacı noktasında zaman ve maliyet açısından fayda sağlayabilecektir.

Kentleşme ile daralan tarım arazilerinin sınırlarının otomatik tespit edilerek daha etkin, verimli ve ekonomik kullanılabilmesi, artan teknolojik gelişmelere paralel bir şekilde kaçınılmaz bir öneme sahiptir. Yapılan bu çalışma ile teknolojinin bu yöndeki çalışmalara katkısının olduğu ve olacağı ortaya konulmuştur.

KAYNAKLAR

- Ankurtripathi, 2022, Meanshift Clustering: <https://www.geeksforgeeks.org/ml-mean-shift-clustering/> [Ziyaret Tarihi: 05 Mayıs 2022].
- Aktaruzzaman, M. D., and Schmitt, T. G., 2010, LiDAR-data: Automatic object detection to support urban flooding simulation. In Proceedings Canadian Geomatics Conference and Symposium of Commission I, ISPRS, Calgary, Alberta, Canada.
- Aroni, E., and Ioannidis, C., 2018, Automated Building Detection in Dense Point Cloud and Update of Open Source Data Bases. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 42, 11-18.
- Awrangjeb, M., 2016, Using point cloud data to identify, trace, and regularize the outlines of buildings. International Journal of Remote Sensing, 373, 551-579.
- Azad, M., and Farnood Ahmadi, F., 2022, A semi-automatic method for extraction of urban features by integrating aerial images and LiDAR data and comparing its performance in areas with different feature structures case study: comparison of the method performance in Isfahan and Toronto. Applied Geomatics, 144, 589-607.
- Balçık, F. B., ve Göksel, Ç., 2010, SPOT 5 ve Farklı Görüntü Birleştirme Algoritmaları. Jeodezi ve Jeoinformasyon Dergisi 101.
- Bayaslı B., 2021, Hava lidar verilerinin yapa zeka yöntemleri kullanılarak sınıflandırılması ve filtrelenmesi, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- Bárdossy, A., and Samaniego, L., 2002, Fuzzy rule-based classification of remotely sensed imagery. IEEE transactions on geoscience and remote sensing, 402, 362-374.
- Bayramlı, B., 2022, https://burakbayramli.github.io/dersblog/algs/algs_090_meanshift/ortalama_kaydi_rma_ile_kumeleme__mean_shift_clustering_.html, [Ziyaret Tarihi: 01 Temmuz 2022].
- Benchabana, A., Kholadi, M. K., Bensaci, R., and Khaldi, B., 2023, Building detection in high-resolution remote sensing images by enhancing superpixel segmentation and classification using deep learning approaches. Buildings, 137, 1649.
- Bitbio, 2022, Clustering RNAseq data using fuzzy c-means clustering, <https://2-bitbio.com/post/clustering-rnaseq-data-using-fuzzy-c-means-clustering/>, [Ziyaret Tarihi: 15 Temmuz 2022].
- Blackledge, J. M., 2005, Digital image processing: mathematical and computational methods. Elsevier.

- Bool, D., Mabaquiao, L., Tupas, M., and Fabila, J., 2018, Automated building detection using RANSAC from classified LiDAR point cloud data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 115-121.
- Borowiec, N., and Marmol, U., 2022, Using LiDAR system as a data source for agricultural land boundaries. *Remote Sensing*, 144, 1048.
- Buyuksalih, G., Baz, I., Bayburt, S., Jacobsen, K., and Alkan, M., 2009, Geometric and mapping potential of WorldView-1 images. *Proceedings of the ISPRS Hannover workshop 2009*.
- Büyükköz, D., 2010, Fuzzy Kümeleme Teknikleri ve Avrupa Birliği Üye Ülkeleri ile Türkiye'nin Fuzzy Kümelenmesi Yüksek Lisans Tezi, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İşletme Ana Bilim Dalı.
- Canaz, S., and Habib, A., 2013, Photogrammetric features for the registration of terrestrial laser scans with minimum overlap. *J. Geod. Geoinf*, 21.
- Canaz, S., Karsli, F., Guneroglu, A., and Dihkan, M., 2015, Automatic boundary extraction of inland water bodies using LiDAR data. *Ocean and Coastal Management*, 118, 158-166.
- Canny, J., 1986, A computational approach to edge detection. *IEEE Transactions on pattern analysis and machine intelligence*, 6, 679-698.
- Cetin, Z., and Yastikli, N., 2022, Automatic detection of single street trees from airborne LiDAR data based on point segmentation methods. *International Journal of Engineering and Geosciences*, 82, 129-137.
- Chehata, N., Guo, L., and Mallet, C., 2009, Airborne lidar feature selection for urban classification using random forests. *Communication Dans Un Congrès - Laserscanning*, Paris, France.
- Chen, L., Zhao, S., Han, W., and Li, Y., 2012, Building detection in an urban area using lidar data and QuickBird imagery. *International Journal of Remote Sensing*, 3316, 5135-5148.
- Comaniciu, D., and Meer, P., 2002, Mean shift: A robust approach toward feature space analysis. *IEEE Transactions on pattern analysis and machine intelligence*, 245, 603-619.
- Coşkun, C., ve Baykal, A., 2011, Veri madenciliğinde sınıflandırma algoritmalarının bir örnek üzerinde karşılaştırılması. *Akademik Bilişim*, 2011, 1-8.
- Dandan, E., 2010, Ev ortamında çocuk güvenliği amaçlı akıllı gözetleme sistemi. Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı.
- Davis, L. S., 1975, A survey of edge detection techniques. *Computer graphics and image processing*, 43, 248-270.

- Değirmenci, A., Çankaya, İ., ve Demirci, R., 2018, Gradyan Anahtarlmalı Gauss Görüntü Filtresi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 61, 196-215.
- Demir, N., 2015, Görüntü ve Lidar Verisinden Bina Tespitinde Farklı Yöntemler. *Journal of Aeronautics and Space Technologies/Havacılık ve Uzay Teknolojileri Dergisi*, 81.
- Demiralay, M., ve Çamurcu, A. Y., 2005, Cure, agnes ve k-means algoritmalarındaki kümeleme yeteneklerinin karşılaştırılması. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 48, 1-18.
- Derpanis, K. G., 2005, Meanshift clustering. *Lecture Notes*, 32, 1-4.
- Dey, E. K., Awrangjeb, M., Tarsha Kurdi, F., and Stantic, B., 2023, Machine learning-based segmentation of aerial LiDAR point cloud data on building roof. *European Journal of Remote Sensing*, 561, 2210745.
- Elsayed, H., Zahran, M., Elshehaby, A., Salah, M., and Elshehaby, A., 2019, Integrating Modern Classifiers for Improved Building Extraction from Aerial Imagery and LiDAR Data. *Am. J. Geogr. Inf. Syst*, 2019, 213-220.
- Ezeomodo, I., and Igbokwe, J., 2013, Mapping and analysis of land use and land cover for a sustainable development using high resolution satellite images and GIS. *Conference of the International Federation of Surveyors FIG, Abuja, Nigeria*.
- Feng, H., Chen, Y., Luo, Z., Sun, W., Li, W., and Li, J., 2022, Automated extraction of building instances from dual-channel airborne LiDAR point clouds. *International Journal of Applied Earth Observation and Geoinformation*, 114, 103042.
- Fidan, M. H., 2010, Kızılötesi hava fotoğraflarından bina detaylarının belirlenmesi Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Ana Bilim Dalı.
- Gamal, A., Wibisono, A., Wicaksono, S. B., Abyan, M. A., Hamid, N., Wisesa, H. A., Jatmiko, W., and Ardhianto, R., 2020, Automatic LiDAR building segmentation based on DGCNN and euclidean clustering. *Journal of Big Data*, 7, 1-18.
- Gao, J., 2009, Digital Analysis of Remotely Sensed Data, School of Geography, Geology and Environmental Science, The University of Auckland, New Zealand.
- Garcia-Pedrero, A., Gonzalo-Martin, C., and Lillo-Saavedra, M., 2017, A machine learning approach for agricultural parcel delineation through agglomerative segmentation. *International Journal of Remote Sensing*, 387, 1809-1819.
- Ghaffarian, S., and Turker, M., 2019, An improved cluster-based snake model for automatic agricultural field boundary extraction from high spatial resolution imagery. *International Journal of Remote Sensing*, 404, 1217-1247.
- Ghit, Y. A. A. G., 2022, Yapay sinir ağlarını kullanarak sayısal görüntülerde kenar tespiti için optimum bir yaklaşım Doktora Tezi, Kastamonu Üniversitesi, Fen Bilimleri Enstitüsü, Malzeme Bilimi ve Mühendisliği Ana Bilim Dalı.

- Giampouras, P., Charou, E., and Kesidis, A., 2013, Artificial neural network approach for land cover classification of fused hyperspectral and LiDAR data. Artificial Intelligence Applications and Innovations: 9th IFIP WG 12.5 International Conference, AIAI 2013, Paphos, Cyprus, Proceedings 9.
- Giannico, V., Laforteza, R., John, R., Sanesi, G., Pesola, L., and Chen, J., 2016, Estimating stand volume and above-ground biomass of urban forests using LiDAR. Remote Sensing, 84, 339.
- Gonzalez, R. C., 2014, Sayısal Görüntü İşleme. Palme Yayıncılık.
- Güler, M., 2018, Lidar Verisinden Bina Çatı Düzlemlerinin Otomatik Çıkarımı ve Modellemesi Yüksek Lisans Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Geomatik Mühendisliği Ana Bilim Dalı.
- Gürbüz, M. F., Karabörk, H., ve Baykan, N., 2023, Nesne Sınırlarının Kenar Bulma Algoritmalarıyla Elde Edilmesi, 6. Uluslararası Ankara Multidisipliner Bilimsel Çalışmalar Kongresi, Ankara, Türkiye, Kongre Kitabı, 1407-1408, ISBN: -978-625-367-369-7.
- Habib, A., Datchev, I., and Bang, K., 2010, A comparative analysis of two approaches for multiple-surface registration of irregular point clouds. Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci, 381.
- Han, J. K., and Kamber, M., 2001, M.: Data Mining: Concepts and Techniques. In: Morgan Kaufmann Publishers, San Francisco.
- Han, Q., Yin, Q., Zheng, X., and Chen, Z., 2021, Remote sensing image building detection method based on Mask R-CNN. Complex and Intelligent Systems, 1-9.
- Hellmann, M., 2001, Fuzzy logic introduction. Université de Rennes, 11.
- Hong, R., Park, J., Jang, S., Shin, H., Kim, H., and Song, I., 2021, Development of a parcel-level land boundary extraction algorithm for aerial imagery of regularly arranged agricultural areas. Remote Sensing, 136, 1167.
- Höfle, B., and Pfeifer, N., 2007, Correction of laser scanning intensity data: Data and model-driven approaches. ISPRS Journal of Photogrammetry and Remote Sensing, 626, 415-433.
- Hui, Z., Li, Z., Cheng, P., Ziggah, Y. Y., and Fan, J., 2021, Building extraction from airborne LiDAR data based on multi-constraints graph segmentation. Remote Sensing, 1318, 3766.
- Javaid, H., Babar, T. K., Rasool, A., and Saghir, R. U., 2013, Video colour variation detection and motion magnification to observe subtle changes. Blekinge Institute of Technology.
- Jintasuttisak, T., Edirisinghe, E., and Elbattay, A., 2022, Deep neural network based date palm tree detection in drone imagery. Computers and Electronics in Agriculture, 192, 106560.

- Joshi, R. C., Yadav, S., Dutta, M. K., and Travieso-Gonzalez, C. M., 2020, Efficient multi-object detection and smart navigation using artificial intelligence for visually impaired people. *Entropy*, 229, 941.
- Kabolizade, M., Ebadi, H., and Ahmadi, S., 2010, An improved snake model for automatic extraction of buildings from urban aerial images and LiDAR data. *Computers, Environment and Urban Systems*, 345, 435-441.
- Kamara, A., and Doğan, S., 2019, 3D Reconstruction of Point Clouds and Solid Models from LiDAR and Digital Stereo Images. 4th International Symposium on Innovative Approaches in Engineering and Natural Sciences, Samsun, Turkey, 203-210.
- Kaş, Ü., 2016, Göz ile fark edilmeyen küçük hareketlerin algılanmasında görüntü büyütme yöntemlerinin performans analizi Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yazılım Mühendisliği Ana Bilim Dalı.
- Konez O., 2022, Görüntü Kalitesi, http://www.konez.com/Goruntu_kalitesi.htm, [Ziyaret Tarihi: 14 Mart 2022].
- Kumar, L., Afzal, M. S., and Afzal, M. M., 2020, Mapping shoreline change using machine learning: a case study from the eastern Indian coast. *Acta Geophysica*, 684, 1127-1143.
- Kurnaz, B., Bayik, C., and Abdikan, S., 2020, Forest fire area detection by using Landsat-8 and Sentinel-2 satellite images: A case study in Mugla, Turkey.
- Kwak, E., and Habib, A., 2014, Automatic representation and reconstruction of DBM from LiDAR data using Recursive Minimum Bounding Rectangle. *ISPRS Journal of Photogrammetry and Remote Sensing*, 93, 171-191.
- Lavanya, K., Gondchar, A., Mathew, I. M., Sarda, S., Ananda Kumar, S., Mahendran, A., and Perera, D. G., 2023, Land Cover Classification Using Landsat 7 Data for Land Sustainability. *Wireless Personal Communications*, 1321, 679-697.
- Li, J., Cao, J., Feyissa, M. E., and Yang, X., 2020, Automatic building detection from very high-resolution images using multiscale morphological attribute profiles. *Remote Sensing Letters*, 117, 640-649.
- Li, J., Huang, X., Tu, L., Zhang, T., and Wang, L., 2022, A review of building detection from very high resolution optical remote sensing images. *GIScience and Remote Sensing*, 591, 1199-1225.
- Lillesand, T., Kiefer, R. W., and Chipman, J., 2015, Remote sensing and image interpretation. John Wiley and Sons, ISBN:111834328X.
- Liu, X., 2008, Airborne LiDAR for DTM generation: Some critical issues. *Progress in Physical Geography*, 32(1), 31-49.

- Liu, L., Ouyang, W., Wang, X., Fieguth, P., Chen, J., Liu, X., and Pietikäinen, M., 2020, Deep learning for generic object detection: A survey. *International journal of computer vision*, 128, 261-318.
- Luo, X., Bennett, R. M., Koeva, M., and Lemmen, C., 2017, Investigating semi-automated cadastral boundaries extraction from airborne laser scanned data. *Land*, 63, 60.
- Ma, L., Zhou, M., and Li, C., 2017, Land covers classification based on Random Forest method using features from full-waveform LiDAR data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 263-268.
- MacQueen, J., 1967, Classification and analysis of multivariate observations. *Proceedings of the 5th Berkeley Symposium on Mathematical Statistics and Probability*, 281-297.
- Marangoz, A., 2009, Uydu görüntülerinden kentsel ayrıntıların nesne-tabanlı sınıflandırma yöntemiyle belirlenmesi ve cbs ortamında bütünleştirilmesi Doktora Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Jeodezi ve Fotogrametri Mühendisliği Ana Bilim Dalı.
- Marangoz, A. M., ve Alkış, Z., 2012, Nesne-Tabanlı Görüntü Sınıflandırma Yöntemlerini Kullanarak Uydu Görüntülerinden Kentsel Detayların Belirlenmesi, Haritaların Güncellenmesi ve CBS'ye Entegrasyonu, IV. Uzaktan Algılama ve CBS Sempozyumu, 16-19.
- Mathews, A. J., and Jensen, J. L., 2012, An airborne LiDAR-based methodology for vineyard parcel detection and delineation. *International Journal of Remote Sensing*, 3316, 5251-5267.
- Mean Shift Clustering, 2021, www.mathworks.com/matlabcentral/fileexchange/10161-mean-shift-clustering, [Ziyaret Tarihi: 25 Nisan 2021].
- Moon, G., Kim, S., Kim, W., Kim, Y., Jeong, Y., and Choi, H. S., 2022, Computer aided facial bone fracture diagnosis CA-FBFD system based on object detection model. *IEEE Access*, 10, 79061-79070.
- Munawar, H. S., Ullah, F., Qayyum, S., and Heravi, A., 2021, Application of deep learning on uav-based aerial images for flood detection. *Smart Cities*, 43, 1220-1242.
- Nacar, F., 2015, Türkiye'deki Kadastro Yenileme Çalışmalarında Ortofoto ve Yüksek Çözünürlüklü Uydu Görüntülerinin Kullanılabilirliğinin Araştırılması Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Ana Bilim Dalı.
- Næs, T., and Mevik, B. H., 1999, The flexibility of fuzzy clustering illustrated by examples. *Journal of Chemometrics*, 133-4, 435-444.

- North, H. C., Pairman, D., and Belliss, S. E., 2018, Boundary delineation of agricultural fields in multitemporal satellite imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 121, 237-251.
- Ojogbane, S. S., Mansor, S., Kalantar, B., Khuzaimah, Z. B., Shafri, H. Z. M., and Ueda, N., 2021, Automated building detection from airborne LiDAR and very high-resolution aerial imagery with deep neural network. *Remote Sensing*, 1323, 4803.
- Ok, A. Ö., 2016, Çok yüksek çözünürlüklü uydu görüntülerinden kentsel alanlardaki binaların ve yolların otomatik tespiti. *Jeodezi ve Jeoinformasyon Dergisi* 108, 69-79.
- Olaya, V., and Conrad, O., 2009, Geomorphometry in SAGA. *Developments in soil science*, 33, 293-308.
- Önal, Y. E., 2018, Gürültüye Karşı Dayanıklı Bir Kenar Tespit Algoritması Geliştirilmesi Yüksek Lisans Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Ana Bilim Dalı.
- Özbalmumcu, M., 2007, Fotogrametrik yöntemle ortofoto harita üretiminin temel esasları, ortofotonun yararları ve kullanım alanları. *TUFUAB IX. Teknik Sempozyumu*, İstanbul, 417-418.
- Özdarıcı Ok, A., ve Ok, A., 2007, Mean Shift Segmentasyon Algoritması Destekli En Büyük Olasılık Sınıflandırma Yöntemi Kullanılarak Tarım Alanlarının Sınıflandırılması TMMOB Harita ve Kadastro Mühendisleri Odası, Ulusal Coğrafi Bilgi Sistemleri Kongresi, Trabzon,
- Park, Y., and Guldman, J. M., 2019, Creating 3D city models with building footprints and LiDAR point cloud classification: A machine learning approach. *Computers, Environment and Urban Systems*, 75, 76-89.
- Peizhuang, W., 1983, Pattern recognition with fuzzy objective function algorithms. *James C. Bezdek. Siam Review*, 253, 442.
- Petrie, G., and Toth, C., 2009, Airborne and Space borne Laser Scanners, Topographic Laser Ranging and Scanning Principles and processing. Taylor and Francis Group, 2985.
- Qidwai, U., and Chen, C. H., 2009, Digital image processing: an algorithmic approach with MATLAB. CRC press, ISBN:1420079514.
- R. C. Gonzalez, R. E. Woods, and B. R. Masters, 2008, Digital Image Processing, third edition., vol. 14, no. 2
- Rahımzadeganasl, A., 2015, An Approach for the Automatic Segmentation of High Resolution Satellite Images into Agricultural Fields. Yüksek Lisans Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Geomatik Mühendisliği Ana Bilim Dalı.

- Ramírez A. J. L., Rubiano F. A., and Jiménez M. R., 2020, Object recognition through artificial intelligence techniques. *Revista Facultad de Ingeniería*, 2954.
- Robb, C., Hardy, A., Doonan, J. H., and Brook, J., 2020, Semi-automated field plot segmentation from UAS imagery for experimental agriculture. *Frontiers in plant Science*, 11, 591886.
- Rottensteiner, F., Trinder, J. C., Clode, S., and Kubik, K., 2003, Building Detection Using LiDAR Data and Multispectral Images. *DICTA*.
- Rydberg, A., and Borgefors, G., 2001, Integrated method for boundary delineation of agricultural fields in multispectral satellite images. *IEEE transactions on geoscience and remote sensing*, 39(11), 2514-2520.
- Saeedi, S., Samadzadegan, F., and El-Sheimy, N., 2009, Object extraction from lidar data using an artificial swarm bee colony clustering algorithm. *CMRT09 IAPRS*, 38, 133-138.
- Sahir, S., 2019, Canny edge detection step by step in python-computer vision. *Towards Data Science*.
- San, D. K., ve Türker, M., 2007, Binaların Yüksek Çözünürlüklü Uydu Görüntülerinden Belirlenebilme Potansiyeli. *Coğrafi Bilgi Sistemleri Kongresi, KTÜ, Trabzon*.
- Sevgen, E., ve Canaz, S., 2016, Elektrik Nakil Hattının Hava LiDAR Verilerinden Çıkarılması. 6. Uzaktan Algılama-CBS Sempozyumu, Adana.
- Sevgen, S. C., 2019, Airborne lidar data classification in complex urban area using random forest: a case study of Bergama, Turkey. *International Journal of Engineering and Geosciences*, 41, 45-51.
- Shackelford, A. K., and Davis, C. H., 2003, A combined fuzzy pixel-based and object-based approach for classification of high-resolution multispectral data over urban areas. *IEEE transactions on geoscience and remote sensing*, 41(10), 2354-2363.
- Shahid, M., Rossholm, A., and Löfström, B., 2011, A reduced complexity no-reference artificial neural network based video quality predictor. *4th International Congress on Image and Signal Processing*.
- Sharifi, A., Mahdipour, H., Moradi, E., and Tariq, A., 2022, Agricultural field extraction with deep learning algorithm and satellite imagery. *Journal of the Indian Society of Remote Sensing*, 1-7.
- Sohn, G., and Dowman, I., 2007, Data fusion of high-resolution satellite imagery and LiDAR data for automatic building extraction. *ISPRS Journal of Photogrammetry and Remote Sensing*, 62(1), 43-63.
- Şeyma, A., ve Şanlı, F. B., 2022, Kıyı Çizgisinin Makine Öğrenmesi Tabanlı Mean-Shift, Rastgele Orman ve Destek Vektör Makinaları ile Belirlenmesi. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 37(3), 835-842.

- Taravat, A., Wagner, M. P., Bonifacio, R., and Petit, D., 2021, Advanced fully convolutional networks for agricultural field boundary detection. *Remote Sensing*, 134, 722.
- Tekin, M., 2018, Uydu görüntülerinden zincir kod yöntemi kullanılarak otomatik yol çıkarımı. Yüksek Lisans Tezi, Yalova Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı.
- Torre, M., and Radeva, P., 2000, Agricultural field extraction from aerial images using a region competition algorithm. *International Archives of Photogrammetry and Remote Sensing*, 33B3/2; Part 3, 889-896.
- Torun, A., ve Düzgün, Ş., 2013, LiDAR nokta bulutundan veri yönelimli teknikle bina çatılarının yatay yüzeylerinin çıkarılması. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği VII. Teknik Sempozyumu, 23-25.
- Treccani, D., and Adami, A., 2023, Single Building Point Cloud Segmentation: Towards Urban Data Modeling and Management. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 48, 511-516.
- Uzar, M., ve Yastikli, N., 2011, LiDAR ve hava fotoğraflarının füzyonu ile otomatik bina çıkarımı. TMMOB Harita ve Kadastro Mühendisleri Odası, 13. Türkiye Harita Bilimsel ve Teknik Kurultayı, Ankara.
- Vosselman, G., Kessels, P., and Gorte, B., 2005, The utilisation of airborne laser scanning for mapping. *International Journal of Applied Earth Observation and Geoinformation*, 63-4, 177-186.
- Wagner, M. P., and Oppelt, N., 2020, Deep learning and adaptive graph-based growing contours for agricultural field extraction. *Remote Sensing*, 1212, 1990.
- Waldner, F., and Diakogiannis, F. I., 2020, Deep learning on edge: Extracting field boundaries from satellite images with a convolutional neural network. *Remote sensing of environment*, 245, 111741.
- Wassie, Y., Koeva, M., Bennett, R., and Lemmen, C., 2018, A procedure for semi-automated cadastral boundary feature extraction from high-resolution satellite imagery. *Journal of spatial science*, 631, 75-92.
- Xia, L., Luo, J., Sun, Y., and Yang, H., 2018, Deep extraction of cropland parcels from very high-resolution remotely sensed imagery. 2018 7th International Conference on Agro-geoinformatics Agro-geoinformatics.
- Yıldız, F., 2022, “Büyük Ölçekli Harita Üretiminde LiDAR ve Ortofoto.” <http://studylibtr.com/doc/1372830/büyük-ölçekli-harita-üretiminde-lidar-ve-ortofoto>, [Ziyaret Tarihi: 10 Temmuz 2022].

- Zhang, H., Liu, M., Wang, Y., Shang, J., Liu, X., Li, B., Song, A., and Li, Q., 2021, Automated delineation of agricultural field boundaries from Sentinel-2 images using recurrent residual U-Net. *International Journal of Applied Earth Observation and Geoinformation*, 105, 102557.
- Zhang, J., Lin, X., and Ning, X., 2013, SVM-based classification of segmented airborne LiDAR point clouds in urban areas. *Remote Sensing*, 58, 3749-3775.
- Zhang, K., Yan, J., and Chen, S. C., 2006, Automatic construction of building footprints from airborne LiDAR data. *IEEE transactions on geoscience and remote sensing*, 44, 2523-2533.
- Zhang, L., and Zhang, L., 2017, Deep learning-based classification and reconstruction of residential scenes from large-scale point clouds. *IEEE transactions on geoscience and remote sensing*, 55, 1887-1897.
- Zhang, W., Li, W., Zhang, C., Hanink, D. M., Li, X., and Wang, W., 2017, Parcel-based urban land use classification in megacity using airborne LiDAR, high resolution orthoimagery, and Google Street View. *Computers, Environment and Urban Systems*, 64, 215-228.

EKLER**Ek-1:**

Canny yöntemine ilişkin algoritma içerisinde yer alan “*Gradient Threshold*” ve “*Operator Scale*” parametreleri için tüm sonuç değerleri.

Test_1							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.9	0.2450	65.2103	-0.1459	0.0196	0.9991	0.0724
	0.4	0.2009	65.2688	-0.0873	0.0193	0.9991	0.0736
	Ortalama	0.2156	65.2505	-0.1057	0.0194	0.9991	0.0728
0.8	0.9	0.3385	65.1307	-0.2254	0.0200	0.9991	0.0803
	0.1	0.2652	65.2189	-0.1372	0.0196	0.9991	0.0728
	Ortalama	0.2766	65.2056	-0.1505	0.0196	0.9991	0.0746
0.7	0.9	0.4077	65.1240	-0.2322	0.0200	0.9991	0.1047
	0.4	0.3322	65.2231	-0.1331	0.0195	0.9991	0.0986
	Ortalama	0.3683	65.1571	-0.1991	0.0198	0.9991	0.0969
0.6	0.9	0.5544	65.0708	-0.2853	0.0202	0.9991	0.1467
	0.1	0.4344	65.1453	-0.2108	0.0199	0.9991	0.1173
	Ortalama	0.4961	65.1143	-0.2418	0.0200	0.9991	0.1320
0.5	0.9	0.6583	64.9823	-0.3738	0.0206	0.9992	0.1766
	0.3	0.5494	65.0550	-0.3012	0.0203	0.9991	0.1368
	Ortalama	0.5943	65.0250	-0.3311	0.0204	0.9991	0.1526
0.4	0.9	0.7578	64.8583	-0.4978	0.0212	0.9992	0.2055
	0.1	0.7063	64.9650	-0.3912	0.0207	0.9992	0.1885
	Ortalama	0.7297	64.9160	-0.4401	0.0210	0.9992	0.1969
0.3	0.9	0.8296	64.7525	-0.6037	0.0218	0.9992	0.2256
	0.1	0.7841	64.8618	-0.4943	0.0212	0.9992	0.2186
	Ortalama	0.8043	64.8275	-0.5286	0.0214	0.9992	0.2240
0.2	0.8	0.8621	64.5758	-0.7804	0.0227	0.9992	0.2282
	0.3	0.8533	64.6334	-0.7227	0.0224	0.9992	0.2290
	Ortalama	0.8574	64.6040	-0.7521	0.0225	0.9992	0.2284
0.1	0.9	0.8700	63.5357	-1.8204	0.0288	0.9991	0.1972
	0.5	0.8898	63.9464	-1.4098	0.0262	0.9992	0.2180
	Ortalama	0.8844	63.8847	-1.4714	0.0267	0.9992	0.2145

Test 2							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.9	0.4056	66.9873	-0.8805	0.0130	0.9994	0.0068
	0.1	0.2460	67.4374	-0.4304	0.0117	0.9994	-0.0001
	Ortalama	0.3315	67.2190	-0.6488	0.0123	0.9994	0.0012
0.8	0.8	0.5464	66.6644	-1.2034	0.0140	0.9993	0.0141
	0.2	0.4176	67.0250	-0.8428	0.0129	0.9994	0.0013
	Ortalama	0.4867	66.8194	-1.0484	0.0135	0.9994	0.0063
0.7	0.9	0.6366	66.5103	-1.3575	0.0145	0.9993	0.0442
	0.1	0.5025	66.7953	-1.0726	0.0136	0.9994	0.0062
	Ortalama	0.5665	66.6430	-1.2249	0.0141	0.9993	0.0198
0.6	0.9	0.7156	66.2187	-1.6492	0.0155	0.9993	0.0545
	0.1	0.6215	66.5366	-1.3313	0.0144	0.9993	0.0236
	Ortalama	0.6630	66.3935	-1.4744	0.0149	0.9993	0.0379
0.5	0.9	0.8039	65.8618	-2.0060	0.0169	0.9993	0.0654
	0.1	0.6890	66.3223	-1.5456	0.0152	0.9993	0.0496
	Ortalama	0.7403	66.1439	-1.7239	0.0158	0.9993	0.0584
0.4	0.7	0.8495	65.7256	-2.1423	0.0174	0.9993	0.0835
	0.3	0.8133	65.9006	-1.9672	0.0167	0.9993	0.0808
	Ortalama	0.8340	65.7897	-2.0782	0.0171	0.9993	0.0815
0.3	0.8	0.9017	65.4121	-2.4558	0.0187	0.9992	0.1009
	0.2	0.9098	65.4141	-2.4537	0.0187	0.9992	0.0952
	Ortalama	0.9071	65.4069	-2.4610	0.0187	0.9992	0.0989
0.2	0.5	0.9320	64.9975	-2.8703	0.0206	0.9992	0.1080
	0.1	0.9272	64.9574	-2.9104	0.0208	0.9992	0.1063
	Ortalama	0.9290	64.9922	-2.8756	0.0206	0.9992	0.1073
0.1	0.7	0.9499	64.4316	-3.4363	0.0234	0.9991	0.1115
	0.5	0.9469	64.3760	-3.4918	0.0237	0.9991	0.1112
	Ortalama	0.9481	64.3320	-3.5359	0.0240	0.9991	0.1124

Test 3							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.9	0.0667	66.5733	-0.0169	0.0143	0.9993	0.0304
	0.3	0.1187	66.1506	-0.4396	0.0158	0.9993	0.0146
	Ortalama	0.0943	66.3506	-0.2395	0.0151	0.9993	0.0204
0.8	0.8	0.1839	66.3284	-0.2618	0.0151	0.9993	0.0309
	0.3	0.2315	65.8075	-0.7827	0.0171	0.9992	0.0171
	Ortalama	0.2099	66.0477	-0.5425	0.0162	0.9993	0.0227
0.7	0.7	0.3314	65.8595	-0.7307	0.0169	0.9992	0.0260
	0.2	0.3511	65.4050	-1.1852	0.0187	0.9991	0.0219
	Ortalama	0.3413	65.6594	-0.9308	0.0177	0.9992	0.0240
0.6	0.9	0.4377	65.7044	-0.8858	0.0175	0.9992	0.0309
	0.4	0.3656	65.2544	-1.3358	0.0194	0.9991	0.0217
	Ortalama	0.3837	65.3643	-1.2259	0.0189	0.9991	0.0251
0.5	0.9	0.6105	65.1270	-1.4631	0.0200	0.9991	0.0487
	0.3	0.4143	65.0231	-1.5671	0.0205	0.9991	0.0277
	Ortalama	0.4915	65.0233	-1.5668	0.0205	0.9991	0.0359
0.4	0.9	0.6676	64.6720	-1.9182	0.0222	0.9990	0.0564
	0.1	0.5643	64.6320	-1.9582	0.0224	0.9990	0.0398
	Ortalama	0.6101	64.6376	-1.9525	0.0224	0.9990	0.0472
0.3	0.9	0.7222	64.2204	-2.3698	0.0246	0.9989	0.0602
	0.1	0.6683	64.3277	-2.2625	0.0240	0.9989	0.0543
	Ortalama	0.6882	64.2754	-2.3148	0.0243	0.9989	0.0572
0.2	0.7	0.7439	63.7172	-2.8729	0.0276	0.9988	0.0703
	0.3	0.7587	63.9785	-2.6117	0.0260	0.9989	0.0682
	Ortalama	0.7524	63.8609	-2.7292	0.0267	0.9989	0.0692
0.1	0.9	0.7585	62.8721	-3.7180	0.0336	0.9986	0.0788
	0.2	0.7914	63.2052	-3.3850	0.0311	0.9988	0.0857
	0.1	0.7786	63.0691	-3.5210	0.0321	0.9987	0.0830

Test 4							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.7	0.1495	63.6866	-0.7503	0.0278	0.9986	0.0073
	0.4	0.1695	63.6819	-0.7549	0.0279	0.9986	0.0120
	Ortalama	0.1581	63.6883	-0.7487	0.0278	0.9986	0.0095
0.8	0.8	0.2220	63.6358	-0.8010	0.0282	0.9986	0.0248
	0.3	0.1971	63.6792	-0.7577	0.0279	0.9986	0.0202
	Ortalama	0.2082	63.6574	-0.7794	0.0280	0.9986	0.0220
0.7	0.6	0.2592	63.6192	-0.8176	0.0283	0.9986	0.0323
	0.3	0.2299	63.6465	-0.7903	0.0281	0.9986	0.0237
	Ortalama	0.2439	63.6318	-0.8050	0.0282	0.9986	0.0279
0.6	0.9	0.2828	63.5965	-0.8404	0.0284	0.9986	0.0350
	0.8	0.2577	63.6200	-0.8169	0.0283	0.9986	0.0317
	Ortalama	0.2660	63.6156	-0.8212	0.0283	0.9986	0.0350
0.5	0.5	0.3862	63.6876	-0.7493	0.0278	0.9986	0.0978
	0.3	0.2683	63.6268	-0.8101	0.0282	0.9986	0.0398
	Ortalama	0.2907	63.6115	-0.8253	0.0283	0.9986	0.0454
0.4	0.9	0.2972	63.5553	-0.8815	0.0287	0.9986	0.0428
	0.4	0.4123	63.6933	-0.7436	0.0278	0.9987	0.1102
	Ortalama	0.3570	63.6195	-0.8173	0.0283	0.9986	0.0776
0.3	0.9	0.6411	63.5210	-0.9159	0.0289	0.9987	0.1678
	0.1	0.4581	63.6100	-0.8268	0.0282	0.9987	0.1164
	Ortalama	0.5530	63.5714	-0.8654	0.0286	0.9987	0.1419
0.2	0.9	0.7574	63.2164	-1.2204	0.0310	0.9988	0.1866
	0.1	0.6877	63.3587	-1.0781	0.0300	0.9987	0.1659
	Ortalama	0.7239	63.3028	-1.1340	0.0304	0.9988	0.1772
0.1	0.9	0.7695	62.3313	-2.1055	0.0380	0.9987	0.1858
	0.4	0.8043	62.6675	-1.7693	0.0352	0.9987	0.1969
	Ortalama	0.7928	62.5551	-1.8818	0.0361	0.9987	0.1933

Test_5							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.9	0.2720	63.0578	-0.6212	0.0322	0.9984	0.0265
	0.3	0.1756	63.1317	-0.5473	0.0316	0.9984	0.0099
	Ortalama	0.2098	63.0974	-0.5816	0.0319	0.9984	0.0140
0.8	0.9	0.4055	62.9073	-0.7717	0.0333	0.9984	0.0485
	0.2	0.3178	63.0094	-0.6696	0.0325	0.9984	0.0292
	Ortalama	0.3578	62.9664	-0.7126	0.0328	0.9984	0.0373
0.7	0.9	0.4207	62.8736	-0.8054	0.0336	0.9984	0.0489
	0.3	0.3799	62.9366	-0.7423	0.0331	0.9984	0.0382
	Ortalama	0.4029	62.9030	-0.7759	0.0333	0.9984	0.0454
0.6	0.7	0.4339	62.8541	-0.8248	0.0337	0.9984	0.0537
	0.3	0.4228	62.8746	-0.8044	0.0335	0.9984	0.0499
	Ortalama	0.4300	62.8550	-0.8240	0.0337	0.9984	0.0514
0.5	0.9	0.4737	62.8049	-0.8740	0.0341	0.9984	0.0552
	0.4	0.4439	62.8351	-0.8439	0.0339	0.9984	0.0585
	Ortalama	0.4599	62.8174	-0.8616	0.0340	0.9984	0.0585
0.4	0.9	0.5614	62.6648	-1.0142	0.0352	0.9984	0.0634
	0.4	0.4829	62.7682	-0.9108	0.0344	0.9984	0.0638
	Ortalama	0.5116	62.7310	-0.9480	0.0347	0.9984	0.0634
0.3	0.9	0.6546	62.5546	-1.1244	0.0361	0.9985	0.0836
	0.3	0.5838	62.6045	-1.0744	0.0357	0.9984	0.0776
	Ortalama	0.6137	62.5778	-1.1012	0.0359	0.9984	0.0797
0.2	0.9	0.7648	62.3944	-1.2845	0.0375	0.9985	0.1250
	0.4	0.7232	62.4304	-1.2485	0.0372	0.9985	0.1131
	Ortalama	0.7418	62.4039	-1.2750	0.0374	0.9985	0.1183
0.1	0.9	0.8051	61.8207	-1.8582	0.0428	0.9984	0.1327
	0.2	0.8233	61.8705	-1.8084	0.0423	0.9984	0.1413
	Ortalama	0.8165	61.8605	-1.8184	0.0424	0.9984	0.1392

Test_6							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.9	0.3460	67.0316	-0.0644	0.0129	0.9993	0.1165
	0.1	0.1486	67.1384	0.0424	0.0126	0.9993	0.1165
	Ortalama	0.2098	67.1223	0.0263	0.0126	0.9993	0.1233
0.8	0.9	0.5855	67.1728	0.0768	0.0125	0.9994	0.2403
	0.1	0.3869	67.1531	0.0571	0.0125	0.9993	0.1624
	Ortalama	0.4453	67.1524	0.0564	0.0125	0.9993	0.1834
0.7	0.9	0.6570	67.1599	0.0638	0.0125	0.9994	0.2617
	0.1	0.4803	67.1417	0.0457	0.0126	0.9993	0.1870
	Ortalama	0.5625	67.1434	0.0474	0.0126	0.9994	0.2144
0.6	0.9	0.8445	67.0002	-0.0958	0.0130	0.9994	0.2743
	0.1	0.6540	67.0462	-0.0498	0.0128	0.9994	0.1960
	Ortalama	0.7512	67.0444	-0.0516	0.0128	0.9994	0.2406
0.5	0.8	0.9154	66.8892	-0.2068	0.0133	0.9995	0.2910
	0.4	0.8557	66.9790	-0.1170	0.0130	0.9995	0.2707
	Ortalama	0.8826	66.9696	-0.1264	0.0131	0.9995	0.2845
0.4	0.8	0.9896	66.5866	-0.5094	0.0143	0.9995	0.3049
	0.1	0.9609	66.7423	-0.3537	0.0138	0.9995	0.2997
	Ortalama	0.9763	66.6729	-0.4231	0.0140	0.9995	0.3039
0.3	0.9	0.9611	66.1371	-0.9589	0.0158	0.9995	0.2936
	0.3	0.9844	66.3645	-0.7315	0.0150	0.9995	0.3145
	Ortalama	0.9776	66.3022	-0.7938	0.0152	0.9995	0.3125
0.2	0.9	0.7714	64.3236	-2.7724	0.0240	0.9991	0.2318
	0.1	0.8888	65.3406	-1.7555	0.0190	0.9994	0.2845
	Ortalama	0.8386	64.9414	-2.1547	0.0209	0.9993	0.2658
0.1	0.9	0.4951	61.3325	-5.7635	0.0478	0.9979	0.1487
	0.2	0.5445	61.5051	-5.5909	0.0460	0.9980	0.1654
	Ortalama	0.5222	61.4023	-5.6937	0.0471	0.9979	0.1594

Test 7							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.8	0.3279	68.5316	-0.2169	0.0091	0.9995	0.0449
	0.4	0.3152	68.5598	-0.1886	0.0091	0.9995	0.0478
	Ortalama	0.3179	68.5546	-0.1939	0.0091	0.9995	0.0469
0.8	0.9	0.5757	68.3690	-0.3795	0.0095	0.9995	0.0483
	0.1	0.3628	68.5411	-0.2074	0.0091	0.9995	0.0519
	Ortalama	0.4381	68.4755	-0.2730	0.0092	0.9995	0.0511
0.7	0.7	0.6659	68.2246	-0.5238	0.0098	0.9995	0.0573
	0.1	0.5414	68.4136	-0.3349	0.0094	0.9995	0.0536
	Ortalama	0.5985	68.3274	-0.4211	0.0096	0.9995	0.0564
0.6	0.8	0.7666	67.9345	-0.8140	0.0105	0.9995	0.0642
	0.1	0.6133	68.2712	-0.4773	0.0097	0.9995	0.0558
	Ortalama	0.6769	68.1310	-0.6174	0.0100	0.9995	0.0605
0.5	0.9	0.8495	67.6180	-1.1305	0.0113	0.9995	0.0714
	0.1	0.7738	67.9659	-0.7825	0.0104	0.9995	0.0603
	Ortalama	0.8120	67.8159	-0.9326	0.0108	0.9995	0.0647
0.4	0.9	0.8204	67.1982	-1.5502	0.0124	0.9995	0.0841
	0.6	0.8473	67.4448	-1.3037	0.0117	0.9995	0.0733
	Ortalama	0.8378	67.4864	-1.2621	0.0116	0.9995	0.0766
0.3	0.9	0.7556	66.4830	-2.2654	0.0146	0.9994	0.0861
	0.1	0.8317	67.1968	-1.5516	0.0124	0.9995	0.0848
	Ortalama	0.8042	66.9199	-1.8286	0.0132	0.9995	0.0873
0.2	0.9	0.6502	65.0796	-3.6689	0.0202	0.9992	0.0822
	0.1	0.7428	65.9444	-2.8040	0.0165	0.9994	0.0963
	Ortalama	0.7047	65.5868	-3.1617	0.0180	0.9993	0.0908
0.1	0.9	0.5206	63.1869	-5.5616	0.0312	0.9987	0.0787
	0.3	0.5295	63.1964	-5.5521	0.0311	0.9986	0.0813
	Ortalama	0.5255	63.1753	-5.5732	0.0313	0.9986	0.0803

Test 8							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.8	0.5608	65.4379	-0.1758	0.0186	0.9990	0.1120
	0.1	0.0303	65.6187	0.0050	0.0178	0.9989	0.0343
	Ortalama	0.3181	65.5173	-0.0964	0.0183	0.9990	0.0792
0.8	0.8	0.6939	65.5424	-0.0713	0.0181	0.9991	0.1835
	0.1	0.4310	65.4581	-0.1556	0.0185	0.9990	0.0791
	Ortalama	0.5866	65.4940	-0.1197	0.0184	0.9991	0.1369
0.7	0.8	0.6939	65.5450	-0.0687	0.0181	0.9991	0.1851
	0.1	0.5630	65.4345	-0.1792	0.0186	0.9990	0.1093
	Ortalama	0.6522	65.5084	-0.1053	0.0183	0.9991	0.1599
0.6	0.8	0.8020	65.3982	-0.2155	0.0188	0.9991	0.2047
	0.1	0.6936	65.5392	-0.0745	0.0182	0.9991	0.1807
	Ortalama	0.7411	65.4664	-0.1473	0.0185	0.9991	0.1890
0.5	0.9	0.8819	65.2983	-0.3154	0.0192	0.9992	0.2378
	0.1	0.7520	65.4292	-0.1845	0.0186	0.9991	0.1806
	Ortalama	0.8349	65.3707	-0.2430	0.0189	0.9992	0.2212
0.4	0.7	0.9365	65.2285	-0.3852	0.0195	0.9992	0.2652
	0.3	0.8731	65.3850	-0.2287	0.0188	0.9992	0.2378
	Ortalama	0.9070	65.2742	-0.3395	0.0193	0.9992	0.2507
0.3	0.7	0.9486	64.9965	-0.6172	0.0206	0.9993	0.2799
	0.4	0.9367	65.1050	-0.5087	0.0201	0.9992	0.2733
	Ortalama	0.9434	65.0787	-0.5350	0.0202	0.9993	0.2770
0.2	0.7	0.9607	64.5565	-1.0572	0.0228	0.9993	0.2737
	0.1	0.9480	64.9178	-0.6959	0.0210	0.9993	0.2780
	Ortalama	0.9556	64.7074	-0.9063	0.0220	0.9993	0.2758
0.1	0.9	0.8754	63.1880	-2.4257	0.0312	0.9989	0.2272
	0.3	0.9313	63.8280	-1.7857	0.0269	0.9991	0.2513
	Ortalama	0.9064	63.5558	-2.0579	0.0287	0.9990	0.2421

Test 9							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.9	0.4450	64.7496	-0.4479	0.0218	0.9990	0.0409
	0.1	0.1530	65.0569	-0.1405	0.0203	0.9990	0.0326
	Ortalama	0.2207	64.9866	-0.2108	0.0206	0.9990	0.0396
0.8	0.8	0.6839	64.3741	-0.8234	0.0238	0.9990	0.0453
	0.1	0.3224	64.8952	-0.3023	0.0211	0.9990	0.0394
	Ortalama	0.4920	64.6592	-0.5382	0.0223	0.9990	0.0407
0.7	0.7	0.6875	64.3316	-0.8659	0.0240	0.9990	0.0445
	0.1	0.6133	64.4770	-0.7205	0.0232	0.9990	0.0354
	Ortalama	0.6517	64.3891	-0.8083	0.0237	0.9990	0.0395
0.6	0.9	0.7266	63.9870	-1.2105	0.0260	0.9990	0.0364
	0.8	0.7102	64.0621	-1.1354	0.0255	0.9990	0.0384
	Ortalama	0.7192	64.1683	-1.0291	0.0249	0.9990	0.0409
0.5	0.6	0.7302	63.9319	-1.2656	0.0263	0.9990	0.0372
	0.3	0.7146	64.0294	-1.1681	0.0257	0.9990	0.0395
	Ortalama	0.7244	63.9408	-1.2567	0.0262	0.9990	0.0377
0.4	0.9	0.7359	63.4424	-1.7550	0.0294	0.9988	0.0340
	0.5	0.7222	63.6558	-1.5417	0.0280	0.9989	0.0359
	Ortalama	0.7305	63.6264	-1.5711	0.0282	0.9989	0.0357
0.3	0.6	0.8086	63.1766	-2.0208	0.0313	0.9988	0.0610
	0.2	0.7918	63.3136	-1.8839	0.0303	0.9988	0.0531
	Ortalama	0.7982	63.1845	-2.0130	0.0312	0.9988	0.0575
0.2	0.5	0.8319	62.5828	-2.6147	0.0359	0.9987	0.0875
	0.3	0.8202	62.6305	-2.5670	0.0355	0.9987	0.0820
	Ortalama	0.8260	62.5865	-2.6110	0.0359	0.9987	0.0869
0.1	0.9	0.7462	61.1547	-4.0428	0.0498	0.9981	0.0847
	0.1	0.7729	0.7729	61.1735	0.0496	0.9981	0.0971
	Ortalama	0.7600	54.4439	3.2018	0.0498	0.9981	0.0915

Test_10							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.9	0.3322	63.3280	-0.1978	0.0302	0.9985	0.1241
	0.1	0.0431	63.5276	0.0017	0.0289	0.9984	0.0532
	Ortalama	0.1113	63.4629	-0.0630	0.0293	0.9984	0.0645
0.8	0.9	0.3565	63.3157	-0.2101	0.0303	0.9985	0.1307
	0.1	0.1958	63.3445	-0.1813	0.0301	0.9984	0.0673
	Ortalama	0.2531	63.3326	-0.1932	0.0302	0.9984	0.0885
0.7	0.9	0.5817	63.0709	-0.4550	0.0321	0.9986	0.1805
	0.1	0.2030	63.3379	-0.1879	0.0302	0.9984	0.0685
	Ortalama	0.3295	63.2676	-0.2582	0.0307	0.9985	0.1068
0.6	0.9	0.6588	63.0569	-0.4689	0.0322	0.9987	0.2164
	0.1	0.4451	63.2409	-0.2850	0.0308	0.9986	0.1512
	Ortalama	0.5419	63.1816	-0.3443	0.0312	0.9986	0.1867
0.5	0.7	0.6726	63.0415	-0.4844	0.0323	0.9987	0.2200
	0.3	0.5132	63.2168	-0.3091	0.0310	0.9986	0.1816
	Ortalama	0.6172	63.0903	-0.4356	0.0319	0.9987	0.2053
0.4	0.8	0.7082	62.4216	-1.1042	0.0372	0.9985	0.1999
	0.3	0.6775	62.9447	-0.5811	0.0330	0.9987	0.2114
	Ortalama	0.6855	62.7311	-0.7948	0.0347	0.9986	0.2083
0.3	0.9	0.6970	60.9944	-2.5314	0.0517	0.9980	0.1692
	0.6	0.7202	61.4449	-2.0810	0.0466	0.9982	0.1849
	Ortalama	0.7064	61.6907	-1.8351	0.0443	0.9983	0.1839
0.2	0.6	0.6417	59.9791	-3.5467	0.0653	0.9974	0.1446
	0.3	0.6572	60.2261	-3.2997	0.0617	0.9975	0.1533
	Ortalama	0.6509	60.0949	-3.4310	0.0636	0.9974	0.1483
0.1	0.6	0.5360	58.2393	-5.2865	0.0975	0.9957	0.1097
	0.2	0.5449	58.1229	-5.4030	0.1002	0.9955	0.1122
	Ortalama	0.5420	58.2293	-5.2966	0.0978	0.9957	0.1108

Sobel, Prewitt ve Roberts kenar bulma operatörlerine ait sonuç değerleri;

Test_1							
		F-Skor	YSGO	SGO	OKH	YBİÖ	KK
Sobel	Yatay	0.8759	64.4810	-0.8751	0.0232	0.9992	0.1664
	Düşey	0.8673	64.7337	-0.6224	0.0219	0.9992	0.2132
	İki Yönlü	0.8830	64.6055	-0.7506	0.0225	0.9992	0.2160
Prewitt	Yatay	0.8677	64.4342	-0.9220	0.0234	0.9992	0.1475
	Düşey	0.8601	64.7161	-0.6400	0.0220	0.9992	0.2014
	İki Yönlü	0.8828	64.6146	-0.7416	0.0225	0.9992	0.2164
Roberts	Yatay	0.8837	64.6010	-0.7551	0.0225	0.9992	0.2370
	Düşey	0.8876	64.5078	-0.8483	0.0230	0.9992	0.2240
	İki Yönlü	0.8798	64.5448	-0.8113	0.0228	0.9992	0.2447

		Test_2					
		F-Skor	YSGO	SGO	OKH	YBiÖ	KK
Sobel	Yatay	0.8517	65.7636	-2.1042	0.0172	0.9992	0.0298
	Düşey	0.9407	65.3573	-2.5106	0.0189	0.9993	0.1167
	İki Yönlü	0.9448	65.1175	-2.7503	0.0200	0.9992	0.1046
Prewitt	Yatay	0.8221	65.7927	-2.0751	0.0171	0.9992	0.0250
	Düşey	0.9366	65.4003	-2.4676	0.0188	0.9993	0.1170
	İki Yönlü	0.9445	65.1290	-2.7389	0.0200	0.9992	0.1044
Roberts	Yatay	0.9427	64.7787	-3.0891	0.0216	0.9991	0.1179
	Düşey	0.9487	64.7052	-3.1627	0.0220	0.9991	0.1148
	İki Yönlü	0.9432	64.7455	-3.1223	0.0218	0.9991	0.1164

		Test_3					
		F-Skor	YSGO	SGO	OKH	YBiÖ	KK
Sobel	Yatay	0.6936	63.9908	-2.5994	0.0259	0.9988	0.0464
	Düşey	0.7203	64.1295	-2.4607	0.0251	0.9989	0.0624
	İki Yönlü	0.7313	63.9815	-2.6087	0.0260	0.9989	0.0611
Prewitt	Yatay	0.6806	63.9466	-2.6436	0.0262	0.9988	0.0470
	Düşey	0.7138	64.0970	-2.4931	0.0253	0.9989	0.0631
	İki Yönlü	0.7158	63.7824	-2.8078	0.0272	0.9988	0.0604
Roberts	Yatay	0.7171	64.4457	-2.1445	0.0234	0.9990	0.0552
	Düşey	0.7193	64.4911	-2.0991	0.0231	0.9990	0.0577
	İki Yönlü	0.7267	64.5714	-2.0188	0.0227	0.9990	0.0565

		Test_4					
		F-Skor	YSGO	SGO	OKH	YBiÖ	KK
Sobel	Yatay	0.6161	63.8158	-0.6210	0.0270	0.9988	0.1321
	Düşey	0.6316	63.5815	-0.8553	0.0285	0.9987	0.1286
	İki Yönlü	0.6714	63.5053	-0.9315	0.0290	0.9987	0.1470
Prewitt	Yatay	0.5374	63.8110	-0.6258	0.0270	0.9987	0.1278
	Düşey	0.6242	63.5774	-0.8594	0.0285	0.9987	0.1254
	İki Yönlü	0.6666	63.5146	-0.9223	0.0289	0.9987	0.1468
Roberts	Yatay	0.6725	63.5503	-0.8865	0.0287	0.9987	0.1503
	Düşey	0.5851	63.5724	-0.8645	0.0286	0.9987	0.1126
	İki Yönlü	0.6210	63.5630	-0.8738	0.0286	0.9987	0.1392

Test_5							
		F-Skor	YSGO	SGO	OKH	YBiÖ	KK
Sobel	Yatay	0.7279	62.8744	-0.8045	0.0335	0.9985	0.1004
	Düşey	0.6819	62.8405	-0.8385	0.0338	0.9985	0.0796
	İki Yönlü	0.6713	62.6810	-0.9980	0.0351	0.9985	0.0792
Prewitt	Yatay	0.7133	62.8831	-0.7959	0.0335	0.9985	0.0985
	Düşey	0.6745	62.8411	-0.8378	0.0338	0.9985	0.0764
	İki Yönlü	0.6654	62.6837	-0.9952	0.0351	0.9985	0.0777
Roberts	Yatay	0.6387	62.7273	-0.9517	0.0347	0.9984	0.0809
	Düşey	0.7240	62.6156	-1.0634	0.0356	0.9985	0.0795
	İki Yönlü	0.6617	62.6746	-1.0043	0.0351	0.9984	0.0816

Test_6							
		F-Skor	YSGO	SGO	OKH	YBiÖ	KK
Sobel	Yatay	0.7267	64.1859	-2.9101	0.0248	0.9991	0.1993
	Düşey	0.7267	64.1838	-2.9122	0.0248	0.9992	0.1953
	İki Yönlü	0.7522	64.5110	-2.5850	0.0230	0.9992	0.2065
Prewitt	Yatay	0.7256	64.1507	-2.9453	0.0250	0.9991	0.1866
	Düşey	0.7405	64.2464	-2.8496	0.0245	0.9992	0.1863
	İki Yönlü	0.7580	64.5710	-2.5250	0.0227	0.9993	0.2042
Roberts	Yatay	0.7997	64.1225	-2.9735	0.0252	0.9991	0.2202
	Düşey	0.7425	63.8096	-3.2864	0.0270	0.9991	0.1679
	İki Yönlü	0.8169	64.3373	-2.7587	0.0240	0.9992	0.2264

Test_7							
		F-Skor	YSGO	SGO	OKH	YBiÖ	KK
Sobel	Yatay	0.5724	64.7678	-3.9807	0.0217	0.9992	0.0701
	Düşey	0.5947	64.8918	-3.8567	0.0211	0.9992	0.0728
	İki Yönlü	0.5885	65.0169	-3.7316	0.0205	0.9992	0.0721
Prewitt	Yatay	0.5703	64.7882	-3.9602	0.0216	0.9992	0.0703
	Düşey	0.5947	64.9049	-3.8436	0.0210	0.9992	0.0731
	İki Yönlü	0.5880	65.0612	-3.6872	0.0203	0.9992	0.0707
Roberts	Yatay	0.5747	64.1847	-4.5638	0.0248	0.9989	0.0799
	Düşey	0.6609	64.7487	-3.9997	0.0218	0.9991	0.1020
	İki Yönlü	0.6427	64.5186	-4.2299	0.0230	0.9991	0.0938

		Test_8					
		F-Skor	YSGO	SGO	OKH	YBiÖ	KK
Sobel	Yatay	0.9497	64.7451	-0.8686	0.0218	0.9993	0.2308
	Düşey	0.9479	64.7193	-0.8944	0.0219	0.9992	0.2124
	İki Yönlü	0.9507	64.7784	-0.8353	0.0216	0.9993	0.2141
Prewitt	Yatay	0.9503	64.8177	-0.7960	0.0214	0.9992	0.2386
	Düşey	0.9472	64.7170	-0.8967	0.0219	0.9992	0.2116
	İki Yönlü	0.9504	64.7903	-0.8234	0.0216	0.9992	0.2142
Roberts	Yatay	0.9647	65.0869	-0.5268	0.0202	0.9992	0.2618
	Düşey	0.9319	64.2060	-1.4077	0.0247	0.9991	0.1424
	İki Yönlü	0.9582	64.4703	-1.1434	0.0232	0.9993	0.2545

		Test_9					
		F-Skor	YSGO	SGO	OKH	YBiÖ	KK
Sobel	Yatay	0.7949	63.0049	-2.1926	0.0326	0.9988	0.0619
	Düşey	0.8052	63.4561	-1.7413	0.0293	0.9989	0.0792
	İki Yönlü	0.8294	63.1269	-2.0706	0.0317	0.9989	0.0650
Prewitt	Yatay	0.7796	63.0120	-2.1855	0.0325	0.9988	0.0587
	Düşey	0.7962	63.5598	-1.6377	0.0286	0.9989	0.0797
	İki Yönlü	0.8238	63.1549	-2.0425	0.0314	0.9989	0.0631
Roberts	Yatay	0.8565	62.9154	-2.2821	0.0332	0.9988	0.1037
	Düşey	0.7779	63.2773	-1.9202	0.0306	0.9988	0.0860
	İki Yönlü	0.8295	63.0935	-2.1039	0.0319	0.9988	0.0916

		Test_10					
		F-Skor	YSGO	SGO	OKH	YBiÖ	KK
Sobel	Yatay	0.6669	61.4749	-2.0510	0.0463	0.9983	0.1388
	Düşey	0.6697	61.2616	-2.2642	0.0486	0.9982	0.1320
	İki Yönlü	0.6854	61.5897	-1.9362	0.0451	0.9984	0.1447
Prewitt	Yatay	0.6685	61.4888	-2.0370	0.0462	0.9983	0.1386
	Düşey	0.6770	61.3338	-2.1921	0.0478	0.9982	0.1340
	İki Yönlü	0.6859	61.6146	-1.9113	0.0448	0.9984	0.1436
Roberts	Yatay	0.6804	61.6279	-1.8980	0.0447	0.9983	0.1415
	Düşey	0.6552	61.2647	-2.2612	0.0486	0.9981	0.1484
	İki Yönlü	0.7190	61.6173	-1.9085	0.0448	0.9983	0.1865

Ek-2:

K-Ortalamlar yöntemine ilişkin; Canny algoritması “*Gradient Threshold*” ve “*Operator Scale*” parametreleri ile kümeleme algoritması “k” parametresi için tüm sonuç değerleri.

Test_1, K-Ortalamlar (k = 2)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.7	0.5	0.7192	63.6817	-1.6744	0.0279	0.9989	0.1825
0.1	0.5	0.7180	63.6737	-1.6824	0.0279	0.9989	0.1821
	Ortalama	0.7184	63.6783	-1.6778	0.0279	0.9989	0.1823

Test_1, K-Ortalamlar (k = 3)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.8	0.5	0.7932	64.3761	-0.9800	0.0237	0.9991	0.1743
0.5	0.5	0.7707	64.2197	-1.1365	0.0246	0.9991	0.1817
	Ortalama	0.7821	64.3044	-1.0518	0.0241	0.9991	0.1783

Test_1, K-Ortalamlar (k = 4)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.7	0.5	0.7939	64.3796	-0.9765	0.0237	0.9991	0.1677
0.2	0.5	0.6726	62.6875	-2.6687	0.0350	0.9987	0.1487
	Ortalama	0.7555	63.7387	-1.6174	0.0286	0.9989	0.1619

Test_1, K-Ortalamlar (k = 5)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.2	0.5	0.8029	63.4565	-1.8996	0.0293	0.9989	0.1464
0.1	0.5	0.6938	61.5525	-3.8036	0.0455	0.9983	0.1280
	Ortalama	0.7754	64.0230	-1.3331	0.0264	0.9990	0.1592

Test_1, K-Ortalamlar (k = 6)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.6326	64.9841	-0.3720	0.0206	0.9992	0.1626
0.5	0.5	0.8297	64.4001	-0.9560	0.0236	0.9992	0.1953
	Ortalama	0.7437	63.9550	-1.4011	0.0273	0.9990	0.1724

Test_1, K-Ortalamlar (k = 7)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.6372	65.0071	-0.3490	0.0205	0.9992	0.1748
0.5	0.5	0.8283	64.3735	-0.9826	0.0238	0.9992	0.1941
	Ortalama	0.7478	63.9281	-1.4280	0.0273	0.9990	0.1730

Test_1, K-Ortalamalar (k = 8)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.3459	65.1819	-0.1743	0.0197	0.9991	0.0963
0.4	0.5	0.8077	64.0695	-1.2866	0.0255	0.9991	0.1972
	Ortalama	0.6391	63.8873	-1.4689	0.0283	0.9989	0.1533

Test_1, K-Ortalamalar (k = 9)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.3381	65.2369	-0.1192	0.0195	0.9991	0.1005
0.4	0.5	0.8145	64.3542	-1.0019	0.0239	0.9991	0.1932
	Ortalama	0.6472	64.1083	-1.2478	0.0267	0.9990	0.1567

Test_1, K-Ortalamalar (k=10)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.4049	65.1538	-0.2023	0.0198	0.9991	0.1052
0.4	0.5	0.7986	64.2416	-1.1145	0.0245	0.9991	0.1902
	Ortalama	0.6505	63.9361	-1.4200	0.0277	0.9989	0.1525

Test_2, K-Ortalamalar (k = 2)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.7008	65.9963	-1.8715	0.0163	0.9993	0.0678
0.2	0.5	0.7045	65.9890	-1.8789	0.0164	0.9993	0.0679
	Ortalama	0.7028	65.9945	-1.8733	0.0163	0.9993	0.0683

Test_2, K-Ortalamalar (k = 3)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.6650	65.8508	-2.0170	0.0169	0.9992	0.0281
0.1	0.5	0.9330	64.5742	-3.2937	0.0227	0.9990	0.1040
	Ortalama	0.8323	65.3999	-2.4679	0.0188	0.9992	0.0651

Test_2, K-Ortalamalar (k = 4)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.6256	66.1733	-1.6946	0.0157	0.9993	0.0077
0.1	0.5	0.9172	63.8985	-3.9694	0.0265	0.9989	0.1306
	Ortalama	0.7189	65.7114	-2.1565	0.0178	0.9992	0.0424

Test_2, K-Ortalamalar (k = 5)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.6214	66.1955	-1.6723	0.0156	0.9993	0.0063
0.1	0.5	0.9132	63.9981	-3.8698	0.0259	0.9989	0.1126
	Ortalama	0.7115	65.7416	-2.1262	0.0176	0.9992	0.0321

Test_2, K-Ortalamlar (k = 6)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.5	0.6117	66.2242	-1.6437	0.0155	0.9993	0.0056
0.1	0.5	0.9118	64.0792	-3.7887	0.0254	0.9989	0.1159
	Ortalama	0.7173	65.6835	-2.1843	0.0179	0.9992	0.0369

Test_2, K-Ortalamlar (k = 7)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.5	0.4733	66.7434	-1.1244	0.0138	0.9994	0.0028
0.1	0.5	0.9046	64.1406	-3.7272	0.0251	0.9990	0.1099
	Ortalama	0.7089	65.7690	-2.0988	0.0176	0.9992	0.0359

Test_2, K-Ortalamlar (k = 8)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.5	0.6138	66.2055	-1.6624	0.0156	0.9993	0.0071
0.2	0.5	0.9237	64.7119	-3.1560	0.0220	0.9991	0.0862
	Ortalama	0.7545	65.6825	-2.1853	0.0178	0.9992	0.0422

Test_2, K-Ortalamlar (k = 9)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.5	0.6179	66.2352	-1.6327	0.0155	0.9993	0.0060
0.2	0.5	0.9427	64.5702	-3.2976	0.0227	0.9991	0.1112
	Ortalama	0.7356	65.6735	-2.1944	0.0180	0.9992	0.0393

Test_2, K-Ortalamlar (k = 10)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.5	0.6151	66.2249	-1.6429	0.0155	0.9993	0.0057
0.2	0.5	0.8910	64.1451	-3.7227	0.0250	0.9990	0.1088
	Ortalama	0.7121	65.6722	-2.1956	0.0180	0.9992	0.0359

Test_3, K-Ortalamlar (k = 2)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.5	0.6749	63.8974	-2.6927	0.0265	0.9989	0.0575
0.1	0.5	0.6652	63.7822	-2.8080	0.0272	0.9988	0.0561
	Ortalama	0.6701	63.8367	-2.7534	0.0269	0.9989	0.0568

Test_3, K-Ortalamlar (k = 3)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.5	0.7386	63.8515	-2.7386	0.0268	0.9989	0.0684
0.2	0.5	0.6815	62.8450	-3.7451	0.0338	0.9985	0.0621
	Ortalama	0.7008	63.1364	-3.4538	0.0317	0.9986	0.0638

Test_3, K-Ortalamalar (k = 4)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.1425	66.3262	-0.2640	0.0152	0.9993	0.0095
0.7	0.5	0.7530	64.0288	-2.5614	0.0257	0.9989	0.0641
	Ortalama	0.6301	63.3345	-3.2557	0.0320	0.9986	0.0558

Test_3, K-Ortalamalar (k = 5)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.1909	66.4795	-0.1107	0.0146	0.9993	0.0442
0.5	0.5	0.7080	63.3705	-3.2196	0.0299	0.9987	0.0646
	Ortalama	0.5743	63.4339	-3.1563	0.0324	0.9986	0.0557

Test_3, K-Ortalamalar (k = 6)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.3280	66.2332	-0.3570	0.0155	0.9993	0.0391
0.4	0.5	0.7291	62.7026	-3.8876	0.0349	0.9985	0.0706
	Ortalama	0.5649	63.5008	-3.0894	0.0325	0.9986	0.0517

Test_3, K-Ortalamalar (k = 7)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.0038	66.5840	-0.0062	0.0143	0.9993	0.0007
0.4	0.5	0.7637	63.0559	-3.5343	0.0322	0.9987	0.0764
	Ortalama	0.5101	63.7800	-2.8102	0.0311	0.9986	0.0485

Test_3, K-Ortalamalar (k = 8)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.1729	66.2141	-0.3761	0.0155	0.9993	0.0243
0.3	0.5	0.7413	62.7987	-3.7914	0.0341	0.9986	0.0712
	Ortalama	0.5024	63.9076	-2.6826	0.0300	0.9987	0.0452

Test_3, K-Ortalamalar (k = 9)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.3521	65.9632	-0.6269	0.0165	0.9993	0.0308
0.3	0.5	0.7828	62.7335	-3.8567	0.0347	0.9985	0.0749
	Ortalama	0.5703	63.6133	-2.9768	0.0325	0.9986	0.0498

Test_3, K-Ortalamalar (k = 10)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.1939	66.2035	-0.3867	0.0156	0.9993	0.0248
0.3	0.5	0.7140	63.2472	-3.3430	0.0308	0.9987	0.0618
	Ortalama	0.5143	63.9525	-2.6377	0.0304	0.9987	0.0451

Test_4, K-Ortalamalar (k = 2)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.5363	62.7644	-1.6724	0.0344	0.9984	0.0825
0.2	0.5	0.5405	62.7578	-1.6790	0.0345	0.9984	0.0837
	Ortalama	0.5392	62.7598	-1.6770	0.0344	0.9984	0.0833

Test_4, K-Ortalamalar (k = 3)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.5258	63.0479	-1.3889	0.0322	0.9984	0.0999
0.1	0.5	0.5762	60.9578	-3.4791	0.0522	0.9978	0.1285
	Ortalama	0.5447	62.5213	-1.9155	0.0372	0.9983	0.1112

Test_4, K-Ortalamalar (k = 4)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.4689	63.0922	-1.3446	0.0319	0.9984	0.0666
0.1	0.5	0.5754	61.1145	-3.3224	0.0503	0.9978	0.1043
	Ortalama	0.4940	62.6520	-1.7848	0.0360	0.9983	0.0754

Test_4, K-Ortalamalar (k = 5)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.2199	63.3498	-1.0870	0.0301	0.9984	0.0154
0.1	0.5	0.5717	59.8586	-4.5783	0.0672	0.9973	0.1166
	Ortalama	0.3166	62.7749	-1.6620	0.0356	0.9983	0.0394

Test_4, K-Ortalamalar (k = 6)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.2125	63.3557	-1.0811	0.0300	0.9984	0.0112
0.2	0.5	0.5816	61.4417	-2.9952	0.0467	0.9980	0.0914
	Ortalama	0.3320	62.6943	-1.7425	0.0366	0.9982	0.0396

Test_4, K-Ortalamalar (k = 7)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.4965	63.2189	-1.2180	0.0310	0.9985	0.0826
0.2	0.5	0.6590	62.4182	-2.0187	0.0373	0.9984	0.1439
	Ortalama	0.5325	62.7046	-1.7323	0.0365	0.9983	0.0968

Test_4, K-Ortalamalar (k = 8)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.2025	63.4459	-0.9910	0.0294	0.9985	0.0107
0.2	0.5	0.7063	62.7207	-1.7161	0.0348	0.9986	0.1450
	Ortalama	0.3438	62.9202	-1.5166	0.0344	0.9984	0.0487

Test_4, K-Ortalamlar (k = 9)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.2000	63.4761	-0.9608	0.0292	0.9985	0.0113
0.2	0.5	0.6974	62.7531	-1.6838	0.0345	0.9986	0.1412
	Ortalama	0.3499	62.9501	-1.4868	0.0341	0.9984	0.0499

Test_4, K-Ortalamlar (k = 10)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.1999	63.4256	-1.0113	0.0295	0.9984	0.0103
0.2	0.5	0.7027	62.7716	-1.6652	0.0343	0.9986	0.1472
	Ortalama	0.3511	62.9607	-1.4761	0.0338	0.9984	0.0498

Test_5, K-Ortalamlar (k = 2)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.7234	61.9502	-1.7288	0.0415	0.9982	0.1080
0.6	0.5	0.7273	61.9217	-1.7572	0.0418	0.9982	0.1091
	Ortalama	0.7259	61.9458	-1.7332	0.0416	0.9982	0.1088

Test_5, K-Ortalamlar (k = 3)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.5875	62.4922	-1.1868	0.0366	0.9983	0.0671
0.2	0.5	0.5947	62.4825	-1.1964	0.0367	0.9983	0.0672
	Ortalama	0.5914	62.4863	-1.1926	0.0367	0.9983	0.0672

Test_5, K-Ortalamlar (k = 4)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.4143	62.6633	-1.0157	0.0352	0.9983	0.0336
0.1	0.5	0.7397	61.5693	-2.1096	0.0453	0.9982	0.0908
	Ortalama	0.4946	62.4975	-1.1815	0.0367	0.9983	0.0435

Test_5, K-Ortalamlar (k = 5)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.4909	62.6122	-1.0668	0.0356	0.9983	0.0531
0.2	0.5	0.5940	62.3408	-1.3381	0.0379	0.9983	0.0818
	Ortalama	0.5162	62.4991	-1.1798	0.0366	0.9983	0.0592

Test_5, K-Ortalamlar (k = 6)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.4132	62.6899	-0.9891	0.0350	0.9983	0.0347
0.1	0.5	0.7104	60.9815	-2.6975	0.0519	0.9980	0.0983
	Ortalama	0.5164	62.4014	-1.2775	0.0377	0.9983	0.0498

Test_5, K-Ortalamalar (k = 7)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.4039	62.7327	-0.9462	0.0347	0.9983	0.0321
0.2	0.5	0.7734	61.6840	-1.9949	0.0441	0.9983	0.1045
	Ortalama	0.5194	62.3960	-1.2829	0.0377	0.9983	0.0516

Test_5, K-Ortalamalar (k = 8)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.4114	62.7273	-0.9517	0.0347	0.9983	0.0347
0.1	0.5	0.7305	61.0421	-2.6369	0.0512	0.9980	0.0991
	Ortalama	0.5080	62.4484	-1.2306	0.0373	0.9983	0.0510

Test_5, K-Ortalamalar (k = 9)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.4022	62.7353	-0.9436	0.0346	0.9983	0.0305
0.2	0.5	0.7473	62.0953	-1.5836	0.0401	0.9984	0.1046
	Ortalama	0.5292	62.4474	-1.2315	0.0372	0.9983	0.0553

Test_5, K-Ortalamalar (k = 10)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.4058	62.7475	-0.9314	0.0345	0.9983	0.0341
0.1	0.5	0.7807	61.3762	-2.3028	0.0474	0.9982	0.1092
	Ortalama	0.5330	62.4219	-1.2570	0.0375	0.9983	0.0540

Test_6, K-Ortalamalar (k = 2)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.5021	64.5735	-2.5226	0.0227	0.9990	0.1107
0.3	0.5	0.5059	64.5596	-2.5364	0.0228	0.9990	0.1120
	Ortalama	0.5050	64.5614	-2.5346	0.0228	0.9990	0.1115

Test_6, K-Ortalamalar (k = 3)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.6658	64.9425	-2.1535	0.0208	0.9992	0.1625
0.1	0.5	0.7005	64.8727	-2.2233	0.0212	0.9992	0.1876
	Ortalama	0.6869	64.9076	-2.1884	0.0210	0.9992	0.1777

Test_6, K-Ortalamalar (k = 4)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.4673	66.6709	-0.4252	0.0140	0.9993	0.0241
0.5	0.5	0.8910	65.7926	-1.3034	0.0171	0.9993	0.1592
	Ortalama	0.6790	65.4953	-1.6008	0.0189	0.9992	0.1187

Test_6, K-Ortalamalar (k = 5)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.0703	67.1124	0.0164	0.0126	0.9993	0.0689
0.4	0.5	0.8936	65.6761	-1.4199	0.0176	0.9994	0.2350
	Ortalama	0.6604	65.7287	-1.3673	0.0180	0.9993	0.1840

Test_6, K-Ortalamalar (k = 6)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.4738	66.6388	-0.4572	0.0141	0.9993	0.0222
0.4	0.5	0.9403	65.7841	-1.3119	0.0172	0.9994	0.2165
	Ortalama	0.7236	65.4398	-1.6562	0.0195	0.9992	0.1356

Test_6, K-Ortalamalar (k = 7)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.4746	66.6225	-0.4735	0.0142	0.9993	0.0263
0.4	0.5	0.9349	65.6346	-1.4614	0.0178	0.9994	0.2323
	Ortalama	0.7135	65.3369	-1.7591	0.0201	0.9992	0.1307

Test_6, K-Ortalamalar (k = 8)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.4697	66.6390	-0.4570	0.0141	0.9993	0.0246
0.4	0.5	0.9934	66.0018	-1.0942	0.0163	0.9994	0.2446
	Ortalama	0.7222	65.4645	-1.6315	0.0200	0.9992	0.1375

Test_6, K-Ortalamalar (k = 9)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.1188	67.0843	-0.0117	0.0127	0.9993	0.0521
0.4	0.5	0.9382	65.8224	-1.2736	0.0170	0.9994	0.2657
	Ortalama	0.6587	65.6611	-1.4349	0.0189	0.9992	0.1858

Test_6, K-Ortalamalar (k = 10)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.4467	66.6579	-0.4381	0.0140	0.9993	0.0247
0.4	0.5	0.9840	66.1108	-0.9852	0.0159	0.9994	0.2312
	Ortalama	0.6975	65.3324	-1.7637	0.0213	0.9991	0.1307

Test_7, K-Ortalamalar (k = 2)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.4502	65.5495	-3.1990	0.0181	0.9992	0.0350
0.1	0.5	0.4491	65.5128	-3.2356	0.0183	0.9992	0.0346
	Ortalama	0.4496	65.5279	-3.2206	0.0182	0.9992	0.0348

Test_7, K-Ortalamlar (k = 3)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.7929	68.0921	-0.6564	0.0101	0.9996	0.1117
0.4	0.5	0.8047	68.0862	-0.6623	0.0101	0.9996	0.1130
	Ortalama	0.8029	68.0824	-0.6661	0.0101	0.9996	0.1124

Test_7, K-Ortalamlar (k = 4)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.3	0.5	0.4136	63.8502	-4.8982	0.0268	0.9988	0.0374
0.2	0.5	0.3519	62.4134	-6.3351	0.0373	0.9983	0.0279
	Ortalama	0.3899	63.9600	-4.7885	0.0270	0.9988	0.0342

Test_7, K-Ortalamlar (k = 5)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.4	0.5	0.8008	68.1028	-0.6457	0.0101	0.9996	0.1122
0.1	0.5	0.4293	64.4089	-4.3396	0.0236	0.9990	0.0418
	Ortalama	0.7141	67.2922	-1.4563	0.0131	0.9995	0.0958

Test_7, K-Ortalamlar (k = 6)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.5	0.5	0.7986	68.1037	-0.6448	0.0101	0.9996	0.1118
0.1	0.5	0.3828	63.2430	-5.5055	0.0308	0.9986	0.0442
	Ortalama	0.6719	66.8960	-1.8525	0.0144	0.9994	0.0856

Test_7, K-Ortalamlar (k = 7)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.5	0.5	0.7923	68.1081	-0.6404	0.0101	0.9996	0.1117
0.1	0.5	0.3722	63.0820	-5.6665	0.0320	0.9985	0.0402
	Ortalama	0.6752	66.8841	-1.8643	0.0146	0.9994	0.0864

Test_7, K-Ortalamlar (k = 8)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.6	0.5	0.7961	68.1045	-0.6439	0.0101	0.9996	0.1112
0.1	0.5	0.3754	62.9210	-5.8274	0.0332	0.9984	0.0354
	Ortalama	0.6780	66.8495	-1.8990	0.0147	0.9994	0.0844

Test_7, K-Ortalamlar (k = 9)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.3725	68.5115	-0.2369	0.0092	0.9995	0.0544
0.5	0.5	0.7667	67.4383	-1.3102	0.0117	0.9995	0.0911
	Ortalama	0.6481	66.7473	-2.0011	0.0150	0.9994	0.0743

Test_7, K-Ortalamlar (k = 10)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.5	0.5	0.7586	67.6688	-1.0797	0.0111	0.9995	0.0688
0.1	0.5	0.4744	63.1479	-5.6005	0.0315	0.9986	0.0462
	Ortalama	0.6625	66.6806	-2.0679	0.0152	0.9993	0.0633

Test_8, K-Ortalamlar (k = 2)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.6935	65.5654	-0.0483	0.0181	0.9991	0.1893
0.1	0.5	0.6935	65.5654	-0.0483	0.0181	0.9991	0.1893
	Ortalama	0.6935	65.5654	-0.0483	0.0181	0.9991	0.1893

Test_8, K-Ortalamlar (k = 3)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.6950	65.5606	-0.0531	0.0181	0.9991	0.1906
0.4	0.5	0.9409	64.8543	-0.7594	0.0213	0.9992	0.2713
	Ortalama	0.8406	65.1784	-0.4353	0.0198	0.9991	0.2331

Test_8, K-Ortalamlar (k = 4)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.6938	65.5632	-0.0505	0.0181	0.9991	0.1907
0.3	0.5	0.9533	64.4304	-1.1833	0.0234	0.9992	0.2611
	Ortalama	0.8461	64.8336	-0.7801	0.0216	0.9991	0.2341

Test_8, K-Ortalamlar (k = 5)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.6801	65.5346	-0.0791	0.0182	0.9991	0.1784
0.4	0.5	0.9608	64.8368	-0.7769	0.0213	0.9992	0.2688
	Ortalama	0.8201	64.7337	-0.8800	0.0224	0.9991	0.2253

Test_8, K-Ortalamlar (k = 6)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.6392	65.5190	-0.0947	0.0182	0.9991	0.1607
0.3	0.5	0.9548	64.3607	-1.2530	0.0238	0.9992	0.2583
	Ortalama	0.8149	64.7328	-0.8809	0.0225	0.9991	0.2195

Test_8, K-Ortalamlar (k = 7)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.6693	65.5262	-0.0875	0.0182	0.9991	0.1706
0.3	0.5	0.9582	64.6514	-0.9623	0.0223	0.9993	0.2781
	Ortalama	0.8120	64.7774	-0.8363	0.0223	0.9991	0.2270

Test_8, K-Ortalamalar (k = 8)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.5527	65.4435	-0.1702	0.0186	0.9990	0.1108
0.3	0.5	0.9583	64.7227	-0.8910	0.0219	0.9993	0.2809
	Ortalama	0.8048	64.8826	-0.7311	0.0217	0.9991	0.2211

Test_8, K-Ortalamalar (k = 9)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.4702	65.4132	-0.2005	0.0187	0.9990	0.0844
0.3	0.5	0.9592	64.8506	-0.7631	0.0213	0.9993	0.2850
	Ortalama	0.8044	64.8804	-0.7333	0.0218	0.9991	0.2200

Test_8, K-Ortalamalar (k = 10)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.4622	65.4125	-0.2012	0.0187	0.9990	0.0814
0.3	0.5	0.9421	65.0124	-0.6013	0.0205	0.9993	0.2836
	Ortalama	0.7963	64.8851	-0.7286	0.0217	0.9991	0.2144

Test_9, K-Ortalamalar (k = 2)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.7290	63.2061	-1.9914	0.0311	0.9987	0.0784
0.1	0.5	0.7264	63.1703	-2.0272	0.0313	0.9987	0.0775
	Ortalama	0.7273	63.1832	-2.0143	0.0312	0.9987	0.0779

Test_9, K-Ortalamalar (k = 3)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.7	0.5	0.7307	63.8792	-1.3183	0.0266	0.9989	0.0645
0.6	0.5	0.7292	63.8719	-1.3255	0.0267	0.9989	0.0644
	Ortalama	0.7299	63.8744	-1.3231	0.0267	0.9989	0.0644

Test_9, K-Ortalamalar (k = 4)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.4	0.5	0.6954	63.9674	-1.2301	0.0261	0.9989	0.0610
0.1	0.5	0.5854	60.6143	-4.5832	0.0564	0.9977	0.0575
	Ortalama	0.6825	63.6010	-1.5965	0.0294	0.9988	0.0608

Test_9, K-Ortalamalar (k = 5)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.7041	64.2067	-0.9908	0.0247	0.9990	0.0584
0.1	0.5	0.6526	60.4702	-4.7273	0.0584	0.9977	0.0713
	Ortalama	0.6863	63.3636	-1.8338	0.0314	0.9987	0.0590

Test_9, K-Ortalamlar (k = 6)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.3	0.5	0.7455	63.4823	-1.7152	0.0292	0.9988	0.0538
0.1	0.5	0.6441	60.7143	-4.4831	0.0552	0.9978	0.0684
	Ortalama	0.6797	63.3076	-1.8899	0.0317	0.9987	0.0526

Test_9, K-Ortalamlar (k = 7)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.5	0.6524	64.4407	-0.7568	0.0234	0.9990	0.0487
0.3	0.5	0.8478	63.2841	-1.9133	0.0305	0.9989	0.0819
	Ortalama	0.7108	63.4687	-1.7288	0.0304	0.9988	0.0577

Test_9, K-Ortalamlar (k = 8)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.5	0.6683	64.4499	-0.7475	0.0233	0.9990	0.0513
0.3	0.5	0.8430	63.3363	-1.8612	0.0302	0.9989	0.0899
	Ortalama	0.7150	63.4856	-1.7118	0.0302	0.9988	0.0604

Test_9, K-Ortalamlar (k = 9)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.5	0.2348	64.9270	-0.2704	0.0209	0.9990	0.0514
0.2	0.5	0.8066	62.3177	-2.8798	0.0381	0.9986	0.0847
	Ortalama	0.6678	63.5037	-1.6938	0.0303	0.9988	0.0563

Test_9, K-Ortalamlar (k = 10)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.6	0.5	0.6709	63.9306	-1.2669	0.0263	0.9989	0.0442
0.3	0.5	0.8375	62.6991	-2.4984	0.0349	0.9987	0.0880
	Ortalama	0.7312	63.2395	-1.9580	0.0320	0.9987	0.0623

Test_10, K-Ortalamlar (k = 2)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.5	0.6220	62.9470	-0.5788	0.0330	0.9986	0.1831
0.1	0.5	0.6400	62.9440	-0.5819	0.0330	0.9986	0.1863
	Ortalama	0.6359	62.9450	-0.5809	0.0330	0.9986	0.1853

Test_10, K-Ortalamlar (k = 3)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
0.9	0.5	0.1068	63.4566	-0.0692	0.0293	0.9984	0.0453
0.1	0.5	0.7288	62.7923	-0.7336	0.0342	0.9987	0.2109
	Ortalama	0.4687	63.1000	-0.4259	0.0319	0.9986	0.1364

Test_10, K-Ortalamalar (k = 4)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.1267	63.4609	-0.0650	0.0293	0.9984	0.0633
0.4	0.5	0.7336	62.3917	-1.1342	0.0375	0.9986	0.2059
	Ortalama	0.5542	62.2960	-1.2299	0.0396	0.9983	0.1571

Test_10, K-Ortalamalar (k = 5)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.1413	63.4330	-0.0929	0.0295	0.9984	0.0606
0.4	0.5	0.6617	61.3871	-2.1387	0.0472	0.9981	0.1475
	Ortalama	0.5240	61.7371	-1.7888	0.0459	0.9981	0.1302

Test_10, K-Ortalamalar (k = 6)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.3140	63.3644	-0.1614	0.0300	0.9985	0.1168
0.4	0.5	0.6935	61.3966	-2.1292	0.0471	0.9982	0.1726
	Ortalama	0.5399	61.9127	-1.6131	0.0445	0.9981	0.1496

Test_10, K-Ortalamalar (k = 7)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.1008	63.1800	-0.3458	0.0313	0.9983	0.0058
0.6	0.5	0.6269	61.1183	-2.4076	0.0503	0.9980	0.1612
	Ortalama	0.5025	60.5986	-2.9272	0.0604	0.9974	0.1176

Test_10, K-Ortalamalar (k = 8)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.1003	63.4136	-0.1122	0.0296	0.9984	0.0363
0.2	0.5	0.6900	60.3145	-3.2114	0.0605	0.9977	0.1574
	Ortalama	0.4969	62.0457	-1.4802	0.0431	0.9981	0.1418

Test_10, K-Ortalamalar (k = 9)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.3140	63.3644	-0.1614	0.0300	0.9985	0.1168
0.4	0.5	0.7088	62.2920	-1.2339	0.0384	0.9985	0.2044
	Ortalama	0.5228	61.6988	-1.8271	0.0493	0.9978	0.1445

Test_10, K-Ortalamalar (k = 10)							
Gradient Threshold	Operator Scale	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
0.9	0.5	0.3140	63.3627	-0.1631	0.0300	0.9985	0.1162
0.4	0.5	0.7188	62.3011	-1.2248	0.0383	0.9985	0.2090
	Ortalama	0.5255	61.7258	-1.8001	0.0489	0.9978	0.1475

Ek-3:

Bulanık C-Ortalamlar yöntemine ilişkin; “k” küme sayısı parametresi için tüm sonuç değerleri.

Test_1, Bulanık C-Ortalamlar								
Canny (Gradient Threshold (0.5), Operator Scale (0.5))								
Küme Sayısı (k)	Maksimum Döngü Sayısı	Tekrarlama Sayısı	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
2	10	Ort.	0.7184	63.6733	-1.6828	0.0279	0.9989	0.1817
		1	0.7168	63.6387	-1.7174	0.0281	0.9989	0.1806
		2	0.7184	63.6764	-1.6798	0.0279	0.9989	0.1822
		3	0.7187	63.6785	-1.6776	0.0279	0.9989	0.1816
		4	0.7184	63.6764	-1.6798	0.0279	0.9989	0.1822
		5	0.7185	63.6704	-1.6857	0.0279	0.9989	0.1820
		6	0.7187	63.6785	-1.6776	0.0279	0.9989	0.1816
		7	0.7187	63.6785	-1.6776	0.0279	0.9989	0.1816
		8	0.7187	63.6785	-1.6776	0.0279	0.9989	0.1816
		9	0.7187	63.6785	-1.6776	0.0279	0.9989	0.1816
		10	0.7187	63.6785	-1.6776	0.0279	0.9989	0.1816
3	10	Ort.	0.6944	62.4208	-2.9353	0.0374	0.9986	0.1329
		1	0.7171	62.9070	-2.4491	0.0333	0.9988	0.1240
		2	0.7543	63.1700	-2.1861	0.0313	0.9988	0.1843
		3	0.6528	61.7115	-3.6446	0.0438	0.9983	0.1057
		4	0.6793	62.2161	-3.1400	0.0390	0.9985	0.1214
		5	0.6561	62.4649	-2.8912	0.0369	0.9986	0.1213
		6	0.7009	62.3872	-2.9690	0.0375	0.9986	0.1519
		7	0.7138	62.5988	-2.7574	0.0357	0.9987	0.1563
		8	0.7042	62.6439	-2.7122	0.0354	0.9987	0.1319
		9	0.6987	62.1857	-3.1705	0.0393	0.9985	0.1238
		10	0.6670	61.9228	-3.4333	0.0418	0.9984	0.1083
4	10	Ort.	0.7153	62.2603	-3.0958	0.0392	0.9985	0.1350
		1	0.6902	62.4713	-2.8848	0.0368	0.9986	0.1305
		2	0.7162	62.3541	-3.0020	0.0378	0.9986	0.1334
		3	0.8065	62.7178	-2.6383	0.0348	0.9987	0.1544
		4	0.6462	61.2655	-4.0906	0.0486	0.9981	0.1028
		5	0.7257	62.2650	-3.0911	0.0386	0.9986	0.1350
		6	0.6728	61.5225	-3.8336	0.0458	0.9982	0.1289
		7	0.7237	61.6560	-3.7002	0.0444	0.9983	0.1333
		8	0.7367	63.8018	-1.5543	0.0271	0.9990	0.1585
		9	0.7751	62.9607	-2.3954	0.0329	0.9988	0.1517
		10	0.6598	61.5884	-3.7677	0.0451	0.9982	0.1215
5	10	Ort.	0.6824	61.7107	-3.6455	0.0448	0.9982	0.1208
		1	0.7379	62.2431	-3.1131	0.0388	0.9985	0.1293
		2	0.6164	60.5155	-4.8406	0.0577	0.9976	0.1006
		3	0.6180	60.8090	-4.5471	0.0540	0.9978	0.0857
		4	0.7196	62.6106	-2.7455	0.0356	0.9987	0.1410
		5	0.6510	60.7027	-4.6534	0.0553	0.9978	0.1182
		6	0.7099	61.3651	-3.9910	0.0475	0.9982	0.1175
		7	0.7326	63.2632	-2.0929	0.0307	0.9988	0.1530
		8	0.6756	61.9159	-3.4402	0.0418	0.9984	0.1173
		9	0.6394	61.1722	-4.1840	0.0496	0.9980	0.0952
		10	0.7232	62.5093	-2.8468	0.0365	0.9986	0.1498

6	10	Ort.	0.6750	61.6272	-3.7289	0.0455	0.9982	0.1225
		1	0.6288	61.1787	-4.1774	0.0496	0.9980	0.0906
		2	0.7428	61.9415	-3.4147	0.0416	0.9985	0.1546
		3	0.6317	60.3505	-5.0056	0.0600	0.9976	0.0984
		4	0.6421	61.8623	-3.4938	0.0423	0.9983	0.1240
		5	0.5971	61.9750	-3.3811	0.0413	0.9983	0.1202
		6	0.7741	63.6282	-1.7279	0.0282	0.9990	0.1757
		7	0.6764	61.1334	-4.2228	0.0501	0.9980	0.1063
		8	0.7255	61.6454	-3.7107	0.0445	0.9983	0.1272
		9	0.6614	61.5265	-3.8296	0.0458	0.9982	0.1103
		10	0.6703	61.0303	-4.3258	0.0513	0.9980	0.1172
7	10	Ort.	0.6460	61.8180	-3.5382	0.0434	0.9983	0.1150
		1	0.5382	63.2700	-2.0861	0.0306	0.9987	0.0787
		2	0.5908	61.9842	-3.3719	0.0412	0.9983	0.0717
		3	0.6412	61.2372	-4.1189	0.0489	0.9981	0.1169
		4	0.6344	60.5752	-4.7809	0.0570	0.9976	0.0891
		5	0.6139	62.2348	-3.1213	0.0389	0.9984	0.1049
		6	0.6368	61.3602	-3.9960	0.0475	0.9981	0.1214
		7	0.7174	61.8413	-3.5148	0.0426	0.9984	0.1409
		8	0.7399	61.6967	-3.6595	0.0440	0.9984	0.1472
		9	0.6570	61.4030	-3.9532	0.0471	0.9981	0.1205
		10	0.6905	62.5772	-2.7790	0.0359	0.9986	0.1586
8	10	Ort.	0.6733	61.4257	-3.9304	0.0475	0.9981	0.1096
		1	0.6511	60.0735	-5.2827	0.0639	0.9974	0.1068
		2	0.7171	61.2933	-4.0628	0.0483	0.9981	0.1159
		3	0.6736	61.0674	-4.2888	0.0509	0.9980	0.1199
		4	0.6227	61.1537	-4.2024	0.0499	0.9979	0.0800
		5	0.5923	62.1100	-3.2461	0.0400	0.9984	0.0637
		6	0.7585	62.1495	-3.2066	0.0396	0.9985	0.1394
		7	0.6916	62.1475	-3.2087	0.0397	0.9985	0.1413
		8	0.6153	60.7864	-4.5697	0.0543	0.9977	0.0709
		9	0.7034	62.3116	-3.0445	0.0382	0.9985	0.1399
		10	0.7074	61.1645	-4.1917	0.0497	0.9981	0.1178
9	10	Ort.	0.6492	60.8327	-4.5234	0.0548	0.9978	0.1093
		1	0.6474	60.2405	-5.1156	0.0615	0.9975	0.1075
		2	0.6597	60.3479	-5.0082	0.0600	0.9976	0.1138
		3	0.6139	59.9415	-5.4146	0.0659	0.9972	0.0981
		4	0.6694	61.1989	-4.1573	0.0493	0.9980	0.1195
		5	0.5746	60.6293	-4.7268	0.0563	0.9976	0.0707
		6	0.6958	62.2190	-3.1371	0.0390	0.9985	0.1407
		7	0.7330	61.5611	-3.7951	0.0454	0.9983	0.1280
		8	0.7008	62.0688	-3.2873	0.0404	0.9984	0.1364
		9	0.5895	59.2629	-6.0932	0.0771	0.9967	0.0931
		10	0.6078	60.8569	-4.4992	0.0534	0.9978	0.0854
10	10	Ort.	0.6201	60.6630	-4.6931	0.0569	0.9976	0.0874
		1	0.6701	60.9695	-4.3866	0.0520	0.9979	0.1185
		2	0.5812	59.8577	-5.4985	0.0672	0.9971	0.0856
		3	0.5635	59.8454	-5.5107	0.0674	0.9970	0.0613
		4	0.6225	60.3025	-5.0536	0.0606	0.9974	0.0777
		5	0.6668	62.0580	-3.2981	0.0405	0.9984	0.1195
		6	0.6178	60.0665	-5.2896	0.0640	0.9973	0.0740
		7	0.6319	60.3175	-5.0387	0.0604	0.9975	0.0902
		8	0.6920	61.2154	-4.1407	0.0492	0.9981	0.1167
		9	0.5708	62.2589	-3.0973	0.0387	0.9984	0.0579
		10	0.5840	59.7385	-5.6176	0.0691	0.9970	0.0725

Test_2, Bulanık C-Ortalamalar								
Canny (Gradient Threshold (0.2), Operator Scale (0.5))								
Küme Sayısı (k)	Maksimum Döngü Sayısı	Tekrarlama Sayısı	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
2	10	Ort.	0.7046	65.9788	-1.8891	0.0164	0.9993	0.0625
		1	0.7046	65.9798	-1.8881	0.0164	0.9993	0.0626
		2	0.7046	65.9798	-1.8881	0.0164	0.9993	0.0626
		3	0.7046	65.9798	-1.8881	0.0164	0.9993	0.0626
		4	0.7046	65.9798	-1.8881	0.0164	0.9993	0.0626
		5	0.7046	65.9798	-1.8881	0.0164	0.9993	0.0626
		6	0.7046	65.9798	-1.8881	0.0164	0.9993	0.0626
		7	0.7046	65.9798	-1.8881	0.0164	0.9993	0.0626
		8	0.7049	65.9696	-1.8982	0.0164	0.9993	0.0613
		9	0.7046	65.9798	-1.8881	0.0164	0.9993	0.0626
		10	0.7046	65.9798	-1.8881	0.0164	0.9993	0.0626
3	10	Ort.	0.8462	64.5302	-3.3377	0.0230	0.9990	0.0947
		1	0.8929	63.7496	-4.1182	0.0274	0.9988	0.1294
		2	0.7135	65.0976	-2.7702	0.0201	0.9991	0.0671
		3	0.8907	64.6622	-3.2056	0.0222	0.9990	0.0946
		4	0.8711	64.7248	-3.1431	0.0219	0.9990	0.0904
		5	0.7330	64.8561	-3.0118	0.0213	0.9990	0.0438
		6	0.7652	64.8746	-2.9933	0.0212	0.9990	0.0641
		7	0.9012	64.6476	-3.2203	0.0223	0.9990	0.0958
		8	0.8768	64.7184	-3.1495	0.0219	0.9990	0.0939
		9	0.9033	63.9172	-3.9506	0.0264	0.9989	0.1328
		10	0.9142	64.0535	-3.8144	0.0256	0.9989	0.1355
4	10	Ort.	0.8817	63.5778	-4.2901	0.0289	0.9987	0.1084
		1	0.8918	63.4404	-4.4275	0.0294	0.9987	0.1197
		2	0.9388	63.8395	-4.0284	0.0269	0.9988	0.1028
		3	0.9077	63.6873	-4.1806	0.0278	0.9988	0.1266
		4	0.8924	63.5270	-4.3409	0.0289	0.9987	0.1199
		5	0.9207	63.7275	-4.1404	0.0276	0.9988	0.1278
		6	0.8924	63.6060	-4.2619	0.0283	0.9988	0.1257
		7	0.8528	64.1750	-3.6929	0.0249	0.9989	0.0890
		8	0.6726	61.7313	-6.1365	0.0436	0.9981	0.0647
		9	0.9319	63.9448	-3.9231	0.0262	0.9988	0.1088
		10	0.9161	64.0991	-3.7688	0.0253	0.9989	0.0988
5	10	Ort.	0.8595	62.8776	-4.9903	0.0341	0.9985	0.1101
		1	0.9035	62.9978	-4.8701	0.0326	0.9986	0.1210
		2	0.9019	63.9918	-3.8761	0.0259	0.9989	0.1025
		3	0.9320	63.2724	-4.5955	0.0306	0.9987	0.1201
		4	0.9226	63.3669	-4.5010	0.0299	0.9987	0.1295
		5	0.9181	63.2969	-4.5709	0.0304	0.9987	0.1278
		6	0.8071	62.3658	-5.5020	0.0377	0.9983	0.0988
		7	0.6602	61.3868	-6.4810	0.0472	0.9979	0.0792
		8	0.9219	63.2640	-4.6038	0.0307	0.9986	0.1320
		9	0.9081	63.0963	-4.7716	0.0319	0.9986	0.1225
		10	0.7194	61.7373	-6.1306	0.0436	0.9981	0.0673

6	10	Ort.	0.7418	61.8841	-5.9838	0.0427	0.9981	0.0815
		1	0.6605	61.3096	-6.5583	0.0481	0.9978	0.0556
		2	0.7359	61.6142	-6.2536	0.0448	0.9980	0.0828
		3	0.6469	61.3179	-6.5500	0.0480	0.9978	0.0678
		4	0.7424	61.8898	-5.9781	0.0421	0.9982	0.0891
		5	0.7398	62.0307	-5.8371	0.0407	0.9982	0.0706
		6	0.7130	61.5009	-6.3670	0.0460	0.9980	0.0740
		7	0.9479	63.5665	-4.3014	0.0286	0.9988	0.1105
		8	0.6439	61.2756	-6.5922	0.0485	0.9978	0.0728
		9	0.6698	61.4790	-6.3889	0.0463	0.9980	0.0693
		10	0.9182	62.8565	-5.0114	0.0337	0.9985	0.1229
7	10	Ort.	0.7514	61.7071	-6.1607	0.0454	0.9980	0.0879
		1	0.9077	63.2803	-4.5876	0.0306	0.9987	0.1344
		2	0.5007	60.3031	-7.5648	0.0606	0.9972	0.0288
		3	0.6877	60.8313	-7.0365	0.0537	0.9976	0.0662
		4	0.8281	62.5149	-5.3530	0.0364	0.9984	0.1029
		5	0.6738	60.7916	-7.0763	0.0542	0.9975	0.0641
		6	0.7345	61.2333	-6.6345	0.0489	0.9978	0.0831
		7	0.9150	63.2690	-4.5989	0.0306	0.9987	0.1330
		8	0.6943	60.6324	-7.2355	0.0562	0.9974	0.0804
		9	0.6633	60.9335	-6.9343	0.0524	0.9977	0.0805
		10	0.9090	63.2820	-4.5858	0.0305	0.9987	0.1053
8	10	Ort.	0.6982	61.1983	-6.6696	0.0500	0.9978	0.0703
		1	0.9140	62.9822	-4.8856	0.0327	0.9985	0.0965
		2	0.6170	61.3785	-6.4894	0.0473	0.9979	0.0481
		3	0.6968	60.8614	-7.0065	0.0533	0.9976	0.0709
		4	0.6284	60.9370	-6.9308	0.0524	0.9976	0.0520
		5	0.6843	60.7858	-7.0821	0.0543	0.9976	0.0643
		6	0.7620	62.0127	-5.8552	0.0409	0.9982	0.0832
		7	0.6706	60.9082	-6.9597	0.0528	0.9976	0.0678
		8	0.6722	60.8538	-7.0141	0.0534	0.9976	0.0711
		9	0.6886	60.5362	-7.3316	0.0575	0.9974	0.0738
		10	0.6479	60.7272	-7.1407	0.0550	0.9975	0.0751
9	10	Ort.	0.6989	61.2174	-6.6505	0.0501	0.9978	0.0757
		1	0.7523	61.3382	-6.5297	0.0478	0.9979	0.0872
		2	0.6909	60.5528	-7.3150	0.0573	0.9974	0.0855
		3	0.8112	62.2797	-5.5881	0.0385	0.9983	0.1029
		4	0.7422	61.1517	-6.7162	0.0499	0.9978	0.0844
		5	0.6668	61.0626	-6.8053	0.0509	0.9978	0.0737
		6	0.6736	60.8993	-6.9686	0.0529	0.9976	0.0532
		7	0.6148	61.0113	-6.8565	0.0515	0.9977	0.0496
		8	0.6303	61.5991	-6.2687	0.0450	0.9981	0.0599
		9	0.8871	62.7374	-5.1305	0.0346	0.9985	0.1097
		10	0.5200	59.5414	-8.3264	0.0723	0.9966	0.0506
10	10	Ort.	0.6945	61.7346	-6.1333	0.0464	0.9979	0.0679
		1	0.5743	59.7621	-8.1057	0.0687	0.9967	0.0552
		2	0.6910	61.9179	-5.9500	0.0418	0.9982	0.0749
		3	0.9140	63.3437	-4.5242	0.0301	0.9987	0.0865
		4	0.8111	63.1407	-4.7272	0.0316	0.9986	0.0717
		5	0.6237	61.2849	-6.5830	0.0484	0.9978	0.0543
		6	0.7286	64.0532	-3.8147	0.0256	0.9989	0.0740
		7	0.5272	59.9115	-7.9564	0.0664	0.9970	0.0636
		8	0.8507	63.0289	-4.8389	0.0324	0.9986	0.0771
		9	0.6365	61.1420	-6.7258	0.0500	0.9977	0.0625
		10	0.5879	59.7609	-8.1069	0.0687	0.9968	0.0588

Test_3, Bulanık C-Ortalamalar								
Canny (Gradient Threshold (0.3), Operator Scale (0.5))								
Küme Sayısı (k)	Maksimum Döngü Sayısı	Tekrarlama Sayısı	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
2	10	Ort.	0.6853	62.9251	-3.6651	0.0332	0.9985	0.0619
		1	0.6848	62.9309	-3.6593	0.0331	0.9985	0.0617
		2	0.6848	62.9309	-3.6593	0.0331	0.9985	0.0617
		3	0.6848	62.9309	-3.6593	0.0331	0.9985	0.0617
		4	0.6848	62.9309	-3.6593	0.0331	0.9985	0.0617
		5	0.6858	62.9192	-3.6709	0.0332	0.9985	0.0620
		6	0.6858	62.9192	-3.6709	0.0332	0.9985	0.0621
		7	0.6858	62.9192	-3.6709	0.0332	0.9985	0.0620
		8	0.6848	62.9309	-3.6593	0.0331	0.9985	0.0617
		9	0.6858	62.9192	-3.6709	0.0332	0.9985	0.0620
		10	0.6858	62.9192	-3.6709	0.0332	0.9985	0.0620
3	10	Ort.	0.6849	61.9831	-4.6071	0.0412	0.9982	0.0637
		1	0.6747	62.0102	-4.5800	0.0409	0.9982	0.0598
		2	0.6883	61.9871	-4.6031	0.0412	0.9982	0.0693
		3	0.6879	62.0425	-4.5477	0.0406	0.9982	0.0612
		4	0.6812	61.8295	-4.7606	0.0427	0.9982	0.0692
		5	0.6918	62.0593	-4.5309	0.0405	0.9983	0.0614
		6	0.6872	61.9385	-4.6517	0.0416	0.9982	0.0657
		7	0.6786	62.0287	-4.5615	0.0408	0.9982	0.0589
		8	0.6895	61.9276	-4.6626	0.0417	0.9982	0.0688
		9	0.6863	62.0306	-4.5595	0.0407	0.9982	0.0610
		10	0.6831	61.9773	-4.6129	0.0412	0.9982	0.0621
4	10	Ort.	0.6676	61.3072	-5.2830	0.0482	0.9979	0.0608
		1	0.6589	61.1461	-5.4440	0.0499	0.9978	0.0632
		2	0.6609	61.1403	-5.4498	0.0500	0.9978	0.0580
		3	0.6620	61.1564	-5.4338	0.0498	0.9978	0.0624
		4	0.6609	61.0847	-5.5055	0.0507	0.9978	0.0521
		5	0.6544	61.6934	-4.8968	0.0440	0.9981	0.0615
		6	0.6848	61.4613	-5.1288	0.0464	0.9980	0.0604
		7	0.6668	61.0275	-5.5626	0.0513	0.9978	0.0635
		8	0.7016	62.0691	-4.5210	0.0404	0.9983	0.0679
		9	0.6569	61.2092	-5.3809	0.0492	0.9978	0.0602
		10	0.6692	61.0835	-5.5067	0.0507	0.9978	0.0585
5	10	Ort.	0.6722	61.3601	-5.2301	0.0478	0.9979	0.0615
		1	0.6723	61.1598	-5.4304	0.0498	0.9978	0.0593
		2	0.6665	61.0023	-5.5879	0.0516	0.9978	0.0639
		3	0.6597	61.6108	-4.9794	0.0449	0.9981	0.0578
		4	0.7199	62.1119	-4.4783	0.0400	0.9983	0.0660
		5	0.6473	60.7984	-5.7918	0.0541	0.9976	0.0563
		6	0.6681	61.4176	-5.1725	0.0469	0.9980	0.0604
		7	0.6566	60.4964	-6.0938	0.0580	0.9975	0.0654
		8	0.6767	61.5817	-5.0085	0.0452	0.9981	0.0603
		9	0.6718	61.7223	-4.8679	0.0437	0.9981	0.0618
		10	0.6827	61.7001	-4.8900	0.0440	0.9981	0.0636

6	10	Ort.	0.6723	61.2537	-5.3365	0.0494	0.9979	0.0631
		1	0.6823	61.5270	-5.0632	0.0457	0.9981	0.0597
		2	0.6660	60.8471	-5.7431	0.0535	0.9977	0.0624
		3	0.6605	60.6480	-5.9422	0.0560	0.9976	0.0617
		4	0.6721	61.6524	-4.9377	0.0444	0.9981	0.0567
		5	0.6676	60.6035	-5.9867	0.0566	0.9975	0.0696
		6	0.6797	62.0570	-4.5331	0.0405	0.9982	0.0618
		7	0.6804	62.0328	-4.5573	0.0407	0.9983	0.0580
		8	0.7217	62.3225	-4.2677	0.0381	0.9984	0.0762
		9	0.6495	60.3165	-6.2736	0.0605	0.9974	0.0647
		10	0.6433	60.5300	-6.0601	0.0576	0.9975	0.0606
7	10	Ort.	0.6393	61.0827	-5.5075	0.0512	0.9978	0.0547
		1	0.6306	60.8334	-5.7568	0.0537	0.9977	0.0512
		2	0.6580	61.1319	-5.4583	0.0501	0.9978	0.0563
		3	0.6210	60.5403	-6.0499	0.0574	0.9974	0.0543
		4	0.6801	62.1207	-4.4695	0.0399	0.9983	0.0570
		5	0.6318	61.7950	-4.7952	0.0430	0.9981	0.0443
		6	0.6445	60.6799	-5.9103	0.0556	0.9976	0.0546
		7	0.6405	61.0273	-5.5629	0.0513	0.9977	0.0568
		8	0.6217	60.7540	-5.8362	0.0547	0.9976	0.0569
		9	0.6362	60.0893	-6.5009	0.0637	0.9972	0.0605
		10	0.6290	61.8549	-4.7352	0.0424	0.9981	0.0550
8	10	Ort.	0.6565	60.9001	-5.6901	0.0533	0.9977	0.0589
		1	0.6535	60.3003	-6.2899	0.0607	0.9974	0.0670
		2	0.6593	61.1782	-5.4120	0.0496	0.9979	0.0576
		3	0.6341	60.4015	-6.1886	0.0593	0.9974	0.0502
		4	0.6678	60.7800	-5.8102	0.0543	0.9976	0.0587
		5	0.6504	60.7083	-5.8819	0.0552	0.9976	0.0567
		6	0.6386	60.9388	-5.6513	0.0524	0.9977	0.0569
		7	0.6636	60.9320	-5.6582	0.0525	0.9977	0.0615
		8	0.6186	60.3384	-6.2518	0.0602	0.9973	0.0466
		9	0.6983	62.3076	-4.2826	0.0382	0.9984	0.0646
		10	0.6810	61.1159	-5.4743	0.0503	0.9978	0.0690
9	10	Ort.	0.6318	61.1228	-5.4674	0.0512	0.9978	0.0509
		1	0.6719	61.0174	-5.5728	0.0514	0.9978	0.0562
		2	0.6315	61.0681	-5.5221	0.0508	0.9978	0.0495
		3	0.6268	59.9784	-6.6118	0.0653	0.9971	0.0561
		4	0.6630	61.8177	-4.7725	0.0428	0.9982	0.0555
		5	0.6296	61.6427	-4.9475	0.0445	0.9981	0.0440
		6	0.6149	60.2433	-6.3468	0.0615	0.9973	0.0542
		7	0.5994	60.8773	-5.7129	0.0531	0.9976	0.0499
		8	0.5973	62.9000	-3.6902	0.0333	0.9985	0.0286
		9	0.6539	61.7601	-4.8300	0.0434	0.9982	0.0573
		10	0.6299	59.9230	-6.6671	0.0662	0.9970	0.0580
10	10	Ort.	0.6205	60.8569	-5.7332	0.0543	0.9976	0.0513
		1	0.5849	61.1369	-5.4532	0.0500	0.9977	0.0474
		2	0.6598	60.3588	-6.2314	0.0599	0.9974	0.0608
		3	0.6290	60.4708	-6.1194	0.0583	0.9974	0.0505
		4	0.6046	60.4165	-6.1736	0.0591	0.9974	0.0427
		5	0.6205	59.9701	-6.6201	0.0655	0.9970	0.0491
		6	0.6289	60.5277	-6.0625	0.0576	0.9974	0.0587
		7	0.5960	62.8861	-3.7041	0.0335	0.9985	0.0432
		8	0.6276	60.8102	-5.7800	0.0540	0.9977	0.0552
		9	0.6239	60.3184	-6.2718	0.0604	0.9973	0.0545
		10	0.6297	61.6739	-4.9162	0.0442	0.9980	0.0504

Test_4, Bulanık C-Ortalamalar								
Canny (Gradient Threshold (0.2), Operator Scale (0.5))								
Küme Sayısı (k)	Maksimum Doğru Sayısı	Tekrarlama Sayısı	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
2	10	Ort.	0.5538	61.4912	-2.9457	0.0462	0.9980	0.0938
		1	0.6004	61.5434	-2.8935	0.0456	0.9981	0.1011
		2	0.5804	61.7823	-2.6545	0.0431	0.9982	0.1063
		3	0.5253	61.4709	-2.9659	0.0463	0.9980	0.0893
		4	0.5161	61.4508	-2.9860	0.0466	0.9979	0.0899
		5	0.5107	60.9633	-3.4735	0.0521	0.9976	0.0780
		6	0.5836	61.8072	-2.6296	0.0429	0.9982	0.1066
		7	0.5182	61.0585	-3.3784	0.0510	0.9977	0.0802
		8	0.5813	61.7263	-2.7105	0.0437	0.9981	0.0856
		9	0.5738	61.6972	-2.7397	0.0440	0.9981	0.1057
		10	0.5483	61.4116	-3.0252	0.0470	0.9980	0.0948
3	10	Ort.	0.5574	60.7327	-3.7041	0.0551	0.9976	0.0963
		1	0.5657	60.7288	-3.7080	0.0550	0.9977	0.1070
		2	0.5738	60.7575	-3.6793	0.0546	0.9977	0.1088
		3	0.5627	60.7162	-3.7206	0.0551	0.9977	0.1099
		4	0.5978	61.4405	-2.9963	0.0467	0.9980	0.1044
		5	0.5689	61.2707	-3.1662	0.0485	0.9979	0.1003
		6	0.5224	60.2085	-4.2284	0.0620	0.9973	0.0777
		7	0.5216	60.9988	-3.4380	0.0517	0.9977	0.0878
		8	0.5414	60.3390	-4.0978	0.0601	0.9974	0.0821
		9	0.5496	60.4358	-4.0011	0.0588	0.9975	0.0888
		10	0.5697	60.4315	-4.0054	0.0589	0.9975	0.0957
4	10	Ort.	0.5297	59.7947	-4.6421	0.0684	0.9971	0.0866
		1	0.5300	59.5266	-4.9102	0.0725	0.9969	0.0927
		2	0.5305	59.5568	-4.8800	0.0720	0.9970	0.0939
		3	0.5392	59.8421	-4.5947	0.0674	0.9972	0.1098
		4	0.4951	59.7304	-4.7064	0.0692	0.9970	0.0670
		5	0.5441	59.5824	-4.8544	0.0716	0.9970	0.0882
		6	0.5441	60.2286	-4.2083	0.0617	0.9974	0.0851
		7	0.4974	59.4214	-5.0154	0.0743	0.9968	0.0665
		8	0.5337	59.6685	-4.7684	0.0702	0.9971	0.0754
		9	0.5306	59.8728	-4.5641	0.0670	0.9971	0.0846
		10	0.5520	60.5177	-3.9191	0.0577	0.9975	0.1029
5	10	Ort.	0.5220	59.5566	-4.8803	0.0724	0.9969	0.0867
		1	0.5398	59.5750	-4.8619	0.0717	0.9969	0.0839
		2	0.5077	59.2049	-5.2319	0.0781	0.9967	0.0867
		3	0.5014	59.8119	-4.6250	0.0679	0.9971	0.0776
		4	0.4771	58.9264	-5.5104	0.0833	0.9964	0.0728
		5	0.5313	59.7667	-4.6701	0.0686	0.9971	0.0979
		6	0.4948	59.1026	-5.3342	0.0799	0.9965	0.0663
		7	0.5096	59.2858	-5.1511	0.0766	0.9967	0.0945
		8	0.5515	60.2719	-4.1650	0.0611	0.9974	0.0873
		9	0.5865	60.2933	-4.1436	0.0608	0.9975	0.1188
		10	0.5206	59.3274	-5.1095	0.0759	0.9968	0.0815

6	10	Ort.	0.5314	59.4128	-5.0241	0.0749	0.9968	0.0885
		1	0.5513	59.4479	-4.9890	0.0738	0.9969	0.0890
		2	0.5444	59.2399	-5.1970	0.0775	0.9967	0.0945
		3	0.5030	58.5198	-5.9171	0.0914	0.9961	0.0661
		4	0.5746	59.9515	-4.4853	0.0658	0.9973	0.1139
		5	0.4750	58.9320	-5.5048	0.0832	0.9963	0.0773
		6	0.5403	59.3769	-5.0599	0.0751	0.9968	0.0962
		7	0.5864	60.1477	-4.2891	0.0629	0.9974	0.1179
		8	0.5198	59.8051	-4.6317	0.0680	0.9971	0.0830
		9	0.5336	59.3098	-5.1271	0.0762	0.9968	0.0772
		10	0.4852	59.3972	-5.0396	0.0747	0.9967	0.0695
7	10	Ort.	0.5486	60.2978	-4.1390	0.0623	0.9974	0.0978
		1	0.5892	60.0241	-4.4127	0.0647	0.9974	0.1177
		2	0.5733	59.7494	-4.6874	0.0689	0.9972	0.1127
		3	0.5676	60.4577	-3.9792	0.0585	0.9976	0.0946
		4	0.5434	60.4260	-4.0108	0.0589	0.9975	0.0910
		5	0.5879	60.6339	-3.8029	0.0562	0.9976	0.1213
		6	0.5294	59.2643	-5.1725	0.0770	0.9967	0.1037
		7	0.5844	61.0425	-3.3944	0.0511	0.9978	0.1192
		8	0.4695	62.8495	-1.5874	0.0337	0.9983	0.0603
		9	0.5223	59.2588	-5.1780	0.0771	0.9967	0.0876
		10	0.5191	59.2721	-5.1648	0.0769	0.9967	0.0694
8	10	Ort.	0.5138	59.4232	-5.0136	0.0762	0.9967	0.0887
		1	0.5123	58.9831	-5.4537	0.0822	0.9965	0.0806
		2	0.5269	59.2984	-5.1384	0.0764	0.9968	0.1152
		3	0.4885	58.2185	-6.2183	0.0980	0.9958	0.0793
		4	0.5927	61.4592	-2.9776	0.0465	0.9981	0.1020
		5	0.5070	58.4652	-5.9716	0.0926	0.9960	0.0934
		6	0.5384	60.0730	-4.3638	0.0639	0.9973	0.1005
		7	0.5535	60.7766	-3.6602	0.0544	0.9977	0.1241
		8	0.4573	59.0935	-5.3434	0.0801	0.9964	0.0578
		9	0.5161	59.5883	-4.8485	0.0715	0.9969	0.0756
		10	0.4455	58.2763	-6.1606	0.0967	0.9956	0.0583
9	10	Ort.	0.5422	59.8634	-4.5735	0.0691	0.9971	0.0910
		1	0.5491	59.0551	-5.3817	0.0808	0.9967	0.0919
		2	0.5922	61.0513	-3.3855	0.0510	0.9978	0.1129
		3	0.4937	58.6291	-5.8077	0.0892	0.9961	0.0750
		4	0.5389	59.0264	-5.4104	0.0814	0.9966	0.1023
		5	0.5149	59.9648	-4.4720	0.0656	0.9971	0.0661
		6	0.4320	59.9691	-4.4677	0.0655	0.9970	0.0612
		7	0.5208	58.8193	-5.6175	0.0853	0.9964	0.0929
		8	0.5101	59.5812	-4.8556	0.0716	0.9969	0.0707
		9	0.5756	60.0725	-4.3644	0.0639	0.9974	0.1060
		10	0.6949	62.4649	-1.9720	0.0369	0.9986	0.1309
10	10	Ort.	0.5198	59.6738	-4.7631	0.0709	0.9969	0.0864
		1	0.5017	59.9409	-4.4959	0.0659	0.9971	0.0713
		2	0.4930	59.9735	-4.4633	0.0654	0.9971	0.0584
		3	0.5138	59.1274	-5.3095	0.0795	0.9966	0.0880
		4	0.5315	59.1486	-5.2883	0.0791	0.9967	0.0977
		5	0.4735	60.1993	-4.2376	0.0621	0.9972	0.0506
		6	0.5328	59.3644	-5.0724	0.0753	0.9967	0.0992
		7	0.5145	59.8141	-4.6227	0.0679	0.9970	0.0928
		8	0.5115	58.9494	-5.4874	0.0828	0.9965	0.0844
		9	0.5125	59.0091	-5.4278	0.0817	0.9965	0.0993
		10	0.6127	61.2111	-3.2257	0.0492	0.9980	0.1218

Test_5, Bulanık C-Ortalamalar								
Canny (Gradient Threshold (0.1), Operator Scale (0.5))								
Küme Sayısı (k)	Maksimum Döngü Sayısı	Tekrarlama Sayısı	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
2	10	Ort.	0.7238	61.6080	-2.0710	0.0450	0.9981	0.1058
		1	0.7295	61.8517	-1.8273	0.0425	0.9982	0.1110
		2	0.7316	61.6977	-1.9812	0.0440	0.9981	0.1069
		3	0.6728	60.8970	-2.7820	0.0529	0.9978	0.0932
		4	0.7340	61.6856	-1.9934	0.0441	0.9981	0.1073
		5	0.7337	61.7777	-1.9013	0.0432	0.9982	0.1097
		6	0.7310	61.8057	-1.8733	0.0429	0.9982	0.1095
		7	0.7388	61.5907	-2.0882	0.0451	0.9981	0.1052
		8	0.7296	61.8541	-1.8248	0.0424	0.9982	0.1106
		9	0.7032	61.1401	-2.5389	0.0500	0.9979	0.0957
		10	0.7342	61.7792	-1.8997	0.0432	0.9982	0.1087
3	10	Ort.	0.6409	59.9159	-3.7631	0.0666	0.9973	0.0956
		1	0.6354	59.8151	-3.8638	0.0679	0.9972	0.1023
		2	0.6026	59.4354	-4.2435	0.0741	0.9969	0.0808
		3	0.6305	60.1172	-3.5617	0.0633	0.9974	0.1004
		4	0.6904	60.7369	-2.9421	0.0549	0.9978	0.1020
		5	0.6790	60.5620	-3.1170	0.0571	0.9977	0.0937
		6	0.6341	59.8346	-3.8443	0.0675	0.9972	0.1009
		7	0.6358	59.7738	-3.9052	0.0685	0.9972	0.0952
		8	0.6320	59.5349	-4.1440	0.0724	0.9970	0.0872
		9	0.6328	59.7186	-3.9603	0.0694	0.9971	0.0972
		10	0.6363	59.6301	-4.0488	0.0708	0.9971	0.0962
4	10	Ort.	0.5741	58.8349	-4.8441	0.0852	0.9964	0.0764
		1	0.6041	59.1281	-4.5509	0.0795	0.9967	0.0753
		2	0.6257	59.2715	-4.4075	0.0769	0.9969	0.0857
		3	0.5262	58.6294	-5.0496	0.0892	0.9962	0.0722
		4	0.5758	58.9714	-4.7076	0.0824	0.9965	0.0713
		5	0.5924	59.0590	-4.6200	0.0808	0.9966	0.0730
		6	0.5442	58.4325	-5.2464	0.0933	0.9960	0.0833
		7	0.5730	58.6082	-5.0708	0.0896	0.9962	0.0812
		8	0.5823	58.9482	-4.7307	0.0828	0.9965	0.0712
		9	0.5840	58.6813	-4.9977	0.0881	0.9963	0.0785
		10	0.5333	58.6197	-5.0593	0.0894	0.9962	0.0721
5	10	Ort.	0.5661	58.4603	-5.2186	0.0929	0.9961	0.0771
		1	0.6169	58.8952	-4.7837	0.0839	0.9966	0.0865
		2	0.5285	58.1966	-5.4824	0.0985	0.9958	0.0710
		3	0.5559	58.2593	-5.4197	0.0971	0.9958	0.0810
		4	0.5901	58.8031	-4.8759	0.0857	0.9964	0.0836
		5	0.5669	58.5322	-5.1468	0.0912	0.9962	0.0772
		6	0.5575	58.4959	-5.1830	0.0919	0.9961	0.0664
		7	0.5640	58.2548	-5.4241	0.0972	0.9959	0.0764
		8	0.6134	58.7923	-4.8866	0.0859	0.9965	0.0905
		9	0.5586	58.3972	-5.2817	0.0940	0.9960	0.0758
		10	0.5090	57.9767	-5.7022	0.1036	0.9955	0.0630

6	10	Ort.	0.5267	57.8832	-5.7957	0.1066	0.9954	0.0684
		1	0.4970	57.3633	-6.3157	0.1193	0.9948	0.0621
		2	0.5467	58.3185	-5.3605	0.0958	0.9959	0.0713
		3	0.4694	57.1386	-6.5404	0.1257	0.9944	0.0588
		4	0.5128	57.3266	-6.3523	0.1203	0.9948	0.0712
		5	0.5652	57.9701	-5.7089	0.1038	0.9956	0.0781
		6	0.5372	58.1574	-5.5216	0.0994	0.9958	0.0737
		7	0.5058	58.3785	-5.3004	0.0945	0.9959	0.0586
		8	0.4932	57.4657	-6.2133	0.1166	0.9949	0.0602
		9	0.5384	58.0663	-5.6126	0.1015	0.9957	0.0665
		10	0.6011	58.6474	-5.0316	0.0888	0.9963	0.0833
7	10	Ort.	0.5308	57.9799	-5.6991	0.1040	0.9955	0.0672
		1	0.4827	57.2345	-6.4444	0.1229	0.9946	0.0515
		2	0.5461	58.1987	-5.4802	0.0984	0.9958	0.0792
		3	0.5202	57.3363	-6.3427	0.1201	0.9947	0.0665
		4	0.5085	57.8082	-5.8708	0.1077	0.9953	0.0564
		5	0.5266	58.4248	-5.2542	0.0935	0.9959	0.0534
		6	0.5452	58.0744	-5.6045	0.1013	0.9957	0.0811
		7	0.5674	58.2166	-5.4624	0.0980	0.9958	0.0805
		8	0.4619	58.2863	-5.3927	0.0965	0.9956	0.0436
		9	0.5458	57.7518	-5.9272	0.1091	0.9953	0.0781
		10	0.6036	58.4669	-5.2121	0.0926	0.9962	0.0817
8	10	Ort.	0.5253	57.7698	-5.9092	0.1111	0.9951	0.0690
		1	0.4384	57.1796	-6.4994	0.1245	0.9943	0.0502
		2	0.7237	60.5904	-3.0885	0.0568	0.9977	0.1094
		3	0.5026	56.9270	-6.7520	0.1319	0.9938	0.0584
		4	0.4781	57.1531	-6.5259	0.1252	0.9944	0.0534
		5	0.5322	57.8221	-5.8568	0.1074	0.9954	0.0741
		6	0.5453	57.9584	-5.7206	0.1041	0.9955	0.0785
		7	0.4727	57.7232	-5.9557	0.1098	0.9951	0.0566
		8	0.5210	57.4736	-6.2054	0.1163	0.9950	0.0690
		9	0.5466	57.7078	-5.9712	0.1102	0.9952	0.0791
		10	0.4921	57.1626	-6.5164	0.1250	0.9945	0.0616
9	10	Ort.	0.5069	57.8704	-5.8085	0.1071	0.9953	0.0661
		1	0.5013	57.2384	-6.4405	0.1228	0.9946	0.0616
		2	0.4814	57.3451	-6.3339	0.1198	0.9948	0.0643
		3	0.5271	57.6025	-6.0765	0.1129	0.9952	0.0758
		4	0.4992	57.3470	-6.3320	0.1198	0.9946	0.0557
		5	0.4623	57.5971	-6.0818	0.1131	0.9951	0.0539
		6	0.5345	58.4662	-5.2128	0.0926	0.9961	0.0890
		7	0.5280	57.7963	-5.8826	0.1080	0.9953	0.0593
		8	0.3942	58.4996	-5.1793	0.0919	0.9956	0.0281
		9	0.5834	59.0606	-4.6184	0.0807	0.9966	0.0917
		10	0.5571	57.7515	-5.9275	0.1091	0.9953	0.0812
10	10	Ort.	0.4847	57.4789	-6.2000	0.1173	0.9947	0.0580
		1	0.5873	58.3960	-5.2830	0.0941	0.9960	0.0848
		2	0.4779	57.0507	-6.6282	0.1282	0.9943	0.0579
		3	0.5262	56.9931	-6.6859	0.1299	0.9941	0.0766
		4	0.4736	57.6939	-5.9851	0.1106	0.9950	0.0545
		5	0.4733	58.5172	-5.1618	0.0915	0.9959	0.0601
		6	0.4605	57.1428	-6.5362	0.1255	0.9942	0.0526
		7	0.5659	58.1167	-5.5623	0.1003	0.9957	0.0748
		8	0.4174	56.8436	-6.8354	0.1345	0.9937	0.0336
		9	0.4112	57.1309	-6.5480	0.1259	0.9942	0.0340
		10	0.4540	56.9044	-6.7745	0.1326	0.9939	0.0509

Test_6, Bulanık C-Ortalamalar								
Canny (Gradient Threshold (0.4), Operator Scale (0.5))								
Küme Sayısı (k)	Maksimum Döngü Sayısı	Tekrarlama Sayısı	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
2	10	Ort.	0.5024	64.5466	-2.5494	0.0228	0.9990	0.1104
		1	0.5026	64.5464	-2.5496	0.0228	0.9990	0.1107
		2	0.5017	64.5478	-2.5482	0.0228	0.9990	0.1100
		3	0.5026	64.5464	-2.5496	0.0228	0.9990	0.1107
		4	0.5017	64.5478	-2.5482	0.0228	0.9990	0.1100
		5	0.5026	64.5464	-2.5496	0.0228	0.9990	0.1107
		6	0.5026	64.5464	-2.5496	0.0228	0.9990	0.1107
		7	0.5017	64.5478	-2.5482	0.0228	0.9990	0.1100
		8	0.5026	64.5464	-2.5496	0.0228	0.9990	0.1107
		9	0.5017	64.5478	-2.5482	0.0228	0.9990	0.1100
		10	0.5040	64.5427	-2.5533	0.0228	0.9990	0.1104
3	10	Ort.	0.6612	64.6786	-2.4175	0.0222	0.9991	0.1813
		1	0.6649	64.7949	-2.3012	0.0216	0.9992	0.1820
		2	0.5974	63.9836	-3.1125	0.0260	0.9989	0.1594
		3	0.6594	64.8019	-2.2941	0.0215	0.9991	0.1827
		4	0.6484	64.7144	-2.3816	0.0220	0.9991	0.1761
		5	0.6799	64.5124	-2.5836	0.0230	0.9991	0.1888
		6	0.6013	64.3432	-2.7528	0.0239	0.9990	0.1421
		7	0.7055	64.9989	-2.0971	0.0206	0.9992	0.2040
		8	0.6835	64.8885	-2.2075	0.0211	0.9992	0.1907
		9	0.7067	64.9531	-2.1429	0.0208	0.9992	0.2047
		10	0.6649	64.7949	-2.3012	0.0216	0.9992	0.1820
4	10	Ort.	0.7192	65.0738	-2.0222	0.0203	0.9992	0.1824
		1	0.6406	65.1978	-1.8982	0.0196	0.9992	0.1622
		2	0.6292	65.0929	-2.0031	0.0201	0.9992	0.1642
		3	0.6726	65.2021	-1.8939	0.0196	0.9992	0.1700
		4	0.7715	64.5206	-2.5754	0.0230	0.9992	0.2057
		5	0.9082	65.7913	-1.3047	0.0171	0.9994	0.1800
		6	0.7291	65.4036	-1.6924	0.0187	0.9992	0.1949
		7	0.7693	64.4805	-2.6155	0.0232	0.9992	0.2066
		8	0.7187	65.3363	-1.7597	0.0190	0.9992	0.1918
		9	0.6371	64.2195	-2.8765	0.0246	0.9990	0.1640
		10	0.7161	65.4933	-1.6027	0.0184	0.9993	0.1845
5	10	Ort.	0.7322	64.6405	-2.4555	0.0226	0.9991	0.1716
		1	0.7827	64.5078	-2.5882	0.0230	0.9992	0.1956
		2	0.7624	64.6889	-2.4071	0.0221	0.9992	0.1642
		3	0.6781	63.1654	-3.9306	0.0314	0.9988	0.1675
		4	0.6871	63.9811	-3.1149	0.0260	0.9990	0.1435
		5	0.7238	64.4894	-2.6066	0.0231	0.9991	0.1650
		6	0.8135	65.0532	-2.0429	0.0203	0.9992	0.1899
		7	0.6267	65.1637	-1.9323	0.0198	0.9992	0.1534
		8	0.6001	64.9554	-2.1406	0.0208	0.9991	0.1518
		9	0.8643	65.4650	-1.6311	0.0185	0.9993	0.1844
		10	0.7834	64.9352	-2.1608	0.0209	0.9992	0.2002

6	10	Ort.	0.7370	64.1342	-2.9619	0.0256	0.9990	0.1732
		1	0.8366	64.8732	-2.2228	0.0212	0.9992	0.1870
		2	0.7548	64.8349	-2.2611	0.0214	0.9992	0.1776
		3	0.9404	65.4564	-1.6396	0.0185	0.9994	0.2239
		4	0.5723	63.6353	-3.4608	0.0282	0.9988	0.1499
		5	0.7123	63.8906	-3.2054	0.0265	0.9990	0.1473
		6	0.6477	63.1659	-3.9302	0.0314	0.9987	0.1489
		7	0.6820	63.7355	-3.3606	0.0275	0.9990	0.1653
		8	0.6686	63.2081	-3.8879	0.0311	0.9988	0.1600
		9	0.6779	63.1449	-3.9511	0.0315	0.9988	0.1852
		10	0.8774	65.3967	-1.6993	0.0188	0.9993	0.1871
7	10	Ort.	0.6769	63.6606	-3.4354	0.0282	0.9989	0.1625
		1	0.6893	63.6108	-3.4852	0.0283	0.9989	0.1512
		2	0.5952	62.6835	-4.4125	0.0351	0.9986	0.1350
		3	0.7398	64.1865	-2.9095	0.0248	0.9991	0.2030
		4	0.7093	63.7514	-3.3446	0.0274	0.9990	0.1825
		5	0.7417	64.1463	-2.9497	0.0250	0.9990	0.1688
		6	0.5764	63.1618	-3.9342	0.0314	0.9987	0.1506
		7	0.6622	63.1274	-3.9687	0.0316	0.9987	0.1540
		8	0.7815	64.2924	-2.8036	0.0242	0.9991	0.2040
		9	0.6464	63.2389	-3.8571	0.0308	0.9988	0.1384
		10	0.6268	64.4071	-2.6889	0.0236	0.9990	0.1370
8	10	Ort.	0.6454	63.1776	-3.9185	0.0319	0.9987	0.1538
		1	0.6074	62.2679	-4.8282	0.0386	0.9984	0.1574
		2	0.5350	62.8232	-4.2728	0.0339	0.9986	0.1374
		3	0.6623	63.1572	-3.9388	0.0314	0.9988	0.1547
		4	0.6917	62.9307	-4.1653	0.0331	0.9987	0.1659
		5	0.6427	62.8087	-4.2873	0.0341	0.9987	0.1739
		6	0.8212	65.1960	-1.9001	0.0197	0.9992	0.1818
		7	0.6744	63.7638	-3.3322	0.0273	0.9989	0.1843
		8	0.5715	61.9827	-5.1133	0.0412	0.9983	0.1035
		9	0.7155	63.8999	-3.1961	0.0265	0.9990	0.1623
		10	0.5325	62.9456	-4.1505	0.0330	0.9986	0.1163
9	10	Ort.	0.5664	62.9721	-4.1240	0.0334	0.9986	0.1159
		1	0.6297	62.6940	-4.4021	0.0350	0.9986	0.1453
		2	0.5779	62.4011	-4.6949	0.0374	0.9985	0.1393
		3	0.6811	63.7290	-3.3670	0.0276	0.9990	0.1659
		4	0.5144	61.7318	-5.3642	0.0436	0.9981	0.0848
		5	0.4480	62.6293	-4.4667	0.0355	0.9984	0.0538
		6	0.4507	63.2496	-3.8465	0.0308	0.9986	0.0974
		7	0.5496	63.8979	-3.1981	0.0265	0.9988	0.1301
		8	0.6033	62.7930	-4.3030	0.0342	0.9985	0.1171
		9	0.5201	62.1894	-4.9066	0.0393	0.9983	0.1277
		10	0.6895	64.4054	-2.6907	0.0236	0.9990	0.0973
10	10	Ort.	0.5923	62.9900	-4.1060	0.0331	0.9986	0.1220
		1	0.5000	63.4071	-3.6889	0.0297	0.9986	0.0677
		2	0.4117	62.6749	-4.4211	0.0351	0.9984	0.0614
		3	0.6262	62.2262	-4.8698	0.0389	0.9985	0.1623
		4	0.5435	63.2193	-3.8767	0.0310	0.9987	0.1389
		5	0.5957	62.1855	-4.9105	0.0393	0.9983	0.1369
		6	0.5607	62.1518	-4.9442	0.0396	0.9983	0.0934
		7	0.5538	62.6217	-4.4743	0.0356	0.9985	0.1002
		8	0.6284	63.2794	-3.8166	0.0306	0.9987	0.0889
		9	0.7490	64.6316	-2.4644	0.0224	0.9992	0.1810
		10	0.7535	63.5027	-3.5933	0.0290	0.9989	0.1889

Test_7, Bulanık C-Ortalamalar								
Canny (Gradient Threshold (0.4), Operator Scale (0.5))								
Küme Sayısı (k)	Maksimum Döngü Sayısı	Tekrarlama Sayısı	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
2	10	Ort.	0.4409	65.3697	-3.3787	0.0189	0.9991	0.0343
		1	0.4269	65.3640	-3.3844	0.0189	0.9991	0.0311
		2	0.4269	65.3641	-3.3844	0.0189	0.9991	0.0311
		3	0.4269	65.3641	-3.3844	0.0189	0.9991	0.0311
		4	0.5622	65.3970	-3.3515	0.0188	0.9992	0.0624
		5	0.4312	65.3878	-3.3606	0.0188	0.9991	0.0318
		6	0.4269	65.3641	-3.3844	0.0189	0.9991	0.0311
		7	0.4269	65.3640	-3.3844	0.0189	0.9991	0.0311
		8	0.4269	65.3641	-3.3844	0.0189	0.9991	0.0311
		9	0.4269	65.3640	-3.3844	0.0189	0.9991	0.0311
		10	0.4269	65.3641	-3.3844	0.0189	0.9991	0.0311
3	10	Ort.	0.5607	64.9240	-3.8245	0.0209	0.9991	0.0663
		1	0.6091	64.9281	-3.8204	0.0209	0.9991	0.0722
		2	0.5863	65.0928	-3.6557	0.0201	0.9992	0.0776
		3	0.5937	65.0467	-3.7017	0.0203	0.9992	0.0792
		4	0.5137	64.4320	-4.3165	0.0234	0.9990	0.0561
		5	0.5195	64.8215	-3.9270	0.0214	0.9991	0.0449
		6	0.5787	65.0983	-3.6502	0.0201	0.9992	0.0744
		7	0.5274	65.1380	-3.6105	0.0199	0.9991	0.0524
		8	0.5912	65.0382	-3.7102	0.0204	0.9992	0.0756
		9	0.5463	64.7064	-4.0421	0.0220	0.9991	0.0658
		10	0.5415	64.9375	-3.8109	0.0209	0.9991	0.0649
4	10	Ort.	0.5307	65.2004	-3.5481	0.0200	0.9991	0.0568
		1	0.5836	64.9135	-3.8350	0.0210	0.9991	0.0746
		2	0.4238	65.2242	-3.5242	0.0195	0.9991	0.0299
		3	0.7806	65.8992	-2.8492	0.0167	0.9994	0.1189
		4	0.5796	64.6230	-4.1255	0.0224	0.9991	0.0685
		5	0.5284	64.9963	-3.7522	0.0206	0.9991	0.0567
		6	0.4312	65.3641	-3.3844	0.0189	0.9991	0.0324
		7	0.4261	64.5743	-4.1741	0.0227	0.9989	0.0395
		8	0.3916	63.8605	-4.8880	0.0267	0.9988	0.0303
		9	0.7381	67.2400	-1.5085	0.0123	0.9995	0.0868
		10	0.4241	65.3085	-3.4400	0.0192	0.9991	0.0300
5	10	Ort.	0.5494	64.1897	-4.5588	0.0258	0.9989	0.0717
		1	0.5449	63.6319	-5.1166	0.0282	0.9988	0.0707
		2	0.5395	63.6142	-5.1343	0.0283	0.9988	0.0686
		3	0.5913	65.0324	-3.7161	0.0204	0.9992	0.0766
		4	0.4932	63.5644	-5.1840	0.0286	0.9987	0.0624
		5	0.5037	63.6439	-5.1046	0.0281	0.9988	0.0543
		6	0.4616	63.0037	-5.7448	0.0326	0.9985	0.0618
		7	0.5848	65.0071	-3.7414	0.0205	0.9991	0.0787
		8	0.4623	62.7697	-5.9788	0.0344	0.9984	0.0570
		9	0.8462	67.5062	-1.2423	0.0115	0.9996	0.1185
		10	0.4660	64.1239	-4.6246	0.0252	0.9989	0.0682

6	10	Ort.	0.4755	63.8855	-4.8630	0.0273	0.9988	0.0515
		1	0.3596	63.0908	-5.6577	0.0319	0.9984	0.0176
		2	0.3457	63.1266	-5.6219	0.0317	0.9985	0.0222
		3	0.6107	65.0754	-3.6731	0.0202	0.9992	0.0832
		4	0.6041	64.6530	-4.0954	0.0223	0.9991	0.0815
		5	0.4522	62.4929	-6.2556	0.0366	0.9983	0.0579
		6	0.4511	62.7350	-6.0135	0.0346	0.9984	0.0561
		7	0.4674	62.9773	-5.7711	0.0328	0.9985	0.0558
		8	0.4399	65.0796	-3.6688	0.0202	0.9991	0.0314
		9	0.4199	64.9530	-3.7955	0.0208	0.9990	0.0253
		10	0.6041	64.6716	-4.0769	0.0222	0.9991	0.0844
7	10	Ort.	0.4846	63.6118	-5.1367	0.0290	0.9987	0.0570
		1	0.5406	64.2462	-4.5023	0.0245	0.9990	0.0614
		2	0.5340	64.2430	-4.5055	0.0245	0.9989	0.0678
		3	0.5370	64.4970	-4.2515	0.0231	0.9990	0.0706
		4	0.4614	63.3298	-5.4187	0.0302	0.9987	0.0605
		5	0.4036	62.7037	-6.0447	0.0349	0.9984	0.0376
		6	0.4034	64.5089	-4.2396	0.0230	0.9989	0.0227
		7	0.4354	62.6140	-6.1345	0.0356	0.9983	0.0476
		8	0.4732	62.8915	-5.8570	0.0334	0.9985	0.0648
		9	0.4196	62.1981	-6.5503	0.0392	0.9982	0.0514
		10	0.6374	64.8861	-3.8624	0.0211	0.9992	0.0851
8	10	Ort.	0.4787	63.9005	-4.8480	0.0279	0.9987	0.0530
		1	0.4208	65.1193	-3.6292	0.0200	0.9991	0.0302
		2	0.4379	63.2277	-5.5208	0.0309	0.9986	0.0373
		3	0.4024	62.7075	-6.0409	0.0349	0.9984	0.0391
		4	0.3387	63.2078	-5.5406	0.0311	0.9985	0.0181
		5	0.4157	64.3680	-4.3804	0.0238	0.9989	0.0289
		6	0.4916	63.3409	-5.4076	0.0301	0.9986	0.0615
		7	0.8360	67.8190	-0.9295	0.0107	0.9996	0.1351
		8	0.4479	62.4873	-6.2612	0.0367	0.9983	0.0562
		9	0.4102	62.5175	-6.2310	0.0364	0.9983	0.0383
		10	0.5854	64.2096	-4.5388	0.0247	0.9990	0.0857
9	10	Ort.	0.4697	63.4599	-5.2886	0.0301	0.9986	0.0567
		1	0.3921	62.9035	-5.8450	0.0333	0.9984	0.0325
		2	0.4399	63.8761	-4.8724	0.0266	0.9988	0.0547
		3	0.6016	64.8977	-3.8508	0.0211	0.9991	0.0743
		4	0.4242	63.5489	-5.1995	0.0287	0.9987	0.0439
		5	0.5572	64.5275	-4.2210	0.0229	0.9990	0.0761
		6	0.3934	61.8194	-6.9291	0.0428	0.9979	0.0421
		7	0.6028	64.7342	-4.0143	0.0219	0.9991	0.0777
		8	0.4260	63.2623	-5.4862	0.0307	0.9986	0.0563
		9	0.4199	62.3265	-6.4220	0.0381	0.9982	0.0536
		10	0.4394	62.7029	-6.0456	0.0349	0.9984	0.0560
10	10	Ort.	0.5283	63.6694	-5.0791	0.0294	0.9987	0.0715
		1	0.3922	62.9570	-5.7915	0.0329	0.9984	0.0331
		2	0.9084	66.6813	-2.0672	0.0140	0.9995	0.1633
		3	0.3029	62.6212	-6.1272	0.0356	0.9982	0.0110
		4	0.7271	65.5637	-3.1847	0.0181	0.9993	0.1043
		5	0.4528	63.7668	-4.9817	0.0273	0.9987	0.0490
		6	0.5858	64.2050	-4.5434	0.0247	0.9989	0.0871
		7	0.3732	62.2591	-6.4894	0.0387	0.9982	0.0325
		8	0.5308	63.8529	-4.8956	0.0268	0.9989	0.0730
		9	0.4643	61.8817	-6.8668	0.0422	0.9981	0.0621
		10	0.5457	62.9053	-5.8432	0.0333	0.9986	0.0993

Test_8, Bulanık C-Ortalamalar								
Canny (Gradient Threshold (0.4), Operator Scale (0.5))								
Küme Sayısı (k)	Maksimum Döngü Sayısı	Tekrarlama Sayısı	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
2	10	Ort.	0.6935	65.5654	-0.0483	0.0181	0.9991	0.1893
		1	0.6935	65.5654	-0.0483	0.0181	0.9991	0.1893
		2	0.6935	65.5654	-0.0483	0.0181	0.9991	0.1893
		3	0.6935	65.5654	-0.0483	0.0181	0.9991	0.1893
		4	0.6935	65.5654	-0.0483	0.0181	0.9991	0.1893
		5	0.6935	65.5654	-0.0483	0.0181	0.9991	0.1893
		6	0.6935	65.5654	-0.0483	0.0181	0.9991	0.1893
		7	0.6935	65.5654	-0.0483	0.0181	0.9991	0.1893
		8	0.6935	65.5654	-0.0483	0.0181	0.9991	0.1893
		9	0.6935	65.5654	-0.0483	0.0181	0.9991	0.1893
		10	0.6935	65.5654	-0.0483	0.0181	0.9991	0.1893
3	10	Ort.	0.9296	64.7195	-0.8942	0.0220	0.9992	0.2609
		1	0.9341	64.7647	-0.8490	0.0217	0.9992	0.2622
		2	0.9346	64.8156	-0.7981	0.0215	0.9992	0.2708
		3	0.8937	64.1296	-1.4841	0.0251	0.9991	0.2076
		4	0.9220	64.7231	-0.8906	0.0219	0.9992	0.2653
		5	0.9308	64.7817	-0.8320	0.0216	0.9992	0.2715
		6	0.9396	64.8518	-0.7618	0.0213	0.9992	0.2743
		7	0.9341	64.7647	-0.8490	0.0217	0.9992	0.2622
		8	0.9387	64.7842	-0.8295	0.0216	0.9992	0.2622
		9	0.9341	64.7647	-0.8490	0.0217	0.9992	0.2622
		10	0.9346	64.8144	-0.7993	0.0215	0.9992	0.2706
4	10	Ort.	0.8969	64.1378	-1.4759	0.0252	0.9991	0.2419
		1	0.8968	64.0502	-1.5635	0.0256	0.9991	0.2355
		2	0.9141	64.3598	-1.2539	0.0238	0.9991	0.2495
		3	0.8988	64.0598	-1.5539	0.0255	0.9991	0.2325
		4	0.7950	63.4901	-2.1235	0.0291	0.9989	0.1995
		5	0.9565	64.5370	-1.0767	0.0229	0.9992	0.2768
		6	0.7576	63.4120	-2.2017	0.0296	0.9988	0.1814
		7	0.8563	64.1090	-1.5047	0.0252	0.9991	0.2454
		8	0.9598	64.4230	-1.1907	0.0235	0.9992	0.2654
		9	0.9676	64.4095	-1.2042	0.0236	0.9992	0.2585
		10	0.9664	64.5279	-1.0858	0.0229	0.9992	0.2740
5	10	Ort.	0.8299	63.4083	-2.2054	0.0299	0.9989	0.2189
		1	0.8158	63.3888	-2.2249	0.0298	0.9989	0.2225
		2	0.7794	62.6362	-2.9775	0.0354	0.9987	0.1945
		3	0.8170	63.4758	-2.1379	0.0292	0.9989	0.2215
		4	0.9387	64.5063	-1.1074	0.0230	0.9992	0.2657
		5	0.9127	64.1955	-1.4182	0.0247	0.9991	0.2557
		6	0.8362	63.4405	-2.1732	0.0294	0.9990	0.2065
		7	0.7417	62.9892	-2.6245	0.0327	0.9988	0.1971
		8	0.8379	63.5054	-2.1083	0.0290	0.9990	0.2135
		9	0.8229	63.2291	-2.3846	0.0309	0.9989	0.2126
		10	0.7970	62.7160	-2.8977	0.0348	0.9988	0.1991

6	10	Ort.	0.7865	62.8071	-2.8066	0.0345	0.9988	0.1978
		1	0.7837	62.5506	-3.0631	0.0361	0.9987	0.1995
		2	0.9200	64.4271	-1.1866	0.0235	0.9992	0.2661
		3	0.8436	63.2158	-2.3979	0.0310	0.9989	0.1972
		4	0.7774	62.8712	-2.7425	0.0336	0.9988	0.1910
		5	0.7878	63.1584	-2.4553	0.0314	0.9988	0.2235
		6	0.7735	62.4953	-3.1184	0.0366	0.9987	0.1874
		7	0.7892	63.1372	-2.4765	0.0316	0.9989	0.1998
		8	0.7753	62.4862	-3.1275	0.0367	0.9987	0.1906
		9	0.7031	61.8041	-3.8096	0.0429	0.9984	0.1643
		10	0.7114	61.9253	-3.6884	0.0417	0.9984	0.1583
7	10	Ort.	0.7598	62.5339	-3.0798	0.0368	0.9986	0.1835
		1	0.7903	62.9156	-2.6981	0.0332	0.9988	0.1935
		2	0.6904	62.2358	-3.3779	0.0389	0.9985	0.1763
		3	0.7073	61.6038	-4.0099	0.0449	0.9983	0.1640
		4	0.7266	61.8837	-3.7300	0.0421	0.9984	0.1799
		5	0.6936	61.4799	-4.1338	0.0462	0.9982	0.1454
		6	0.7576	62.5502	-3.0635	0.0361	0.9987	0.1744
		7	0.8450	63.2548	-2.3589	0.0307	0.9989	0.1932
		8	0.7771	62.9461	-2.6676	0.0330	0.9988	0.1928
		9	0.7922	62.5877	-3.0260	0.0358	0.9987	0.1944
		10	0.8180	63.8811	-1.7326	0.0266	0.9990	0.2212
8	10	Ort.	0.7628	62.9419	-2.6718	0.0334	0.9987	0.1748
		1	0.8520	63.5110	-2.1027	0.0290	0.9989	0.1899
		2	0.6742	62.6087	-3.0050	0.0357	0.9985	0.1451
		3	0.6593	62.2008	-3.4129	0.0392	0.9984	0.1353
		4	0.6906	62.6768	-2.9369	0.0351	0.9986	0.1562
		5	0.7101	62.3065	-3.3072	0.0382	0.9985	0.1417
		6	0.9059	64.3739	-1.2398	0.0238	0.9991	0.2317
		7	0.7131	62.2900	-3.3237	0.0384	0.9985	0.1470
		8	0.7700	62.6682	-2.9455	0.0352	0.9987	0.1920
		9	0.8499	63.5592	-2.0545	0.0287	0.9990	0.2104
		10	0.8026	63.2235	-2.3902	0.0310	0.9989	0.1990
9	10	Ort.	0.7166	62.3178	-3.2959	0.0388	0.9985	0.1454
		1	0.7715	62.7902	-2.8235	0.0342	0.9987	0.1653
		2	0.7023	61.7026	-3.9111	0.0439	0.9982	0.1379
		3	0.7939	62.6671	-2.9466	0.0352	0.9987	0.1632
		4	0.7042	62.0975	-3.5162	0.0401	0.9984	0.1193
		5	0.8123	63.5054	-2.1083	0.0290	0.9989	0.1633
		6	0.6505	62.0055	-3.6082	0.0410	0.9983	0.1199
		7	0.7503	62.5255	-3.0882	0.0364	0.9986	0.1615
		8	0.6076	60.8933	-4.7204	0.0529	0.9978	0.1254
		9	0.8046	63.3975	-2.2162	0.0297	0.9989	0.1966
		10	0.5685	61.5937	-4.0200	0.0451	0.9980	0.1014
10	10	Ort.	0.7094	62.3811	-3.2326	0.0384	0.9985	0.1521
		1	0.6989	62.0851	-3.5286	0.0402	0.9984	0.1454
		2	0.9017	63.9055	-1.7082	0.0265	0.9991	0.2153
		3	0.8321	63.5351	-2.0785	0.0288	0.9990	0.2195
		4	0.5482	63.3801	-2.2336	0.0299	0.9986	0.0869
		5	0.6820	61.7289	-3.8848	0.0437	0.9983	0.1460
		6	0.6829	61.9280	-3.6857	0.0417	0.9983	0.1372
		7	0.6649	62.2589	-3.3548	0.0387	0.9984	0.1159
		8	0.7196	62.1136	-3.5001	0.0400	0.9985	0.1551
		9	0.6355	60.7599	-4.8538	0.0546	0.9978	0.1451
		10	0.7279	62.1161	-3.4976	0.0399	0.9985	0.1543

Test_9, Bulanık C-Ortalamalar								
Canny (Gradient Threshold (0.3), Operator Scale (0.5))								
Küme Sayısı (k)	Maksimum Döngü Sayısı	Tekrarlama Sayısı	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
2	10	Ort.	0.7245	63.1023	-2.0952	0.0318	0.9987	0.0779
		1	0.7257	63.1485	-2.0490	0.0315	0.9987	0.0772
		2	0.7257	63.1485	-2.0490	0.0315	0.9987	0.0772
		3	0.7257	63.1485	-2.0490	0.0315	0.9987	0.0772
		4	0.7247	63.1181	-2.0793	0.0317	0.9987	0.0778
		5	0.7247	63.1181	-2.0793	0.0317	0.9987	0.0778
		6	0.7166	62.8107	-2.3868	0.0340	0.9986	0.0812
		7	0.7257	63.1485	-2.0490	0.0315	0.9987	0.0772
		8	0.7247	63.1181	-2.0793	0.0317	0.9987	0.0778
		9	0.7260	63.1151	-2.0824	0.0317	0.9987	0.0779
		10	0.7257	63.1485	-2.0490	0.0315	0.9987	0.0772
3	10	Ort.	0.6379	61.2082	-3.9893	0.0495	0.9979	0.0581
		1	0.6222	60.9032	-4.2943	0.0528	0.9978	0.0581
		2	0.6421	61.2689	-3.9286	0.0486	0.9980	0.0602
		3	0.6217	61.0373	-4.1602	0.0512	0.9979	0.0555
		4	0.6411	61.2477	-3.9498	0.0488	0.9980	0.0609
		5	0.6323	61.0774	-4.1200	0.0507	0.9979	0.0487
		6	0.6218	60.8385	-4.3590	0.0536	0.9978	0.0474
		7	0.6388	61.2053	-3.9921	0.0493	0.9979	0.0605
		8	0.6190	60.9057	-4.2918	0.0528	0.9978	0.0563
		9	0.6265	60.9973	-4.2002	0.0517	0.9978	0.0590
		10	0.7136	62.6007	-2.5968	0.0357	0.9985	0.0747
4	10	Ort.	0.5842	59.9440	-5.2534	0.0661	0.9972	0.0480
		1	0.5374	59.4249	-5.7726	0.0742	0.9968	0.0471
		2	0.5297	59.4027	-5.7947	0.0746	0.9968	0.0494
		3	0.6349	60.3434	-4.8541	0.0601	0.9975	0.0633
		4	0.5962	59.8998	-5.2977	0.0665	0.9971	0.0518
		5	0.6009	60.3973	-4.8002	0.0593	0.9975	0.0549
		6	0.6058	60.1640	-5.0335	0.0626	0.9973	0.0512
		7	0.5771	60.0747	-5.1228	0.0639	0.9972	0.0421
		8	0.5919	60.0411	-5.1563	0.0644	0.9972	0.0378
		9	0.6172	60.0569	-5.1406	0.0642	0.9973	0.0502
		10	0.5513	59.6355	-5.5619	0.0707	0.9969	0.0326
5	10	Ort.	0.6035	60.3581	-4.8394	0.0616	0.9974	0.0550
		1	0.5501	59.3378	-5.8597	0.0757	0.9968	0.0517
		2	0.6262	60.5249	-4.6726	0.0576	0.9976	0.0568
		3	0.5384	59.1862	-6.0113	0.0784	0.9966	0.0554
		4	0.6401	60.9943	-4.2032	0.0517	0.9978	0.0497
		5	0.4938	58.4084	-6.7890	0.0938	0.9958	0.0298
		6	0.6409	61.5342	-3.6633	0.0457	0.9981	0.0523
		7	0.6447	60.5058	-4.6917	0.0579	0.9976	0.0654
		8	0.6897	61.6878	-3.5097	0.0441	0.9982	0.0841
		9	0.6037	60.3203	-4.8772	0.0604	0.9975	0.0543
		10	0.6075	61.0813	-4.1161	0.0507	0.9979	0.0505

6	10	Ort.	0.5867	59.8620	-5.3355	0.0679	0.9971	0.0497
		1	0.6424	60.9739	-4.2236	0.0520	0.9978	0.0445
		2	0.5801	59.6643	-5.5332	0.0703	0.9969	0.0426
		3	0.5831	60.2450	-4.9524	0.0615	0.9974	0.0437
		4	0.5841	59.6271	-5.5703	0.0709	0.9970	0.0651
		5	0.6491	60.7035	-4.4940	0.0553	0.9977	0.0504
		6	0.5507	58.7614	-6.4361	0.0865	0.9962	0.0393
		7	0.5963	59.9579	-5.2396	0.0657	0.9972	0.0613
		8	0.5541	59.6776	-5.5199	0.0700	0.9970	0.0403
		9	0.5499	59.0492	-6.1483	0.0809	0.9965	0.0466
		10	0.5773	59.9597	-5.2378	0.0656	0.9973	0.0632
7	10	Ort.	0.5363	58.9972	-6.2002	0.0828	0.9963	0.0461
		1	0.6045	59.6478	-5.5497	0.0705	0.9970	0.0473
		2	0.5516	59.0200	-6.1775	0.0815	0.9964	0.0450
		3	0.5249	58.3262	-6.8712	0.0956	0.9957	0.0439
		4	0.5140	58.4637	-6.7337	0.0926	0.9959	0.0403
		5	0.5055	59.0849	-6.1126	0.0803	0.9965	0.0420
		6	0.5844	60.4288	-4.7687	0.0589	0.9976	0.0630
		7	0.4776	58.1688	-7.0287	0.0991	0.9952	0.0267
		8	0.5137	59.1184	-6.0791	0.0797	0.9965	0.0472
		9	0.5612	59.1717	-6.0258	0.0787	0.9965	0.0500
		10	0.5257	58.5421	-6.6554	0.0910	0.9960	0.0554
8	10	Ort.	0.5322	58.9396	-6.2579	0.0850	0.9962	0.0451
		1	0.5161	59.4710	-5.7265	0.0734	0.9968	0.0447
		2	0.5476	58.1692	-7.0283	0.0991	0.9956	0.0568
		3	0.5625	58.8941	-6.3033	0.0839	0.9963	0.0582
		4	0.5502	58.9019	-6.2956	0.0837	0.9962	0.0417
		5	0.6638	61.1021	-4.0954	0.0505	0.9979	0.0581
		6	0.4811	58.3168	-6.8807	0.0958	0.9955	0.0360
		7	0.4862	57.9708	-7.2267	0.1038	0.9951	0.0352
		8	0.5960	60.1652	-5.0323	0.0626	0.9972	0.0429
		9	0.4658	58.3400	-6.8575	0.0953	0.9956	0.0353
		10	0.4524	58.0644	-7.1331	0.1015	0.9953	0.0419
9	10	Ort.	0.5482	58.9529	-6.2445	0.0844	0.9962	0.0500
		1	0.4995	58.6891	-6.5084	0.0879	0.9960	0.0505
		2	0.5578	58.9302	-6.2672	0.0832	0.9964	0.0573
		3	0.5696	59.0993	-6.0982	0.0800	0.9965	0.0622
		4	0.5360	57.9532	-7.2443	0.1042	0.9953	0.0479
		5	0.5703	59.5918	-5.6056	0.0714	0.9970	0.0566
		6	0.4825	57.8401	-7.3573	0.1069	0.9951	0.0396
		7	0.4633	58.3863	-6.8112	0.0943	0.9956	0.0339
		8	0.6295	60.2371	-4.9604	0.0616	0.9974	0.0557
		9	0.5263	58.2776	-6.9198	0.0967	0.9956	0.0412
		10	0.6468	60.5246	-4.6729	0.0576	0.9975	0.0553
10	10	Ort.	0.5379	59.4427	-5.7548	0.0774	0.9965	0.0458
		1	0.5935	59.6052	-5.5923	0.0712	0.9968	0.0535
		2	0.4925	58.5635	-6.6340	0.0905	0.9959	0.0376
		3	0.4930	58.3407	-6.8567	0.0953	0.9956	0.0347
		4	0.6146	63.1754	-2.0221	0.0313	0.9987	0.0456
		5	0.5492	58.5562	-6.6413	0.0907	0.9959	0.0492
		6	0.4768	58.3076	-6.8899	0.0960	0.9956	0.0429
		7	0.4749	58.1862	-7.0113	0.0987	0.9953	0.0358
		8	0.5166	59.8952	-5.3023	0.0666	0.9971	0.0479
		9	0.6353	60.2542	-4.9433	0.0613	0.9973	0.0605
		10	0.5330	59.5426	-5.6549	0.0722	0.9968	0.0498

Test_10, Bulanık C-Ortalamalar								
Canny (Gradient Threshold (0.4), Operator Scale (0.5))								
Küme Sayısı (k)	Maksimum Döngü Sayısı	Tekrarlama Sayısı	F-Skor	YSGO	SGO	OKH	YBİÖ	KK
2	10	Ort.	0.6353	62.9297	-0.5961	0.0331	0.9986	0.1825
		1	0.6353	62.9297	-0.5961	0.0331	0.9986	0.1825
		2	0.6353	62.9297	-0.5961	0.0331	0.9986	0.1825
		3	0.6353	62.9297	-0.5961	0.0331	0.9986	0.1825
		4	0.6353	62.9297	-0.5961	0.0331	0.9986	0.1825
		5	0.6353	62.9297	-0.5961	0.0331	0.9986	0.1825
		6	0.6353	62.9297	-0.5961	0.0331	0.9986	0.1825
		7	0.6353	62.9297	-0.5961	0.0331	0.9986	0.1825
		8	0.6353	62.9297	-0.5961	0.0331	0.9986	0.1825
		9	0.6353	62.9297	-0.5961	0.0331	0.9986	0.1825
		10	0.6353	62.9297	-0.5961	0.0331	0.9986	0.1825
3	10	Ort.	0.6247	61.0737	-2.4522	0.0511	0.9980	0.1268
		1	0.6222	60.6449	-2.8809	0.0561	0.9977	0.1124
		2	0.6365	60.9509	-2.5750	0.0522	0.9979	0.1294
		3	0.6400	61.5507	-1.9751	0.0455	0.9982	0.1309
		4	0.6340	61.7767	-1.7491	0.0432	0.9983	0.1708
		5	0.6269	60.6837	-2.8422	0.0556	0.9978	0.1122
		6	0.6411	61.6013	-1.9246	0.0450	0.9982	0.1364
		7	0.6043	60.6507	-2.8752	0.0560	0.9977	0.1116
		8	0.6079	60.5454	-2.9805	0.0574	0.9977	0.1024
		9	0.6311	61.6794	-1.8465	0.0442	0.9983	0.1506
		10	0.6025	60.6529	-2.8729	0.0559	0.9977	0.1117
4	10	Ort.	0.5888	60.6414	-2.8845	0.0574	0.9976	0.1103
		1	0.4610	60.7003	-2.8256	0.0553	0.9975	0.0276
		2	0.6911	61.6162	-1.9096	0.0448	0.9983	0.1898
		3	0.6011	62.3108	-1.2150	0.0382	0.9984	0.1587
		4	0.5366	59.3708	-4.1551	0.0752	0.9968	0.0896
		5	0.5913	59.7631	-3.7628	0.0687	0.9972	0.0954
		6	0.4854	60.7577	-2.7681	0.0546	0.9976	0.0258
		7	0.7091	61.7987	-1.7272	0.0430	0.9984	0.1774
		8	0.5592	59.7109	-3.8149	0.0695	0.9969	0.0966
		9	0.6311	60.0691	-3.4568	0.0640	0.9974	0.1187
		10	0.6224	60.3161	-3.2097	0.0605	0.9976	0.1235
5	10	Ort.	0.5973	60.3177	-3.2082	0.0612	0.9975	0.1207
		1	0.5286	60.5057	-3.0202	0.0579	0.9976	0.1136
		2	0.6330	59.9567	-3.5691	0.0657	0.9973	0.1256
		3	0.6469	61.0506	-2.4753	0.0511	0.9980	0.1399
		4	0.5866	59.4173	-4.1085	0.0744	0.9969	0.1114
		5	0.5887	59.9401	-3.5857	0.0659	0.9973	0.1217
		6	0.6497	60.7016	-2.8242	0.0553	0.9978	0.1411
		7	0.4886	60.2585	-3.2674	0.0613	0.9973	0.0346
		8	0.6753	61.8062	-1.7197	0.0429	0.9983	0.1834
		9	0.6125	59.9442	-3.5816	0.0659	0.9973	0.1154
		10	0.5634	59.5958	-3.9300	0.0714	0.9971	0.1198

6	10	Ort.	0.5839	59.6989	-3.8270	0.0705	0.9971	0.1174
		1	0.4926	58.7047	-4.8212	0.0876	0.9960	0.0815
		2	0.6268	60.1837	-3.3422	0.0623	0.9976	0.1285
		3	0.5658	60.0362	-3.4897	0.0645	0.9974	0.1267
		4	0.6190	59.9044	-3.6214	0.0665	0.9973	0.1044
		5	0.5580	58.9541	-4.5718	0.0827	0.9965	0.1169
		6	0.5946	60.4185	-3.1074	0.0591	0.9976	0.1282
		7	0.5754	59.1602	-4.3656	0.0789	0.9966	0.1131
		8	0.5551	60.5632	-2.9627	0.0571	0.9976	0.1279
		9	0.5686	59.0112	-4.5146	0.0817	0.9966	0.1095
		10	0.6827	60.0524	-3.4734	0.0642	0.9976	0.1377
7	10	Ort.	0.6018	60.1280	-3.3979	0.0651	0.9973	0.1284
		1	0.6877	61.4125	-2.1134	0.0470	0.9982	0.1919
		2	0.6107	60.5632	-2.9627	0.0571	0.9977	0.1210
		3	0.5161	59.7393	-3.7866	0.0690	0.9969	0.0967
		4	0.5033	59.2999	-4.2260	0.0764	0.9966	0.0869
		5	0.5563	58.7252	-4.8007	0.0872	0.9963	0.0998
		6	0.6087	59.4756	-4.0503	0.0734	0.9970	0.1171
		7	0.6953	62.5877	-0.9382	0.0358	0.9986	0.2197
		8	0.6573	60.4004	-3.1255	0.0593	0.9977	0.1226
		9	0.5483	59.0461	-4.4798	0.0810	0.9965	0.0972
		10	0.6344	60.0300	-3.4958	0.0646	0.9974	0.1308
8	10	Ort.	0.5732	58.8348	-4.6910	0.0856	0.9964	0.1066
		1	0.6553	59.4230	-4.1028	0.0743	0.9970	0.1487
		2	0.5274	58.5467	-4.9792	0.0909	0.9960	0.0999
		3	0.5289	58.3898	-5.1361	0.0942	0.9958	0.0996
		4	0.5572	58.4001	-5.1258	0.0940	0.9961	0.0886
		5	0.6660	59.8328	-3.6930	0.0676	0.9974	0.1281
		6	0.5730	58.7915	-4.7343	0.0859	0.9964	0.1179
		7	0.6305	59.4023	-4.1236	0.0746	0.9970	0.1335
		8	0.5098	58.8516	-4.6743	0.0847	0.9963	0.0654
		9	0.5455	58.5415	-4.9843	0.0910	0.9961	0.0941
		10	0.5386	58.1690	-5.3568	0.0991	0.9956	0.0900
9	10	Ort.	0.5688	59.2662	-4.2596	0.0782	0.9967	0.1096
		1	0.4787	59.0896	-4.4363	0.0802	0.9964	0.0782
		2	0.7046	60.6021	-2.9238	0.0566	0.9979	0.1564
		3	0.5309	58.6885	-4.8373	0.0879	0.9961	0.1066
		4	0.6290	60.2133	-3.3126	0.0619	0.9976	0.1278
		5	0.5134	58.7089	-4.8169	0.0875	0.9961	0.0826
		6	0.5414	58.2873	-5.2386	0.0965	0.9958	0.1003
		7	0.5013	58.5374	-4.9884	0.0911	0.9958	0.0909
		8	0.5375	59.3500	-4.1759	0.0755	0.9968	0.0929
		9	0.5850	58.9253	-4.6005	0.0833	0.9965	0.0996
		10	0.6666	60.2597	-3.2661	0.0613	0.9976	0.1608
10	10	Ort.	0.5226	59.1106	-4.4153	0.0816	0.9964	0.0864
		1	0.4011	58.5390	-4.9868	0.0910	0.9957	0.0237
		2	0.5058	58.7555	-4.7704	0.0866	0.9962	0.0949
		3	0.6863	61.6002	-1.9257	0.0450	0.9983	0.1422
		4	0.5518	59.0955	-4.4304	0.0801	0.9965	0.1085
		5	0.4357	58.9143	-4.6116	0.0835	0.9962	0.0419
		6	0.5233	57.9036	-5.6222	0.1054	0.9953	0.0970
		7	0.5175	58.6835	-4.8424	0.0881	0.9962	0.0616
		8	0.5066	58.3755	-5.1503	0.0945	0.9958	0.0723
		9	0.5294	59.3486	-4.1772	0.0755	0.9967	0.1120
		10	0.5682	59.8899	-3.6360	0.0667	0.9973	0.1098

Ek-4:

Ortalama Kaydırma yöntemine ilişkin; “r” yarıçap parametresi için tüm sonuç değerleri.

Test_1, Ortalama Kaydırma						
Canny (Gradient Threshold (0.5), Operator Scale (0.5))						
r	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
2	0.5921	65.0413	-0.3148	0.0204	0.9992	0.1535
3	0.5924	65.0375	-0.3186	0.0204	0.9992	0.1533
4	0.5953	65.0274	-0.3287	0.0204	0.9991	0.1522
5	0.6061	65.0178	-0.3383	0.0205	0.9992	0.1545
6	0.6138	65.0334	-0.3228	0.0204	0.9992	0.1597
7	0.6003	65.0332	-0.3229	0.0204	0.9992	0.1567
8	0.6007	65.0286	-0.3276	0.0204	0.9992	0.1534
9	0.6136	65.0282	-0.3279	0.0204	0.9992	0.1601
10	0.5907	64.9884	-0.3678	0.0206	0.9991	0.1482

Test_2, Ortalama Kaydırma						
Canny (Gradient Threshold (0.2), Operator Scale (0.5))						
r	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
2	0.9316	65.0013	-2.8665	0.0206	0.9992	0.1088
3	0.9307	64.9932	-2.8746	0.0206	0.9992	0.1080
4	0.9252	65.0064	-2.8614	0.0205	0.9992	0.1064
5	0.9262	65.0021	-2.8658	0.0206	0.9992	0.1111
6	0.9235	65.0202	-2.8476	0.0205	0.9992	0.1077
7	0.9265	64.9898	-2.8780	0.0206	0.9992	0.1112
8	0.9300	64.9831	-2.8848	0.0206	0.9992	0.1122
9	0.9108	64.8661	-3.0017	0.0212	0.9991	0.1080
10	0.9193	64.9121	-2.9558	0.0210	0.9992	0.1121

Test_3, Ortalama Kaydırma						
Canny (Gradient Threshold (0.3), Operator Scale (0.5))						
r	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
2	0.6863	64.2803	-2.3099	0.0243	0.9990	0.0571
3	0.6858	64.2750	-2.3151	0.0243	0.9989	0.0565
4	0.6878	64.2786	-2.3116	0.0243	0.9989	0.0577
5	0.6877	64.2654	-2.3247	0.0244	0.9989	0.0561
6	0.6898	64.2580	-2.3322	0.0244	0.9989	0.0572
7	0.6969	64.2443	-2.3459	0.0245	0.9989	0.0576
8	0.6990	64.2176	-2.3726	0.0246	0.9989	0.0596
9	0.7183	64.1266	-2.4635	0.0251	0.9989	0.0638
10	0.7032	64.2043	-2.3859	0.0247	0.9989	0.0609

Test 4, Ortalama Kaydırma						
Canny (Gradient Threshold (0.2), Operator Scale (0.5))						
r	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
2	0.7380	63.2870	-1.1498	0.0305	0.9988	0.1781
3	0.7200	63.3084	-1.1284	0.0304	0.9988	0.1769
4	0.7420	63.3368	-1.1000	0.0302	0.9988	0.1877
5	0.7159	63.3261	-1.1107	0.0302	0.9988	0.1789
6	0.7367	63.3343	-1.1025	0.0302	0.9988	0.1882
7	0.7234	63.3127	-1.1241	0.0303	0.9988	0.1807
8	0.7344	63.2789	-1.1579	0.0306	0.9988	0.1809
9	0.7168	63.2780	-1.1588	0.0306	0.9987	0.1733
10	0.7369	63.2200	-1.2169	0.0310	0.9987	0.1768

Test 5, Ortalama Kaydırma						
Canny (Gradient Threshold (0.1), Operator Scale (0.5))						
r	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
2	0.8177	61.8684	-1.8106	0.0423	0.9984	0.1392
3	0.8185	61.8950	-1.7840	0.0420	0.9984	0.1405
4	0.8186	61.8778	-1.8012	0.0422	0.9984	0.1400
5	0.8206	61.8923	-1.7867	0.0421	0.9984	0.1401
6	0.8060	61.7568	-1.9222	0.0434	0.9984	0.1342
7	0.7888	61.7448	-1.9341	0.0435	0.9983	0.1257
8	0.7872	61.7125	-1.9665	0.0438	0.9983	0.1263
9	0.7831	61.6609	-2.0181	0.0444	0.9983	0.1257
10	0.7794	61.6233	-2.0556	0.0447	0.9983	0.1253

Test 6, Ortalama Kaydırma						
Canny (Gradient Threshold (0.4), Operator Scale (0.5))						
r	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
2	0.9885	66.6454	-0.4506	0.0141	0.9995	0.3059
3	0.9751	66.7294	-0.3666	0.0138	0.9995	0.3108
4	0.9851	66.6776	-0.4184	0.0140	0.9995	0.3103
5	0.9836	66.7245	-0.3715	0.0138	0.9995	0.3094
6	0.9683	66.7497	-0.3464	0.0137	0.9995	0.3107
7	0.9737	66.6732	-0.4228	0.0140	0.9995	0.3037
8	0.9662	66.7336	-0.3624	0.0138	0.9995	0.2983
9	0.9773	66.7376	-0.3584	0.0138	0.9995	0.3061
10	0.9772	66.4982	-0.5978	0.0146	0.9995	0.2742

Test 7, Ortalama Kaydırma						
Canny (Gradient Threshold (0.4), Operator Scale (0.5))						
r	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
2	0.8448	67.4875	-1.2610	0.0116	0.9995	0.0758
3	0.8393	67.4802	-1.2683	0.0116	0.9995	0.0748
4	0.8415	67.4722	-1.2763	0.0116	0.9995	0.0749
5	0.8398	67.4891	-1.2594	0.0116	0.9995	0.0765
6	0.8367	67.4762	-1.2723	0.0116	0.9995	0.0762
7	0.8402	67.4766	-1.2719	0.0116	0.9995	0.0752
8	0.8364	67.4858	-1.2627	0.0116	0.9995	0.0716
9	0.8442	67.5057	-1.2428	0.0115	0.9995	0.0769
10	0.8333	67.4109	-1.3376	0.0118	0.9995	0.0741

Test 8, Ortalama Kaydırma						
Canny (Gradient Threshold (0.4), Operator Scale (0.5))						
r	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
2	0.8891	65.2517	-0.3620	0.0194	0.9992	0.2437
3	0.9399	65.1951	-0.4186	0.0197	0.9992	0.2598
4	0.9410	65.2896	-0.3241	0.0192	0.9992	0.2692
5	0.9525	65.1953	-0.4184	0.0197	0.9993	0.2867
6	0.9563	64.8046	-0.8091	0.0215	0.9992	0.2742
7	0.9390	64.7851	-0.8286	0.0216	0.9992	0.2566
8	0.9405	65.2319	-0.3818	0.0195	0.9992	0.2766
9	0.9508	64.8568	-0.7569	0.0213	0.9992	0.2636
10	0.9514	64.7941	-0.8196	0.0216	0.9992	0.2684

Test 9, Ortalama Kaydırma						
Canny (Gradient Threshold (0.3), Operator Scale (0.5))						
r	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
2	0.8042	63.2079	-1.9896	0.0311	0.9988	0.0589
3	0.8078	63.2046	-1.9929	0.0311	0.9988	0.0606
4	0.8059	63.1777	-2.0198	0.0313	0.9988	0.0597
5	0.8087	63.2451	-1.9524	0.0308	0.9988	0.0598
6	0.8001	63.2074	-1.9901	0.0311	0.9988	0.0558
7	0.7976	63.1821	-2.0154	0.0313	0.9988	0.0549
8	0.7740	63.2194	-1.9781	0.0310	0.9988	0.0483
9	0.7806	63.2363	-1.9612	0.0309	0.9988	0.0559
10	0.7976	63.1828	-2.0147	0.0312	0.9988	0.0541

Test 10, Ortalama Kaydırma						
Canny (Gradient Threshold (0.4), Operator Scale (0.5))						
r	F-Skor	YSGO	SGO	OKH	YBiÖ	KK
2	0.6941	62.8983	-0.6276	0.0334	0.9987	0.2147
3	0.6948	62.8222	-0.7037	0.0340	0.9986	0.2137
4	0.6930	62.8442	-0.6816	0.0338	0.9986	0.2139
5	0.6974	62.8597	-0.6661	0.0337	0.9986	0.2156
6	0.6927	62.8273	-0.6985	0.0339	0.9986	0.2124
7	0.6754	62.8244	-0.7015	0.0339	0.9986	0.2094
8	0.6908	62.8391	-0.6868	0.0338	0.9986	0.2102
9	0.6807	62.7201	-0.8057	0.0348	0.9986	0.2071
10	0.6730	62.7691	-0.7568	0.0344	0.9986	0.2022