ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

RADAR VİDEO GÖRÜNTÜLERİNDE KARASAL ALANLARIN BELİRLENMESİ

Sümeye Nur AKAYDIN

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

ANKARA
2018

Her hakkı saklıdır

TEZ ONAYI

Sümeye Nur AKAYDIN tarafından hazırlanan "**Radar Video Görüntülerinde Karasal Alanların Belirlenmesi**" adlı tez çalışması 09/01/2018 tarihinde aşağıdaki jüri tarafından oy birliği ile Ankara Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Yrd. Doç. Dr. Gökhan SOYSAL
Ankara Üniversitesi Elektrik – Elektronik Mühendisliği Anabilim Dalı

Jüri Üyeleri :

Başkan : Doç. Dr. Umut ORGUNER
Orta Doğu Teknik Üniversitesi Elektrik–Elektronik Mühendisliği Anabilim Dalı

Üye : Prof. Dr. Murat EFE
Ankara Üniversitesi Elektrik – Elektronik Mühendisliği Anabilim Dalı

Üye : Yrd. Doç. Dr. Gökhan SOYSAL
Ankara Üniversitesi Elektrik – Elektronik Mühendisliği Anabilim Dalı

Yukarıdaki sonucu onaylarım.

Prof. Dr. Atila YETİŞEMİYEN
Enstitü Müdürü

ETİK

Ankara Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez içindeki bütün bilgilerin doğru ve tam olduğunu, bilgilerin üretilmesi aşamasında bilimsel etiğe uygun davrandığımı, yararlandığım bütün kaynakları atıf yaparak belirttiğimi beyan ederim.

09.01.2018



Sümeye Nur AKAYDIN

ÖZET

Yüksek Lisans Tezi

RADAR VİDEO GÖRÜNTÜLERİNDE KARASAL ALANLARIN BELİRLENMESİ

Sümeye Nur AKAYDIN

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Yrd. Doç. Dr. Gökhan SOYSAL

Radar sistemlerinde hedefin tespit edilme olasılığını azaltan etmenlerin azaltılması önemli bir konudur. Kıyı sınırlarının güvenliğinin sağlanması veya gemi takibi yapılması gibi uygulamalarda sadece takibi yapılan hedef nesne ile çalışılması uygulama başarısını yükseltmektedir. Radar ile görüntüleme radar vericisi tarafından gönderilen sinyallerin hedeflerden radara yansımalarının gücü kullanılarak yapılmaktadır. Deniz radarları ile görüntüleme yapılırken kara ve kargaşa bölgelerinden gelen güçlü yansımalar hedef tespit ve takip performansını olumsuz yönde etkilemektedir. Bu sebeple harita ve Doppler bilgisinin bulunmadığı durumlarda radar videolarında karasal alanların belirlenmesi önem taşımaktadır. Tez çalışmasında deniz radarı videolarında karasal alanların saptanmasının belirli bir doğrulukta gerçekleştirilmesi için çıkıntı saptamaya dayalı bir yöntem önerilmiştir. Video verisi kullanılan çalışmalarda statik ve dinamik olmak üzere iki çıkıntı durumu bulunmaktadır. Çalışma kapsamında statik belirginliğin saptanması için görüntü bölütleme yöntemleri önerilmiş ve bu yöntemlerin başarım analizleri yapılarak en iyi sonuç veren yöntem seçilmiştir. Dinamik belirginliğin saptanması için de Horn-Schunk optik akış yönteminin kullanılması önerilmiştir. Optik akış ile elde edilen vektörlerden, yapılan literatür çalışması sonucunda, çıkarılması gereken özniteliklerin zamansal alan öznitelikleri olduğu belirlenmiştir. Belirlenen özniteliklerden sınıflandırıcının performansını olumsuz yönde etkileyen öznitelikler elenerek öznitelik seçme işlemi gerçekleştirilmiştir. Seçilen özniteliklerin kullanıldığı çeşitli sınıflandırıcıların performansları karşılaştırılmış, en yüksek başarıma sahip sınıflandırıcı seçilerek kara, deniz ve kargaşa bölgeleri sınıflandırılmıştır. Yapılan çalışmada radar videolarında karasal alanların bilgisayarla görme ve makine öğrenmesine ait yöntemler kullanılarak yüksek oranda tespit edilebildiği gösterilmiştir.

Ocak 2018, 109 sayfa

Anahtar Kelimeler: Radar sinyal işleme, video sinyal işleme, kara tespiti, bölütleme, optik akış, öznitelik çıkarımı, öznitelik seçimi, kara sınıflandırma

ABSTRACT

Master Thesis

DETERMINATION OF LAND REGIONS IN RADAR VIDEO IMAGE

Sümeye Nur AKAYDIN

Ankara University
Graduate School of Natural and Applied Sciences
Department of Electrical and Electronics Engineering

Supervisor: Asst. Prof. Dr. Gökhan SOYSAL

In radar systems, reducing the factors that decrease probability of target detection is an important issue. Working with only the object that is tracked for the applications such as assuring coastal safety or ship tracking increases the application success. Radar imaging is done using the power of radar reflections from the targets of the signals sent by the radar transmitter. While imaging is done with marine radar, strong reflections from land and cluttered areas lead to decreasing the performance of target detection and tracking. Therefore, when there is no map and Doppler information, land area detection becomes so important task. In this thesis, a method based on saliency detection which results significant accuracy, is proposed for detection of land areas in marine radar videos. Static and dynamic saliency detection are main two subjects of working on video data. In this study, to detect static saliency, image segmentation methods are proposed and the best image segmentation method has chosen after evaluation of their performance. To detect dynamic saliency, Horn-Schunk optical flow method is proposed. As a result of the literature study, it has been determined from the optical flow vectors that the features to be extracted is temporal domain features. Some of these features which reduce classifier performance are eliminated in feature selection phase. The performances of the various classifiers in which the selected features are In this study, it has been shown that land areas can be detected with high accuracy rate in radar videos with using computer vision and machine learning methods used are compared and the land, sea and cluttered areas are classified by choosing the classifier with the highest performance.

January 2018, 109 pages

Key Words: Radar signal processing, video signal processing, land determination, segmentation, optical flow, feature extraction, land classification

TEŞEKKÜR

Çalışmalarım sırasında kıymetli bilgi, birikim ve tecrübeleri ile bana yol gösteren, değerli zamanını esirgemeyen, danışmanım Sayın Yrd. Doç. Dr. Gökhan SOYSAL'a (Ankara Üniversitesi Elektrik-Elektronik Mühendisliği Anabilim Dalı teşekkürlerimi ve saygılarımı sunarım.

Bu süreçte desteklerini hiçbir zaman esirgemeyen sevgili annem ve eşime teşekkür ederim.

Sümeye Nur AKAYDIN
Ankara, Ocak 2018

İÇİNDEKİLER

TEZ ONAYI SAYFASI
ETİK i
ÖZET ii
ABSTRACT iii
TEŞEKKÜR iv
ŞEKİLLER DİZİNİ viii
ÇİZELGELER DİZİNİ xi
1. GİRİŞ 1
2. KURAMSAL TEMELLER 12
2.1 Veri normalizasyonu 12
2.1.1 Karekök dönüşümü 12
2.1.2 Log dönüşümü 13
2.1.3 Ters dönüşüm 13
2.2 Görüntü Bölütleme Yöntemleri 13
2.2.1 Süreksizlik tabanlı yöntemler 15
2.2.1.1 Nokta saptanması 17
2.2.1.2 Çizgi saptanması 17
2.2.1.3 Kenar saptanması 18
2.2.1.3.1 Birinci dereceden türeve dayalı yöntem ile kenar saptama 18
2.2.1.3.2 İkinci dereceden türeve dayalı yöntem ile kenar saptama 20
2.2.2 Eşikleme tabanlı bölütleme 21
2.2.2.1 Çoklu seviye parlaklık eşiklemesi 22
2.2.2.2 Global eşikleme 23
2.2.2.3 Optimal eşikleme 24
2.2.2.4 Otsu eşiklemesi 26
2.2.3 Benzerlik tabanlı bölütleme tekniği 29
2.2.3.1 Alan büyümesi 29
2.2.3.2 Alan ayırma birleştirme 31
2.2.3.3 Su seti bölütlemesi 32
2.2.3.3.1 Baraj inşa edilmesi 33

2.3 Bölütleme Performans Analizi 36
2.3.1 Metrik seçimi 39
2.4 Optik Akış 42
2.4.1 Horn-Schunk Yöntemi 46
2.4.1.1 Kısmi türevlerin hesaplanması 46
2.4.1.2 Toplam hatanın minimize edilmesi 47
2.4.2 Lucas-Kanade Yöntemi 48
2.5 Öznitelik Çıkarma 50
2.5.1 Zaman alanı öznitelikleri 51
2.5.1.1 Karekök ortalaması (RMS) 51
2.5.1.2 Tepe genliği 51
2.5.1.3 Mesafe 51
2.5.1.4 Ortalama 52
2.5.1.5 Standart sapma 52
2.5.1.6 Basıklık değeri (Kurtosis) 52
2.5.1.7 Çarpıklık değeri (Skewness) 52
2.5.1.8 Çeyrekler arası açıklık 53
2.6 Öznitelik Seçme 53
2.6.1 Filtre Yöntemi 54
2.6.2 Sarmal Yöntemler 55
2.6.3 Gömülü Yöntemler 56
2.6.4 Hibrit Yöntemler 57
2.7 Sınıflandırma 57
2.7.1 Karar ağaçları ile sınıflandırma 60
2.7.2 Destek vektör makineleri (SVM) ile sınıflandırma 62
2.7.2.1 Doğrusal destek vektör makineleri 63
2.7.2.2 Doğrusal olmayan destek vektör makineleri 63
2.7.3 K en yakın komşu algoritması ile sınıflandırma (KNN) 65
3. MATERYAL VE YÖNTEM 68
3.1 Materyal 68
3.2 Yöntem 70
3.2.1 Normalizasyon işlemi 70

3.2.2 Bölütleme işlemi sonuçları **71**
3.2.3 Kargaşa haritası oluşturma ve başarım analizi **76**
3.2.4 Optik akış vektörlerinin elde edilmesi **77**
3.2.5 Öznitelik çıkarımı yapılması **79**
3.2.6 Öznitelik seçilmesi **79**
3.2.7 Sınıflandırma **80**
4. ARAŞTIRMA BULGULARI **87**
5. TARTIŞMA VE SONUÇ **93**
KAYNAKLAR **96**
EK 1 Karmaşıklık Matrisi **103**
ÖZGEÇMİŞ **109**

ŞEKİLLER DİZİNİ

Şekil 2.1 Görüntü bölütleme yöntemleri ……14
Şekil 2.2 Görüntü üzerinde türev alma işlemleri ……....16
Şekil 2.3 Farklı yön çizgileri için kullanılan maskeler ……...18
Şekil 2.4 Birinci dereceden türev ile kenar saptamaya ait akış diyagramı ……..…19
Şekil 2.5 Eşik değerinin belirlenmesi ……....20
Şekil 2.6 İkinci dereceden türev alma maskeleri ……..….20
Şekil 2.7 Türev alma işlemleri ve sıfır geçiş noktası ……..……21
Şekil 2.8 Tek ve iki tane eşik gerektiren gri seviye sıklık grafikleri ……..….22
Şekil 2.9 Üçgen metodu …….....23
Şekil 2.10 Görüntü sıklık grafiğinin iki olasılık yoğunluk dağılım fonksiyonu ile modellenmesi ……24
Şekil 2.11 Alan büyümesi yönteminin başlatılması ……...…30
Şekil 2.12 Birkaç yenileme sonucu büyüme işlemi ……...….30
Şekil 2.13 Ayırma birleştirme işlemi ……...…...31
Şekil 2.14 Su seti yönteminin fiziksel yorumlanışı ……..…..32
Şekil 2.15 8-komşuluk içeren yapılanma elemanı ve nesnenin genişletilerek arka plan piksellerinden bazılarının ön plan pikseline dönüşmesi ……..….33
Şekil 2.16 Genişletme ve baraj inşasının sonucu ……...34
Şekil 2.17 Topografik yüzey gösterimi ……..……35
Şekil 2.18 Tanımında DN içeren değerlendirme yöntemlerinin bölüt boyutunun artmasıyla değişimi ……...41
Şekil 2.19 Görüntü üzerinde optik akış vektörleri gösterimi ……..…42
Şekil 2.20 Berber simgesindeki açıklık problemi ……...43
Şekil 2.21 Hareket kestirimden açıklık problemi ……...…44
Şekil 2.22 Ardışık iki video çerçevesi ……....47
Şekil 2.23 Çekirdek matrisi ……48
Şekil 2.24 İlgisiz, az ilgili ve güçlü ilgiye sahip elemanlardan oluşan öznitelik uzayı ……...54
Şekil 2.25 Filtre yöntemi ile öznitelik seçimi ……...…..55
Şekil 2.26 Sarmal yöntemler ile öznitelik seçimi ……..….…56
Şekil 2.27 Gömülü yöntemler ile öznitelik seçimi ……..……...56
Şekil 2.28 Çapraz sağlama yöntemi ……...…59
Şekil 2.29 Karar ağacı ile sınıflandırma ……..…...61

Şekil 2.30 SVM sınıflandırıcısı …….....63

Şekil 2.31 Doğrusal olmayan destek vektör makineleri ……..…...64

Şekil 2.32 KNN sınıflandırma örneği ……...….65

Şekil 3.1 Yüksek nesnelerin ardına sinyal gönderilememesi örneği ……...…...70

Şekil 3.2 Birinci dereceden kenar saptama yöntemine ait doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları …….....72

Şekil 3.3 İkinci dereceden kenar saptama yöntemine ait doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları …….72

Şekil 3.4 Global eşikleme yöntemine ait doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları ……...73

Şekil 3.5 Optimal eşikleme yöntemine ait doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları ……..…73

Şekil 3.6 Otsu eşikleme yöntemine ait doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları ……...74

Şekil 3.7 Alan büyümesi yöntemine ait doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları ……..….74

Şekil 3.8 Alan ayırma-birleştirme yöntemine ait doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları ……...75

Şekil 3.9 Su seti bölütlemesi yöntemine ait doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları ……..…….75

Şekil 3.10 Kargaşa haritası oluşturulduğunda doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları …….....77

Şekil 3.11 Bir ve ikinci video çerçeveleri arasındaki optik akış ……....78

Şekil 3.12 Kırk derece açısında bulunan optik akış vektörleri ……...78

Şekil 3.13 Tüm özniteliklerin kullanılması ile elde edilen karar ağacı sınıflandırma sonucu ……81

Şekil 3.14 Tüm özniteliklerin kullanılması ile elde edilen doğrusal DVM sınıflandırma sonucu ……81

Şekil 3.15 Tüm özniteliklerin kullanılması ile elde edilen doğrusal olmayan DVM sınıflandırma sonucu ……...…82

Şekil 3.16 Tüm özniteliklerin kullanılması ile elde edilen 3 komşuluk ve öklit mesafesi kullanılan KNN sınıflandırma sonucu ……...…82

Şekil 3.17 Tüm özniteliklerin kullanılması ile elde edilen 10 komşuluk ve öklit mesafesi kullanılan KNN sınıflandırma sonucu ……...…83

Şekil 3.18 Seçilen öznitelikler kullanılması ile elde edilen karar ağacı sınıflandırma sonucu ……..83

Şekil 3.19 Seçilen öznitelikler kullanılması ile elde edilen doğrusal DVM sınıflandırma sonucu ……..84

Şekil 3.20 Seçilen öznitelikler kullanılması ile elde edilen doğrusal olmayan DVM sınıflandırma sonucu ……...…84

Şekil 3.21 Seçilmiş öznitelikler kullanılması ile elde edilen 3 komşuluk ve öklit mesafesi kullanılan KNN sınıflandırma sonucu ……...….85

Şekil 3.22 Seçilmiş öznitelikler kullanılması ile elde edilen 10 komşuluk ve öklit mesafesi kullanılan KNN sınıflandırma sonucu ……...….85

Şekil 3.23 Sınıflandırma sonucunda doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları ……..…86

ÇİZELGELER DİZİNİ

Çizelge 2.1 3*3'lük uzamsal filtre maskesi ……..……..15

Çizelge 2.2 Süzgeç dürtü cevabı ……...…..17

Çizelge 2.3 Bölütleme değerlendirme ölçütleri ……...…...37

Çizelge 2.4 Metrikler arasındaki korelasyon katsayıları ……...….39

Çizelge 4.1 Bölütleme yöntemleri sonucunda elde edilen kara tespit yüzdesi ortalama ve standart sapma değerleri …….....87

Çizelge 4.2 Bölütleme yöntemleri sonucunda kara olarak tespit edilen deniz pikseli yüzde ortalama ve standart sapma değeri ve hatalı saptanan piksel sayısı ortalama ve standart sapma değeri ……..88

Çizelge 4.3 Referans görütüye göre saptanan kara tespit yüzdesi ortalama ve standart sapma değerleri ……...…...88

Çizelge 4.4 Bölütleme yöntemlerinin performans değerlendirmesi ……...…90

Çizelge 4.5 Kargaşa haritasına ait başarım analizi sonuçları ……..…...91

Çizelge 4.6 Tüm özniteliklerin kullanıldığı sınıflandırma ……..…...92

Çizelge 4.7 Seçilen özniteliklerin kullanıldığı sınıflandırma doğruluğu ……...….92

1. GİRİŞ

Radarlar kiplenmiş dalgalar ve yönlendirici antenler kullanarak elektromanyetik enerjiyi belli bir hacim içinde bulunan hedefi bulmak için kullanmaktadırlar (Mahfaza 2005). Kullanılacak elektromanyetik sinyalin türü hedefe göre farklılık göstermektedir. Işık hızında hareket eden bir enerjinin iletilmesi ve bu enerjinin bir hedefle karşılaştığında yankı olarak geri dönmesi prensibi ile çalışmaktadırlar. Bu duruma yankı prensibi de denilmektedir. Bu yankılar, radar alıcısı tarafından işlenerek hedefe ait mesafe, hız, açısal pozisyon gibi özellikler çıkarılmaktadır.

Radar sistemleri anten konumuna, kullanılan dalga tipine ve kullanım alanına göre sınıflandırılmaktadırlar. Radar sinyallerini ileten ve alan antenlerin ayrı olduğu sistemler bistatik, tek bir anten ile alıcı ve verici modlar arasında geçiş yapılabilen monostatik yapılar olmak üzere, anten konumlarına göre iki sınıfa ayrılmaktadır. Radar sistemleri kullandıkları dalga tiplerine göre de sürekli dalga sinyalleri ve darbe sinyalleri radarları olarak iki sınıfta incelenmektedirler. Sürekli dalga sinyalleri kullanan radarların başlıca amacı ortamda bulunan hedeflerin hızını, Doppler kaymasını, ve açısal pozisyonunu ölçmektir. Darbe sinyali kullanan radar sistemleri ise ortamda bulunan hedeflerin menzillerini de ölçebilmektedir. Bunların yanı sıra radar sistemleri kullanım alanlarına göre kara, deniz, hava ve uzay radarları olarak sınıflandırılmaktadırlar.

Deniz radarları, karaya ya da deniz platformları üzerine konuşlu olup, ortamda bulunan deniz araçlarının tespit ve takibini gerçekleştirmektedir. Bu işlevleri yanı sıra gemilerde bu radarlar, navigasyon ve çarpışmadan kaçınma amacıyla da kullanılmaktadır. Deniz radarları için en önemli problemlerden biri, radarın aydınlattığı bölgedeki kara parçalarından gelen yansımalardır (radarın karaya konuşlu olması durumunda coğrafi koşullardan kaynaklı görüş alanındaki karalar ya da seyir halindeki bir geminin karaya yakın geçerken maruz kaldığı kara paçaları). Kara parçaları genellikle güçlü yansıtıcı özelliği gösterir ve Doppler ölçme özelliğine sahip olmayan radarlarda (deniz radarları genellikle darbe radarı olup Doppler ölçümü yapmamaktadır), hedef tespit eşiğinin doğru ayarlanmaması ve sinyal işleme yükünün artması problemlerine neden olmaktadır. Kara bölgelerinin radar sinyalinden ayıklanmasının bir yolu harita

kullanmaktır. Ancak harita bilgisinin olmadığı durumlarda kara bölgelerinin tespiti ve radar sinyalinden temizlenmesi önemli bir problem olup bu tez çalışmasının da ana konusunu oluşturmaktadır.

Çoğu deniz radarı Doppler bilgisi sağlamayan darbe sinyalleri kullanmaktadırlar ve 360 derece dönebilen antenler ile su yüzeyi üzerinde dar mikrodalga ışınları gezdirerek, ortam resmini oluşturmaktadır. Vericiden gönderilen sinyalin, ortamda bulunan yansıtıcılardan saçılarak alıcıya ulaşması arasında geçen süre kullanarak menzil ölçülebilmektedir. Ayrıca mekanik dönme hareketi örneklenerek ortamda bulunan yansıtıcı nesnelerin açı ölçümleri de yapılabilmektedir. Genellikle radar tarafından ölçümlenen yansımalar, menzil ve açı bilgileri kullanılarak plan pozisyon göstergesi (PPI) olarak bilinen ekranda, enerjisi yüksek yansımalar daha parlak olacak şekilde gösterilmektedir. Radar ile görüntülenen bir çevrede, yüzey sertliği fazla olan alanların geri saçılma sinyalleri daha güçlü iken, nemli yüzeylerin geri saçılma sinyalleri zayıf olmaktadır. Dolayısı ile kara ve denizlerin bulunduğu ortamı görüntüleyen bir radar için elde edilen görüntülerde kara bölgelerinden yansıyan sinyallerin enerjisi yüksek, deniz bölgelerinden yansıyanların düşük oluşmaktadır. Bunların yanı sıra atmosferik şartlara bağlı olarak dalgaların artması (deniz durumunun değişmesi) gibi geri saçılma oranını yükselten bir durum varsa bu bölgelerden de değişken enerjili yansımalar olmakta ve bu yansımalar deniz kargaşası olarak adlandırılmaktadır.

Radar sistemlerinde hedef tespit olasılığını azaltan etkenlerin en aza indirilmesi büyük önem arz etmektedir. Gemi takibi yapılabilmesi, gemi için rota belirlenebilmesi veya kıyı sınırlarının korunması gibi durumlar açısından, radar görüntüleri üzerinde sadece takip edilecek nesneler ile çalışılması hedef takibinin daha doğru gerçekleşmesine katkı sağlamaktadır. Radar ile görüntüleme sistemlerinde, radar tarafından gönderilen sinyallerin hedeflerden radara doğru geri yansımalarının gücü kullanılmaktadır ve radar ile görüntülenen bir çevrede, yüzey sertliği fazla olan alanların geri saçılma sinyalleri daha güçlü iken, nemli yüzeylerin geri saçılma sinyalleri zayıf olmaktadır (Mather ve Tso 2001, Joseph 2005, ve Muja 2012, https://earth.esa.int, 2000). Özellikle deniz radarlarında, harita ve Doppler bilgisinin olmadığı durumda kara ve kargaşa bölgelerinden gelen güçlü yansımalar kıyıya yakın hedeflerin tespit ve takibini

güçleştirmektedir. Bunun yanı sıra karadan gelen yansıma sinyallerinin hedef tespit ve takibine yönelik işlenmesi için harcanan enerji nedeniyle hâlihazırda takibi yapılan hedeflerin, kaybedilmesi, takip doğruluğunun azalması ve önem derecelerinin doğru tahmin edilememesi gibi sorunlar ortaya çıkmaktadır. Ayrıca harita bulunmayan durumlarda bir gemi için rota belirlenirken kargaşa bölgelerinin kara bölgeleri olarak değerlendirilmesi de hataya sebep olabilmektedir.

Ardışık radar taramaları sonucu elde edilen çerçevelerden (resimlerden) oluşan radar videosunda kara bölgelerinin belirlenmesi dinamik olarak çözülmesi gereken önemli bir problem olup, tez çalışmasında bu problemin çözümüne yönelik görüntü işleme tabanlı yöntemler araştırılmıştır. Ulaşılabilen literatürde radar videolarında karasal alanların saptanmasına yönelik görüntü işleme tekniklerinin kullanıldığı çalışmalara rastlanılmamıştır. Literatürde kara ve deniz bölgelerinin birbirinden ayrılmasına yönelik çalışmalar; kargaşa haritası oluşturma, uzun süreli ölçümler alarak kara ve deniz istatistiklerinin belirlenmesi temelindedir(Skolnik 2000, Jun ve Dongdong 2012). Tez çalışmasında ise radar videosunu oluşturan çerçevelere görüntü işleme teknikleri uygulanması yoluyla kara bölgelerinin belirlenmesi incelenmiş, özellikle optik akış vektörleri temelli öznitelikler çıkarılarak kara bölgelerinin görüntü içerisinde sınıflandırılabileceği sonucuna ulaşılmıştır.

Tez çalışmasında görüntü işleme tekniklerinin uygulandığı radar video çerçeveleri bilinen anlamda görüntü çerçevelerine benzememektedir. Radar video çerçevelerinde bulunan noktalar radara yansıyan enerji ile oluşmaktadırlar, deniz radarı ile alınan görüntülerde durgun deniz yüzeylerinden ve iletilen sinyalin ulaşamadığı kara bölgelerinden yansıyan enerji yok denecek kadar azken, kara bölgelerinden yansıyan enerji çok büyüktür. Bu durum radar görüntüsünün en büyük ve en küçük değerleri arasındaki farkın oldukça fazla olmasına sebep olmaktadır. Görüntü işleme uygulamalarında kullanılan gri seviye veya siyah-beyaz görüntülerden, bu sebepten dolayı farklıdırlar.

İlk olarak radar video çerçevelerine ait sinyallerin standart video çerçevelerine dönüştürülmesi için normalizasyon işlemi uygulanmasından sonra yapılması gereken

çalışma için izlenecek yol çıkıntı saptama problemine dönüşmüştür. Son dönemlerde görüntü bölütleme, nesne tanıma, video özetleme ve sıkıştırmada verimli bir biçimde kullanılabilmesinden dolayı çokça önem kazanan çıkıntı saptanması, tüm veri yerine ilgilenilen veri kısımlarına odaklanılmasına yardımcı olmaktadır. Literatürde çıkıntı saptanması için farklı yöntemler bulunmaktadır. Bu çalışmaların genel hatlarını öncelikle tek bir video çerçevesi üzerinde statik belirginliğin, diğer anlamıyla uzamsal belirginliğin, saptanması, daha sonra çerçeveler arasında dinamik belirginliğin yani zamansal belirginliğin saptanması oluşturmaktadır. Bir veri içerisinde benzer özelliklere sahip veri parçalarını açık bir şekilde ayırt edilebilen bölümlere ayırmak bölütleme olarak tanımlanmaktadır. Bir video çerçevesi veya görüntü içerisinde belirgin alanları saptama işlemi de temel olarak bir bölütleme işlemidir. Literatürde uzamsal belirginliğin saptanması ile ilgili Gauss piramitlerinden, süperpiksellerden veya dalgacık dönüşümü gibi yöntemlerden yararlanılmıştır. Bu yöntemlerin temel amacı bölütleme yapmaktır. Socarras vd. (2012), bahsedildiği üzere bölütleme günümüzde hala aktif bir çalışma alanıdır ve bu alanda çok fazla yöntem önerisi bulunmaktadır. Bu yöntemlerden hangisinin seçilmesi gerektiği sorusu için ise literatürde hala net bir yanıt bulunmamaktadır. Çalışma kapsamında uzamsal çıkıntı saptanması için yararlanılan bölütleme yöntemi ise kuramsal temeller bölümünde bahsedilen temel görüntü bölütleme tekni̇kleridir. Zamansal belirginliğin saptanması işlemi ise video çerçeveleri arasında hareketli noktaların saptanması anlamına gelmektedir. Hareket saptanması için her piksel noktasının x ve y eksenlerindeki hızları ve açısal konum değişiminden yararlanılmaktadır. Video çerçevelerine piksellerin, çerçeveler arasında sahip oldukları hız ve açı bilgilerini elde etmek için kullanılan en temel yaklaşım optik akıştır (Jodoin vd. 2014). Çalışma kapsamında da zamansal çıkıntı saptanırken, optik akıştan yararlanılmıştır.

Itti vd. (1998) uzamsal belirginliğin saptanması amacını taşıyan çalışmalarında renk, yeğinlik, yön gibi görüntü özelliklerinin tek bir çıkıntı haritası oluşturmasını sağlayacak, görsel dikkate dayalı bir model önermişlerdir. Gauss piramitlerinden yararlanılan bu çalışmada görüntü alt ölçeklenmiş, alt ölçekler ve orijinal görüntü ölçeği arasındaki farklar ile özellik çıkarımı yapılmıştır. Gauss piramitlerine ait her alt ölçekte

bu özellikler birleştirilerek yerel çıkıntı haritaları elde edilmiş ve ardından yerel çıkıntı haritaları birleştirilerek görüntüye ait çıkıntı saptanmıştır.

Yerel ve global çıkıntıların karışımı ile belirginliğin saptanması için Peng vd. (2016) çalışmalarında görüntü yumuşatılarak daha homojen olması sağlatıldıktan, sonra görüntü parçalara ayrılmış, orijinal görüntü parçaları ve yumuşatılmış görüntü parçaları arasındaki renk ve doku farklılıklarından yola çıkarak çıkıntı saptanmıştır.

Ren vd. (2014) belirginliği kullanarak nesne tanıma işlemini gerçekleştirmek için alan tabanlı bir çalışma yapmışlardır. Adaptif ortalama kaydırma yöntemini kullanarak görüntüden elde ettikleri süperpikselleri Gauss karışım modelleri ile renklerine göre kümelemişlerdir. Yoğunluğu fazla olan kümeler ve kümelerin birbirleri ile bağlantısını gösteren PageRank algoritması ile uzamsal belirginliği elde etmişlerdir.

Fang ve Wang (2014) uzamsal ve zamansal bilgileri kullanarak görsel belirginliği saptamayı amaçlamışlardır. Renk, parlaklık, doku gibi uzamsal çıkıntı özelliklerini saptamak için öncelikle video çerçeveleri RGB renk uzayından YCbCr renk uzayına dönüştürülmüş, daha sonra bu çerçeveler üst üste örtüşmeyen 8*8'lik bölmelere ayrılarak ayrık kosinüs dönüşümüne tabi tutulmuşlardır. Her bölmeden bir tane parlaklık, iki tane renk ve bir tane doku özelliği elde edilmiştir. Daha sonra video çerçevelerine optik akış vektörleri uygulanarak zamansal çıkıntı elde edilmiştir. Uzamsal çıkıntı ve zamansal çıkıntı noktalarının güvenilirlikleri kontrol edilerek hem zamansal hem de uzamsal çıkıntı belirsizlikleri hesaplanmıştır. Uzamsal ve zamansal çıkıntılar ve bunların belirsizlikleri entropilerine göre ağırlıklandırılarak uzamsal-zamansal çıkıntı haritası elde edilmiştir.

Wang ve Shen (2015) gradyan akış alanı ve enerji optimizasyonu kullanarak videolardaki belirgin alanlarını saptamaya çalışmışlardır. Çalışmada öncelikle her video çerçevesindeki süperpikseller bulunmuş, gereksiz detaylar atılmış güçlü kenarlar ve kontur bilgileri korunmuştur. Korunan bu bilgiler ile hem çerçeve içindeki hem de çerçeveler arasındaki hareket bilgisi gradyan akış alanı ile çıkarılmış, çıkıntı haritası elde edilmiştir. Hareket bilgisi çıkarımının çıkıntı açısından daha doğru olarak

kullanılması için çıkıntı haritası üzerindeki noktaların enerjileri öznitelikleri ile uzamsal-zamansal çıkıntı elde edilmiştir.

Belirgin bölgelerin çevrelerinden farklı olduğu esasına dayanarak Kim vd. (2011) merkez çevre yaklaşımını kullanmışlardır. Görüntü üzerindeki kenarlar, renklerdeki çıkıntı merkez çevre sıklık grafikleri ile belirlenmiş ve görüntü çerçevelerinin birbirleri arasındaki farklarının merkez çevrede mutlak değerlerinin toplamı ile zamansal çıkıntı saptanmıştır. Uzamsal ve zamansal çıkıntılar birleştirilerek çıkıntı haritası çıkarılarak belirginliğe ulaşılmıştır.

Li vd. (2003), video içerisinde bulunan çerçevelerden renk çıkarımı ve yön haritalarının kullanılması ile belirgin alanların saptanması üzerine çalışmışlardır. Çalışmada renk çıkarımı için k ortalamalı kümeleme ve dalgacık dönüşümünden yararlanılmıştır. Yön haritaları ise gerçek görüntü ve gerçek görüntünün yumuşatılmış halinin arasındaki fark ile elde edilmiştir. Daha sonra saptanan belirgin alanlar çerçevelerin sonuna kadar takip edilmiştir. Takip etme işlemi bir çerçevede elde edilen belirgin alanın, bir diğer çerçevede genişletilmesi temeline dayanmaktadır, eğer genişleyen alan ile önceki alanın renk özellikleri belirli ölçüde benziyorsa hareket saptanmış olmaktadır. Belirgin alanlar bilgisiyle çerçevelerin önemleri belirlenmiş ve bu durum sayesinde video özetlemek için kullanılan anahtar-çerçeve çıkarımı yapılabileceğini göstermişlerdir.

On binlerce görüntüden bir veri tabanı oluşturularak, birden fazla kullanıcıdan bu görüntülerde belirgin alanların dikdörtgen içine alınarak etiketlenmesi istenen Liu vd. (2007), belirgin nesnenin saptanmasını görüntü bölütleme problemi olarak ele almış, belirgin nesne ve arka planı ayırmayı amaçlamıştır. Çoklu ölçek karşıtlığı, merkez çevre sıklık grafiği ve nesnenin uzamsal renk dağılımı kullanılarak yerel ve genel özellikleri ile nesne saptanmaya çalışılmıştır. Çoklu ölçek karşıtlığı ile görüntü içindeki benzer alanlara düşük puan verilerek yüksek karşıtlık içeren bölgeler daha belirgin hale getirilmiştir. Merkez çevre sıklık grafiğinde ise belirgin nesneyi içine alan bir R dikdörtgeni olduğu varsayılarak, R'yi çevreleyen başka bir Rs dikdörtgeni çizilir, bu iki dikdörtgene ait RGB renk sıklık grafikleri arasındaki X^2(ki-kare) mesafesi hesaplanır. Belirgin nesneler daha büyük merkez çevre sıklık grafiği mesafesine sahiptirler.

Uzamsal renk dağılımı için ise görüntüdeki her piksel bir renk bileşenine atanmış ve bu renklerin uzamsal pozisyonunu gösteren yatay ve dikey varyanslar kullanılmıştır. Varyansın azalması belirginliğin arttığını göstermektedir. Çoklu ölçek karşıtlığı, merkez çevre sıklık grafiği ve uzamsal renk dağılımı görüntüdeki öznitelikler olarak kullanılarak, koşullu rastgele alanlar ile öğrenme işlemine tabi tutulmuştur.

Li vd. (2013), kullanıcıyla herhangi bir etkileşim içinde olmadan veya eğitim için veri kullanmadan nesne çıkarım işlemini gerçekleştirmeyi amaçlamıştır. Video çerçeveleri içindeki ön plan ve arka plan bölgelerini ayırmak için hareketsel ve görsel

belirgin alanlar saptanması sağlanmıştır. Görsel belirginliğin saptanması her video çerçevesinde görüntü bölütleme işlemi ile sağlanmıştır. Hareketsel belirginliğin saptanması ise optik akış vektörleri kullanılarak sağlanmıştır. Belirginliği saptanan bölgeleri koşullu rasgele alanlar yardımı ile ön plan ve arka plan olarak sınıflandırmışlardır.

Oakes ve Abhayaratne (2012), dalgacık dönüşümü ile uzamsal-zamansal olarak videoda belirginliğin saptanması amaçlanmıştır. Çıkıntı haritası oluşturabilmek için uzamsal ve zamansal özellikler birleştirilmiştir. Uzamsal haritalar dalgacık dönüşümünün özelliklerinden yararlanılarak bir video kesitindeki her çerçeve için oluşturulur. Uzamsal olarak ayrıştırılmış çerçevelerin farkı alınıp, bir fark görüntüsü çıkarılarak, zamansal çıkıntı elde edilmiştir. Eğer görüntüleme yapan kamera hareket ediyorsa ve bu hareket hakkında varsa, bu hareket tüm çerçevelerden çıkarılarak sadece nesne hareketi üzerinde çalışılmıştır. Uzamsal ve zamansal çıkıntı haritaları ağırlıklı toplanarak birleştirilip sonuç belirginliği çıkarılır. Ağırlıklı birleştirme işlemi harekete bakılarak yapılmıştır, hareketin olmadığı durumlarda zamansal haritanın katkısı sıfır alınarak çıkıntı sadece uzamsal haritadan hesaplanmıştır.

Zhang vd. (2014), videolarda çıkıntı tespiti için süperpiksel tabanlı zamansal-uzamsal çıkıntı modeli önermişlerdir. Video çerçevelerindeki süperpikseller ile hareket ve renk sıklık grafikleri çıkarılmıştır. Daha sonrasında bir çerçevede bulunan süperpikseller ile bir önceki çerçevede bulunan süperpiksellerin bağlantısından yararlanarak zamansal

belirginliği saptamışlardır. Uzamsal çıkıntı ise süperpikselllerdeki karşıtlık bilgisi kullanılarak saptanmıştır. Son olarak da zamansal ve uzamsal çıkıntı birleştirilerek zamansal-uzamsal çıkıntı elde edilmiştir.

Dong vd. (2016), yüksek dinamik aralıklı (HDR) görüntülerde ve videolarda çıkıntı tespiti için yapılmış tek çalışmadır. Uzamsal ve zamansal çıkıntı haritalarından yararlanılan bu çalışmada uzamsal belirginliğin saptanması için Itti (1998) çalışması ile aynı yol izlenmiştir. Zamansal çıkıntı için ise optik akıştan yararlanılmıştır. Elde edilen zamansal ve uzamsal çıkıntı haritalarının çarpımı ile hem zamansal hem de uzamsal olarak nesne olmaya yatkın pikseller saptanmıştır.

Bahsedildiği üzere radar videosu üzerinde kara bölgelerinin tespiti için ulaşılabilen literatürde bir çalışmaya rastlanılmamıştır. Ancak hedef takibi için sentetik açıklıklı radar görüntülerinin kullanıldığı çalışmalar literatürde bulunmaktadır. Bu çalışmalarda genellikle deniz kargaşası bölgesindeki hedefi saptayabilmek için, kargaşa modellemesi yapılması üzerinde yoğunlaşılmış, deniz kargaşasının modellenmesi için genellikle k dağılımından yararlanılmıştır. Bazı diğer çalışmalarda da yanlış alarm oranı temelli eşikleme kullanılarak hedef saptanması gerçekleştirilmiştir.

Jun ve Dongdong (2012), ters sentetik açıklıklı radar görüntülerinde gemi hedeflerinin saptanması amaçlanmıştır. Bu çalışmada her görüntü pikselinin etiketinin saptanması için, bir koruyucu bir de arka plan olmak üzere iki yerel pencere kullanılmıştır. Arka plan penceresi arka plan istatistiklerinden yararlanarak hedef saptama eşiğinin bulunması için kullanılırken, koruyucu pencere de hedef pikselinin arka plan penceresine karışarak arka plan kargaşasının istatiksel kesinliğini bozmaması için kullanılır. Deniz kargaşasını modellemek için k dağılımından yararlanılan çalışmada arka plan penceresi istatistikleri ile k dağılımına ait ortalama ve şekil parametreleri elde edilmiştir. Elde edilen k dağılımı ve yanlış alarm olasılığı ile kargaşa bölgesi içinden gemi saptamak için gerekli olan eşik değerini bulunmuştur.

Skolnik (2000) kitabında, deniz radarlarında nesne saptanmasın yönelik olarak deniz kargaşasının bir taramada oluşup bir sonraki taramada kaybolması ancak hedef nesnenin

her taramada aynı genlikte gözükmesini temel olarak aldığı bir çalışma yapmış ve 360 derece dönebilen radarın her bir taramasında kargaşaları yok etmek için üç ayrı yöntem verilmektedir. İlki sabit bir eşik değerinden yararlanarak radar sinyalinin eşik değerini geçtiği yerlerde nesne saptamaktır, eşik değerinin doğru ayarlanmaması eksik veya fazla saptamaya neden olabilmektedir. İkincisi ortalama seviyesi takip edilemeyen kargaşalarda herhangi bir hedef yokken radar hedefinin varlığının göstergesi olan yanlış alarm oranından yararlanmaktır. Üçüncü ise haritada var olan kargaşa yankılarının her taramada sekizde birini kargaşa haritasında saklayarak, bu değerlerin ortalamasının alınması ile kargaşa için bir eşik değerinin saptanmasıdır.

Radar ile elde edilmiş arazi görüntülerinde Kamel vd. (2013), Weibull dağılımından yararlanmıştır. Genellikle kenar saptama algoritmaları birinci ve ikinci dereceden türev maskelerinin görüntü ile katlanılmasıyla çalıştırılır. Ancak bu çalışmada türev maskeleri yerine Weibull dağılımından yararlanılmıştır, çünkü Weibull dağılımı ile hem simetrik hem de simetrik olmayan şekiller saptanabilmektedir. İki boyutlu Weibull dağılımının hesaplanarak bu dağılımdan elde edilen 3*3'lük bir maske ile radar görüntüsü katlanarak kenarlar saptanmıştır.

Bu tez çalışması kapsamında radar videolarında karasal alanların tespitinin yapılabilmesi için araştırma gerçekleştirilmiştir. Direk olarak video üzerinden çalışmak yerine videonun çerçevelerine ayrıştırılmasıyla elde edilen görüntüler ile çalışılmış, daha sonra tüm video çerçeveleri ile çalışılmıştır.

Görüntü işleme tekniklerinde kullanılmaya uygun olmayan radar video çerçevelerinin, işlenmeye uygun hale getirilebilmesi için logaritmik normalizasyon tekniği kullanılmış ve bu teknik ile çerçeveler işlenmeye hazır hale getirilmiştir. Çerçeveler üzerindeki uzamsal belirginliği saptamak için görüntü bölütleme teknikleri kullanılmış ve elde edilen sonuçlar değerlendirilerek radar videosu için uygun bölütleme tekniği ortaya konmuştur. Bölütlenerek görsel belirginliği ortaya konan çerçevelerde her piksel noktası çerçeveler arasında takip edilerek optik akış vektörleri bulunmuştur. Vektörler sınıflandırma işlemine tabi tutulup hareketli ve sabit noktaların saptanması amaçlanmıştır. Kullanılan video çerçevelerinin boyutları büyük olduğu için optik akış

vektörlerinin de sayısı fazladır ve bu sebeple işlenmesi zordur. Sınıflandırma işlemini kolaylaştırmak ve performansını artırmak için kullanılan veriyi bir anlamada özetlemeye yarayan öznitelik çıkarımı yapılmaktadır. (Theodoris ve Koutroumbas 2009, Ladha 2011, Gupta ve Sharma 2015). Ancak öznitelik olarak belirlenen parametrelerden bazıları sınıflandırma performansını ya kötü etkilemekte ya da katkı sağlamamaktadır, bu sebeple özniteliklerden sınıflandırma performansı üzerinde iyi etki gösterenler seçilmelidir(Bishop 1995, Guill'en vd. 2009). Çalışma kapsamında öznitelik seçme işlemi gerçekleştirildikten daha sonra veri içindeki seçilmiş öznitelikler kullanılarak eğitim ve test işlemleri gerçekleştirilerek, sınıflandırma işlemi tamamlanmıştır. Sınıflandırma ile elde edilen sonuçlar, kara bölgelerinin yüksek oranda tespitinin gerçekleştiğini göstermektedir.

Tez kapsamında çıkıntı saptanmasına yönelik bir çalışma gerçekleştirilmiştir. Var olan çıkıntı saptama çalışmalarından farklı olarak uzamsal ve zamansal çıkıntılar ayrı ayrı saptanmamış, bunun yerine uzamsal çıkıntı ile saptanan noktalar için zamansal çıkıntı saptama işlemi gerçekleştirilmiştir. Böylelikle iki ayrı çıkıntı saptaması yapılarak sonradan bunların birleştirilmesi yerine zamansal çıkıntı için, uzamsal çıkıntıdan yararlanılabileceği gösterilmiştir. Ayrıca radarın duruş biçimi ve yüksekliğinde meydana gelen hareketler nedeniyle görüntülerde sabit olan kara bölgelerinde hareket saptanmış ve bu hareketin tüm görüntüye yansımasından dolayı tüm kara bölgelerinin optik akış vektörlerinde aynı yönde hareket ettiği gözlemlenmiştir. Kargaşa bölgelerinde herhangi bir yönde sabit olmayan vektörler gözlemlenmiştir. Vektörlerin kara bölgeleri ve kargaşa bölgelerindeki farklılıklarından yararlanılarak öznitelikler aracılığı ile sınıflandırma işlemi gerçekleştirilmiş, kara bölgelerinin yüksek oranda başarı elde edilerek saptanabileceği gösterilmiştir.

Tez, beş bölümden oluşmaktadır. Birinci bölümde, tez çalışmasının amacı ve kapsamından bahsedilmiş, tez konusuna benzer çalışmalar ana hatları ile özetlenmiştir. İkinci bölümde, tez çalışmasına ait problemin çözümünde kullanılan yöntemler hakkında kuramsal bilgi verilmiştir. Kuramsal bilgi bölümünde sırası ile veri normalizasyonu, görüntü bölütleme, bölütleme performansının değerlendirilmesi, optik akış, öznitelik çıkarımı, öznitelik seçimi ve sınıflandırma yöntemleri açıklanmıştır.

Üçüncü bölümde çalışma kapsamında kullanılan materyal ve özellikleri anlatılmış, üzerinde çalışılan problemin çözümünde kullanılan yöntemlere ait özellikler anlatılmıştır. Dördüncü bölümde elde edilen araştırma bulguları sonuçlarından bahsedilmiştir. Son bölümde ise yapılan çalışma hakkında değerlendirme yapılmıştır.

2. KURAMSAL TEMELLER

Bu bölümde tez çalışmasında kullanılan yöntemler hakkında bilgi verilmiştir. Kuramsal temeller bölümü yedi alt bölümden oluşmaktadır. İlk bölümde veri normalizasyonu yöntemleri, ikinci bölümde görüntü bölütleme teknikleri, üçüncü bölümde bölütleme tekniklerini değerlendirme yöntemleri, dördüncü bölümde optik akış yöntemleri, beşinci bölümde öznitelik çıkarımı, altıncı bölümde öznitelik seçimi ve yedinci bölümde ise gözetimli sınıflandırma teknikleri incelenmiştir.

2.1 Veri Normalizasyonu

Veri normalizasyonu, veri içindeki değişkenlerin matematiksel uygulamalar ile değiştirilmesi anlamına gelmektedir. Çoğu uygulamada verinin normal dağılıma sahip olduğu varsayılmaktadır, ancak bu varsayım ya aşırı tahmin ya da eksik tahmin ile sonuçlanmaktadır. Normal dağılımlı olmayan veriler normal hale getirilip, varyansları sabitlenerek uygulamalarda kullanılmaktadırlar (Priyanga vd. 2015).

Veri normalizasyonu literatürde doğrusal dönüşümler ve doğrusal olmayan dönüşümler olmak üzere iki grupta incelenmişlerdir. Doğrusal dönüşümler veri elemanlarının bir sabitle çarpılması, bir sabite bölünmesi veya elemanlara bir sabit eklenmesi ile elde edilen elemanlar arasındaki doğrusal ilişkinin korunduğu yöntemdir. Nercessian vd. 2010, doğrusal dönüşümlerin değer aralığı büyük olan bir veri setinde doğru sonuçlar üretmediğinden bahsetmişlerdir. Doğrusal olmayan yöntemler ise karekök dönüşümü, log dönüşümü ve ters dönüşüm olmak üzere üç gruba ayrılmışlardır.

2.1.1 Karekök dönüşümü

Her bir verinin karekökünün alınması temeline dayanmaktadır. Ancak negatif bir sayının karekökü alınamayacağı için, veri setindeki minimum değeri sıfırın üzerine, genellikle bire, çekmek için sabit bir sayı eklenmesi gerekmektedir. Ayrıca bir ve birin üstündeki sayılar 0 ve 0.99 arasındaki sayılardan farklı davranmaktadırlar. 1 ve üstü

sayıların karekökü kendilerinden küçük iken, 0 ve 0.99 arasındaki sayıların karekökü kendilerinden büyüktür. Bu sebeple 0 ve 1 arasında ve 1'den büyük değerler içeren sayılar içeren bir veriye bu yöntemde farklı davranılması istenilmeyen bir özelliktir.

2.1.2 Log dönüşümü

En sık kullanılan dönüşüm çeşididir. Bu dönüşüm büyük çarpıklığa sahip verinin, normal bir veri haline yaklaştırılmasında kullanılmaktadır. Logaritmik ölçekleme yöntemi ile yüksek değerli verilerin aralığı sıkıştırılırken, düşük değerli verinin aralığı genişletilmektedir, böylelikle yüksek ve düşük değerli veriler arasındaki mesafe azaltılmaktadır. Bu yöntemde veri setindeki elemanların on tabanında logaritması alınır ve bunun yanı sıra veride 1'den küçük elemanlar bulunuyorsa veri elemanlarına 1 eklenerek negatif bir sonucun çıkması engellenir. Çünkü log dönüşümü bir görüntü üzerinde kullanıldığında piksel yeğinliklerinin negatif değere sahip olması sorun teşkil eder.

2.1.3 Ters dönüşüm

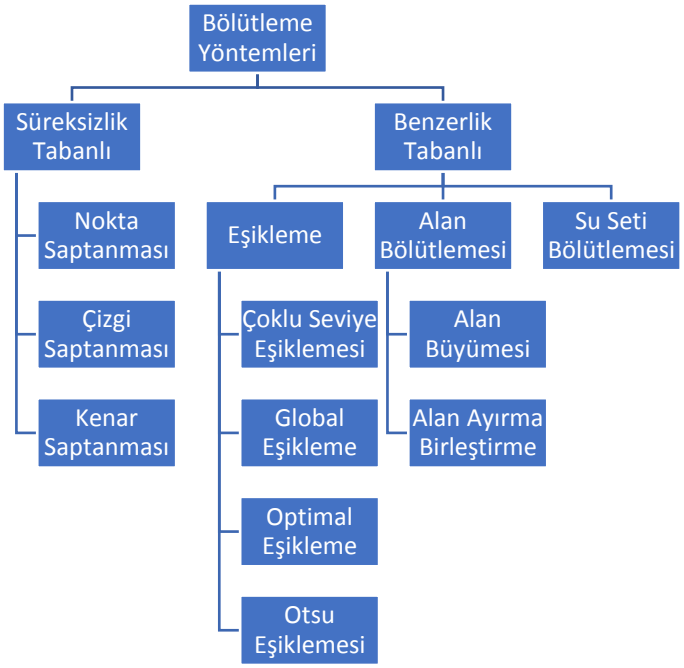
Veri içerisindeki eleman herhangi bir x değerinin tersinin alınarak -(1⁄x) değerine dönüştürülmesi temeline dayanmaktadır. Bu dönüşüm tekniği veri içindeki elemanların büyükten küçüğe sıralamasını tersine çevirmektedir. Veri içindeki birbirinden farklı eleman sayısı yüksek olduğunda kullanılması uygun görülmektedir.

2.2 Görüntü Bölütleme Yöntemleri

Görüntü bölütlemenin tanımı görüntüyü benzer özelliklerine göre alanlara ayırmak olarak yapılmaktadır. Bölütleme yapılırken kullanılabilecek en basit özellikler siyah-beyaz görüntüde parlaklık seviyesi, renkli görüntüde renk elemanları olabilir. Ayrıca görüntü içinde bulunan nesnelerin kenarları da bölütleme için sıkça kullanılan özelliklerdir. Her görüntüde iyi sonuç verecek veya görüntü çeşidine göre kullanılması uygun görülen bir bölütleme yöntemi bulunmamaktadır. Birçok bölütleme yöntemi

vardır ve üzerinde çalışılan görüntüye göre kullanılacak olan yöntem seçilmektedir. Görüntü bölütleme algoritmaları genel olarak gri seviye değerlerine bağlı iki özelliğe bakılarak kullanılmaktadır. Bunlardan birincisi süreksizlik olup, görüntü yeğinliğinde yaşanan ani değişimlerden (görüntünün kenarları gibi) yararlanmaktadır. İkinci özellik ise benzerliktir, belirlenen kriterlere göre görüntünün bölgelere ayrılmasına dayanmaktadır (Radha vd. 2011).

Haralick ve Saphiro iyi bir görüntü bölütlemesi için, gri seviye, doku gibi karakteristik özelliklere göre bölütlenmiş görüntüde oluşturulan bölgelerin tek biçimli ve homojen olması gerektiğini söylemişlerdir (Haralick ve Saphiro, 1984). Bu bölgelerin içleri basittir ve komşu bölgeler ile farklı özellikler taşıyor olmak zorundadırlar. Bölge sınırları basit, düzenli ve uzamsal olarak kesin olmalıdır. Bu çalışmada süreksizlik tabanlı yöntemler nokta, çizgi ve kenar saptanması başlıkları altında, benzerlik tabanlı yöntemler ise eşikleme, kümeleme, alan tabanlı bölütleme ve morfolojik su setleri başlıkları altında incelenmiştir. Çalışmada görüntü üzerinde (x, y) koordinatlarında bulunan bir piksel yeğinliği $f(x, y)$ ile gösterilmektedir.



Şekil 2.1 Görüntü bölütleme yöntemleri

2.2.1 Süreksizlik tabanlı yöntemler

Gri seviye bir görüntüde süreksizlik izole noktaları, çizgileri ve kenarları bulurken kullanılmaktadır. Süreksizlik gri seviyelerde ani değişimlerin yaşandığı bölgelerde bulunmaktadır ve süreksizliği bulmak için kullanılan yol görüntüye maske uygulamaktır. Görüntüye maske uygulama işlemi, görüntünün piksellerini içeren bir düzlem olarak adlandırılan uzamsal bölgede süzme işlemine denk düşmektedir.

Çizelge 2.1 3*3'lük uzamsal filtre maskesi

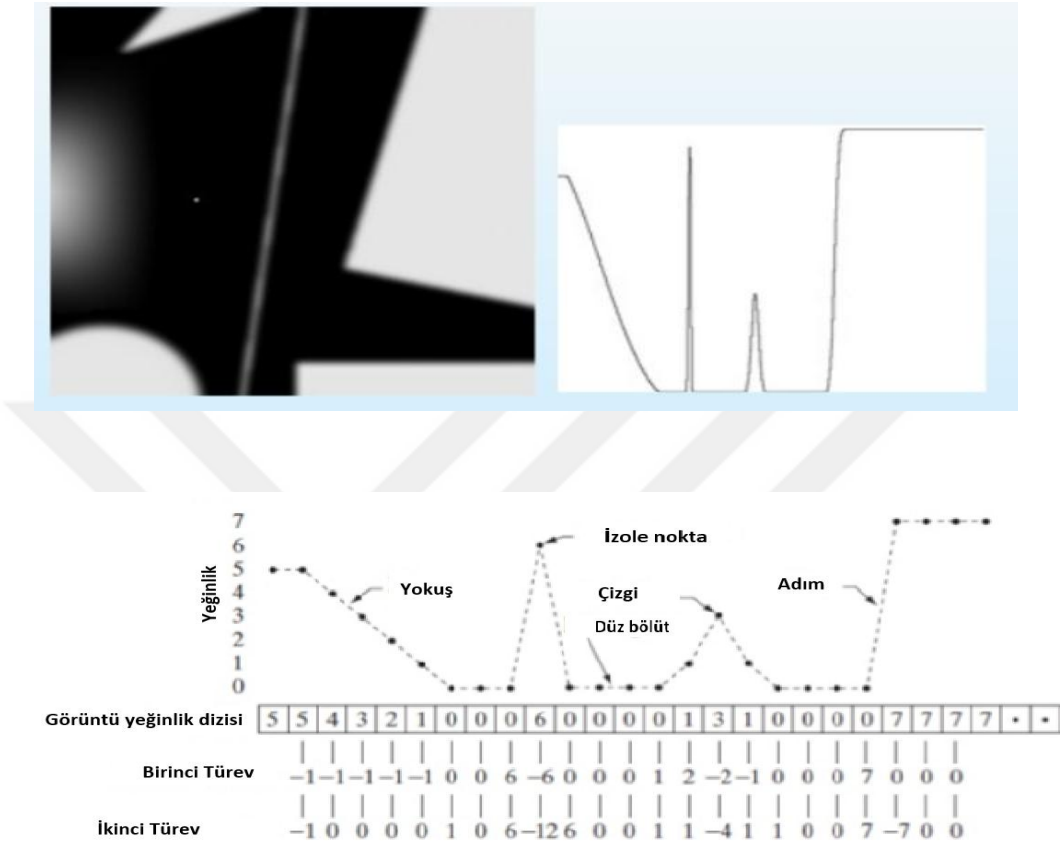
w_1	w_2	w_3
w_4	w_5	w_6
w_7	w_8	w_9

$$R = w_1z_1 + w_2z_2 + \cdots + w_9z_9 = \sum_{i=1}^{9} w_iz_i \quad (2.1)$$

Çizelge 2.1'de bulunan w_i değerleri maskenin elemanlarını gösterirken, z_i değerleri ilgilenilen piksellerin yeğinlik değerlerini göstermektedir. R değeri ilgilenilen piksellerin komşu piksellerinden ne kadar farklı olduğunun göstergesidir, R değerinin büyük olması pikselin bir nokta veya bir çizgiye ait olma olasılığının yüksek olduğunu göstermektedir. Bu işlem bir piksel ile komşusu olan sekiz piksel arasındaki ağırlıklı farkları ölçmektedir Maske gri seviyede oluşan ani değişiklikleri saptamak için kullanıldığından, sabit yeğinlikli bölgelerde maske cevabının sıfır olması için maske içindeki elemanların toplamı sıfır yapılmaktadır.

Maskelerin temelini türev işlemleri oluşturmaktadırlar. Bir görüntüde süreksizlik durumu varsa, süreksizliğin olduğu yerde görüntünün birinci dereceden türevi maksimum veya minimum değerindedir, aynı zamanda ikinci dereceden türevinde de

işaret değişimi vardır. Gri seviye bir görüntüde türev alma işlemi aşağıdaki örnekteki gibidir.



Şekil 2.2 Görüntü üzerinde türev alma işlemleri (Gonzalez ve Woods 2009)

İki boyutlu sayısal fonksiyonlarda türev işlemleri, fark denklemleri ile ifade edilebilir. Görüntü üzerinde x yönünde türev işleminin eşitliği, fark denklemleri eşitlik 2.2'de verilmiştir.

$$\frac{\partial f(x,y)}{\partial x} \cong [f(n_1+1,n_2+1)-f(n_1-1,n_2+1)]+[f(n_1+1,n_2)-f(n_1-1,n_2)]+[f(n_1+1,n_2-1)-f(n_1-1,n_2-1)] \quad (2.2)$$

$f(n_1,n_2)$, (x,y) pikseline komşu piksellerin yeğinlik değerini vermektedir. Fark denklemleri $f(n_1,n_2)$ ile dürtü cevabı $h(n_1,n_2)$ olan bir süzgecin katlanması olarak yorumlanabilir.

Çizelge 2.2 Süzgeç dürtü cevabı

$n_1 - 1, n_{2+1}$	$n_1, n_2 + 1$	$n_1 + 1, n_2 + 1$
$n_1 - 1, n_2$	n_1, n_2	$n_1 + 1, n_2$
$n_1 - 1, n_{2-1}$	$n_1, n_2 - 1$	$n_1 + 1, n_{2+1}$

Çizelge 2.2'de bulunan süzgeç dürtü cevabının, görüntü ile katlanılması sonucunda görüntünün türevi alınmış olmaktadır.

2.2.1.1 Nokta saptanması

Görüntüde bulunan bir nokta, noktaya ait maske cevabı önceden belirlenen pozitif bir eşik değerinden büyükse saptanabilmektedir

$$|R| \geq T \tag{2.3}$$

Burada eşikten büyük olan R değerine sahip noktaya izole nokta da denilmektedir, izole noktalar arka plandan ve bulundukları homojen bölgeden oldukça farklıdırlar. İzole noktaları bulurken kullanılan maske katsayıları için iki boyutlu bir dizinin x ve y yönündeki ikinci dereceden türevlerinin toplamı olan Laplasyen kullanılır.

2.2.1.2 Çizgi saptanması

Bir piksel genişliğindeki çizgilerin bulunmasını sağlamaktadır. Bu yöntem nokta saptamadaki gibi Laplasyen tabanlıdır. Bir piksel genişliğinde çizgilerin saptanabilmesinin sebebi Laplasyen sonucunun iki tane farklı yönde tepe oluşturmasıdır. Bu tepe noktalarından birbirlerine doğru çizgi çekildiğinde orta nokta sıfırdan geçiş noktasıdır ve bu noktadan çizgi geçmektedir. Görüntü bölütlemede ince

kenarlar belirlemek, daha kesin bölütleme yapmak açısından çizgi saptanması önem taşımaktadır. Hangi yöndeki çizgiler saptanmak isteniyorsa, kullanılacak olan maskede o yönün katsayıları büyük tutulur. Örneğin yatay yönde olan çizgilerin saptanması için maskenin orta satırındaki katsayılar büyük tutulur, bu durum diğer yönlerde de en büyük katsayılı kısımlar için geçerlidir.

Görüntüdeki farklı i ve j noktaları için eğer $|R_i| > |R_j|$ ise i yönünde bir çizginin olması daha olasıdır.

-1	-1	-1
2	2	2
-1	-1	-1

-1	-1	2
-1	2	-1
2	-1	-1

-1	2	-1
-1	2	-1
-1	2	-1

2	-1	-1
-1	2	-1
-1	-1	2

Şekil 2.3 Farklı yön çizgileri için kullanılan maskeler

2.2.1.3 Kenar saptanması

Görüntüdeki keskin belirsizlikleri sınıflandırmaya kenar saptama denmektedir (Radha vd. 2011). Kenar saptanmasında görüntüye ait birinci dereceden türeve dayalı (gradyan) ve ikinci dereceden türeve dayalı (Laplasyen) yöntemler kullanılmaktadır. Görüntünün birinci dereceden türevi kenara ait olan bir noktada maksimum veya minimum değerindedir, aynı zamanda ikinci dereceden türevinde de işaret değişimi yaşanmaktadır. Görüntünün türevini almak, görüntünün keskinleşmesini sağlamaktadır.

2.2.1.3.1 Birinci dereceden türeve dayalı yöntem ile kenar saptama

Bir boyutlu bir sistemde $f(x)$ fonksiyonunun birinci dereceden türevi, $f'(x)$ ile ifade edilmektedir ve $f'(x)$ değeri kenarın yönünü ve büyüklüğünü kestirmede kullanılmaktadır. Eğer $f'(x)$ değerinin genliğini ifade eden $|f'(x)|$ değeri çok büyükse, x noktasına ait gri seviyede ani bir değişikliğin olduğu söylenebilmektedir. $|f'(x)|$ değeri bir eşik seviyesinden büyükse kenar olma ihtimali artmaktadır.

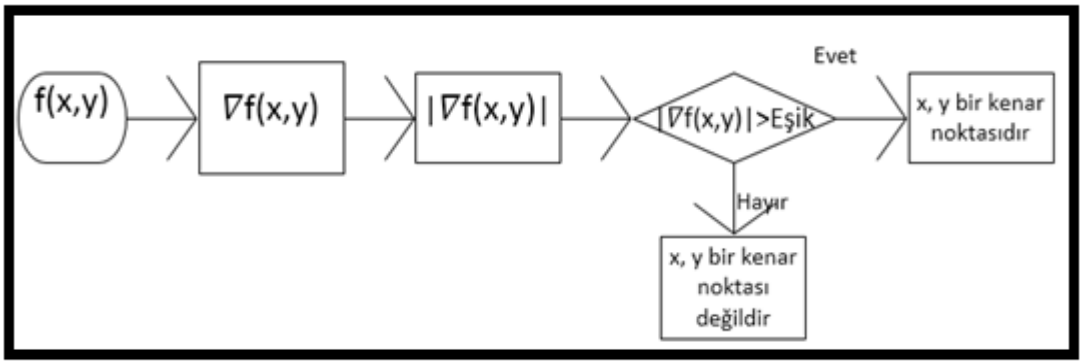
Bir görüntü için iki boyutlu $f(x,y)$ fonksiyonun birinci dereceden türevi $\nabla f(x,y)$ olarak ifade edilmektedir ve aşağıdaki formül ile gösterilmektedir.

$$\nabla f(x,y) = \frac{\partial f(x,y)}{\partial x} + \frac{\partial f(x,y)}{\partial y} \tag{2.4}$$

Kenar saptayıcıları ise birinci dereceden türev vektörünün genliğinden yola çıkılarak bulunmaktadır.

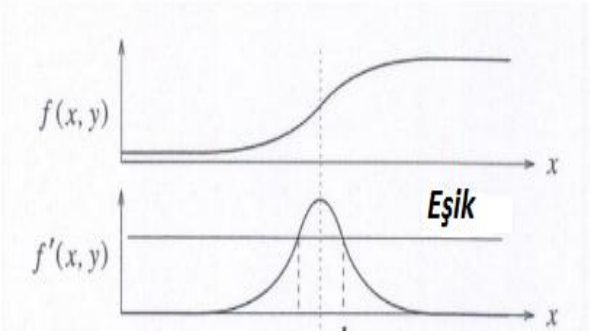
$$|\nabla f(x,y)| = \sqrt{(\frac{\partial f(x,y)}{\partial x})^2 + (\frac{\partial f(x,y)}{\partial y})^2} \tag{2.5}$$

Birinci dereceden türev tabanlı kenar belirleme, yönlü ve yönsüz kenar saptayıcılar olarak iki şekilde kullanılabilmektedir. Yönlü kenar saptayıcıları tek bir yöndeki kenarları tanırken diğer yönlerdeki kenarları tanımamaktadır. Örneğin $|\nabla f(x,y)|$ ifadesi hem yatay hem de dikey eksendeki kenarları bulmada kullanılırken, $\left|\frac{\partial f(x,y)}{\partial x}\right|$ ifadesi ile sadece düşey eksendeki kenarlar saptanıp, yatay yöndekiler saptanamamaktadır.



Şekil 2.4 Birinci dereceden türev ile kenar saptamaya ait akış diyagramı

Şekil 2.4'te verilen akış diyagramında bahsedilen eşik değeri genellikle birinci dereceden türevi alınmış görüntünün en büyük elemanının % 5 veya % 10'u kadar altında seçilmektedir (http://akizilkaya.pamukkale.edu.tr, 2008).



Şekil 2.5 Eşik değerinin belirlenmesi (http://akizilkaya.pamukkale.edu.tr 2013'ten değiştirilerek alınmıştır)

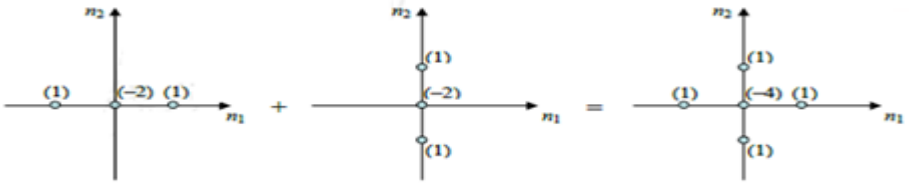
2.2.1.3.2 İkinci dereceden türeve dayalı yöntem ile kenar saptama

İki boyutlu bir fonksiyonun ikinci dereceden x ve y yönündeki türevlerinin toplamı o fonksiyonun Laplasyeni olarak adlandırılmaktadır ve daha önce de bahsedildiği üzere kenara ait olan bir noktanın birinci dereceden türevi maksimum değerinde iken, ikinci dereceden türevi sıfır geçiş noktasında bulunmaktadır.

Görüntüye ait ikinci dereceden türev aşağıdaki gibi ifade edilmektedir.

$$\nabla^2 f(x,y) = \nabla\big(\nabla f(x,y)\big) = \frac{\partial^2}{\partial x^2} f(x,y) + \frac{\partial^2}{\partial y^2} f(x,y) \qquad (2.6)$$

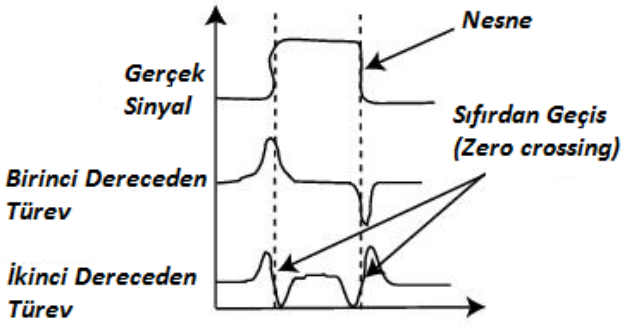
Eşitlik 2.6'da bulunan ifade de bulunan x ve y yönünde ikinci dereceden türevler fark denklemleri ile ifade edilmektedir ve sonuç olarak fark denklemleri, görüntünün x ve y yönünde süzgeçlerle katlanması olarak yorumlanmaktadır.



Şekil 2.6 Ikinci dereceden türev alma maskeleri

Görüntü ile Laplasyen maskesinin katlanması ile elde edilen sonuca eşik değeri uygulandıktan sonra kenar görüntüsüne ulaşılmaktadır. Birinci dereceden türev ile aynı işlemler yapılıyormuş gözükmesine rağmen, her iki yöntem ile elde edilen kenar görüntüleri arasında farklar bulunmaktadır. Türev fonksiyonun gürültüye duyarlı olması nedeniyle ikinci dereceden türeve dayalı olan Laplasyen, x ve y yönündeki ikinci dereceden türevlerin toplamı olduğu için birinci dereceden türev ile kenar saptamaya göre gürültüye çok daha fazla hassastır. Birinci dereceden türevin genliği ile bir noktanın kenara ait olup olmadığı, ikinci dereceden türev ile de kenara ait bir pikselin karanlık veya açık taraflardan hangisinde olduğu anlaşılmaktadır (Saleh vd. 2010).

Ancak ikinci dereceden türev görüntüsündeki her kenar için iki tane değer üretilmesi istenilmeyen bir özelliktir ayrıca negatif bir değerden pozitif bir değere geçerken pikseller arasındaki fark çok küçük olsa bile kenar üretebilmektedir. Bu yüzden sıfır geçiş noktalarını oluşturan pikseller arasındaki yeğinlik farkı belirlenen eşik değerinden büyükse kenar vardır denilmektedir. Eşik değeri genellikle Laplasyeni alınmış görüntünün mutlak değer ortalamasının %75'i olarak alınır (http://akizilkaya.pamukkale.edu.tr, 2008).



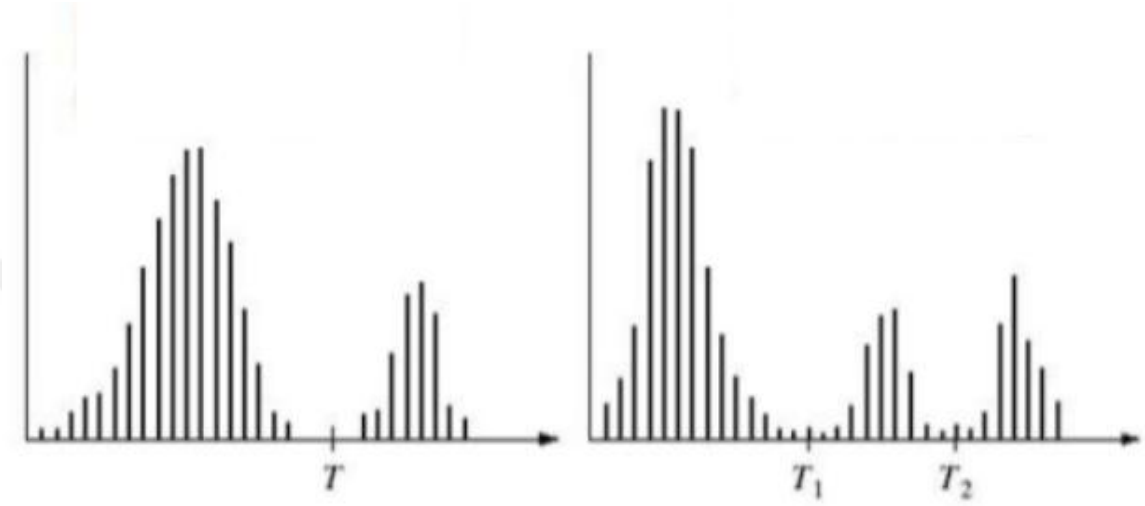
Şekil 2.7 Türev alma işlemleri ve sıfır geçiş noktası (Gonzales ve Woods 2009)

2.2.2 Eşikleme tabanlı bölütleme

Anlaşılabilir ve basit olması nedeniyle eşikleme görüntü bölütlemede çokça kullanılan bir yöntemdir. Çoklu seviye eşiklemesi, global eşikleme, optimal eşikleme ve Otsu eşiklemesi olmak üzere dört başlık altında incelenecektir.

2.2.2.1 Çoklu seviye parlaklık eşiklemesi

Birden fazla nesne bulunan arka planı geniş gri seviyeye sahip görüntülerde bu bölütleme yöntemi kullanılmaktadır. İkiden fazla tepe bulunduran görüntü sıklık grafiklerinde kullanılabilmektedir.



a b

Şekil 2.8 Tek ve iki tane eşik gerektiren gri seviye sıklık grafikleri (Gonzales ve Woods 2009)

Şekil 2.8. a'da $f(x,y)$ görüntüsüne ait gri seviye sıklık grafiği bulunmaktadır ve sıklık grafiğinden görüldüğü üzere iki tepeli sıklık grafiği görüntünün açık renkli nesneler ve koyu arka plana sahip olduğunu gösterir. Bu nesneleri arka plandan ayırmak için kullanılacak en açık yöntem bir T eşiği belirleyerek bu modları birbirinden ayırmaktır. $f(x,y) > T$ olan noktalar nesnelere aittir denilmektedir.

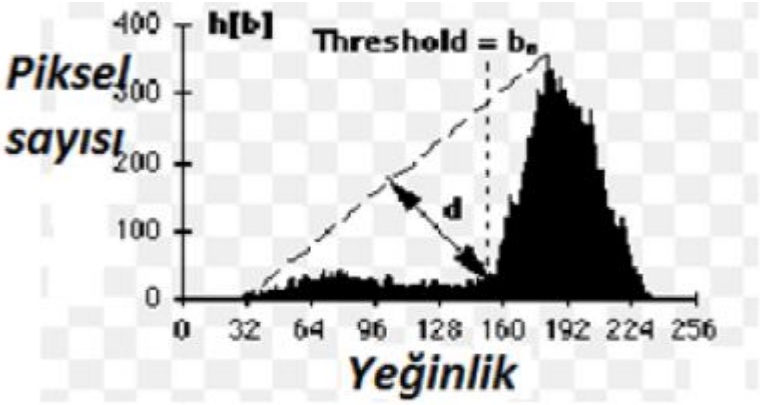
Şekil 2.8. b'de ise üç tane dominant tepe bulunmaktadır ve bu çoklu seviye eşiklemeye ihtiyaç olduğunu gösterir. Bu görüntüdeki nesnelerden biri $T_1 < f(x,y) < T_2$, diğeri ise $f(x,y) > T_2$ eşikleriyle belirlenir, arka plan f(x,y)< T_1 ile belirlenir. Çoklu seviye eşikleme gerektiren görüntülerde genelde alan büyüme yöntemi, başlangıç tohumlarını doğru yerleştirildiği takdirde, ile daha iyi sonuçlar alınmaktadır. Böyle görüntülerde lokal eşikleme tekniğiyle bölgesel olarak değişen eşik değerlerinin saptanması gerekmektedir. Birden fazla bölgeyi etkili bir biçimde bölütleyen eşik değerlerinin

belirlenmesi zor bir işlemdir. Bu sebeple çoklu seviye eşiklemesi, global eşikleme yönteminde anlatılacağı gibi tek bir eşik değeri ile görüntüyü eşiklemekten daha az güvenilir sonuçlar vermektedir.

2.2.2.2 Global eşikleme

Global eşikleme orijinal görüntü ile bölütlerinin arasındaki farkın minimum olmasına dayanmaktadır. Basit olarak anlatılacak olursa sıklık grafiğini parçalara ayırarak bir tane T eşiği ile yapılmaktadır. Görüntünün tamamı piksel piksel incelenerek T eşiğinden büyük olan pikseller nesneye, küçük olanlar arka plana aittir diyerek etiketlenirler. Tek tepeli sıklık grafiğine sahip görüntülerde iyi çalışmaktadır.

Bu bölütleme yönteminin başarısı, görüntü sıklık grafiğinin iyi bir biçimde bölümlenmesine bağlıdır. Global eşik değeri olan *T*'yi otomatik olarak bulmak için Üçgen Metodundan yararlanılmaktadır. Bu işlem görüntü sıklık grafiğinde en çok ve en az kullanılan gri seviye değerleri arasına çizilen bir çizgiye, sıklık grafiğindeki tüm gri seviyelerin uzaklıklarının hesaplanmasına dayanmaktadır. En büyük uzaklığa sahip olan gri seviye değeri eşik değeri olarak atanmaktadır. Üçgen yöntemi tek seviyeli sıklık grafiğine sahip görüntülerde iyi sonuçlar vermektedir (Şekil 2.9).



Şekil 2.9 Üçgen metodu (https://cs.gmu.edu/~kosecka/cs682/lect-segmentation-part1 2013)

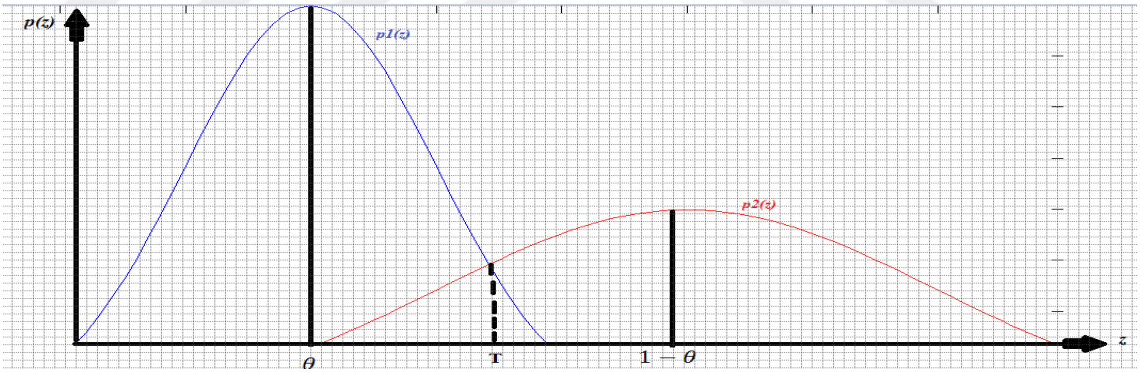
2.2.2.3 Optimal eşikleme

Görüntüde sadece iki temel parlaklık seviyesi olduğu varsayıldığında, görüntünün sıklık grafiğinden yararlanılarak toplam hata olasılığını en küçük yapan eşik değeri bulunurken kullanılmaktadır. Bu iki parlaklık seviyesinden biri açık, diğeri koyudur ve görüntünün tamamındaki $p(z)$, bu bölgelerin olasılık yoğunluk fonksiyonlarının karışımı olarak ifade edilmektedir. Koyu olan alanın arka plana ait olduğunu varsayarak $p_1(z)$ ile açık alanın da nesneye ait olduğunu varsayarak $p_2(z)$ ile olasılık yoğunluk fonksiyonları gösteriliyor olsun.

Buna göre görüntünün karıştırılmış olasılık yoğunluk fonksiyonu aşağıdaki gibidir.

$$p(z) = (1-\theta)p_1(z) + \theta p_2(z) \tag{2.7}$$

θ görüntü içerisinde nesneye ilişkin piksellerin var olma olasılığıdır.



Şekil 2.10 Görüntü sıklık grafiğinin iki olasılık yoğunluk dağılım fonksiyonu ile modellenmesi

Nesne pikselinin arka plan olarak yanlışlıkla sınıflandırılması olasılığı eşitlik 2.8 gibi ifade edilir.

$$E_1(T) = \int_{-\infty}^{T} p_2(z) \tag{2.8}$$

Arka plan pikselinin nesne olarak yanlışlıkla sınıflandırılması olasılığı eşitlik 2.9 gibi ifade edilir.

$$E_2(T) = \int_T^{\infty} p_1(z) \tag{2.9}$$

Toplam hata olasılığı ifadesi eşitlik 2.10 gibidir.

$$E(T) = \theta E_1(T) + (1-\theta) E_2(T) \tag{2.10}$$

Toplam hata olasılığını minimize eden T eşik değeri, $E(T)$'nin türevinin sıfıra eşitlenmesiyle bulunmaktadır. Bu işlemi yapabilmek için Leibnitz (sınırları belli integralin türevi) kuralından yararlanılmaktadır.

Leibnitz kuralı eşitlik 2.11'de verilmiştir.

$$F(x) = \int_{u(x)}^{v(x)} f(t)dt \rightarrow F'(x) = f[v(x)]v'(x) - f[u(x)]u'(x) \tag{2.11}$$

Bu kuralı kullanarak, yukarıda söylenildiği gibi hata olasılığını minimize etmek için $E(T)$'nin türevinin sıfıra eşitlenmelidir.

$$E(T) = \theta \int_{-\infty}^{T} p_2(z) + (1-\theta) \int_T^{\infty} p_1(z) \tag{2.12}$$

$$\frac{dE(T)}{dT} \cong \theta[p_2(T)T'] + (1-\theta)[-p_1(T)T'] = 0 \tag{2.13}$$

Sonuç olarak optimum eşik değeri için en genel ifade eşitlik 2.14 gibi olmaktadır.

$$\theta p_2(T) = (1-\theta) p_1(T) \tag{2.14}$$

Ancak bu yöntemi kullanabilmek için sıklık grafiğini modelleyen olasılık yoğunluk fonksiyonlarının ve θ değerinin bilinmesi gerekmektedir. Olasılık yoğunluk fonksiyonlarına normal dağılım fonksiyonları ile yaklaşılabilir ancak bu durumda bile nesne ve arka plana ait ortalama değer ve standart sapma değerlerinin kestirilmesi gerekmektedir. Her görüntüde bunları bilmek zor olduğundan optimal eşikleme yöntemi tercih edilmemektedir.

Görüntüye ait herhangi bir gerçek istatiksel özellik kullanmadan optimal eşik değerine, sonucuna Eşitlik 2.15 ile rasgele bir değerin eşik olarak belirlenip, daha sonra bu eşiğe göre ön ve arka plan piksellerinin tekrarlı olarak ortalamalarının toplamının ikiye bölünmesi ile yaklaşılabilmektedir. Bu işlem eşik değeri olarak bulunan T'nin değeri neredeyse hiç değişmeyecek kadar kararlı hale geldiğinde durdurulur.

$$T = \frac{\mu_1 + \mu_2}{2} \tag{2.15}$$

2.2.2.4 Otsu eşiklemesi

Optimal eşiklemenin aksine görüntüye ilişkin nesne ve arka plan ile ilgili herhangi bir olasılık dağılım fonksiyonu belirlemeye ihtiyaç duymayan bu yöntemle ilgili bir çalışma 1979 yılında Otsu tarafından gerçekleştirilmiştir. Otsu yöntemi kolay hesaplanabilmesi sebebiyle en başarılı sonuç veren bölütleme yöntemlerinden biridir (Vala ve Baxi 2013). Otsu yöntemi ile iki renkli (genellikle siyah-beyaz) görüntüler elde edilir (Daniel vd. 2012). Bu yöntemde görüntü üzerindeki tüm piksel değerleri eşik değeri olarak kullanılıp piksel saçılımı hesaplanmaktadır. Burada amaç arka plan ve ön plan saçılımının en az olduğu eşik değerini bulmaktır. Ön plan ve arka plan standart sapması saçılma ölçütüdür.

Görüntüde bulunan toplam L tane gri seviye değerinden, her bir gri seviye değeri x ile temsil edilmektedir. Gri seviye bir görüntü toplam 256 tane gri seviyeden oluşmaktadırlar, x gri seviye değeri sayısının görüntüdeki piksel toplamına oranı $p(x)$ ile gösterilmektedir.

Eşik olarak herhangi bir t değeri seçildiğinde, arka planda olacak piksellerin görüntüde bulunma olasılığı eşitlik 2.16'da gösterilmiştir..

$$\theta(t) = \sum_{x=1}^{t} p(x) \tag{2.16}$$

Aynı durumda görüntüdeki nesneyi oluşturan piksellerin görüntüde bulunma olasılığı eşitlik 2.17 ile ifade edilir.

$$1 - \theta(t) = \sum_{x=t+1}^{L} p(x) \tag{2.17}$$

Arka plana ve nesneye ait piksellerin ortalama değerleri ve varyansları eşitlik 2.18– 2.21 ile ifade edilir.

$$\mu_{arkaplan} = \frac{\sum_{x=1}^{t} xp(x)}{\sum_{x=1}^{t} p(x)} = \frac{\mu(t)}{\theta(t)} \tag{2.18}$$

$$\mu_{nesne} = \frac{\sum_{x=1}^{L} xp(x) - \sum_{x=1}^{t} xp(x)}{1-\theta(t)} = \frac{\mu - \mu(t)}{1-\theta(t)} \tag{2.19}$$

$$\delta^2_{arkaplan} = \frac{\sum_{x=t+1}^{L} (x-\mu_{arkaplan})^2 p(x)}{\sum_{x=1}^{t} p(x)} = \frac{1}{\theta(t)} \sum_{x=1}^{t} (x - \mu_{arkaplan})^2 p(x) \tag{2.20}$$

$$\delta^2_{nesne} = \frac{\sum_{x=t+1}^{L} (x-\mu_{nesne})^2 p(x)}{\sum_{x=t+1}^{t} p(x)} = \frac{1}{1-\theta(t)} \sum_{x=t+1}^{L} (x - \mu_{nesne})^2 p(x) \tag{2.21}$$

Görüntüdeki piksellerin dağılımının toplam varyansı eşitlik 2.22 de ifade edilmiştir. .

$$\delta_T^2 = \sum_{x=1}^{L} (x-\mu)^2 p(x) \tag{2.22}$$

Eşitlik 2.22, ön plan ve arka plan varyanslarının toplamı olarak eşitlik 2.23 ile de yazılabilmektedir.

$$\delta_T^2 = \sum_{x=1}^{t}(x-\mu)^2 p(x) + \sum_{x=t+1}^{L}(x-\mu)^2 p(x) \quad (2.23)$$

μ bütün görüntüdeki gri seviye ortalamasını göstermektedir.

Eşitlik 2.23'te bulunan ifade arka plan ve nesneye ait varyanslara benzetilerek eşitlik 2.24 ile yazılabilmektedir.

$$\delta_2^T = \sum_1^t \left(x-\mu_{arkaplan}+\mu_{arkaplan}-\mu\right)^2 p(x) + \sum_{x=t+1}^{L}(x-\mu_{nesne}+\mu_{nesne}-\mu)^2 p(x) \quad (2.24)$$

$$= \sum_{x=1}^{t}\left(x-\mu_{arkaplan}\right)^2 p(x) + \sum_{x=1}^{t}\left(\mu_{arkaplan}-\mu\right)^2 p(x) + 2\sum_{x=1}^{t}\left(x-\mu_{arkaplan}\right)\left(\mu_{arkaplan}-\mu\right)p(x) + \sum_{x=t+1}^{L}(x-\mu_{nesne})^2 p(x) + \sum_{x=t+1}^{L}(\mu_{nesne}-\mu)^2 p(x) + 2\sum_{x=t+1}^{L}(x-\mu_{nesne})(\mu_{nesne}-\mu)p(x)$$

Eşitlik 2.24 içerisinde sıfıra eşit olan işlemler eşitlik 2.25 – 2.26'da gösterilmiştir.

$$\sum_{x=1}^{t}\left(x-\mu_{arkaplan}\right)p(x) = \sum_{x=1}^{t} x\,p(x) - \mu_{arkaplan}\sum_{x=1}^{t} p(x) = \mu_{arkaplan}\theta(t) - \mu_{arkaplan}\theta(t) = 0 \quad (2.25)$$

$$\sum_{x=1}^{t}(x-\mu_{nesne})p(x) = \sum_{x=t+1}^{L} x\,p(x) - \mu_{nesne}\sum_{x=1}^{t} p(x) = \mu_{nesne}[1-\theta(t)] - \mu_{nesne}[1-\theta(t)] = 0 \quad (2.26)$$

Sonuç olarak eşitlik 2.24, eşitlik 2.27 ile aynıdır.

$$\delta_T^2 = \underbrace{\theta(t)\delta_{arkaplan}^2 + [1-\theta(t)]\delta_{nesne}^2}_{\delta_w^2(t)} + \underbrace{\left(\mu_{arkaplan-}\mu\right)^2\theta(t) + (\mu_{nesne-}\mu)^2[1-\theta(t)]}_{\delta_B^2(t)} \quad (2.27)$$

$\delta_w^2(t)$ nesne ve arkaplan ile ilgili her iki piksel grubunun kendi içerisindeki varyansı ifade etmektedir (within class variance). $\delta_B^2(t)$ ise nesne ve arkaplan ile ilgili her piksel grubu arasındaki varyansı ifade etmektedir (between class variance).

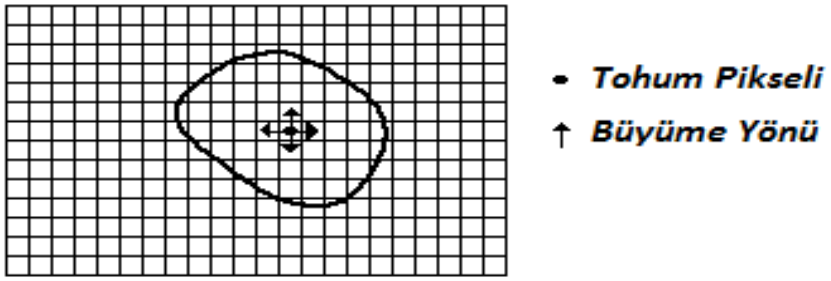
Piksel grubu içerisindeki varyans değeri ile piksel grupları arasındaki varyans değeri ters orantılıdır. Piksel grupları arsındaki varyans değerinin büyük olması iki grubun birbirinden iyi bir şekilde ayrıldığını gösterir, aynı şekilde piksel grubu içindeki varyansın küçük olması da grubun içindeki piksellerin birbirine çok benzediğini ve aralarına diğer gruptan elemanların girmediğini gösterir. Görüntüyü bölütlemek için kullanılacak en uygun eşik değeri pikseller grubu arasındaki standart sapma değerinin en büyük olduğu, bu yüzden de pikseller grubu içindeki standart sapma değerinin en küçük olduğu noktadır. $\delta_B(t)$'nin en büyük olduğu yerde $\delta_W(t)$ en küçüktür, bu yüzden sadece $\delta_W(t)$'nın hesaplanması yeterlidir. Burada amaç bölütlenmiş ön planın ve arka planın kendi içlerinde sıkı bir şekilde kalıp, birbirleri arasında ise hiç çakışma olmadan ayrılabilmelerini sağlamaktır.

2.2.3 Benzerlik tabanlı bölütleme tekniği

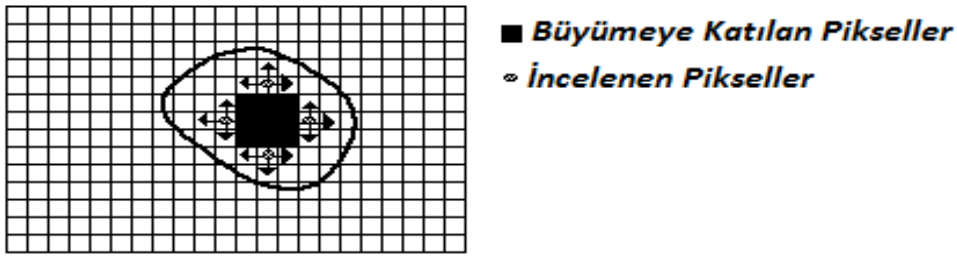
Görüntü üzerinde belli kriterleri sağlayan, başka bir deyişle birbirlerine benzeyen alanları bölütlemeyi temel alarak çalışmaktadır. Bu başlık altında alan büyümesi ve alan ayırma birleştirme ile bölütleme tekniklerinden bahsedilecektir.

2.2.3.1 Alan büyümesi

Alan büyümesi yöntemi, görüntü üzerinden bir tohum pikselin seçilmesi ve bu tohuma eşik değeri ile belirlenmiş seviyede benzerlik gösteren komşu piksellerin yinelemeli olarak bir araya gelip bir bölüt oluşturması temeline dayanmaktadır (Gonzales ve Woods 2009). Başlangıç olarak bir tohum piksel seçilir ve tohuma komşu olan pikseller tohumla aynı özelliklere sahipse alana eklenir.



Şekil 2.11 Alan büyümesi yönteminin başlatılması (https://users.cs.cf.ac.uk. 1997)



Şekil 2.12 Birkaç yenileme sonucu büyüme işlemi (https://users.cs.cf.ac.uk. 1997)

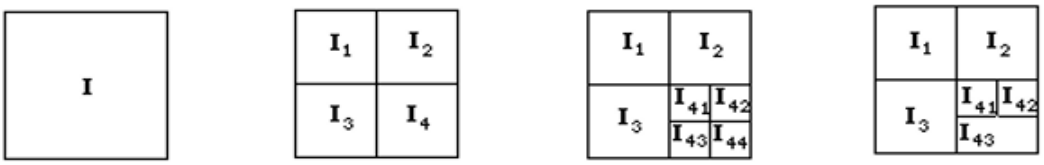
Eğer benzerlik açısından bir kriter belirli değilse, tüm piksellerde aynı özelliklere bakılır ve bu şekilde pikseller kümelendirilir, bu kümelerin merkezindeki pikseller bölütleme sırasında her yinelemede tohum olarak seçilir. Benzerlik kriterini seçme, üzerinde çalışılan problemin yanı sıra görüntü verisinin çeşidine de bağlıdır (Gonzales ve Woods 2009). Örneğin uydu ile çekilen arazi görüntüleri renk tabanlıdır. Renkli görüntüler hakkında bilgi sahibi olmadan bu problemin çözümü neredeyse imkânsızdır. Görüntü üzerinde sadece tek bir gri seviyeye dayalı benzerlik kriteri seçip bu kritere göre komşuluklara bakmak hatalı olabilmektedir, çünkü nesne piksellerinin hepsi aynı gri seviye değerine sahip olmayabilmektedir. Bu sebeple aynı gri seviye değeri yerine belli bir gri seviye değerinden yüksek seviyeler veya belli bir gri seviye etrafında bir varyans değeri kullanılarak alan oluşturulması sağlanmaktadır. Alan büyümesi yönteminde ikinci bir problem ise durdurma kriterinin formüle edilmesidir. Alan büyümesi, o alana dahil olma kriterini sağlayacak piksel kalmadığında durmaktadır, ancak tek bir tohum pikseli seçildiğinde görüntü içindeki nesneler ayrıksa sadece tohum pikselinin olduğu nesne bölütlenebilmektedir. Çözüm olarak birden fazla tohum pikseli noktası seçilebilsede, tohum pikselinin nerede seçileceği bu yöntemin başka bir problemidir.

Ayrıca arka plan üzerinden tohum pikselinin seçilmesi yanlış bölütleme sonucunu getirmektedir.

2.2.3.2 Alan ayırma birleştirme

Bu yöntemde öncelikle ayırma birleştirme işlemlerini yapmak için bir koşul seçilmektedir, bu koşul alan büyümesi yönteminde anlatıldığı gibi görüntünün özelliklerine bağlıdır. Başlangıçta tüm görüntü eşit parçalara bölünmektedir, genellikle dört parçaya bölme kullanılmaktadır. Bölünmüş parçalardaki görüntüler ayrı ayrı tek bir alan olarak ele alınmaktadır ve koşulu sağlayıp sağlamadığına bakılmaktadır. Eğer koşul sağlanmıyor ise alan dörde bölünür ve bu işlem her alana tekrardan uygulanır, bölünecek alan kalmadığında işlem durdurulur. Bölünmüş kısımlarda koşulu sağlayan komşu olan alanlar birleştirilir. Ayırma birleştirme yöntemi görüntüyü dikdörtgen biçiminde böldüğü için görüntü yapısına uyum sağlamada yeterli değildir (Chaudhuri ve Agrawal 2010).

Ayrıca Ayırma birleştirme yönteminde ayırma işlemi nesnenin kapsadığı alana bakılmaksızın yapılmaktadır bu kararlı olmayan sonuçlar üretir (Amoda 2013). Kararlı olmayan sonuçtan kastedilen, bu yöntemde alanlar dörtgenlere bölünüp daha sonra benzerlik bulunan kısımlar birleştirirken oluşan bölütlerin kenarları, bölütün gerçekteki kenar şeklinden farklı olarak küçük kareler şeklinde oluşmasıdır.



Şekil 2.13 Ayırma birleştirme işlemi (Gonzales ve Woods 2009)

2.2.3.3 Su seti bölütlemesi

Su seti dönüşümü morfoloji tabanlı görüntü bölütleme aracıdır. Bu yöntem gri seviye bir görüntünün topografik rölyef olarak ele alınması ile kullanılmaktadır (Serra 1982, El Allaoui 2012).

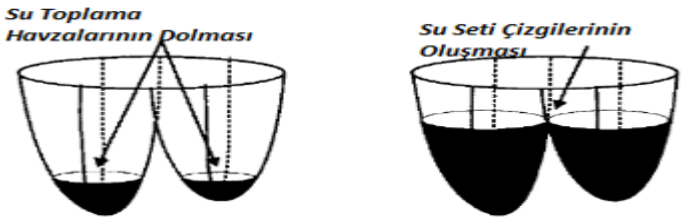
En eski bölütleme tekniklerinden biri olan su seti bölütlemesi aynı zamanda en güçlü tekniklerden biridir (Jaafar ve Mourou 2009). Su setleri, iki boyutlu uzamsal koordinatlar ve gri seviyeleri olmak üzere 3 boyutlu olarak düşünülmektedir. Bu şekilde topografik yorumlaması yapılan görüntüde üç nokta önemlidir.

1) Bölgesel minimuma ait noktalar

2) Suyun ineceği noktalar, su toplama havzası olarak adlandırılmaktadırlar.

3) Suyun birden fazla minimuma düşebileceği noktalar, baraj inşa edilecek noktalar olarak adlandırılmaktadırlar.

Su seti yöntemini fiziksel olarak açıklamak istersek; uzamsal koordinatlarının yanı sıra üçüncü boyutu içinde bulunan piksellerin yeğinliği olarak düşünülen görüntünün, minimumlarından birer delik açılıp görüntü suya batırılıyor gibi düşünülmesi olarak açıklanabilir. Bütün minimumlara su aynı hızla dolar, farklı minimumlara ait sular birleşmeye başladıkları anda birleşme noktalarına baraj örülür, suyun dolması baraj tepeleri gözükene kadar devam eder.



Şekil 2.14 Su seti yönteminin fiziksel yorumlanışı (https://www.jhu.edu. 2015)

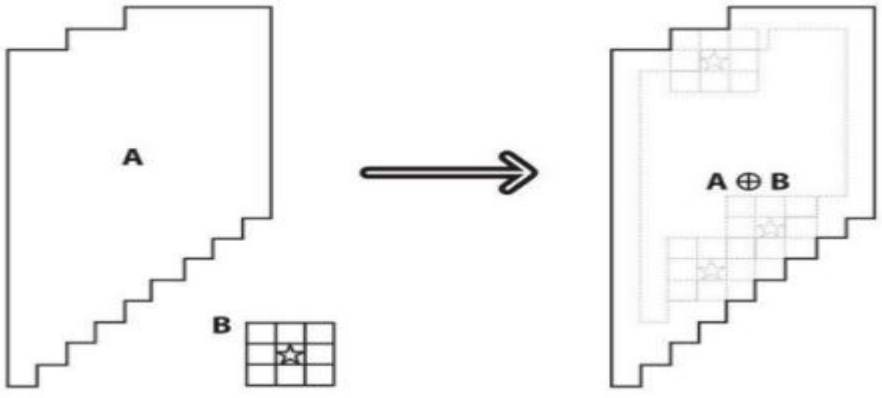
2.2.3.3.1 Baraj inşa edilmesi

Baraj inşası için kullanılan en basit yol genişleme yöntemidir. Genişleme matematiksel morfolojinin en temel operatörlerinden biridir. Ön plan nesnesine ait sınırları yavaş yavaş genişleterek, o bölgedeki açıklıkların azalmasını sağlar. Su seti dönüşümünde baraj oluştururken görüntünün kendisinden değil, gradyan görüntüsünden yararlanılmaktadır. Gri seviyesinde küçük değişiklikler ile karakterize edilen bölgeler küçük gradyan değerlerine sahiptirler. Su seti dönüşümünde bölgesel minimumlar küçük gradyan değerleri olarak seçilmektedirler. Böylelikle küçük gradyan değerine sahip bölgeleri birbirinden ayıran su seti çizgileri yani yüksek gradyan değerleri bulunmaktadır. Gradyan görüntü üzerinden genişleme işlemi yapılmaktadır.

Genişleme aşağıdaki gibi iki adımda gerçekleştirilmektedir.

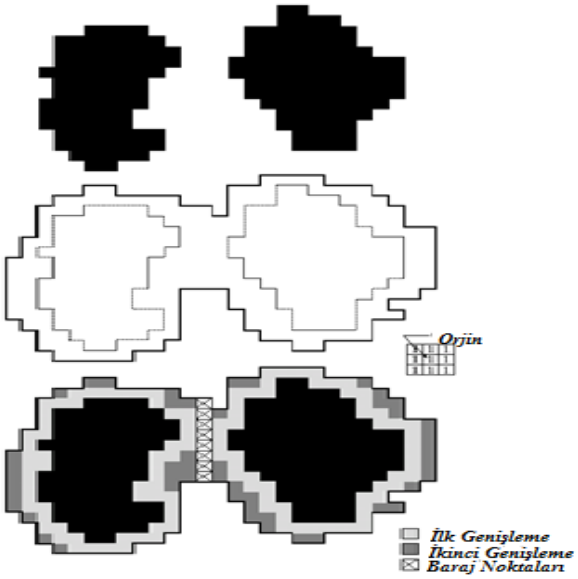
1) Başlangıçta en düşük gri seviye değerine sahip piksellere 1, diğer tüm piksellere 0 değeri verilir.

2) Her adımda minimumlardan başlayarak görüntü 3*3'lük yani 8-komşuluğa sahip yapılanma elemanı ile genişletilir, genişleyen piksellerin değeri 0'dan 1'e dönüşür.



Şekil 2.15 8-komşuluk içeren yapılanma elemanı ve nesnenin genişletilerek arka plan piksellerinden bazılarının ön plan pikseline dönüşmesi (http://www.cacr.caltech.edu. 2014)

Genişleme adımı, piksel piksel genişleyen minimum bölgeleri birbirleri ile kesiştikleri anda durdurulur (http://gim.unmc.edu/dxtests/ROC3.htm, 2014). Kesişmenin olduğu yerlere görüntüdeki maksimum gri seviye değerinde bir piksel kalınlığında baraj örülür. Böylelikle bölütleme yapılmış olur.



Şekil 2.16 Genişletme ve baraj inşasının sonucu (Gonzales ve Woods 2009)

M_1, M_2 iki bölgesel minimumunda bulunan noktaların koordinatları kümesidir.

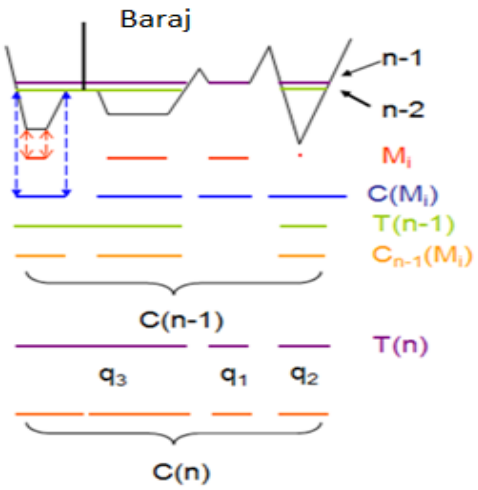
$C_{n-1}(M_1), C_{n-1}(M_2)$, su n-1 adımındayken M_1, M_2 minimumlarından oluşan su toplanma havzası koordinatları kümesidir.

$C[n-1]$ ise $C_{n-1}(M_1)\ ve\ C_{n-1}(M_2)$ 'in birleşimidir.

Şekil 2.16'da görüldüğü üzere *n-1*'inci su doldurma adımında iki tane bağlı eleman vardır, ancak (b) şeklinde görüldüğü üzere n'inci adımda sadece bir tane bağlı eleman vardır. Bu n'inci adımda iki su toplama havzasındaki suların karıştığını göstermektedir. Bu bir tane olan bağlı elemana q diyelim. $C_{n-1}(M_1)\ ve\ C_{n-1}(M_2)$, q sınırları içerisinde 3*3'lük genişleme matrisi (c) ile genişletilirler. Matrisin merkez elemanının her zaman q'nun üzerinde olması genişlemenin q sınırını aşmamasını sağlar. Genişletilen kümeler

birleştiği anda, oraya bir piksel kalınlığında baraj yapılır ve barajdaki her noktaya görüntünün sahip olduğu maksimum gri seviye değeri verilir, siyah beyaz bir görüntü için bu değer birdir.

Aşağıda su seti dönüşümünün uygulanmasında izlenen işlemler anlatılmıştır.



Şekil 2.17 Topografik yüzey gösterimi (Gonzales ve Woods 2009)

$M_1, M_2, .., M_R$, $g(x,y)$ gradyan görüntüsüne ait bölgesel minimumlardaki noktaların kümesi olsun. $C(M_i)$, M_i bölgesel minimumuna ait su toplama havzası olsun. $C_n(M_i)$, su n adımındayken M_i minimumunda toplan suyun koordinatları kümesi olsun. Gradyan görüntüsü $g(x,y)$'nin maksimum ve minimum gri seviyelerini kısaca max, min diye adlandıralım. $T[n]$, su n adımındayken su ile dolmuş tüm noktaların koordinatları kümesi olsun. Topografi $n = min + 1$'den, $n = max + 1$'e kadar su ile dolduruluyor. $C[n]$, n seviyesindeki tüm havzaların birleşimi olarak aşağıdaki gibi gösterilir.

$$C_n(M_i) \subseteq T[n]$$

$$C[n] = \bigcup_{i=1}^{R} C_n(M_i) \; ve \; C[max+1] = \bigcup_{i=1}^{R} C(M_i)$$

Başlangıçta $C[min+1] = T\,[min+1]$ olarak kabul edilir.

Her n adımında $C[n-1]$ oluşturulur ve amaç $C[n-1]$'den $C[n]$'i elde etmektir.

$Q[n]$, $T[n]$ içindeki bağlı elemanlar kümesi olsun. Her $q \in Q[n]$ için üç tane olasılık vardır:

1) $q \cap C[n-1] = \emptyset$ (q_1) ise yeni bir minimum ile karşılaşılmıştır ve q ile $C[n-1]$ birleştirilerek $C[n]$ oluşturulur.

2) $q \cap C[n-1]$, bir tane bağlı eleman içeriyorsa (q_2), q'nun bölgesel minimum havzasında olduğu anlaşılır ve q ile $C[n-1]$ birleştirilerek $C[n]$ oluşturulur.

3) $q \cap C[n-1]$, birden fazla bağlı eleman içeriyorsa (q_3), q su toplanma havzaları arasındadır ve suların karışmaması için baraj konulmalıdır. $q \cap C[n-1]$ bölgesi 3*3'lük yapısal elemanlarla genişletilerek, bir piksellik baraj inşa edilir.

4) Bu işlemler algoritma *n= max+1* olana kadar tekrarlı bir şekilde devam ettirilir, böylelikle su setleri ile bölütleme işlemi gerçekleştirilmiş olmaktadır.

Tez çalışması kapsamında Bölüm 2.2'de anlatılan tüm görüntü bölütleme teknikleri kullandığımız radar video çerçevelerine uygulanmıştır. Bölüm 2.3'de anlatılan performans analizi ile tüm bölütleme yöntemlerinin performansları ölçülmüştür.

2.3 Bölütleme Performans Analizi

Görüntü bölütleme hem bilgisayarla görme hem de görüntü işleme uygulamalarında kullanılan görüntü içinde ilgilenilen bölgeyi tanımlamaya yarayan, önemli bir araçtır. Uygulamaya özgü yapısı ve birçok uygulamada önemli olması nedeniyle geçtiğimiz on yıldan şimdiye kadar bölütleme hakkında araştırmalar yapılmaktadır. Görüntü bölütleme algoritmaları sınır, benzerlik tabanlı olmak üzere ikiye ayrılmaktadırlar. Sınır tabanlı bölütleme yöntemleri piksel süreksizliğinden, benzerlik tabanlı olanlar ise piksel benzerliğinden yararlanarak çalışmaktadırlar (Prabha ve Kumar 2016). Bu bölütleme algoritmalarını verim ve etkililik açısından değerlendirme önemli bir iştir. Aynı zamanda uygulama türüne göre bölütleme performansı hesaplamak da zor bir işlemdir (Kumar ve Arthanariee 2014). Çok sayıda bölütleme algoritması bulunmasına ve

sayılarının artmasına rağmen bölütleme değerlendirme algoritmalarının sayısı azdır. En iyi bölütleme sonucunu veren genel bir yöntem olmadığı gibi, bölütlemenin sonucunu en iyi değerlendiren genel bir ölçütte bulunmamaktadır (Taha vd. 2014). Genel olarak değerlendirme algoritmaları öznel ve nesnel olmak üzere ikiye ayrılmaktadır.

Öznel yöntemler insan gözlemine dayalıdır. Bölütleme yöntemlerinin sonuçlarını değerlendirmek kişiye göre değişen bir olgudur ve kişisel sezgi ile bu konuda karar vermek oldukça zordur (Xess ve Agnes 2014). Her kişi sonuçları farklı yorumlayabileceğinden öznel yöntemler yanlıdırlar, çok zaman gerektirirler ve pahalıdırlar, bu sebeplerle tercih edilmezler. Nesnel yöntemler ise uzamsal örtüşme, çift sayma, bilgi teorisi, olasılık ve uzamsal mesafe tabanlı olmak üzere beş gruba ayrılmaktadır. Çizelge 2.3'de bu beş grupta bulunan ölçütler verilmiştir.

Performans analizi yapılırken kullanılan doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif kavramlar performans analizinin görselleştirilmesini sağlayan karışıklık matrisinin elemanlarıdır. Karışıklık matrisi ile ilgi bigilendirme EK 1'de bulunmaktadır.

Çizelge 2.3 Bölütleme değerlendirme ölçütleri (http://www.visceral.eu. 2010)

Ölçüt	**Sembol**	**Kategori**
Dice	DICE	Uzamsal örtüşme tabanlı
Jaccard indeksi	JAC	Uzamsal örtüşme tabanlı
Doğru pozitif oranı (Hassaslık)	TPR	Uzamsal örtüşme tabanlı
Doğru negatif oranı (Özgünlük)	TNR	Uzamsal örtüşme tabanlı
Yanlış pozitif oranı (1-Özgünlük)	FPR	Uzamsal örtüşme tabanlı
Pozitif tahmin değeri (Duyarlılık)	PPR	Uzamsal örtüşme tabanlı
Kesinlik	ACU	Uzamsal örtüşme tabanlı
F-Ölçümü (F1 Ölçümü = Dice)	FMS	Uzamsal örtüşme tabanlı
Hacimsel benzerlik	VS	Uzamsal örtüşme tabanlı
Global tutarlılık hatası	GCE	Uzamsal örtüşme tabanlı
Rand indeksi	RI	Çift sayma tabanlı
Ayarlı Rand indeksi	ARI	Çift sayma tabanlı
Ortak bilgi	MI	Bilgi teorisi tabanlı
Bilginin değişmesi	VOI	Bilgi teorisi tabanlı
Sınıf içi ilişki	ICC	Olasılık tabanlı
Olasılık mesafesi	PDB	Olasılık tabanlı
KAP	KAP	Olasılık tabanlı
ROC eğrisi altında kalan alan	AUC	Olasılık tabanlı
Hausdorff mesafesi	HD	Uzamsal mesafe tabanlı
Ortalama Mesafe	AVD	Uzamsal mesafe tabanlı
Mahalanobis Mesafesi	MHD	Uzamsal mesafe tabanlı

Çizelge 2.3'de bulunan ölçütlerden bazıları birbirleri ile yüksek oranda bağlantıya sahiptirler, aralarında yüksek bağlantı bulunan ölçütlerden sadece birinin hesaplanılması performans ölçmek açısından yeterli olmaktadır. Örneğin, JAC ve F-Skorunun, DICE katsayısı ile aralarında aritmetiksel ilişki bulunmaktadır, yani birbirleri ile bağlantılıdırlar ve bu sebeple sadece DICE katsayısının hesaplanılması yeterli olmaktadır, DICE katsayısının büyük olduğu durumlarda JAC VE F-Skoru da büyük olacaktır, tersi içinde aynı durum geçerlidir. Ayrıca FPR ve FNR sırasıyla TNR ve TPR ile bağlantılı oldukları için hesaplanılmalarına gerek duyulmamaktadır (Taha vd. 2015). Bunların yanı sıra yapılan bir çalışmada (Taha vd.) geriye kalan metrikler arasındaki Pearson Korelasyon Katsayıları, 4833 tane bölütleme sonucu kullanılarak hesaplanmıştır. Pearson korelasyon katsayısı veri çiftleri arasındaki lineer ilişkinin gücünü göstermektedir, değeri +1 ve -1 arasında değişmektedir, sıfır değeri hiçbir ilişkinin olmadığını ifade etmektedir. Bölütleme performansı değerlendirme ölçütleri arasındaki bu katsayılar çizelge 2.3'de gösterilmektedir. Metrikler mesafe, örtüşme gibi farklı özellikleri saptamaktadırlar, korelasyon katsayıları sayesinde metriklerin birbirleri ile ilişkileri hakkında bilgi sahibi olunmaktadır. Çizelge 2.3'den görüleceği üzere korelasyon katsayısı büyük olan metriklerin tanımlarında aynı parametrelerden yararlanmaktadırlar. Örneğin ARI, KAP, ICC, DICE, AVD, MHD PBD ve VS arasında güçlü bir korelasyona bulunmaktadır, aynı zamanda TNR, RI, GCE, VOI aynı şekilde birbirleri ile güçlü korelasyona sahiptirler ve bu iki grup arasında korelasyon yok denecek kadar azdır. MI, AUC TPR ve HD'den oluşan üçüncü grup ise hem kendi arasında hem de diğer gruplarla orta derecede korelasyona sahiptir. Birinci grubun tamamının tanımında doğru pozitifler bulunmazken, ikinci grup ölçütlerinin tanımında doğru negatiflerin bulunması sayesinde bu gruplar kendi içlerinde güçlü, birbirleri arasında zayıf korelasyona sahiptirler.

Çizelge 2.4 Metrikler arasındaki korelasyon katsayıları (Taha vd. 2015)

	ARI	KAP	ICC	DICE	AVD	MHD	PBD	VS	MI	AUC	TPR	HD	TNR	RI	GCE	VOI	
ARI	1.00	1.00	1.00	1.00	0.95	0.93	0.91	0.81	0.80	0.75	0.74	0.52	-0.07	-0.07	-0.15	-0.15	
KAP	1.00	1.00	1.00	1.00	0.95	0.93	0.91	0.81	0.80	0.75	0.74	0.52	-0.08	-0.08	-0.16	-0.16	
ICC	1.00	1.00	1.00	1.00	0.95	0.93	0.91	0.81	0.81	0.75	0.74	0.52	-0.08	-0.09	-0.17	-0.17	
DICE	1.00	1.00	1.00	1.00	0.95	0.93	0.91	0.81	0.81	0.75	0.74	0.52	-0.08	-0.09	-0.17	-0.17	
AVD	0.95	0.95	0.95	0.95	1.00	0.93	0.86	0.76	0.67	0.70	0.69	0.70	0.07	0.08	0.00	0.00	Group 1
MHD	0.93	0.93	0.93	0.93	0.93	1.00	0.83	0.71	0.73	0.74	0.74	0.53	-0.07	-0.06	-0.13	-0.13	
PBD	0.91	0.91	0.91	0.91	0.86	0.83	1.00	0.74	0.71	0.65	0.64	0.45	-0.07	-0.09	-0.16	-0.16	
VS	0.81	0.81	0.81	0.81	0.76	0.71	0.74	1.00	0.60	0.45	0.44	0.40	-0.03	0.00	-0.08	-0.07	
MI	0.80	0.80	0.81	0.81	0.67	0.73	0.71	0.60	1.00	0.65	0.65	0.22	-0.49	-0.58	-0.64	-0.64	
AUC	0.75	0.75	0.75	0.75	0.70	0.74	0.65	0.45	0.65	1.00	1.00	0.35	-0.35	-0.14	-0.19	-0.19	Group 3
TPR	0.74	0.74	0.74	0.74	0.69	0.74	0.64	0.44	0.65	1.00	1.00	0.34	-0.36	-0.15	-0.20	-0.20	
HD	0.52	0.52	0.52	0.52	0.70	0.53	0.45	0.40	0.22	0.35	0.34	1.00	0.32	0.35	0.30	0.30	
TNR	-0.07	-0.08	-0.08	-0.08	0.07	-0.07	-0.07	-0.03	-0.49	-0.35	-0.36	0.32	1.00	0.84	0.84	0.84	
RI	-0.07	-0.08	-0.09	-0.09	0.08	-0.06	-0.09	0.00	-0.58	-0.14	-0.15	0.35	0.84	1.00	0.99	1.00	Group 2
GCE	-0.15	-0.16	-0.17	-0.17	0.00	-0.13	-0.16	-0.08	-0.64	-0.19	-0.20	0.30	0.84	0.99	1.00	1.00	
VOI	-0.15	-0.16	-0.17	-0.17	0.00	-0.13	-0.16	-0.07	-0.64	-0.19	-0.20	0.30	0.84	1.00	1.00	1.00	
	Group 1								Group 3				Group 2				

2.3.1 Metrik seçimi

Farklı metrikler, farklı özellikleri ve farklı tip hataları bulmak için kullanılmaktadır. Taha vd. en uygun metriği seçme üzerine çalışarak bölütlerin özelliklerine göre hangi metriğin daha uygun olacağını gösteren kıstaslar belirlemişlerdir. Bu kıstaslar aşağıda anlatılmaktadır.

1) Özellikle bölütlerin küçük olduğu bu sebeple bölütlenmiş ve temel doğru görüntü üzerinde birebir örtüşme ihtimalinin düşük veya sıfır olduğu bir durumda örtüşme tabanlı yöntemler yerine mesafe tabanlı yöntemler tercih edilmelidir.

2) Mesafe tabanlı yöntemler bölütlemenin kontur yani bölütlerin sınırlarının kesinliği önem taşıdığında kullanılmalıdır.

3) Olasılıksal mesafe (PDB) ve örtüşme tabanlı yöntemler bölütlerin hizalarının, tüm bölütleme sonucunun kesinliğinden daha önemli olduğu durumlarda kullanılmalıdır.

4) Eğer tanımında DN içeren ölçütler kullanılıyorsa, bu ölçütler bölüt boyutuna duyarlıdır. Yani bir miktar ön plan ve arka plan içeren bir görüntünün boyutu küçültülürse bölütleme sonucu değerlendirmede pozitif sonuç üretirken, boyutun küçültülmesinde negatif sonuç üretir, bu tür durumlara sınıf oransızlığı (class imbalance) denilmektedir. Şekil 2.20'de DN sayısının değişmesi ile değerlendirme sonucu arasındaki bağlantıyı gösteren bir örnek bulunmaktadır. Bu şekilde sınıf oransızlığı bulunan bölütleme sonuçlarında KAP ölçütü veya ARI ölçütü kullanılarak değerlendirme yapılabilmektedir.

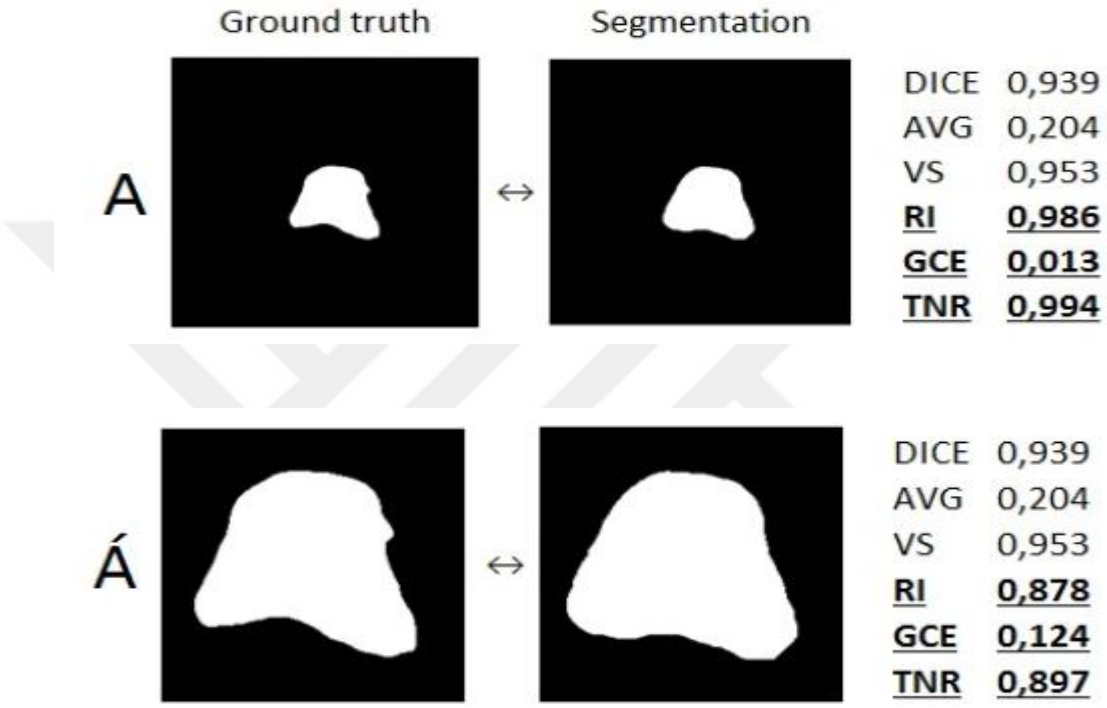
5) En uygun metriği seçmede başka bir dikkat edilecek konu da aykırılık (outliers) olarak adlandırılan, ana bölütten ayrı oluşan küçük bölütlerdir. Böyle bölütleme sonuçları değerlendirildiğinde Hausdorff mesafesi aykırılıklara karşı hassas olduğundan kullanılması önerilmemektedir, bunun yerine aykırılık varlığında kararlı sonuçlar üreten ortalama mesafe (AVG), örtüşme tabanlı ölçütler veya olasılık tabanlı ölçütler kullanılmalıdır.

6) Eğer birden fazla ölçüt kullanılarak değerlendirme yapılacaksa bu ölçütlerin Çizelge 2.1'de bulunan farklı gruplardan seçilmesi ve aynı zamanda birbirleri ile ilişkilerinin düşük olması amaçlanmalıdır. Bu şekilde yanlı bir değerlendirme yapmak önlenmiş olur.

Bu çalışmada metriklerin ayrıldığı beş kategorinin her birinden, birbirleri arasındaki korelasyonu düşük olan birer tane ölçüt seçilmiştir. Bu ölçütler uzamsal örtüşme tabanlı kategorisinden DICE katsayısı, çift sayma kategorisinden Rand indeksi, bilgi tabanlı

kategoriden çiftli bilgi, olasılık tabanlı kategoriden RoC eğrisi altında kalan alan ve uzamsal mesafe tabanlı kategoriden ortalama mesafedir.

Şekil 2.18'da performans analizinde kullanılan ölçütün sonucu etkilemesi ile ilgili bir örnek verilmiştir.



Şekil 2.18 Tanımında DN içeren değerlendirme yöntemlerinin bölüt boyutunu artmasıyla değişimi (Taha vd. 2015)

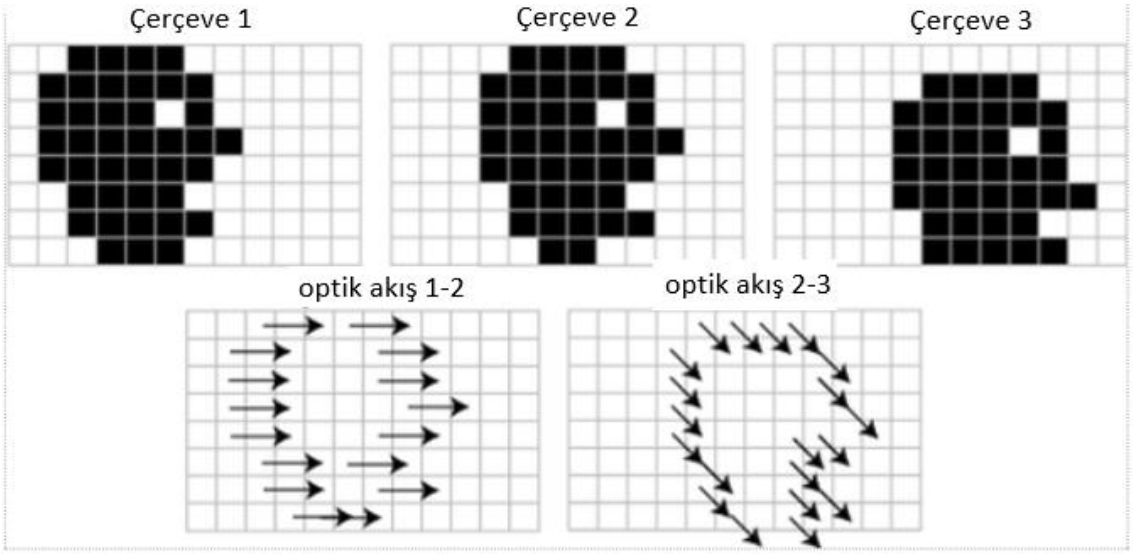
Şekil 2.18'de A ve *Á* gösterimlerinde temel doğru ve bölütleme tipi aynıdır, yalnızca *Á* gösteriminde, A gösterimindeki nesne daha küçük bir alana sınırlandırıldığından ön plan nesnesi büyümüş, arka plan pikseli sayısı yani TN sayısı azalmıştır. Bunun sonucunda aynı sonuçlara sahip bu iki bölütlemenin değerlendirilme sonuçları, tanımında TN içeren ölçütlerde de aynı kalması gerekirken değişerek benzerlik ölçütünde azalmaya, hata ölçütlerinde artmaya sebep olmuştur. Yani bu ölçütler arka plan pikseli sayısının artışında bölütlemenin sonucunu daha iyi gösterip, azalışında daha kötü göstermektedir.

2.4 Optik Akış

Zamanda kamera ile bir sahne kaydedildiğinde, elde edilen veri $I(x, y, t)$ fonksiyonu ile gösterilen görüntü serilerinde, t anında (x, y) piksel koordinatlarında bulunan piksellerin yeğinliğidir. Kameranın veya nesnenin hareket halinde bulunduğu görüntülerde sahne dinamiktir ve burada oluşan hareket görüntü serilerinde gri seviye değerinin zamana bağlı değişmesi ile oluşmaktadır. Görüntüde oluşan görünür hareket alanı, optik akış alanı olarak adlandırılmaktadır (Wedel ve Cramers 2011).

Burton ve Radford (1978) ve Warren ve Strelow (1985) optik akışı gözlemci ve gözlenen arasındaki bağıl hareketten dolayı oluşan nesnelerin görünür hareket kalıbı olarak tanımlamışlardır.

Seri görüntüler sayesinde hareket anlık görüntü hızı veya ayrık görüntü yer değişimi olarak anlaşılabilmektedir. Optik akış yöntemleri t ve $t + \Delta t$ çerçeveleri arasındaki hareketi hesaplamada kullanılmaktadır. Bu yöntemlere Taylor serisi yaklaşımları kullanıldığı için uzamsal ve zamansal koordinatlarda türev kullanılarak hesaplanmaktadırlar.

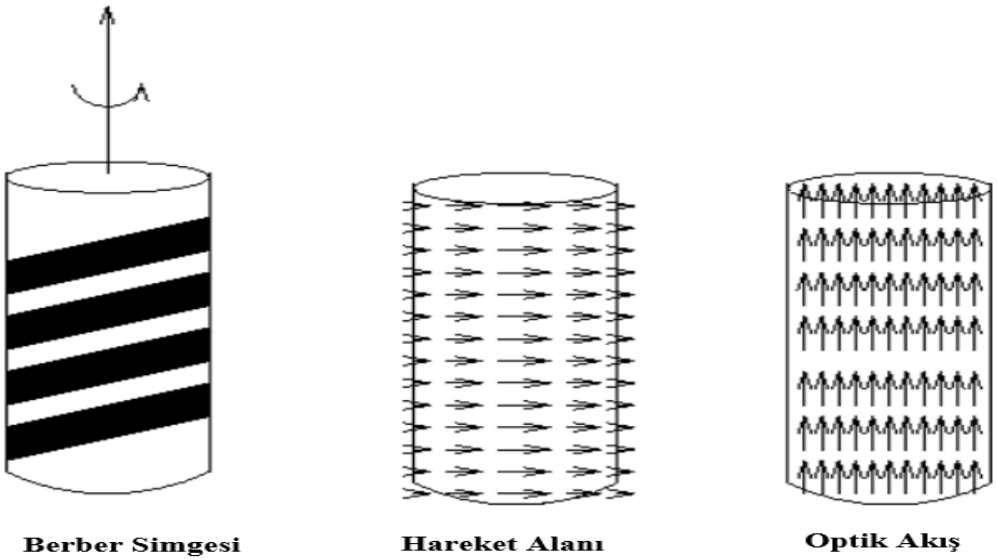


Şekil 2.19 Görüntü üzerinde optik akış vektörleri gösterimi

Optik akış kestiriminde yapılan en genel varsayım, ardışık iki çerçevede bir noktadan başka bir noktaya giden piksellerin parlaklıklarının sabit kalmasıdır. Fakat hem her nesne hareketi gri seviyelerde bir farklılığa yol açmayabilir, hem de gri seviyelerdeki değişikliğin sebebi nesne hareketi olmayabilir. Ancak hareket kestiriminin kalitesi düşse de, optik akışın saptanması için parlaklık sabitliği varsayımı yapılmaktadır.

Optik akış kestiriminde bir diğer belirsizlik açıklık problemidir. Homojen bir kontur görüntüsünün hareketi yerel olarak belirsizdir, yani bir açıklıktan bu kontura bakıldığında hareketi anlaşılamaz. Kameralar, video çekiminde dünyaya bir açıklıktan bakıyormuş gibidirler(Hilderth 1983 ve 1984). Bu açıklıkta farklı fiziksel hareketler ayırt edilemezler. Örneğin sağdan sola çizgilerin hareketi ile yukarıdan aşağıya hareketi arasında fark yoktur.

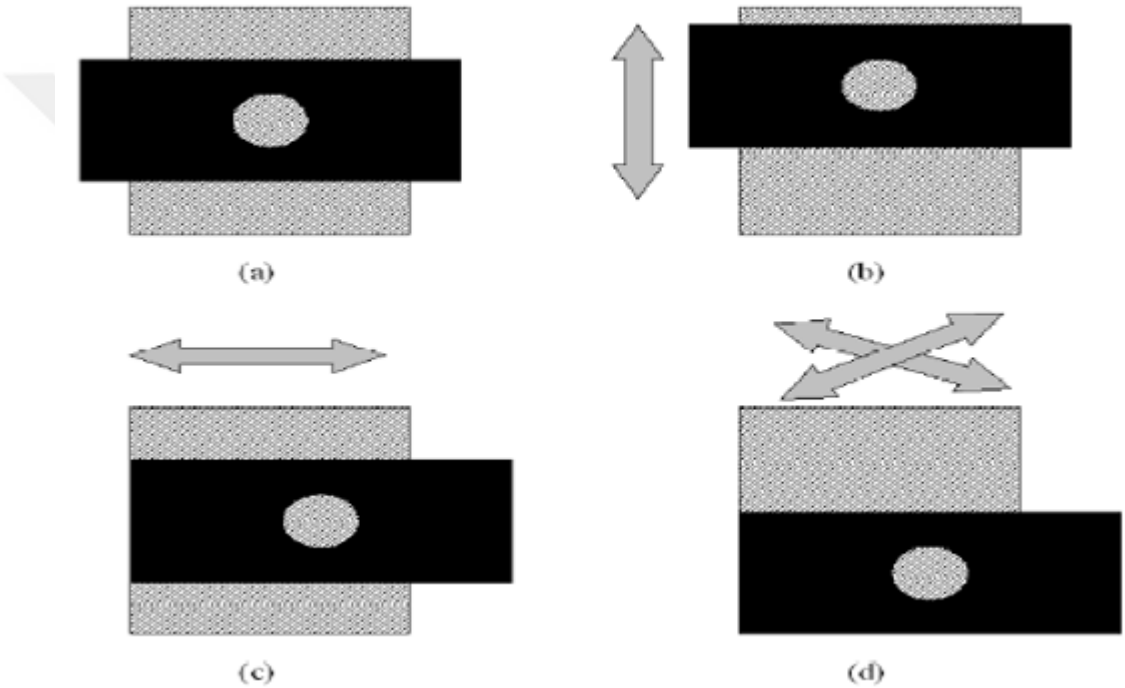
Hareket kestiriminde açıklık problemi, hareket kamera gibi küçük bir açıklıktan izlediğinde oluşmaktadır. Hareketli bir nesne bir açıklıktan gözlendiğinde sadece nesneye dik olan hareket ölçülebilmektedir (Malhorta 2008), Şekil 2.19'de bununla ilgili örnek bulunmaktadır.



Şekil 2.20 Berber simgesindeki açıklık problemi (http://homepages.inf.ed.ac.uk. 2017)

Şekil 2.20'de açıklık problemini anlatmada en sık kullanılan örnek olan berber simgesi bulunmaktadır, bu simge kendi etrafında dönme işlemi gerçekleştirmektedir, yani yatay yönde hareket alanına sahiptir. Ancak simgeye bir açıklıktan bakıldığında , hareketin yönü yukarıya doğru gözükür ve bu sebeple optik akış kestirimi de yukarıya doğru olmaktadır.

Açıklık problemi ile ilgili bir başka örnek de şekil 2.21'de verilmiştir.



Şekil 2.21 Hareket kestirimden açıklık problemi (Malhotra 2008)

Şekil 2.21'de homojen bir nesne bir açıklıktan izlenmektedir. Nesne yukarı, aşağı, sağ ve sol veya çapraz hareketi etmektedir. Ancak tüm durumlarda açıklık içinden izlenen kısım aynı kalmıştır. Sadece aralığın içindeki görüntü gözlemlendiğinde Şekil 2.21'de ki dört durumda da hareket yok gibi gözükür. Herhangi iki kamera görüntüsü için hareket kestirilmek istendiğinde sonuç anlaşılmazdır. Bu probleme açıklık problemi denir ve bilinen en açık çözümü daha büyük açıklık kullanmaktır. Ancak çoğu video ve görüntü kamera ile kaydedildiğinden daha büyük açıklık kullanmak imkansızdır (Malhotra 2008).

Sonuç olarak açıklık problemi dolayısıyla optik akış problemi, birçok ters problem gibi iyi konumlanmamıştır. Bu yüzden optik akış formüllerine optik akış alanının yumuşatılması gibi varsayımlar eklenmektedir.

Parlaklığın sabit olması varsayımı ile optik akışın elde edilmesi eşitlik 2.29 – 2.30 gösterilmiştir.

t anında (x, y) pikselinin yeğinliği *I(x,y,t)* ile, akış ise *u(x,y,t)* ve *v(x,y,t)* ile gösterilmektedir. Ardışık iki çerçeve arasında parlaklığın sabit olması varsayımı eşitlik 2.28 ile ifade edilmektedir.

$$I(x, y, t) = I(x + u, y + v, t + 1) \tag{2.28}$$

Yukarıdaki eşitlik birinci dereceden Taylor serisi ile açıldığında eşitlik 2.29 elde edilmektedir.

$$I(x, y, t) = I(x, y, t) + \frac{dI}{dx}\Delta x + \frac{dI}{dy}\Delta y + \frac{dI}{dt}\Delta t + H.O.T. \tag{2.29}$$

Bu eşitliğin, basitleştirilmesi ile eşitlik 2.30'da gösterilen optik akış kısıtı elde edilmektedir.

$$u\,\frac{dI}{dx} + v\frac{dI}{dy} + \frac{dI}{dt} = 0 \tag{2.30}$$

Hem parlaklık sabiti hem de optik akış kısıtı denklemleri her piksel için bir kısıt ve iki tane değişken (eksik belirtilmiş-underdetermined) içermektedir. Bu durum açıklık probleminin yani iyi konumlanmamış olmanın kaynağıdır (Baker vd. 2011).

Optik akışın saptanması için Horn-Schunk (HS) ve Lucas-Kanade (LK) en sık kullanılan yöntemleridir. HS global iken, LK yerel bir yöntemdir. HS yönteminde açıklık probleminin çözülmesine yönelik, parlaklık sabitliği kısıtına ek, görüntüde

yumuşaklık varsayımı kullanılmaktadır. LK yönteminde ise açıklık probleminin çözülmesine yönelik ardışık iki çerçeve arasında bir pikseldeki hareketin çok küçük olduğu ve piksel hareketinin komşu piksellerde de aynı olması gerektiği varsayımları kullanılmaktadır.

2.4.1 Horn-Schunk Yöntemi

1981 yılında Horn ve Schunk tarafından yapılan çalışmada, türev tabanlı olan optik akış vektörlerini bulmak için tüm görüntüye yumuşaklık kısıtlaması getirilerek açıklık probleminin çözülmesi amaçlanmıştır. Yumuşaklık kısıtlaması ile anlatılmak istenen görüntüdeki optik akış vektörlerinin video boyunca çok küçük değişimlere sahip olduklarının, akışın yumuşak olduğunun varsayımıdır. Bu varsayımın temeli görüntüdeki nesnenin her noktasında aynı hız vektörüne sahip olması gerekmesine dayalıdır. Ancak kamera hareketi veya gürültü gibi etkenlerden dolayı nesne üzerinde farklı vektör hızları gözlemlenebilmektedir. HS yönteminde meydana gelen bu değişikliklerin minimize edilmesine çalışılarak yumuşaklık kısıtı uygulanmaktadır. Tüm görüntüye yumuşaklık kısıtlaması getirildiği için global bir yöntemdir (Horn ve Schunk 181). HS algoritmasında iki ana işlem bulunmaktadır. Birincisi kısmi türevlerin hesaplanması, ikincisi yineleme ile hata toplamının minimize edilerek sonuç hız vektörlerinin bulunmasıdır (Kesarart ve Patanavijit 2011). HS yönteminde görüntünün her noktasına ait optik akış vektörleri kullanılmaktadır, dolayısı ile homojen nesnelerin iç kısımlarında kalan noktalarına ait hareketi de hesaplayabilmesi avantajlıdır. Ayrıca yerel yöntemlerin aksine, görüntü boyunca sadece yatay, dikey ve zamansal türevleri hesapladığı için hızlı çalışmaktadır.

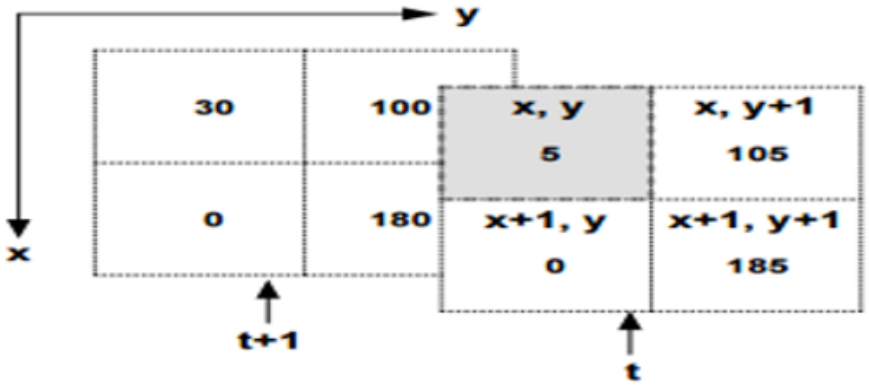
2.4.1.1 Kısmi türevlerin hesaplanması

Bu kısımda görüntü serilerindeki görüntülerin yeğinliğinin kısmi türevi kullanılır. Her pikselin parlaklığı tüm görüntülerde hareket yörüngesi boyunca sabittir. $I(x, y, t)$ olarak ifade edilen t anındaki *(x,y)* noktasının yeğinliğidir. Her görüntüde *x, y* ve *t*'ye göre göre türevlerin hesaplanışı eşitlik 2.31-2.32'de verilmiştir.

$$I_x = \frac{1}{4}\{I_{x,y+1,t} - I_{x,y,t} + I_{x+1,y+1,t} - I_{x+1,y,t} + I_{x,y+1,t+1} - I_{x,y,t+1} + I_{x+1,y+1,t+1} - I_{x+1,y,t+1}\} \quad (2.31)$$

$$I_y = \frac{1}{4}\{I_{x+1,y,t} - I_{x,y,t} + I_{x+1,y+1,t} - I_{x,y+1,t} + I_{x+1,y,t+1} - I_{x,y,t+1} + I_{x+1,y+1,t+1} - I_{x,y+1,t+1}\} \quad (2.32)$$

$$I_t = \frac{1}{4}\{I_{x,y,t+1} - I_{x,y,t} + I_{x+1,y,t+1} - I_{x+1,y,t} + I_{x,y+1,t+1} - I_{x,y+1,t} + I_{x+1,y+1,t+1} - I_{x+1,y+1,t}\} \quad (2.33)$$



Şekil 2.22 Ardışık iki video çerçevesi

Şekil 2.22 için kısmi türevlerin hesaplanışı aşağıda gösterilmiştir.

$$I_x = \frac{(105-5) + (185-0) + (100-30) + (180-0)}{4} = 133.75$$

$$I_y = \frac{(0-5) + (185-105) + (0-30) + (180-100)}{4} = 31.25$$

$$I_t = \frac{(30-5) + (0-0) + (100-105) + (180-185)}{4} = 3.75$$

2.4.1.2 Toplam hatanın minimize edilmesi

Görüntü yeğinliği gürültüden dolayı bozulmuş olabilir. Görüntünün parlaklığındaki değişim oranı için eşitlik 2.35'ten yararlanılmaktadır.

$$I(x, y, t) = I(x + u, y + v, t + 1) \tag{2.34}$$

$$\varepsilon = uI_x + vI_y + I_t = 0 \tag{2.35}$$

u ve v yatay ve dikey optik akış hareket vektörleridir. ε'yi 0'a yaklaştırmak hatayı minimize etmektir. α parametresi ile yumuşaklık kontrol edilir. u ve v görüntüdeki her piksel için hesaplanır ancak akış alanındaki komşu piksellerinde etkisi olduğundan yinelemeli olarak komşu piksellerde güncellenir ve hata minimize edilir.

$$u^{k+1} = \overline{u^k} - \frac{I_x(I_x\overline{u^k} + I_y\overline{v^k} + I_t)}{\alpha^2 + I_x^2 + I_y^2} \tag{2.36}$$

$$v^{k+1} = \overline{v^k} - \frac{I_x(I_x\overline{u^k} + I_y\overline{v^k} + I_t)}{\alpha^2 + I_x^2 + I_y^2} \tag{2.37}$$

$\bar{u}(x, y)$, (x, y) piksel koordinatındaki u hareket vektörünün komşularının ağırlıklandırılmış ortalamasıdır. Bu ağırlıklandırma aşağıdaki çekirdek matris kullanılarak bulunmaktadır (Kesarart ve Patanavijit 2011).

1/12	1/6	1/12
1/6	-1	1/6
1/12	1/6	1/12

Şekil 2.23 Çekirdek matrisi

2.4.2 Lucas-Kanade Yöntemi

Lucas-Kanade (LK) yöntemi optik akış saptamak için kullanılan yerel bir yöntemdir. HS'nin aksine bir tane büyük (global) problem yerine birbirinden bağımsız birçok

küçük problem ile çözümü sağlamaktadır. Tüm optik akış yöntemlerinde bulunan parlaklık sabitliğinin yanı sıra bu yöntemde iki varsayım daha bulunmaktadır. Bunlardan biri bir çerçevede (x, y) noktasında bulunan bir pikselin konumunun çok az değiştiği, birkaç piksel kadar, yani bir sonraki pencerede (x, y) noktasında bulunan pikselin (x, y)'nin çok yakınında olduğudur. Bir diğeri ise noktaların komşularında da aynı hareketin gözlemlendiğidir, bir nokta (u, v) hızında hareket ettiyse komşularının hareketi de aynı şekilde gerçekleşmiştir. Komşu piksellerden alınan bilgiler kullanılarak optik akışın yapısında var olan belirsizliklerin çözümü için kullanılmaktadır. Optik akış vektörlerini bulmak için piksel komşularına ait denklemlerinde bulunduğu matris gösterimine, en küçük kareler yöntemi uygulanarak çözüme ulaşılmaktadır (Burton ve Radford 1978, Warren ve Strelow 1985).

Gürültüye piksel üzerinde çalışan HS yöntemine oranla daha dayanıklıdır. Ancak, tam anlamıyla yerel bir yöntem olduğundan, homojen bölgelerin iç kısımları ile ilgili akış bilgisi üretemez ve üzerinde çalıştığı her pikselin komşuluklarında da işlemler gerçekleştirdiğinden uzun zaman gerektirmektedir.

Eşitlik 2.30'da bulunan denklem aşağıdaki gibi de yazılabilir.

$$\begin{bmatrix} \frac{dI}{dx} & \frac{dI}{dy} \end{bmatrix} * \begin{bmatrix} u \\ v \end{bmatrix} = -\frac{dI}{dt} \tag{2.38}$$

Lukas-Kanade yönteminin komşularında aynı hareketi yapması varsayımı yapıldığı için eşitlik 2.38 tüm komşular içinde yazılır. Örneğin 8 komşuluk ile bu varsayım kullanılacaksa, ilgilenilen piksel ve komşularına ait 9 tane denklem yazılmalıdır. Bu kısımda önemli olan nokta tüm komşular ve ilgilenilen pikselin hızının aynı olmasıdır. Yazılan denklemleri eşitlik 2.39'daki gibi matrisler şeklinde düzenlenebilmektedir.

$$A = \begin{bmatrix} \frac{dI(x_1,y_1)}{dx} & \frac{dI(x_1,y_1)}{dy} \\ \vdots & \vdots \\ \frac{dI(x_n,y_n)}{dx} & \frac{dI(x_n,y_n)}{dy} \end{bmatrix} * \begin{bmatrix} u \\ v \end{bmatrix} = \begin{bmatrix} -\frac{dI(x_1,y_1)}{dt} \\ \vdots \\ -\frac{dI(x_n,y_n)}{dt} \end{bmatrix} \tag{2.39}$$

$A = \begin{bmatrix} \frac{dI(x_1,y_1)}{dx} & \frac{dI(x_1,y_1)}{dy} \\ \vdots & \vdots \\ \frac{dI(x_n,y_n)}{dx} & \frac{dI(x_n,y_n)}{dy} \end{bmatrix}$, $V = \begin{bmatrix} u \\ v \end{bmatrix}$ ve $b = \begin{bmatrix} -\frac{dI(x_1,y_1)}{dt} \\ \vdots \\ -\frac{dI(x_n,y_n)}{dt} \end{bmatrix}$ dönüşümleri yapılarak eşitlik 2.39, eşitlik 2.40 gibi genelleştirilebilir .

$$AV = b \tag{2.40}$$

Eşitlik 2.39'dan görüleceği üzere bu sistem bilinmeyenlerden fazla denkleme sahiptir, fazla tanımlıdır (over-determined). Bu sebeple en küçük kareler ile sonuç oluşturularak x ve y yönündeki optik akış vetörleri eşitlik 2.42'de gösterildiği gibi elde edilir.

$$A^T AV = A^T b \tag{2.41}$$

$$V = (A^T A)^{-1} A^T b \tag{2.42}$$

2.5 Öznitelik Çıkarma

Makine öğrenmesi, örüntü tanıma, görüntü işleme, bilgisayarla görme gibi alanlarda , ölçülen verilerden daha iyi yararlanabilmek, bu verilerin kullanılacağı çalışma ile bağlantısının artması ve sınıflandırma yapmayı kolaylaştırması amacı ile kullanılmaktadır. Öznitelik çıkarımı asıl olarak boyut küçültmek olarak tanımlanmaktadır. Bir çalışmada kullanılan materyalin boyutu büyük ise, bu materyal öznitelikler ile daha küçük bir boyutta ve daha anlamlı bir şekilde ifade edilebilmektedir. Literatürde video kullanılan çalışmalarda ayırt edici öznitelikler araştırılmıştır. Bu tür çalışmalarda piksel bazında elde edilen hareket vektörlerinden hangilerinin gerçek hareketi yansıttığını saptamak için video çerçeve serilerinde zaman alanı istatiksel öznitelikleri kullanılmıştır (Jadhav 2014, Calow ve Lappe 2007, Martínez vd. 2012, Dawkins vd. 2012, Vatani vd. 2014). Çalışma kapsamında optik akış vektörlerinden elde edilen zaman alanı istatistikleri kullanılarak öznitelikler çıkarılmıştır. Aşağıda zaman alanı özniteliklerine ait bilgi ve formüller verilmiştir.

$V_t(i,j)$ ile t çerçevesinde (i,j) konumunda bulunan optik akış vektörünü göstermektedir.

2.5.1 Zaman alanı öznitelikleri

2.5.1.1 Karekök ortalaması (RMS)

Sinyal elemanları karesinin aritmetik ortalamasının kareköküdür.

$$RMS(t) = \sqrt{\frac{\sum_{i,j=1}^{m} V_t(i,j)^2}{m}} \tag{2.43}$$

2.5.1.2 Tepe genliği

Bir sinyal vektörü içindeki genliği en yüksek ve en düşük olan elemanı ifade etmektedir.

$$Maksismum\ Tepe\ Genliği(t) = \max(V_t(i,j)) \tag{2.44}$$

$$Minimum\ Tepe\ Genliği(t) = \min(V_t(i,j)) \tag{2.45}$$

2.5.1.3 Mesafe

Sinyal elemanları arasındaki maksimum ve minimum tepe genliğinin arasındaki farkı ifade etmektedir.

$$Mesafe(t) = \max(V_t(i,j)) - \min(V_t(i,j)) \tag{2.46}$$

2.5.1.4 Ortalama

Ortalama μ, sinyal elemanlarının ortalamasıdır.

$$\mu(t) = \frac{1}{m} \sum_{i,j=1}^{m} V_t(i,j) \tag{2.47}$$

2.5.1.5 Standart sapma

Standart sapma σ, Sinyal elemanları içindeki değerlerin saçılımını göstermektedir.

$$\sigma(t) = \sqrt{\frac{1}{m}\sum_{i,j=1}^{m}(V_t(i,j) - \mu(t))^2} \tag{2.48}$$

2.5.1.6 Basıklık değeri (Kurtosis)

Verinin olasılık dağılımının tavan değerinin ölçüsüdür.

$$K(t) = \frac{\mu_4(t)}{\sigma^4(t)} \tag{2.49}$$

μ_4, dördüncü momenti ifade etmektedir.

$$\mu_4(t) = \frac{1}{m} \sum_{i,j=1}^{m}(V_t(i,j) - \mu(t))^4 \tag{2.50}$$

2.5.1.7 Çarpıklık değeri (Skewness)

Verinin asimetrisini ölçmekte kullanılmaktadır, eğer bir veri dağılımı simetrik değilse çarpık denilmektedir.

$$S(t) = \frac{\mu_3(t)}{\sigma^3(t)} \tag{2.51}$$

$\mu_3, 3$, üçüncü momenti ifade etmektedir.

$$\mu_3(t) = \frac{1}{m} \sum_{i,j=1}^{m} (V_t(i,j) - \mu(t))^3 \quad (2.52)$$

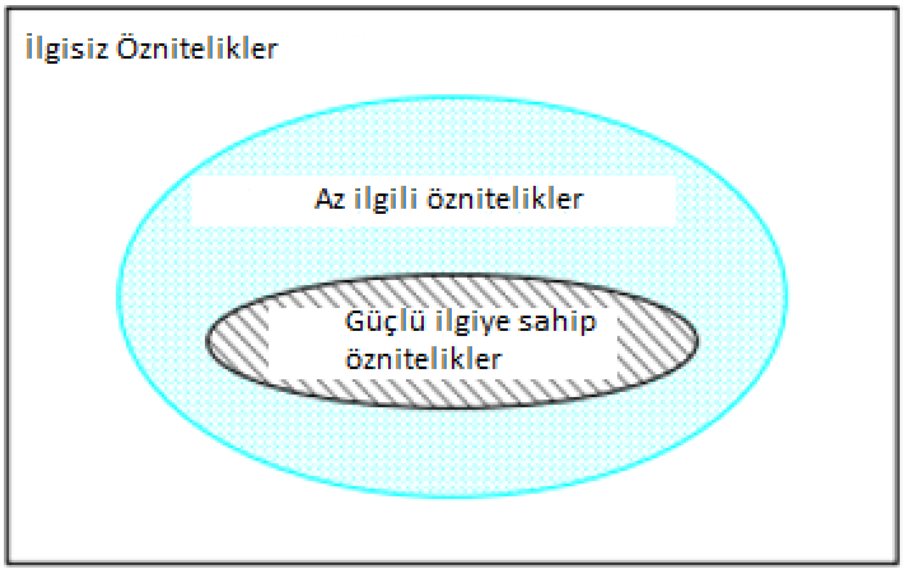
2.5.1.8 Çeyrekler arası açıklık

Çeyrekler açıklığı küçükten büyüğe sıralanmış bir veri dizisinin orta yarısını (%50'sini) kapsayan ve üçüncü dörtte birlik ve birinci dörtte birlik aralığını veya farkını (yani Q3 - Q1) gösteren bir istatistiksel yayılma ölçüsüdür. Çeyrekler açıklığı sıralanmış veriler içinde aşırı küçük veya aşırı büyük uçsal değerlerden etkilenmez. Özel bir istatistiksel terimle çeyrekler açıklığı güçlü bir yayılma ölçüsüdür.

2.6 Öznitelik Seçme

Makine öğrenmesinde öznitelik seçimi ön işleme safhasında kullanılmaktadır. Örüntü tanımada ilgisiz öznitelikleri yok etmek için öznitelik seçme yöntemlerine ihtiyaç duyulmaktadır. Öznitelik seçme veriye ait gereksiz olan, sınıflandırıcının performansını olumsuz yönde etkileyen özniteliklerin atılarak, sınıflandırma işlemi için gerekli olanların seçilmesi işlemidir. Sınıflandırma sonucunun doğruluğunu artırması ve sınıflandırmanın hızını artırması sebebiyle öznitelik seçimi önemli bir işlemdir.

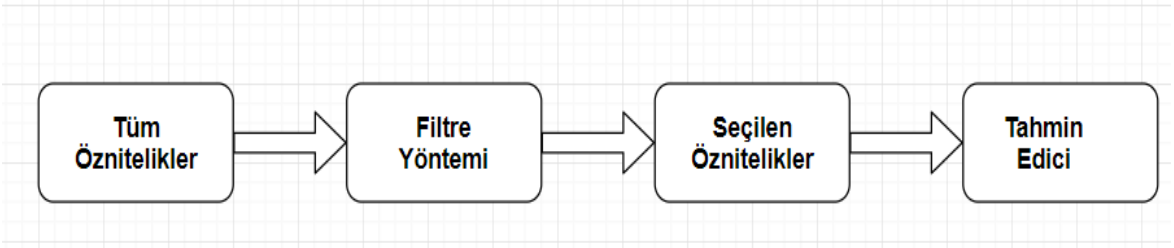
Öznitelik seçme ile ilgili yaklaşımlar filtre, sarmal, gömülü ve hibrit yöntemler olmak üzere dörde ayrılmaktadır.



Şekil 2.24 İlgisiz, az ilgili ve güçlü ilgiye sahip elemanlardan oluşan öznitelik uzayı

2.6.1 Filtre Yöntemi

Her özniteliğin, sonuçla olan bağlantısının ölçüsünü vermektedir. Bu yöntem ile öznitelikler sonuçla olan ilişkilerine göre derecelendirilir. Filtre yönteminin en belirgin özelliği sonuç ile arasındaki ilişki indeksini ölçmede sadece tek bir öznitelik ile kullanılmasıdır, diğer öznitelikler kullanılmazlar. Bundan dolayı filtreler öznitelikler arasında var olabilecek bağlılıkları hesaba katmazlar, bu durum da optimal öznitelik kümesini bulunmasında sıkıntı oluşturur. Çünkü en iyi öznitelik kümesi bulmak için öznitelikler arasındaki bağlantılar önemlidir, bunun sebebi bazı özniteliklerin birlikte daha iyi sonuçlar üretmeleri mümkündür. Ancak hızlı çalıştıkları için verimlidirler ve aşırı uyuma (ovefitting) karşı teorik olarak daha sağlamdırlar (Ng 1998). Aşırı uyum bir eğitim verisini en iyi tanımlayan modelin, yeni bir veri geldiğinde uygun olmaması durumudur (Kuang 2009). Öznitelik seçiminde, özellikle eğitim verisi küçükse aşırı uyumdan sakınan yöntemlerin seçilmesi önerilir. Filtre yöntemlerinde, herhangi bir öğrenme algoritması olmadan, bilgi, bağımlılık ve tutarlılık gibi istatiksel ölçümler kullanılarak öznitelikler seçilir. Bu metotlar sarmal yöntemine göre daha az karmaşık ve hızlı olduğundan dolayı büyük veri setlerine uygundur (Guyon ve Elisseeff 2003, Yıldız vd. 2012) .



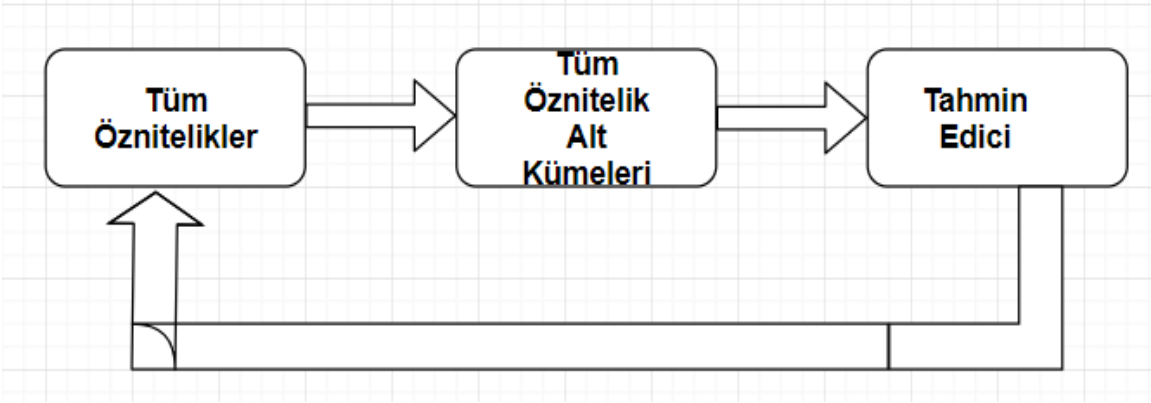
Şekil 2.25 Filtre yöntemi ile öznitelik seçimi

2.6.2 Sarmal Yöntemler

İlk olarak Kohavi ve John tarafından 1997'de önerilen bu yöntemde her özniteliği derecelendirmek yerine, bir sınıflandırıcıya gönderilen öznitelik alt kümesinden elde edilen tahmin performansına göre öznitelik alt kümelerini derecelendirir. Sarmal yöntemi, filtre yönteminin aksine olabilecek tüm öznitelik alt kümelerini inceler ve öznitelikler arasındaki karşılıklı bilgiyi hesaplar. Bu yöntemde alt küme seçimi bir öğrenme algoritması ile gerçekleştirilmektedir. Sarmal yöntemler alt kümelerin gücünü değerlendirmek için öğrenme algoritmasını kullanmaktadırlar (Guyon ve Elisseeff 2003, Gupta ve Sharma 2015). Bir sınıflandırıcı seçtikten sonra, sarmal tahmin performansı çaprazlama ile ölçülür. Sınıflandırıcı seçiminde farklılıklar olabileceği gibi, sarmal yöntemler araştırma stratejileri yönünden de farklılık göstermektedirler.

Doğru sınıflandırma oranına bağlı olarak verimliliğin ölçüldüğü bir sınıflandırıcı algoritması kullanılan bu yöntemlerde model seçimi ve en iyi alt öznitelik grubu seçimi arasında bir etkileşim vardır. Sarmal yöntemler bu etkileşimin ayarlanmasına bağlı olarak genellikle daha iyi sonuçlar vermektedir (Guyon ve Elisseeff 2003).

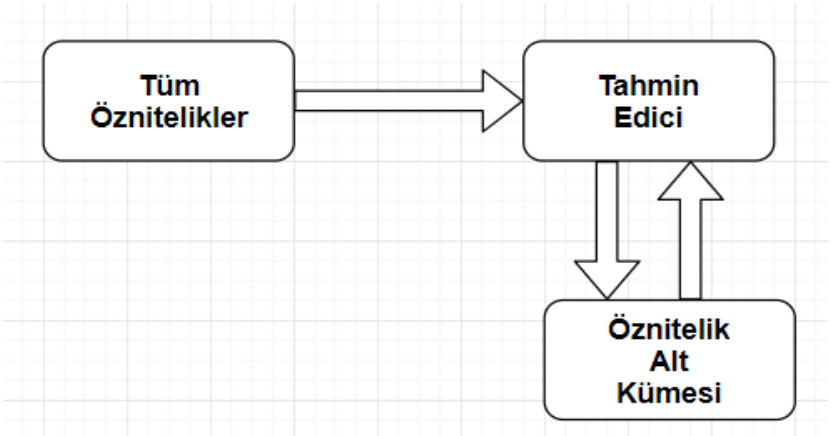
Bu yöntem için kullanılan birçok yol vardır, ancak bunlardan bazıları kombinasyon ile alt küme seçimi yapmaktadırlar, bu tür seçim yapmak işlem yükü açısından NP-Zordur ve aşırı uyuma meyillidir(Amaldi ve Kann 1998). Bu sebeple greedy search stratejileri ile öznitelik alt kümesi seçme tercih edilmektedir, bunlara örnek olarak ardışık ileri/geri öznitelik seçimi (sequential forward/backward feature selection) yöntemi verilmektedir.



Şekil 2.26 Sarmal yöntemler ile öznitelik seçimi

2.6.3 Gömülü Yöntemler

Yapısında hem sınıflandırıcı hem de öğrenme algoritması bulundurmaktadır. Sarmal yöntemlerin aksine öğrenme ve sınıflandırma süreçlerini ayırmamaktadırlar ve seçilen özniteliklerin sınıflandırıcı yapısına karşı duyarlılığını hesaba katmamaktadırlar. Bu sebeple bir gömülü yöntem ile seçilen öznitelikler, başka bir gömülü yöntem ile seçilen özniteliklerden farklı olabilmektedirler. Gömülü sistemlerde eğitim aşaması içinde öğrenme algoritmasına göre öznitelik seçimini gerçekleştirmektedirler. Yöntemin yapısında bir sınıflandırıcı algoritması bulunmaktadır, bu durum algoritmanın çalışma zamanını etkilemekte ve algoritmayı yavaşlatmaktadır (Kaya 2014), ancak sarmal yöntemlere göre daha hızlıdırlar. Gömülü yöntemler algoritmalarında var olan özniteliklere yenileri eklendiğinde performansları düşmektedir. Gömülü öznitelik seçme yapılarına en iyi örnek karar ağaçlarıdır.



Şekil 2.27 Gömülü yöntemler ile öznitelik seçimi

2.6.4 Hibrit Yöntemler

Hibrit yöntemlerde filtre ve sarmal yöntemlerin en iyi özelliklerinin birleştirilmesi amaçlanmaktadır. Öncelikle filtre yöntemi kullanılarak öznitelik uzayı küçültülür, daha sonra sarmal yöntem ile en iyi öznitelik alt kümesi bulunur. Filtre ve sarmal yöntemlere ait herhangi bir kombinasyon ile hibrit bir öznitelik seçme algoritması elde edilebilmektedir (Kaufmann 2001). Hibrit yöntemlerde sarmal yöntem sayesinde kesinlik artarken, filtre yöntemi sayesinde de verim artmaktadır (Jovic vd. 2015).

Sarmal yöntemlerde daha önce de anlatıldığı üzere işlem karmaşıklığı açısından greedy search yöntemlerini kullanılması önerilmektedir, bu yöntemler ileri ve geri öznitelik seçiminden oluşmaktadır. İleri öznitelik seçiminde, öznitelik alt kümesi boşken birer birer öznitelikler eklenip sınıflandırıcı sonucu incelenir ve sonuçtaki değişme çok küçük bir değer ve ya sıfır olduğunda alt küme seçimi tamamlanmış olur. Geri öznitelik seçiminde ise tüm öznitelikler alt kümeye ait olarak başlarlar ve birer birer alt kümeden çıkartılarak sınıflandırıcı sonucu incelenir, sonuçtaki değişim çok küçük veya sıfır olduğunda öznitelik alt kümesi oluşturulmuş olur. Ancak bu iki yöntemde de hangi öznitelik ile başlanılacağı sorun yaratmaktadır. Çünkü başlangıçta kullanılan öznitelik sonucu etkileyecektir. Bu sebeple (Guill'en vd. 2009 ve Islam vd. 2016) tarafından yapılan çalışmalarda izlenen yol şu şekilde açıklanmaktadır. Öncelikle filtre yöntemi ile öznitelikler derecelendirilir. Daha sonra ileri öznitelik seçimi yönteminin başlangıcı olarak en yüksek dereceye sahip olan öznitelik atanır. Böylelikle hangi öznitelik ile sarmal yönteme başlanacağı problemi çözülmüş olmaktadır.

Bu çalışmada da önce karşılıklı bilgi daha sonra ileri öznitelik seçimi kullanılarak filtre ve sarmal yöntemlerin birleşiminden oluşan hibrit bir yol kullanılmıştır.

2.7 Sınıflandırma

Makine öğrenmesi algoritmaları belli bir modele bağlı kalmadan işlemsel yöntemler ile öğrenmeyi gerçekleştirebilmektedirler. Gözetimli öğrenme ve gözeticisiz öğrenme ve

olmak üzere iki ana başlıktan oluşmaktadırlar. Gözetimli öğrenme yöntemleri bilinen girdi ve çıktı eğitim veri modelinden yararlanarak, ileri aşamalardaki girdi sonuçlarını tahmin edebilmektedirler. Gözeticisiz öğrenme teknikleri de eğitim verisi kullanmadan, girdi verisi içerisinde örüntüler bularak tahmin yapabilmektedirler.

Gözeticisiz öğrenme teknikleri, gözetimli öğrenme tekniklerinde olduğu gibi hedefleri bilmedikleri için doğru tahmin olasılıkları az olabilmektedir. Gözetimli öğrenmede ise hedef verilerinden tamamını kapsayan eğitim verisi kullanıldığında iyi sonuçlara alınabilmektedir. "No Free Lunch" teoremi her problem için en iyi çalışan bir modelin var olmadığını tanımlamada kullanılmaktadır. Wolpert 1996'da gözetimli öğrenme ile ilgili yaptığı çalışmasında, gözetimli öğrenme modellerinde de bu teoremin geçerli olduğundan bahsetmiştir. Kullanılan her modelin sonucu bir çok parametreye bağlı olarak değişmektedir, bu durumda herhangi bir öğrenme modelinin diğerinden üstün olduğundan bahsedilemez. Bu sebeple uğraşılan problem için en iyi çalışan öğrenme yöntem saptanmaya çalışılır, bunun içinde bir çok model denenerek sonuçlar karşılaştırılır ve problem için en iyi olan seçilir.

Gözetimli öğrenme regresyon ve sınıflandırma başlıkları altında incelenmektedir. Regresyon bir modele ait sürekli sayısal sonuçlarını tahmin etmede kullanılmaktadır, yani hedefin sonucu gerçek bir değerdir, örneğin bir evin büyüklüğü göz önüne alındığında fiyatının tahmin edilmesi gibi. Sınıflandırma da ise tahmin sonuçları ayrık değerlerdir, örneğin görüntü üzerinden saptanan hayvan türlerinde sonuç kümesi kedi, köpek gibi ayrık tahminlerden oluşmaktadır. Çalışma kapsamında hedefler kara, deniz ve deniz olduğu halde kara olarak gözüken bölgelerin saptanması olduğu için, burada kullanılan yöntem sınıflandırmadır.

Sınıflandırma yapılırken izlenen yol aşağıda adım adım anlatılmıştır.

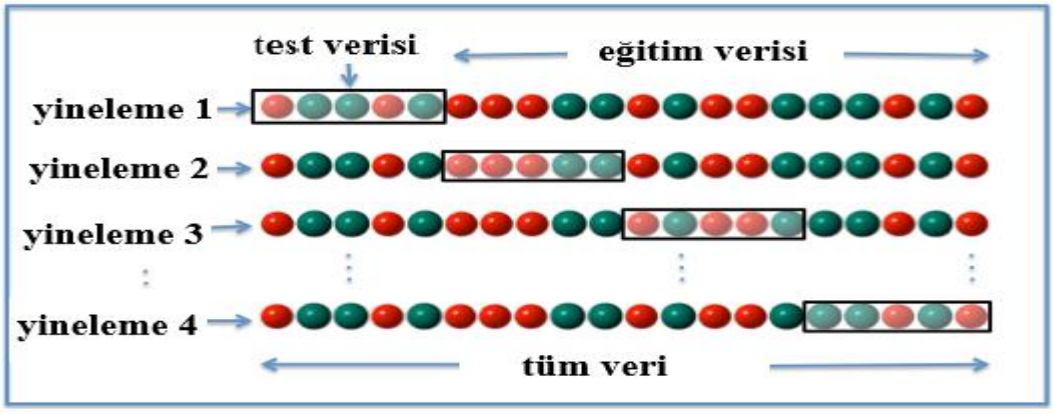
- Çalışmacı tarafından eğitim verisine karar verilir. Eğitim verisine karar verilirken, hedefte bulunan tüm sonuçları kapsayacak eğitim verisi seçilmesi sınıflandırmanın performansı açısından önemlidir.

- Eğitim verisine ait kullanılacak öznitelik kümesi oluşturulur, öznitelikler veriyi ne kadar iyi temsil ediyorsa sınıflandırma sonucu o kadar iyi olmaktadır.

- Eğitim verisinin ne kadarının eğitim, ne kadarının test için kullanılacağını ayarlamak için kontrol parametreleri kullanılmaktadır, bunlar hold-out kümeleri olarak adlandırılmaktadırlar. Hold-out kümelerinin yanı sıra çapraz-sağlama (cross validation) yönteminde kullanılmaktadır, seçilen kat (fold) sayısınca veri eşit parçalara bölünür ve bu katlardan biri test, geri kalanları eğitim için kullanılarak hold-out işlemi kat sayısınca yinelenir. Çapraz sağlama sonucunda elde edilen sonuçlarının ortalaması alınarak başarı yüzdesi hesaplanır. Sınıflandırma yapılırken, sınıflandırıcı performansı genellikle karışıklık matrisi üzerinden değerlendirilmektedir.

- Farklı sınıflandırma modelleri kullanılarak eğitim gerçekleştirilir, bu modellerden alınan sonuçlara bakılarak en iyi sonucu veren model seçilir.

- Tüm veri eğitilmiş model ile sınıflandırılır.



Şekil 2.28 Çapraz sağlama yöntemi (https://genome.tugraz.at. 2006)

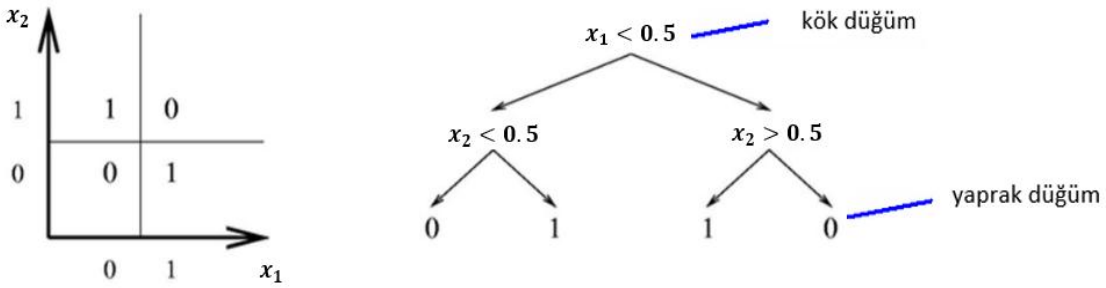
Çalışma kapsamında bir çok sınıflandırma yöntemi kullanılmıştır ve farklı sonuçlar elde edilmiştir. Aşağıda en iyi sonuçların elde edildiği yöntemeler hakkına teorik bilgi bulunmaktadır.

2.7.1 Karar ağaçları ile sınıflandırma

Karar ağaçları böl ve kazan stratejisi kullanan aşamalı veri yapılarıdır. Bu yapı gözetimli sınıflandırma modellerinden biridir.

Sınıflandırma ağaçları veriden yararlanarak bir model tahmin etmede kullanılan makine öğrenmesi yöntemleridir. Tahmin modeli veriyi yinelemeli olarak parçalara ayırıp, her bir parçanın tahmin modeline uygunluğuna bakmaktadır. Sonuç olarak bu parçalara ayırma işlemi karar ağaçları şeklinde ifade edilebilmektedir. sınıflandırma ağaçları ile elde edilen tahminler, sınıfalara ait etiketlerden oluşmaktadır. Maliyetinin düşük olması, uygulama kolaylığı ve güvenilir olmaları açısında en sık kullanılan sınıflandırma tekniklerinden biridir.

Bir örüntüyü bir dizi soru sorular sorarak sınıflandırırken, bir sonraki soru bir önceki sorunun cevabına bağlıdır. Bu şekilde soruların sorulduğu bir örüntüyü sınıflandırmak için ağaç modelleri kullanılmaktadır. Sınıflandırılması istenen ana veri kök düğüm olarak adlandırılır ve ağacın en tepesindedir ve bu düğümün diğer düğümler ile arasında yönlü bir dal veya bağlantı bulunmaktadır. Düğümlere sorular sorularak daha alt dallara ayrışmalarının sona erdiği düğüme yaprak düğümü adı verilmektedir. Bir ağaç sınıflandırması modelinde, kök düğüm yani örüntü ile başlanır ve örüntüye belirli özellikler sorulur. Kök düğümünden çıkan her dal farklı olasılıkların sonuçlarını içermektedir. Verilen cevaplardan yola çıkılarak yaprak düğümüne ulaşılıncaya kadar sorular sorulmaya devam edilir, yaprak düğümüne ulaşılması sorulacak soru kalmadığı anlamına gelmektedir. Elde bulunan veri bilgisini ağaç yöntemi ile sınıflandırmak çok kolay ve anlaşılabilir olması nedeniyle, diğer sınıflandırma tekniklerine göre daha basittir.



Şekil 2.29 Karar ağacı ile sınıflandırma

Şekil 2.29'da bulunan örnekte kök düğümüne x_1 değerinin 0.5'ten büyük olup olmadığı sorusu sorulur ve cevaba göre kök düğümü dala ayrılır. Daha sonra dalların olduğu düğümlere x_2 değerinin 0.5'ten büyük veya küçük olup olmadığı sorularak bu düğümlerinde alt iki düğüme ayrılması sağlanmıştır. Bu aşamadan sonra sorulacak soru kalmadığından en son düğümlere yaprak düğüm denilmiştir.

Karar ağacı sınıflandırma prensibini şöyle açıklayabiliriz. Elimizde bulunan veri setinin, bu çalışma kapsamında özniteliklerin, tamamı kök düğüme yerleştirildikten sonra sorular sorularak yaprak düğümüne kadar ilerlenir ve yaprak düğümündeki her sonucun hangi sınıflandırma etiketine sahip olduğu saptanır. İdeal bir sınıflandırmada yaprak düğümlerdeki her sonucun bir sınıflandırma etiketine sahip olması beklenilmektedir. Ancak daha fazla sorulamadığı ve yaprak düğümlerinden bazılarının herhangi bir sınıfa ait olmadığı durumlarla da karşılaşılmaktadır. Bu tür durumlarda düğümlerin dallanması durdurularak hatalı sonuç kabul edilebilir veya dallanmanın devam etmesi için yeni öznitelikler eklenerek çalışmaya devam edilebilmektedir.

CART algoritması, karar ağaçları ile öğrenmede en sık kullanılan yöntemlerden biridir. Bu yöntem Breiman vd. (1984)'te, veri içinde maksimum homojenliğe sahip iki parçayı bulup bölmeyi amaçlamışlardır. Her seviyede maksimum homojen iki parçanın bulunması, her alt seviyede daha iyi bir homojenliğin elde edilmesini sağlamaktadır. Bu ikiye ayırma işlemi elde edilen en alt kümedeki veri saf hale geldiğinde durdurulmaktadır veya durdurma için belli bir sayıda bölünme olması gibi bir kriterle göre durmaktadır. CART algoritmasında ağacın yapısı önceden belirlenmez, eldeki

verilere göre oluşturulmaktadır. CART ağaçları kesin bir safsızlık ölçüsünü kullanarak düğümlerde dallanma işlemi gerçekleştirmektedir, bu nedenle homojen yapraklar oluşmaktadır (Ahola ve Esa 2001). Literatürde en iyi bölme özellikleri saptamak için iyilik fonksiyonu, bilgi kazancı ve gini indeksi kullanılmaktadır. Bunların arasından gini indeksi en sık kullanılandır.

Sınıflandırma ağaçlarının anlaşılması kolaydır, yorumlamak için istatiksel bir bilgi birikimi gerektirmez ve iki veya daha fazla değişken arasındaki ilişkiyi tanımlamada en hızlı yöntemdir. Ayrıca dışarıdan yeni bir öznitelik verildiğinde tahmin performansı kötü yönde etkilenmez. Gürültüden etkilenmezler, her veri tipi için uygundurlar ve parametrik olmayan bir yöntemdir, yani herhangi bir varsayım yapmazlar. Ancak çok fazla soru sorarak parçalara ayrıştırma işlemi yaptığı için fazla uyum sorunuyla karşılaşılabilir.

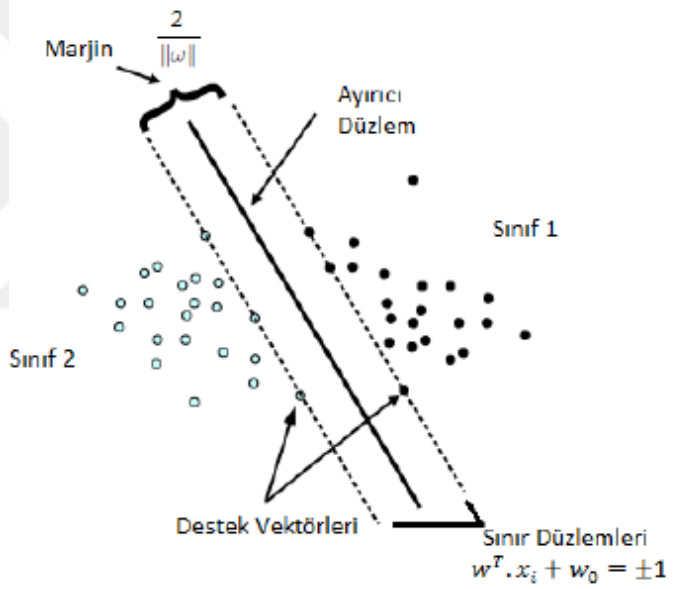
2.7.2 Destek vektör makineleri (SVM) ile sınıflandırma

Cortes ve Vapnik tarafından (1995)'te geliştirilen destek vektör makineleri gözetimli sınıflandırma tekniklerinden biridir. Doğrusal ve doğrusal olmayan bir çok problemin çözümümde kullanılan bu yöntem basit bir algoritmaya sahiptir. Bir karar düzlemi bir veri kümesine ait elemanları farklı sınıflara ayırabilmektedir. SVM'de karar sınıfları tanımlayan, karar düzlemi tabanlı bir yöntemdir. Sisteme giriş olarak gönderilen öznitelikleri n boyutlu uzaya yerleştirerek, veriyi en iyi ayıran ayırıcı düzlem (hyper-plane) ile farklı sınıfları birbirlerinden ayırmaktadır. Sınıfları ayıran birden fazla karar düzlemi bulunmaktadır, her sınıfın birbirine olan uzaklığı maksimum (maksimum marjin) olacak şekilde karar düzlemi belirlenmesi SVM ile yapılmaktadır. Sınıflandırma yapabilmek için karar düzlemlerinin eğitim verileriyle bulunmasından sonra, test verisi üzerinde çalışarak sınıflandırma işlemini yapmaktadırlar.

Veri elemanları birbirlerinden doğrusal bir şekilde ayırabilen ayırıcı düzlem bulunuyorsa, işlem doğrusal SVM ile sınıflandırma işlemi olarak adlandırılmaktadır. Ancak veri elemanları birbirlerinden doğrusal olarak ayrılamıyorlarsa doğrusal olmayan yöntem kullanılmaktadır.

2.7.2.1 Doğrusal destek vektör makineleri

Sınıflandırılması istenen vektörler doğrusal olarak ayrılabiliyorsa kullanılmaktadırlar. Birbirleri arasındaki mesafenin maksimum olduğu ve birbirlerine paralel olan iki sınır düzlemi kullanarak, en optimal ayırıcı düzlemi bulmaya çalışmaktadırlar. En optimal ayırıcı bulma işlemi aynı zamanda en büyük marjin değerini bulmaya denk gelmektedir. İki sınır düzleminin birbirinden uzak olmasının istenilmesinin sebebi, bu şekilde sınıfların birbirlerinden en doğru şekilde ayrılıyor olmalarıdır. Bu yöntemde optimal ayırıcı düzlemi bulmak bir optimizasyon problemine dönüşmektedir ve Lagrance yöntemlerinden yardım alınarak analitik bir çözüm sunulmaktadır.



Şekil 2.30 SVM sınıflandırıcısı (Çelebi 2017)

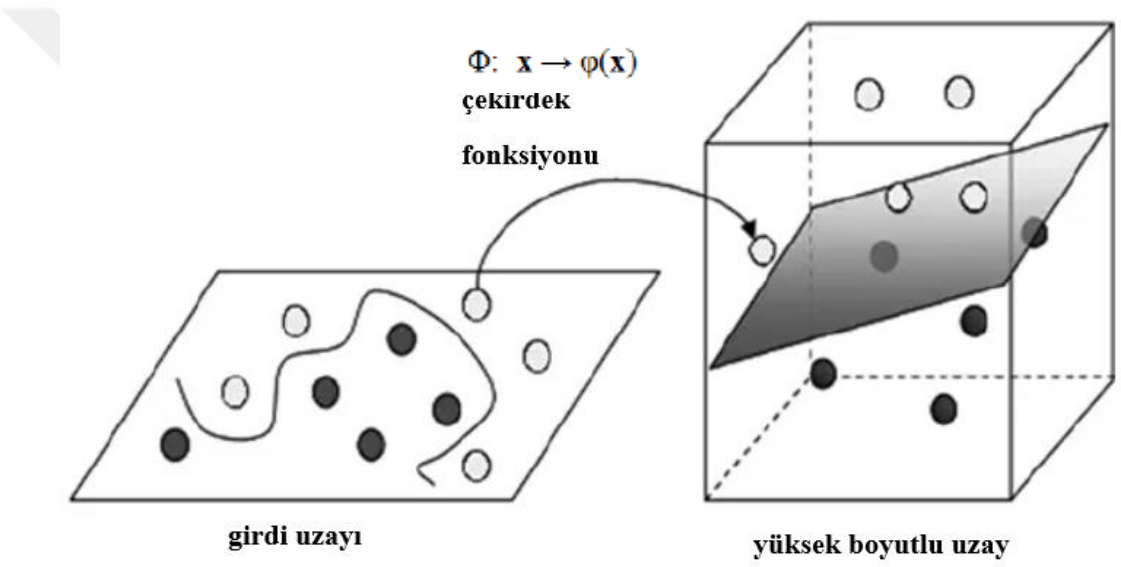
Ayırıcı düzleme ait $f(x) = w^T.x_i + b = 0$ denklemi çözülerek optimum sonuca ulaşılmaktadır.

2.7.2.2 Doğrusal olmayan destek vektör makineleri

Sınıflandırılma için kullanılan eğitim verisi doğrusal bir ayırıcı düzlem kullanılarak ayırılamadığında, bu yöntemden yararlanılmaktadır. Asıl olarak bu yöntemin amacı

doğrusal bir şekilde ayrılamayan veriyi, çekirdek fonksiyonları kullanarak $\emptyset$ ile gösterilen bir haritalama fonksiyonu ile yüksek boyutlu bir uzaya taşıyıp doğrusal bir şekilde ayrılmalarını sağlamaktır. Yüksek boyutlu uzayda doğrusal destek vektör makineleri kullanılarak sınıflar birbirlerinden ayrıştırılmaktadırlar. Yüksek boyutlu uzayda doğrusal vektör makineleri kullanırken ayırıcı düzlem denkleminden yararlanılmaktadır. Eşitlik 2.53, yüksek boyutlu uzayda ayırıcı düzlem denklemini vermektedir.

$$K(x, x_i) = \emptyset(x)\emptyset(x_i) \tag{2.53}$$



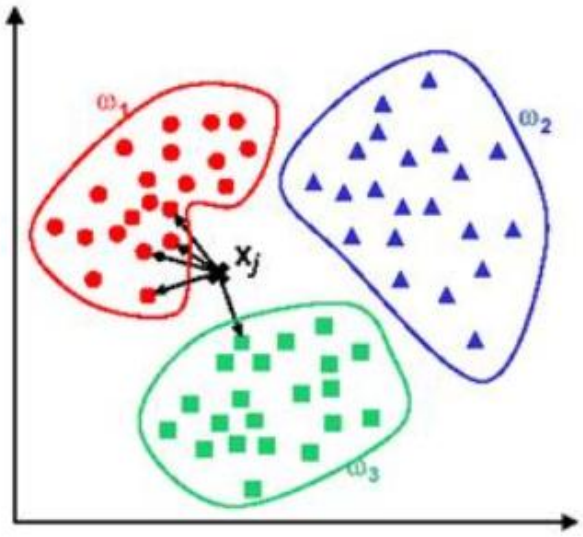
Şekil 2.31 Doğrusal olmayan destek vektör makineleri (Moreira 2011)

Destek vektör makineleri yüksek boyuttaki verilerle iyi çalışabilmektedirler, eğitim için veri içinden eleman kullandıklarından dolayı hafıza yönünden faydalıdırlar, hedef sınıf sayısının öznitelik sayısından büyük olduğu durumlarda verimlidirler. Marjin doğru bir şekilde bulunduğunda çalışma performansları yüksektir. Ancak veri seti büyükse performansları iyi değildir çünkü eğitim süreci uzun zaman gerektirmektedir ve gürültüden kolaylıkla etkilenmektedirler.

2.7.3 K en yakın komşu algoritması ile sınıflandırma (KNN)

KNN algoritması parametrik olmayan, tembel bir algoritmadır. Bir yöntemin parametrik olmaması kullandığı verinin dağılımı hakkında hiçbir varsayımda bulunmadığı anlamına gelmektedir. Bu özelliği pratikte kullanılan verilerin, teorik varsayımlara uymadığı gerçeği düşünüldüğünde kullanışlı olduğunun göstergesidir. Bu yöntemin tembel olmasından kastedilen ise bir sınıflandırma modeli belirlemek için eğitim yapmamasıdır. Eğitim veri setinde bulunan öznitelikleri sınıf etiketlerine göre gruplandırır ve yeni gelen verinin hangi gruba daha yakın olduğuna bakarak sınıf etiketine karar verir. Bu sebeple çok hızlı çalışmaktadır. KNN algoritması en basit gözetimli öğrenme algoritması olarak bilinmektedir.

KNN algoritması şu şekilde çalışmaktadır. Eğitimde kullanılan veri seti öznitelikler ve bunlara karşılık gelen etiketlerden oluşmaktadır. Öznitelik vektörü içindeki verileri $x_i, i = 1,2,..,n$ ve etiketlerde $w_i, w \in \{w_1, w_2, \dots w_c\}$ şeklinde ifade edilsin. Her x_i, etiketi w_i'ye göre n boyutlu uzaya yerleştirilir.Eğitim verisine sınıfı bilinmeyen bir x_j verisi eklendiğinde, x'in tüm x_i'lere mesafesine bakılır ve en yakın k tane mesafeye sahip x_i'ler ve x_i'lerin sahip olduğu sınıf etiketi saptanır. Bu sınıf etiketlerinden hangisinde daha çok yakın elemana sahipse x_j verisine o sınıf etiketi atanır.



Şekil 2.32 KNN sınıflandırma örneği (Zhang 2017)

KNN sınıflandırıcısın performansı mesafe ölçütüne ve k parametresine bağlıdır (Gosh 2006). Kullanılan veri setine göre en doğru sonucu veren k değeri değişmektedir yada aynı veri seti için farklı k değerleri kullanıldığında sonuçlar farklı olmaktadır (Chomboon 2015). Gürültü etkisini azaltmak için k değerini büyük tutmak gerektiği önerilse de bu durumda sınıflar arasındaki fark azalmaktadır. Mesafe ölçütlerinden ise öklit mesafesi en sık kullanılan ölçüttür. Bunun dışında Mahalonobis, Minkowski, Manhattan ve Chebyschev mesafe ölçütleri de yaygın olarak kullanılmaktadır.

Öklit Mesafesi: Kartezyen koordinatlarda bulunan iki noktanın, koordinatları farkları toplamının karekökü ile elde edilir.

$$Öklit\ Mesafesi = \sqrt{\sum_{i=1}^{n}(x_i - y_i)^2} \tag{2.54}$$

Manhattan Mesafesi: Kartezyen koordinatlarda bulunan iki noktanın, koordinatları farkının mutlak değerlerinin toplamı olarak ölçülmektedir.

$$Manhattan\ Mesafesi = \sum_{i=1}^{n}|x_i - y_i| \tag{2.55}$$

Minkowski Mesafesi: birimleri farklı olan iki nokta arasındaki mesafeyi ölçmeden önce verilerin normalleştirilmesi gerekmektedir. Bu mesafe ölçütü normalleştirilmiş vektör uzayında uzaklığı saptamaktadır.

$$Minkowski\ Mesafesi = (\sum_{i=1}^{n}|x_i, y_i|^p)^{1/p} \tag{2.56}$$

$p = 1$ ise Manhattan mesafesi, $p = 2$ ise Öklid mesafesi, $p = \infty$ise Chebyschev mesafesi elde edilmektedir (Chomboon 2015).

Chebyschev Mesafesi: Kartezyen koordinatlarda bulunan iki noktanın, koordinatları arasındaki farkın mutlak değerinin maksimumudur.

$$Chebyschev\ Mesafesi = max_{i=1}^{n}|x_i, y_i| \tag{2.57}$$

Mahalanobis Mesafesi: Bir nokta ve verinin dağılımı arasındaki mesafe ölçütüdür, C kovaryans matrisini de kullanır.

$$Mahalanobis\ Mesafesi = \sqrt{(X-Y)C^{-1}(X-Y)^T} \tag{2.58}$$

3. MATERYAL VE YÖNTEM

3.1 Materyal

Tez çalışması kapsamında deniz radarından elde edilen görüntülerde kara bölgelerinin saptanması amacıyla götüntü işleme tekniklerinden yararlanılmıştır. Bu çalışmada kullanılan materyal deniz radarından elde edilmiş zamanda sıralı çerçevelerin oluşturduğu bir videodur. Karaya veya bir deniz aracı üzerine kurulan bu radarlar, deniz araçlarının tespiti ve takibinde, navigasyon ve çarpışmadan kaçınmada kullanılmaktadır. Kara ve kargaşa bölgelerinden gelen güçlü yansımalar hedef takibini ve rota belirlemeyi zorlaştırmaktadır. Bu sebeple kara bölgelerinin belirlenmesi önem taşımaktadır. Aşağıda çalışma kapsamında kullanılan videonun ve video çerçeve görüntülerinin sahip olduğu özellikler anlatılmıştır, çalışma kapsamında bu özelliklerden yararlanılarak kara bölgelerinin tespiti yapılmıştır.

1) Bahsedildiği üzere radar görüntülemesinde hedefe gönderilen sinyalin, hedeften radara geri yansırken sahip olduğu enerjiden yararlanılmaktadır. Yansıyan enerji, sinyalin karşılaştığı hedefe göre farklılık göstermektir. Mather ve Tso (2001), Joseph (2005), Muja (2012) çalışmalarında değinildiği üzere yüzey sertliği fazla olan bölgelerden yansıyan sinyallerin enerjileri büyük, yüzey sertliği az olan bölgelerden yansıyan sinyallerin enerjileri küçük olduğundan bahsetmişlerdir. Bu sebeple deniz radarı ile gözlemlenen çevreyi oluşturan kara bölgelerinden yansıyan sinyal enerjileri çok büyük, deniz bölgelerinden yansıyan sinyallerin enerjileri çok küçük, neredeyse sıfırdır. Ayrıca deniz durumunun atmosferik şartlara bağlı olarak değişmesi sebebiyle oluşan dalgalarında yansıtıcılıkları yer yer kara bölgeleri kadar yüksek olmaktadır.

2) Yansıma enerjisi ile radar tarafından kaydedilen görüntü, görüntü işleme uygulamalarında kullanılan 0 ve 1'lerden oluşan iki seviyeli, 0 ve 1 arasında veya 0 ve 255 arasında değerler içeren gri seviyeli ya da kırmızı, yeşil, mavi renk kodlarının her biri için bir gri seviye değere sahip renkli seviye görüntülerden farklıdır. Yüksek yansıtıcılığa sahip noktalar radar görüntüsü üzerinde çok çok

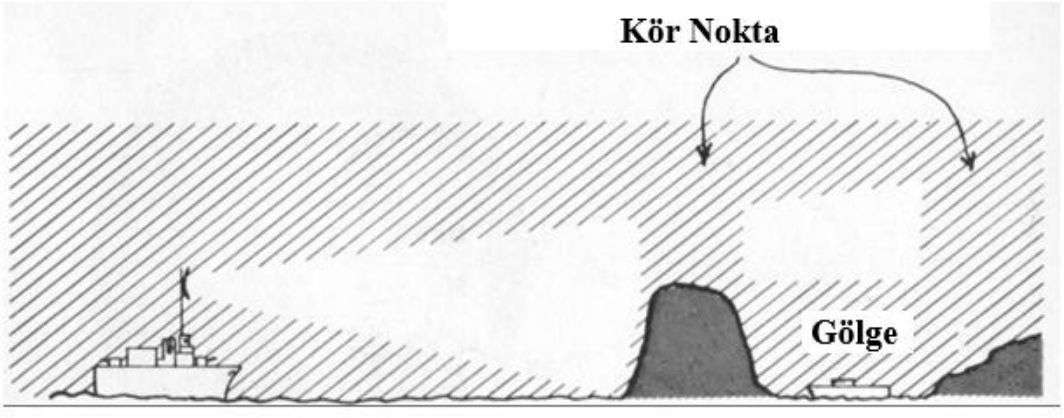
büyük yeğinlik değerine sahipken, düşük yansıtıcılığa sahip veya sinyal alınamayan noktalar ise çok küçük yeğinliğe sahiptirler. Çalışma kapsamında kullanılan görüntü piksellerinde en yüksek yeğinlikli nokta $5 * 10^4$ değeri içerirken, en düşük yeğinliğe sahip nokta ise $5 * 10^{-4}$ değeri içermektedir. Maksimum ve minimum noktalar arasında var olan böyle bir büyüklükle görüntü işleme uygulamalarında karşılaşılmamaktadır.

3) Deniz radarı ile yapılan bir görüntülemede vericiden gönderilen sinyalin hedeften saçılarak alıcıya ulaşması için geçen süre bilgisinden yararlanılarak görüntülenen nesnenin menzili hakkında bilgi sahibi olunmaktadır. Bunun yanı sıra radarın mekanik dönme hareketi ile de nesnenin açı bilgisi hakkında da bilgi sahibi olunmaktadır. Bu sebeple kullanılan video çerçevelerinin eksenleri açı ve menzil bilgilerini bulundurmaktadır. Çalışmada kullanılan radar video çerçevelerinin boyutu $8000 * 80$ $(menzil - açı)$'dir.

4) Konumu değişmeyen bir deniz radarı kullanıldığında radarın her tam tur dönüşünde aynı çevre gözlemlenmektedir. Bu gözlenme durumunda kara gibi hareketsiz nesnelerin menzil ve açı bilgisi değişmemekte, ancak hedef veya kargaşa gibi noktalara ait menzil ve açı bilgileri değişmektedir. Çalışma kapsamında kullanılan radara ait açı bilgisi kaydedilirken kaymalar yaşanmıştır. Bu sebeple elde edilen video çerçevelerinde kara bölgelerinin de hareket ettiği gözlemlenmiştir.

5) Ayrıca radardan, yansımaları kaydedilmek üzere gönderilen sinyaller aynı açı üzerinde yüksekliği fazla olan bir nesne ile karşılaştıklarında, o nesnenin arkasında kalan daha kısa nesneleri saptayamamaktadırlar. Ancak aynı açıda karşılaşılan ilk yüksek nesneden daha yüksek bir nesne ile karşılaşılana kadar sinyal ulaştıramadıkları için görüntüleme yapamamaktadırlar. Sinyal ulaşmayan bölgelere kör noktada denmektedir. Şekil 3.1'de görüldüğü üzere yüksek kara parçasının ardındaki gemi ve kısa kara parçası radar tarafından saptanamaz ve görüntü üzerine bu bölgeler gürültü olarak yansırtılırlar. Çalışmada görüntülenen çevreye ait harita ile radar tarafından çekilen görüntüler arasında, yüksek nesnelerin bulunmasından dolayı farklar bulunmaktadır.

6) Harita ile çekilen görüntüler arasında farklılıkların bulunması sebebiyle performans analizi yapılırken, harita ve çekilen görüntüde eşleşebilen noktaların bulunduğu yeni bir görüntü temel doğru (ground truth) olarak kabul edilmiştir.



Şekil 3.1 Yüksek nesnelerin ardına sinyal gönderilememesi örneği (https://www.ibiblio.org/hyperwar/USN/ref/RADONEA/COMINCH-P-08-06.html 2014)

3.2 Yöntem

Radar videolarında kara bölgelerinin saptanması amaçlanan video çerçevelerine normalizasyon işlemi uygulanması, çerçevelerin çeşitli yöntemler ile bölütlenerek görsel belirgin noktaların saptanması ve sonuçlara ait başarım analizi yapılması, ham veri üzerinde hareketin optik akış ile belirlenerek hareketsel belirginliğin saptanması öznitelik çıkarımı, öznitelik seçimi ve son olarak da elde edilen hareket vektörlerinin sınıflandırılması ile kara bölgelerinin saptanması olmak üzere yedi bölümden oluşmaktadır. Bu kısımda tez çalışması kapsamında uygulanan yöntemler ve sonuçlarından sırası ile bahsedilecektir.

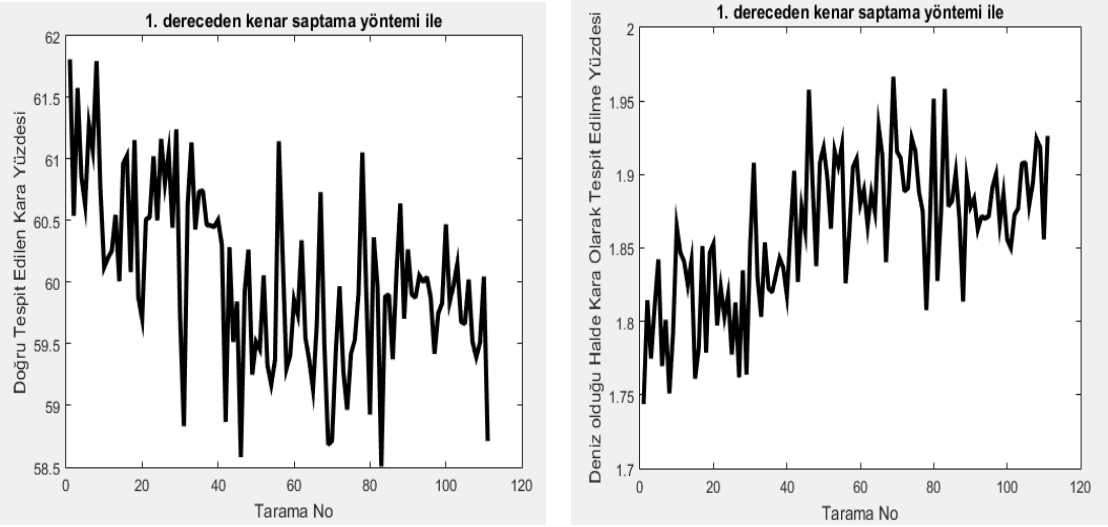
3.2.1 Normalizasyon işlemi

Çalışma kapsamında kullanılan radar video çerçeveleri Bölüm 3.1'de söylenildiği üzere çok geniş bir değer aralığına sahiptir. Bu çerçevelerin işlenebilmesi için gri seviye değer aralığına çevrilmeleri gerekmektedir. Çevrim işleminde doğrusal ya da doğrusal

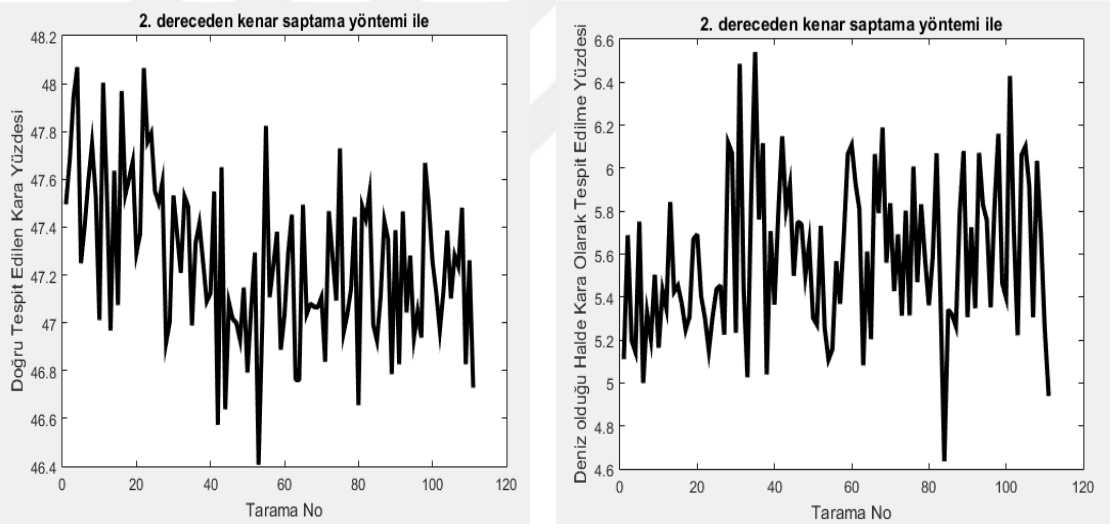
olmayan yöntemler kullanılmaktadır. Doğrusal yöntemler değer aralığının çok geniş olduğu durumlarda uygun sonuç üretmediğinden (Nercessian vd. 2010)çalışmada doğrusal olmayan logaritmik ölçekleme yönteminin kullanılması uygundur. Bunun sebebi logaritmik ölçekleme yöntemi ile yüksek değerli verilerin aralığı sıkıştırılırken, düşük değerli verinin aralığı genişletilmektedir. Bu yöntem kullandığımız çerçevelerin sinyal seviyesi dağılımının yapısı, logaritmik ölçeklendirmeye uygun olduğundan tercih edilmiştir. Logaritmik ölçekleme sonucunda radar görüntü piksel yeğinlikler 0 ve 1 arasında değerler alarak görüntü işleme teknikleri kullanılmaya hazır hale gelmişlerdir.

3.2.2 Bölütleme işlemi sonuçları

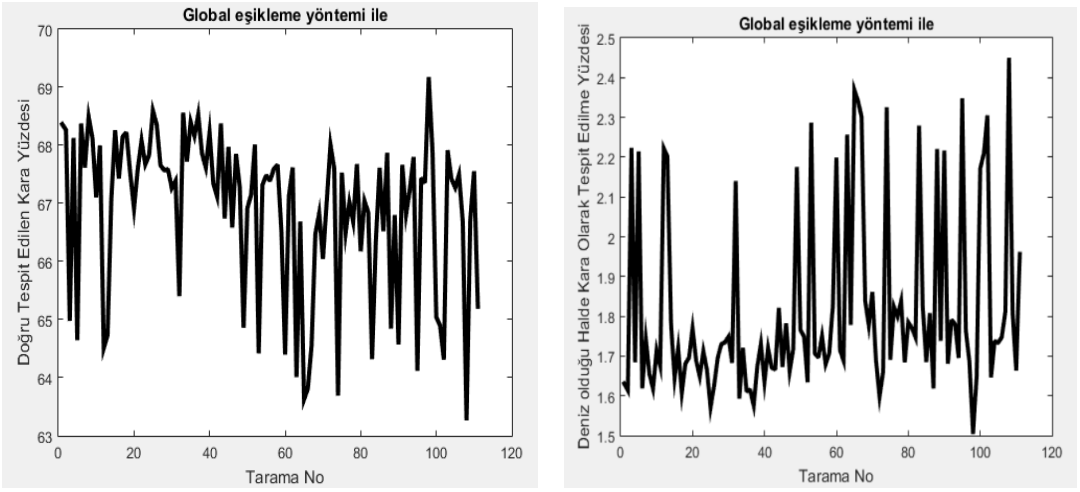
Bu bölümde normalize edilmiş video çerçevelerinin bölütlenmesi ile görsel belirginliğin saptanması amaçlanmıştır. Bölüm 2.2'de bahsedildiği üzere belli bir görüntü türüne göre iyi sonuç verecek veya görüntü çeşidine göre kullanılması uygun görülen bir bölütleme yöntemi bulunmamaktadır, birçok bölütleme yöntemi vardır ve üzerinde çalışılan görüntüye göre kullanılacak olan yöntem seçilmektedir. Çalışma kapsamında kullanılan radar çerçevelerinde 1. dereceden türeve dayalı kenar saptaması yönteminde 0.1834, 2. dereceden türeve dayalı kenar saptaması yönteminde 0.225, global eşikleme yönteminde 0.1851, Otsu eşiklemesi yönteminde 0.2282, optimal eşikleme yönteminde 0.2142 değerleri eşik değeri olarak saptanmıştır. Alan büyümesi yöntemi için tohum pikseli, her çerçevede, görüntü içerisinde en yüksek yeğinliğe sahip noktaya yerleştirilmiştir. Alan büyümesi ve alan ayırma birleştirme yöntemlerinde benzerlik kriteri olarak birçok değer denenmiştir. Alan ayırma birleştirme yönteminde, bu değerlerden küçük olanlar deniz olduğu halde kara olan piksel sayısını artırırken, büyük olanlar ise doğru saptanan kara pikseli sayısını düşürmüşlerdir. Alan büyümesi yönteminde ise bu durum tohum pikselinin etrafında saptanan kara yüzdesini değiştirmiştir. Her iki yöntem içinde benzerlik kriteri otomatik olarak bulunabilmesi ve sıklık grafiği dolayısıyla görüntü yapısına uygun olmasından dolayı global eşik değeri seçilmiştir.



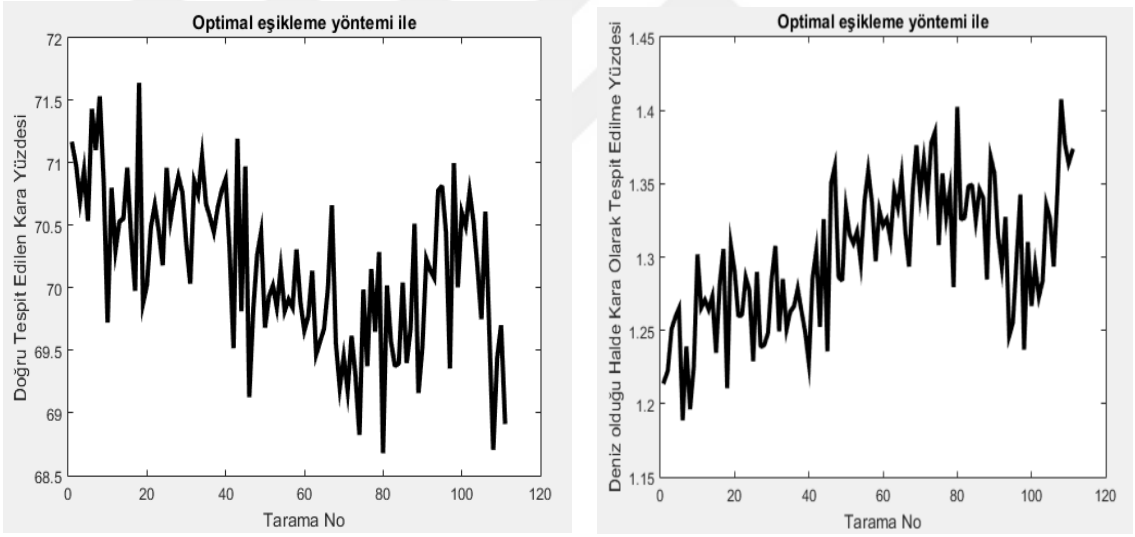
Şekil 3.2 Birinci dereceden kenar saptama yöntemine ait doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları



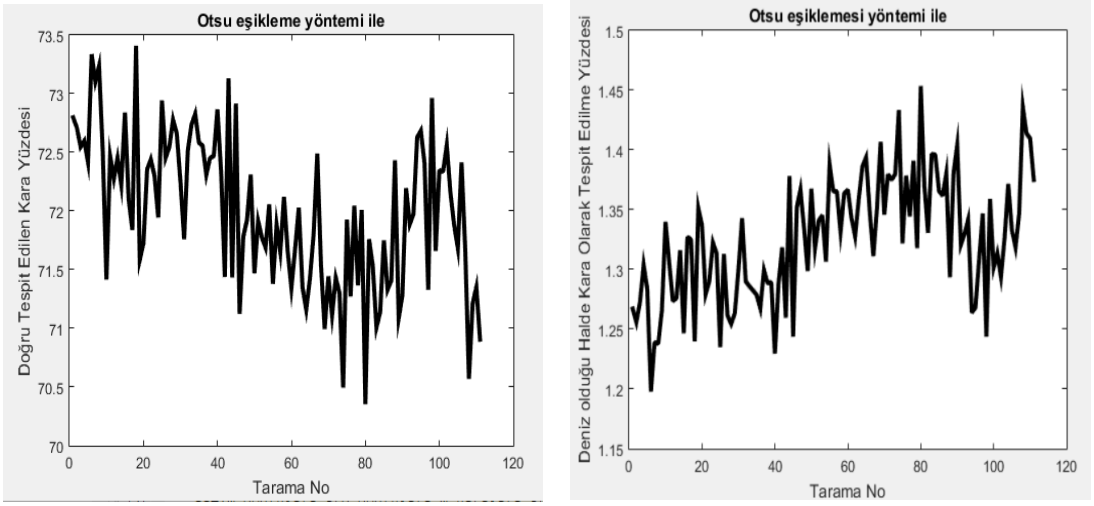
Şekil 3.3 İkinci dereceden kenar saptama yöntemine ait doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları



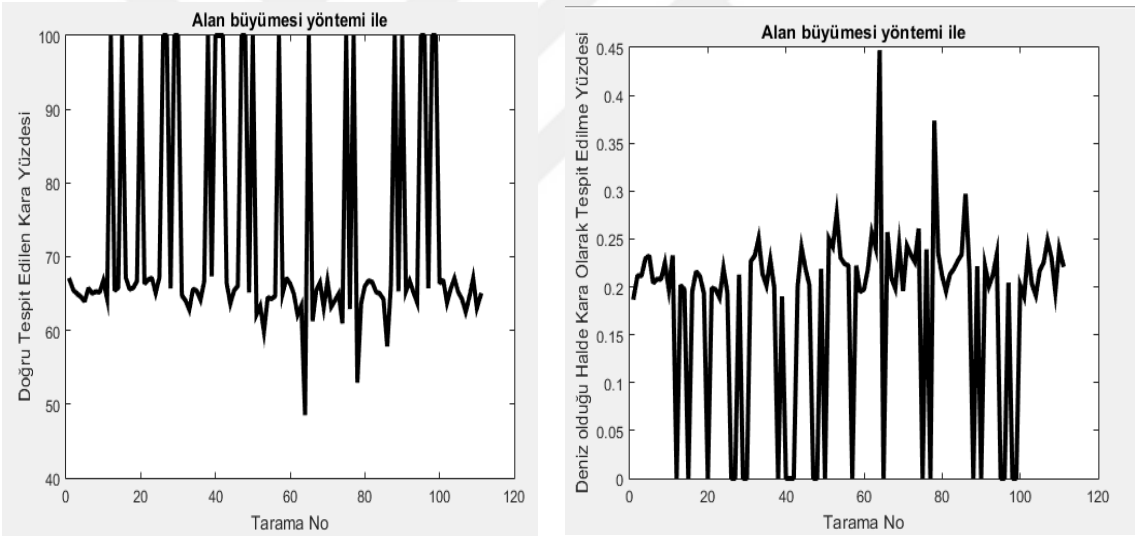
Şekil 3.4 Global eşikleme yöntemine ait doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları



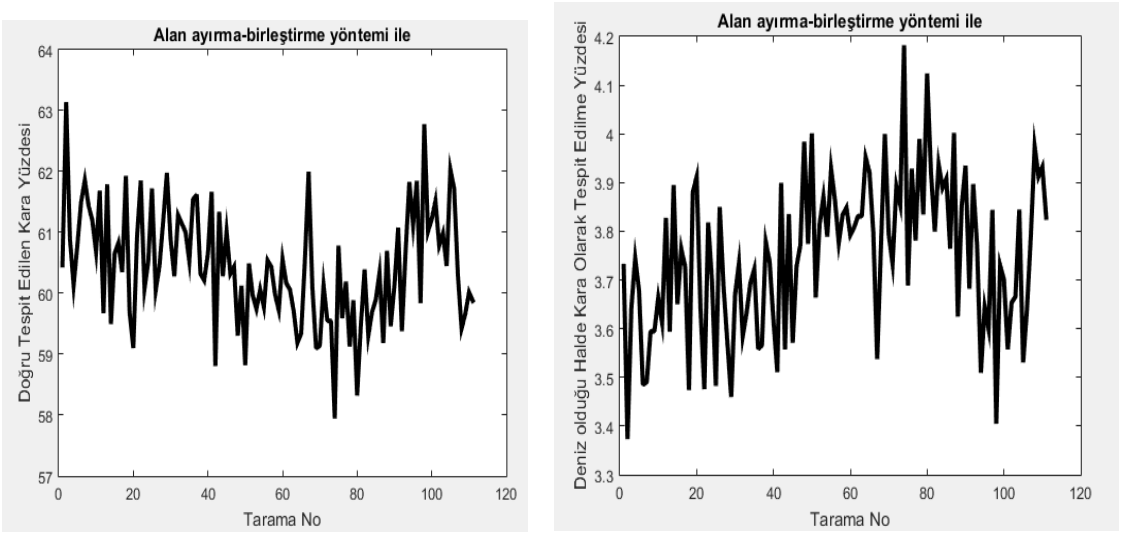
Şekil 3.5 Optimal eşikleme yöntemine ait doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları



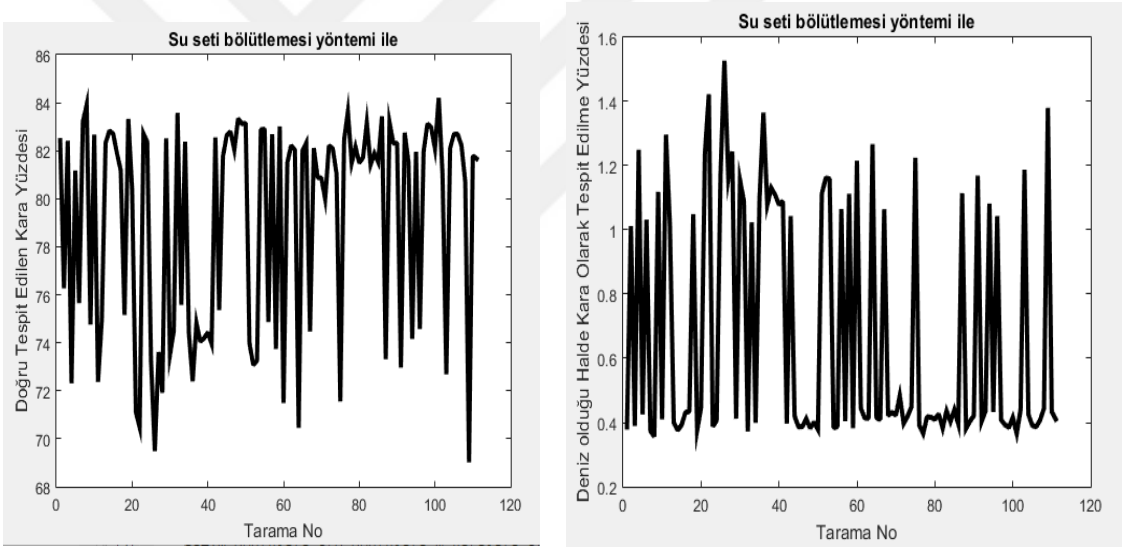
Şekil 3.6 Otsu eşikleme yöntemine ait doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları



Şekil 3.7 Alan büyümesi yöntemine ait doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları



Şekil 3.8 Alan ayırma-birleştirme yöntemine ait doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları



Şekil 3.9 Su seti bölütlemesi yöntemine ait doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları

Kara Tespit Yüzdesi =

$$100 * \frac{Hem\ bölütleme\ sonucu\ hem\ de\ referans\ görüntüsünde\ aynı\ olan\ kara\ pikseli\ sayısı}{Bölütleme\ işlemi\ sonucu\ elde\ edilen\ kara\ pikseli\ sayısı} \quad (3.1)$$

Kara Olarak Tespit Edilen Deniz Pikseli =

$$100 * \frac{Bölütlemiş\ ve\ kesin\ referans\ görüntüsü\ arasındaki\ farkın\ 1'e\ eşit\ olduğu\ noktaların\ sayısı}{Bölütleme\ işlemi\ sonucu\ elde\ edilen\ deniz\ pikseli\ sayısı} \quad (3.2)$$

Referans Görüntüsüe Göre Kara Tespit Yüzdesi =

$$100 * \frac{Hem\ bölütleme\ sonucu\ hem\ de\ referans\ görüntüsünde\ aynı\ olan\ kara\ pikseli\ sayısı}{Kesin\ referans\ görüntüsünde\ bulunan\ kara\ pikseli\ sayısı} \quad (3.3)$$

Eşitlik 3.1-3.3, bölüm 4'te verilen başarım analizi sonuçlarının hesaplanılmalarında kullanılmışlardır.

3.2.3 Kargaşa haritası oluşturma ve başarım analizi

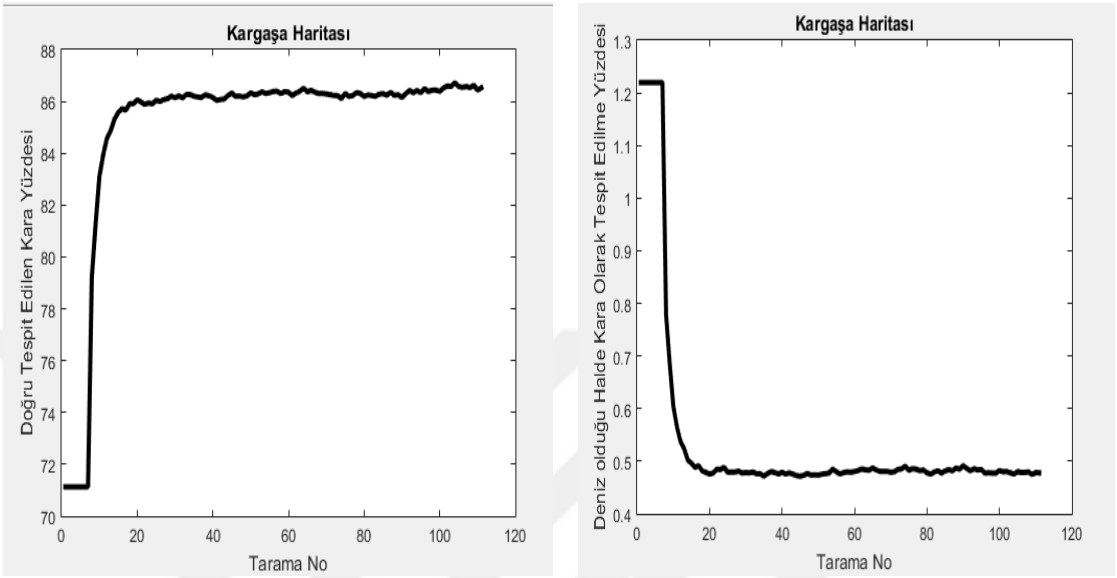
Bölütleme işlemi sadece tek bir çerçeve kullanılarak gerçekleşmektedir. Elimizde yeteri kadar fazla sayıda çerçeve bulunduğunda kara tespiti yapma için kargaşa haritalarından da yararlanılabilmektedir. Kargaşa haritaları eşitlik 3.1'de gösterilen yinelemeli basit bir filtre işlemi ile elde edilmektedir.

$$y(i) = (1 - \alpha)y(i - 1) + \alpha x(i) \quad (3.4)$$

$y(i-1)$ eski kargaşa haritası genliğini, $y(i)$ güncellenmiş kargaşa haritası genliğini ve $x(i)$ şimdiki zamandan elde edilen radar tarama çıktısı genliğini ifade etmektedir. α ise kargaşa değişim tespitinin hızı ve kararlı hale gelme doğruluğu arasındaki dengeyi sağlayan kazanç katsayısıdır. Hareketli hedef takibi yapmak için sabit noktalardan gelen sinyalleri yok etmek amacıyla kargaşa haritası kullanılmaktadır. Sabit noktalar her taramada aynı, hareketli hedefler ise her taramada farklılık göstermektedirler. Kargaşa haritası oluştururken kara bölgelerinden gelen sinyallerin değişmediği bilgisinden yola çıkılarak, α katsayısı ile bir önceki taramadan farkı sadece hareketli noktalar olan yeni tarama sinyalinin etkisi küçük tutulup, hafızada saklı bir önceki kargaşa haritası bilgisi büyük tutularak her kargaşa haritası yinelemesinde sabit noktalar daha çok öne çıkarılıp, hareketli noktalar geri plana atılmaktadır. Böylelikle kara bölgelerin kolaylıkla ayırt edilebildiği kargaşa haritası oluşturulmaktadır.

Çalışma kapsamında hareketli nesne saptamak için hareketsiz noktalardan gelen sinyalleri yok etmekte kullanılan kargaşa haritaları, kara bölgelerini saptamak amacıyla kullanılmışlardır. Kargaşa değişim tespit hızı ve kargaşa haritasının kararlı hale gelmesi

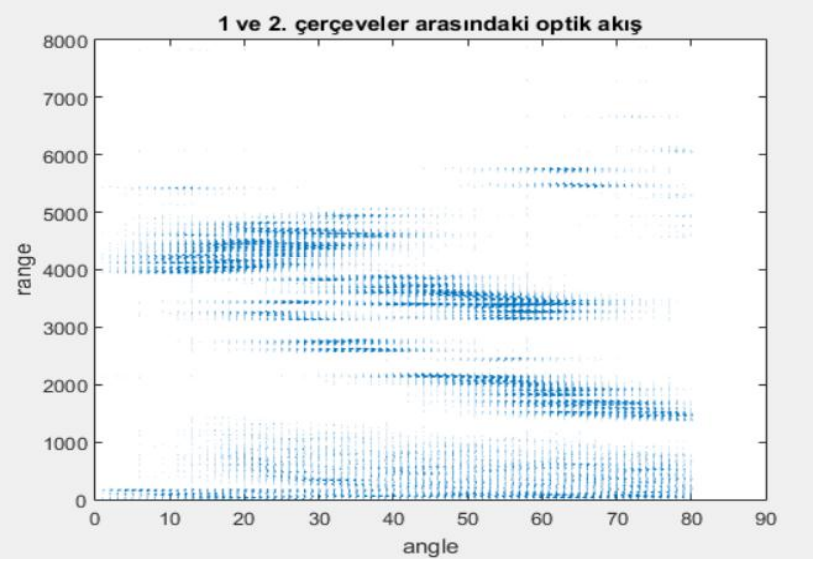
arasındaki bağlantıyı sağlayan α değeri 0.9 alınarak, taramalar boyunca hareketli noktalardan gelen sinyaller bastırılmış, sabit noktalardan gelen sinyaller yükseltilmiştir. Böylelikle kargaşa haritasında kara bölgeleri tespit edilmiştir.



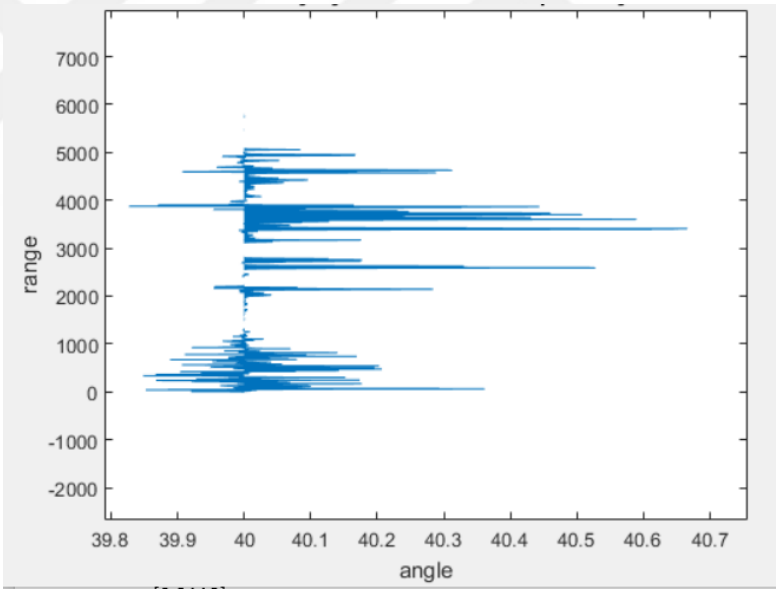
Şekil 3.10 Kargaşa haritası oluşturulduğunda doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları

3.2.4 Optik akış vektörlerinin elde edilmesi

Veri sayısı sınırlı olduğunda kara tespiti için bölütleme yöntemi kullanılabilmektedir ancak bölütleme tekniklerinin başarımları bölüm 4'te gösterildiği üzere yeteri kadar iyi değildir. Bu sebeple sınırlı veri varlığında ardışık termal gürültüsü elenmiş iki çerçeve arasında takip etme işlemi çalışma kapsamında optik akış ile gerçekleştirilmiştir. Böylelikle sadece iki tarama kullanılarak kara bölgelerinin saptanması amaçlanmıştır. Çalışma kapsamında görüntünün her noktasına ait optik akış vektörlerini bulması ve homojen nesnelerin iç kısımlarında kalan noktalara ait hareketi hesaplayabilmesi avantajından dolayı HS optik akış yönteminden yararlanılmıştır. Çalışma kapsamında, optik akış vektörlerini bulmak için yumuşaklık katsayısı 10 ve yineleme sayısı 100 seçilmiştir.



Şekil 3.11 Bir ve ikinci video çerçeveleri arasındaki optik akış



Şekil 3.12 Kırk derece açısında bulunan optik akış vektörleri

Şekil 3.2'nin kırkıncı derecesine menzil boyunca bakılıp karşılaştırıldığında optik akış vektörlerinin deniz, kara ve kargaşa varlığında nasıl davrandığı gözlemlenebilmektedir. Deniz olduğu halde kara olarak saptanan piksellere ait optik akış vektörlerinin yönü sürekli değişen ve genliği küçük vektörler bulunmaktadır, açı kaymasından dolayı tüm kara bölgeleri aynı yönde optik akış vektörlerine sahiptir ve denize ait optik akış

vektörleri de sıfıra yakındır. Optik akış vektörlerine ait özellikler kullanılıp öznitelik çıkarma işlemi yapılarak, bu vektörlerin ait olduğu bölgeler ile ilgi daha doğru daha açıklayıcı bilgiler elde edilmesi için çalışılmıştır.

3.2.5 Öznitelik çıkarımı yapılması

Sınıflandırmayı kargaşa haritası yöntemine göre daha az sayıda çerçeve kullanarak yapabilmek için on adet radar video çerçevesi kullanılmıştır. Bölüm 2.5.1'de anlatılan her öznitelik, optik akış çerçevelerinde bir pikselin aynı konumdaki her çerçeve değeri hesaba katılarak yapılmaktadır. Çalışmada on çerçeve kullanıldığı için dokuz tane optik akış çerçevesi bulunmaktadır ve her çerçevede $8000 * 80 = 640000$ tane yatay, dikey eksenlerindeki piksel hızı ve açısı bilgisi bulunmaktadır. Her optik akış vektörü de yatay ve dikey yönde hareket, genlik ve açı bilgisi olmak üzere 4 adet bilgi bulundurmaktadırlar Bölüm 2.5.1'de sekiz tane öznitelik belirlendiğine göre tüm çalışmaya ait toplam öznitelik vektörü $640000 * 8 * 4$ boyutuna sahiptir. Öznitelik vektörünün büyük olması hem işlem karmaşıklığı hem de işlem süresi açısından kullanışlı değildir. Ayrıca öznitelikler içinde sınıflandırma performansına etki etmeyen ya da sınıflandırma performansını düşüren öznitelikler bulunabilmektedir. Bu sebeple öznitelik seçimi yapılması gerekmektedir.

3.2.6 Öznitelik seçilmesi

Başlıca sınıflandırma performansının artırılması ve işlem karmaşıklığının azaltılması açısından öznitelik seçimi yapılmaktadır. Çalışma kapsamında bölüm 2.6.4'te anlatılan hibrit öznitelik seçimi yöntemi kullanılmıştır. Bu yöntemin seçilmesinin nedeni filtre ve sarmal öznitelik seçme yöntemlerinin iyi taraflarını birleştirerek doğruluğu yüksek sonuçlar sunmasıdır. Öncelikle filtre yöntemlerinden karşılıklı bilgi (MI) öznitelik seçimi yöntemi kullanılmıştır. Bu yöntem her özniteliğin diğer öznitelikler hakkında sahip olduğu bilgi miktarını kullanarak, bilgi miktarı fazla olan öznitelikleri belirlemekte ve tüm öznitelikleri aralarındaki bilgi miktarına göre puanlamaktadır. Aralarındaki bilgi miktarları fazla olan özniteliklerin aynı anda kullanılması gereksiz olduğu için bunlardan birine düşük puan verir ve aralarında bilgi miktarı az olan

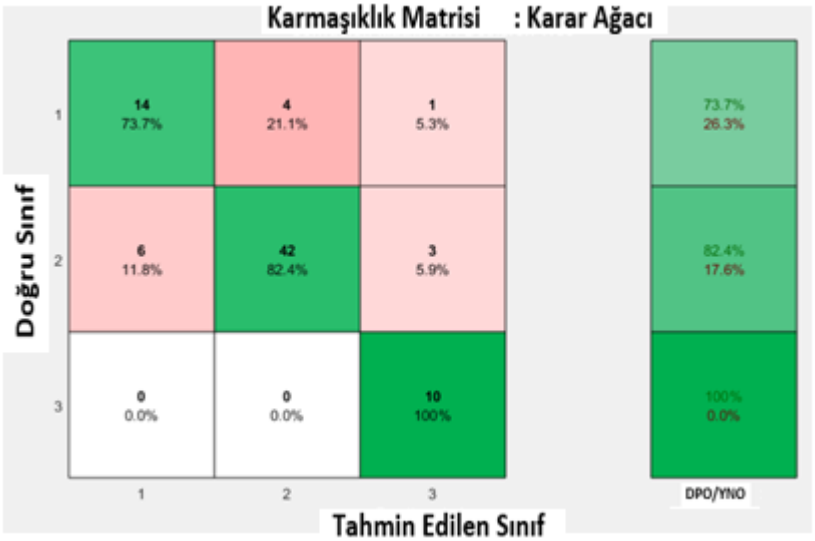
öznitelikler ise çok puan verir. Bu yöntemden alınan yüksek puanlı öznitelikler sarmal öznitelik seçicisi olan ileri belemeli öznitelik seçimi yöntemine gönderilir. Bu yöntem girişinde bulunan öznitelikleri eklemeli olarak tek tek alır ve sınıflandırıcı performansını ölçer. Sınıflandırıcı performansında az veya hiç değişiklik yaşanmaya başlandığında öznitelik eklemeyi bırakır. Çalışma kapsamında filtre yöntemi ve ardından sarmal yöntem ile bölüm 2.6.4'te verilen özniteliklerden ortalama karekök ortalaması ve tepe genliği değeri seçilmiştir. Böylelikle öznitelik vektörü boyutu $640000 * 2 * 4$ olmuştur.

3.2.7 Sınıflandırma

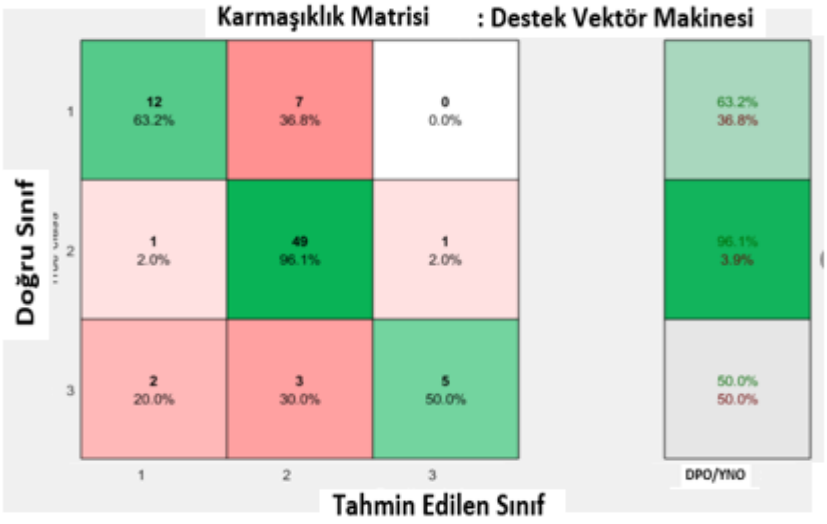
Kara, deniz ve deniz olduğu halde kara olarak gözüken bölgelerin optik akış vektörlerine ait özniteliklerden yararlanarak bu bölgelerin gözetimli olarak sınıflandırma işlemi yapılmıştır. Gözetimli bir sınıflandırma yapılabilmesi için öncelikle sonuçları belli olan test ve eğitim verisi belirlenmelidir. Test ve eğitim verisine ait sonuçlar kara, deniz ve kargaşaya ait sınıf etiketleridir. Bu çalışmada termal gürültüsü elenmiş görüntüden yararlanılarak toplamda 80 tane kara, deniz ve deniz olduğu halde kara olarak gözüken noktalar seçilmiş ve bölüm 3.2.6'dan yararlanılarak bu noktalara ait seçilmiş öznitelikler hesaplanmıştır. Ayrıca kara bölgelerine 1, deniz bölgelerine 2, deniz olduğu halde kara olarak gözüken bölgelere 3 değeri sınıf etiketi verilmiştir. Seçilen bu noktalar ve etiketleri sınıflandırıcıya test verisi olarak gönderilmiştir. Test verisinin bir kısmı eğitim, bir kısmı da test için ayrılır. Çalışma kapsamında test ve eğitim verilerinin seçimi için 5-katlı çapraz-sağlama yöntemi kullanılmıştır. Yani 80 tane nokta içeren veri beş eşit bölünmüş her bir parçası test kalan diğer dört parçası eğitim verisi olarak kullanılmıştır. Bu işlem beş parçadan her birinin test verisi olarak kullanılasıya kadar, yani beş yineleme ile devam etmiştir. Her yinelemede test, eğitim verisi ve bunlara ait sınıf etiketleri sınıflandırıcıya gönderilmiştir. Her yineleme sonrasında alınan sınıflandırıcı performansı toplanıp beşe bölünerek sınıflandırmaya ait gerçek sonuç elde edilmiştir.

Çalışma kapsamında basit karar ağaçları yönteminden yararlanılmış ve kök olarak konumlanan özniteliği belirlemek için özniteliklerin bilgi kazancı hesaplanmış ve en yüksek bilgi kazancına sahip olanı kök olarak belirlenmiştir. DVM yönteminde ise hem

doğrusal hem de doğrusal olmayan yöntemler denenmiştir. Doğrusal olmayan yöntemlerde en iyi sonuç Gauss çekirdeği kullanıldığında alınmıştır. Doğrusal DVM yöntemleri veriyi iki gruba ayırmaktadır ve çalışma kapsamında ayırılması gereken üç grup bulunmaktadır. Bu sebeple doğrusal DVM yöntemi, veri seti içinden ikişerli olarak grupları alıp sınıflandırma yaparak, tüm sınıflandırma sonucunu vermiştir. K en yakın komşu sınıflandırmasında ise k sayısı değeri, en az k sayısı ile en iyi sonucu veren, 3 olarak seçilmiştir. Ayrıca mesafe ölçütü olarak öklit mesafesi kullanılmıştır.

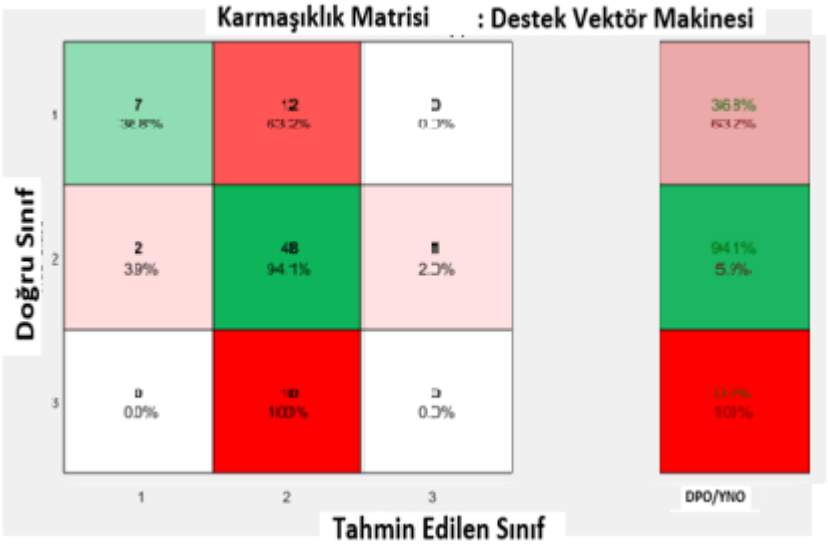


Şekil 3.13 Tüm özniteliklerin kullanılması ile elde edilen karar ağacı sınıflandırma sonucu

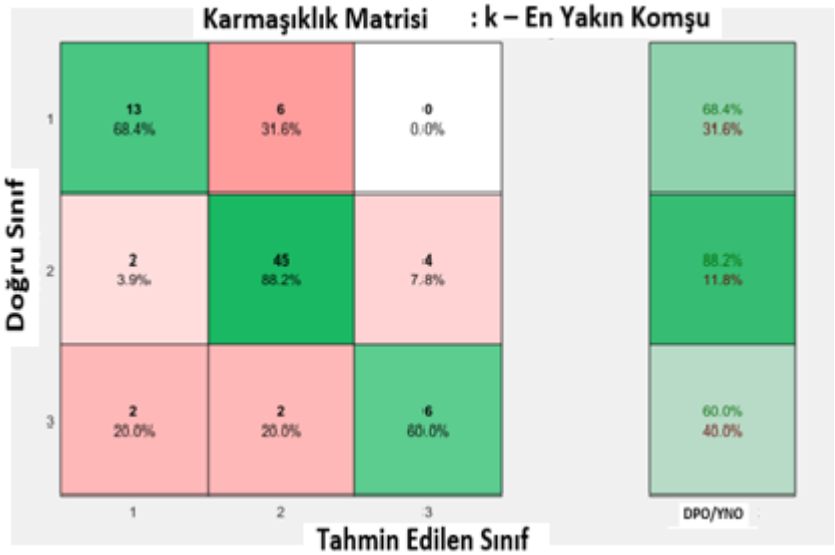


Şekil 3.14 Tüm özniteliklerin kullanılması ile elde edilen doğrusal DVM

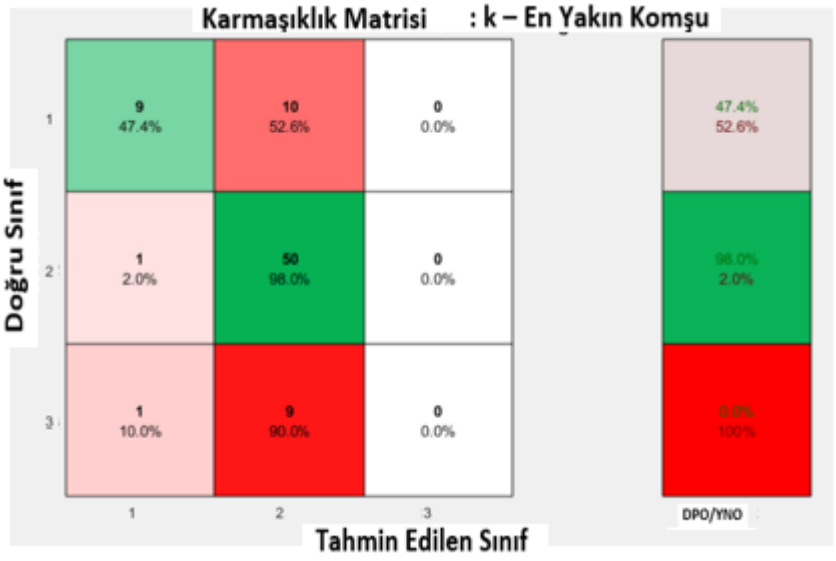
sınıflandırma sonucu



Şekil 3.15 Tüm özniteliklerin kullanılması ile elde edilen doğrusal olmayan DVM sınıflandırma sonucu

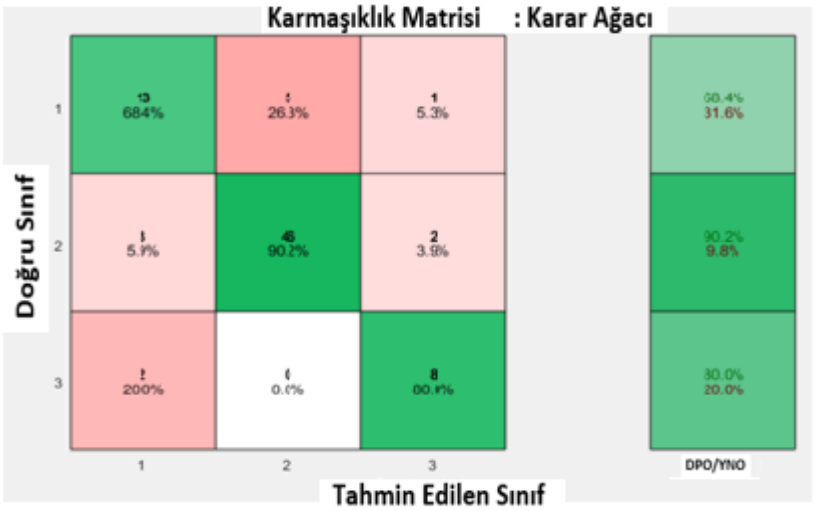


Şekil 3.16 Tüm özniteliklerin kullanılması ile elde edilen 3 komşuluk ve öklit mesafesi kullanılan KNN sınıflandırma sonucu

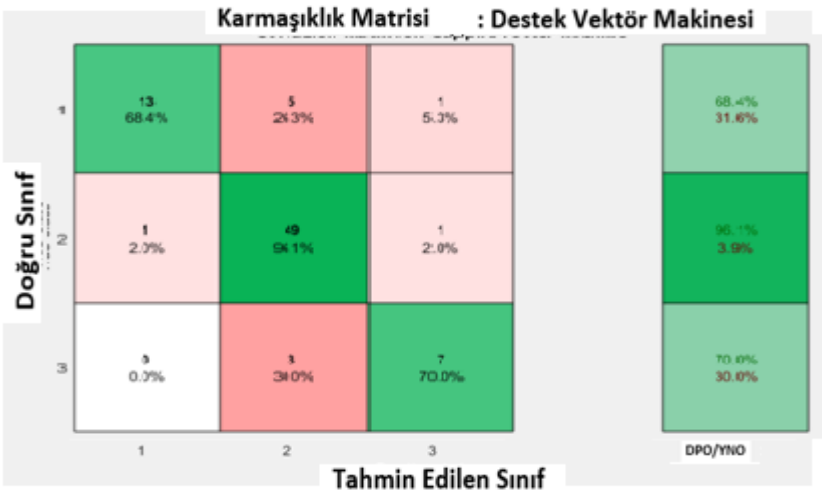


Şekil 3.17 Tüm özniteliklerin kullanılması ile elde edilen 10 komşuluk ve öklit mesafesi kullanılan KNN sınıflandırma sonucu

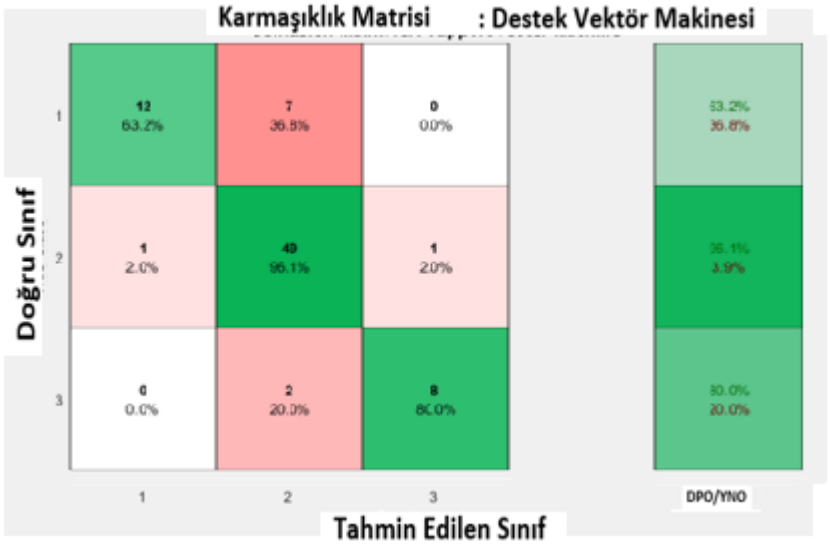
Bölüm 3.2.6'da seçim yapılarak bulunan karekök ortalaması ve genlik mesafesi özniteliklerinin sınıflandırıcıya gönderilmesi ile elde edilen sınıflandırma performansları şekil 3.18-3.22 arasında karmaşıklık matrisleri ile gösterilmiştir.



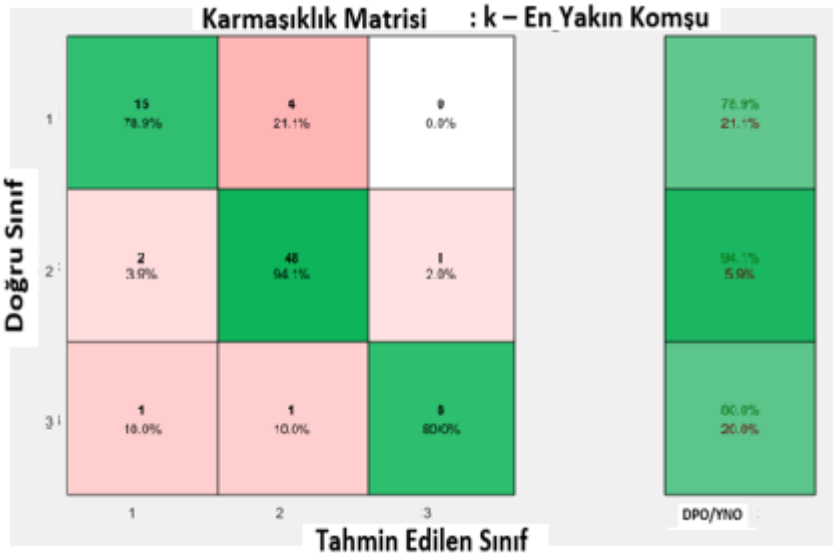
Şekil 3.18 Seçilen öznitelikler kullanılması ile elde edilen karar ağacı sınıflandırma sonucu



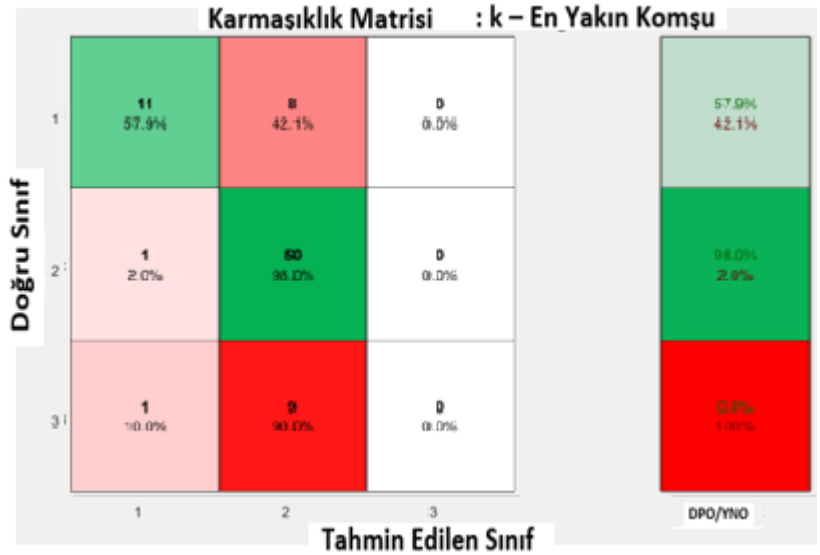
Şekil 3.19 Seçilen öznitelikler kullanılması ile elde edilen doğrusal DVM sınıflandırma sonucu



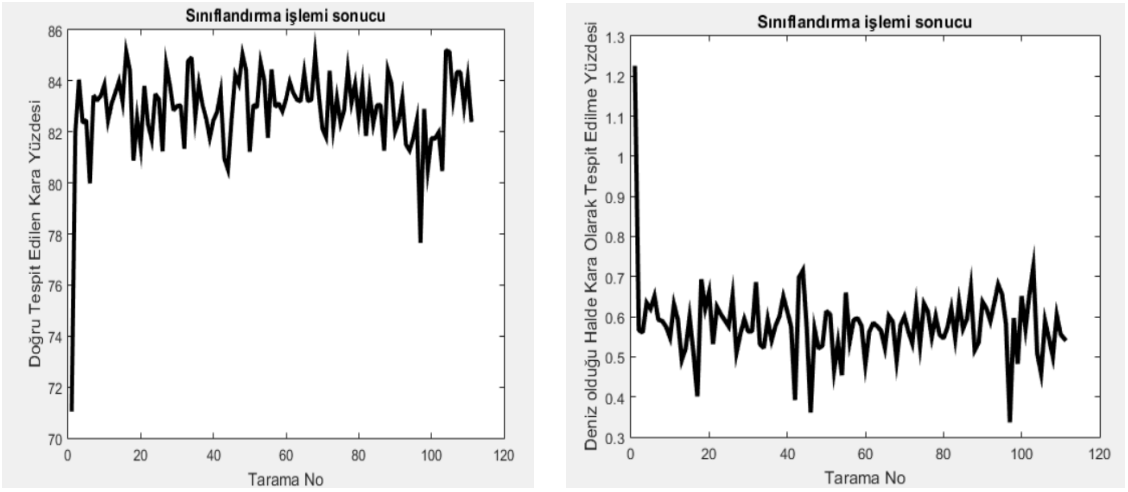
Şekil 3.20 Seçilen öznitelikler kullanılması ile elde edilen doğrusal olmayansan DVM sınıflandırma sonucu



Şekil 3.21 Seçilmiş öznitelikler kullanılması ile elde edilen 3 komşuluk ve öklit mesafesi kullanılan KNN sınıflandırma sonucu



Şekil 3.22 Seçilmiş öznitelikler kullanılması ile elde edilen 10 komşuluk ve öklit mesafesi kullanılan KNN sınıflandırma sonucu



Şekil 3.23 Sınıflandırma sonucunda doğru tespit edilen kara ve deniz olduğu halde kara olarak tespit edilme yüzdesi başarımları

4. ARAŞTIRMA BULGULARI

Çalışma kapsamında önerilen yöntemler için radar videosundan elde edilmiş 110 tane çerçeve kullanılmıştır. Bu video çerçeveleri kara ve deniz bölgelerini içeren bir çevrenin 8000*80 boyutunda görüntülenmiş halidir. Görüntüler üzerinde kara bölgelerinin yeğinlikleri çok yüksekken, deniz bölgelerine ait yeğinlikler çok düşüktür.

Tez çalışmasında kara bölgelerinin tespiti için görüntü işleme yöntemleri, kargaşa haritası ve sınıflandırma yöntemlerinden yararlanılmıştır. Bu yöntemlere ait başarımlar bu bölümde bulunan çizelgeler ile açıklanmıştır.

Kara tespiti için önerilen yöntemler kullanılmadan önce video çerçeveleri normalize edilerek, piksel değerleri 0-1 arasına ölçeklenmiştir.

Çizelge 4.1-4.3'te görüntü bölütleme yöntemleri kullanılan video çerçevelerinde kara bölgelerinin hangi oranda saptanabileceği ve deniz olduğu halde kara olarak tespit edilen noktaların sayısı incelenmiştir.

Çizelge 4.1 Bölütleme yöntemleri sonucunda elde edilen kara tespit yüzdesi ortalama ve standart sapma değerleri

	Kara Tespit Yüzdesi Ortalama Değeri	**Kara Tespit Yüzdesi Standart Sapma Değeri**
1.Dereceden türeve dayalı kenar saptama	60.0505	1.8612
2.Dereceden türeve dayalı kenar saptama	47.2634	0.3367
Global eşikleme	66.9092	1.3646
Optimal eşikleme	70.1692	0.6325
Otsu eşiklemesi	71.9953	0.6427
Alan büyümesi	72.2820	14.8271
Alan ayırma-birleştirme	60.4469	0.9362
Su seti bölütlemesi	79.1527	4.4298

Çizelge 4.2 Bölütleme yöntemleri sonucunda kara olarak tespit edilen deniz pikseli yüzde ortalama ve standart sapma değeri ve hatalı saptanan piksel sayısı ortalama ve standart sapma değeri

	Kara Olarak Tespit Edilen Deniz Pikseli Yüzdesi Ortalama	Kara Tespit Yüzdesi Standart Sapma Değeri	Kara Olarak Tespit Edilen Deniz Pikseli Sayısı Ortalama Değeri	Kara Olarak Tespit Edilen Deniz Pikseli Sayısı Standart Sapma Değeri
1.Dereceden türeve dayalı kenar saptama	1.8612	0.0483	6106.4	158.4
2.Dereceden türeve dayalı	5.5830	0.3618	18317	1186.9
Global eşikleme	1.8132	0.2295	5949	753.1065
Optimal eşikleme	1.3004	0.0472	4266.4	154.8405
Otsu eşiklemesi	1.3253	0.0512	4.1980	168.1332
Alan büyümesi	0.1752	0.0978	574.9099	320.8676
Alan ayırma-birleştirme	3.7488	0.1578	12300	517.6697
Su seti bölütlemesi	0.6708	0.3674	2200.7	1205.5

Çizelge 4.3 Referans görütüye göre saptanan kara tespit yüzdesi ortalama ve standart sapma değerleri

	Haritaya göre Saptanan Kara Tespit Yüzdesi	Haritaya göre Saptanan Kara Tespit Yüzdesi
1.Dereceden türeve dayalı kenar saptama yöntemi	36.3120	3.4299
2.Dereceden türeve dayalı kenar saptama	12.0359	0.4953
Global eşikleme	80.5582	3.0175
Optimal eşikleme	74.6359	2.9862
Otsu eşiklemesi	75.0297	2.9903
Alan büyümesi	7.7260	4.0102
Alan ayırma-birleştirme	54.8695	1.0700
Su seti bölütlemesi	50.6643	5.3223

Çizelge 4.1-4.2'de bulunan değerler eşitlik 3.1-3.2 kullanılarak, çizelge 4.3'te bulunan değerler ise eşitlik 3.3 kullanılarak elde edilmişlerdir.

Şekil 3.2-3.9 ve çizelge 4.1-4.2'de bölütleme yöntemleri uygulanmış çerçevelerde doğru tespit edilen kara yüzdesi ve deniz olduğu halde kara pikseli olarak saptanan hatalı saptama yüzdesine ait ortalama ve standart sapma değerleri verilmiştir. Doğru tespit edilen kara pikseli oranı bölütlenmiş görüntü ile harita üzerinde denk gelen nokta sayısının, tüm bölüt pikseli sayısına oranlanması ile elde edilmiştir. Deniz olduğu halde kara olarak saptanan piksel oranı ise bölütlenmiş görüntünde harita üzerine düşmeyen piksel sayısının tüm deniz pikseli sayısına oranlanması ile elde edilmiştir. Görüntülerin büyük bir bölümünü deniz pikselleri oluşturduğundan hatalı saptanan kara pikseli oranı tüm bölütlemelerde çok küçük gözükmektedir. Bu sebeple çizelge 4.2'de hatalı olarak saptanan kara piksel sayısına bakılarak hata hakkında yorum yapılması daha doğrudur. Çizelge 4.1'de bulunan kara tespit yüzdesi değerlerine bakıldığında su seti ve alan büyümesi bölütlemesi yöntemlerinin en iyi sonucu gösterdiği gözükmektedir. Ancak doğru tespit edilen kara pikseli oranı bölütlenmiş görüntüde harita ile çakışan piksel sayısının, toplam bölütleme pikseline oranı ile edildiği için, az sayıda piksel bölütleyebilen yöntemlerde yanlı sonuç vermektedir. Su seti ve alan büyümesi yöntemleri az sayıda bölüt oluştururlar ve oluşturdukları bölütlerin birçoğu harita ile çakışmaktadır, ancak haritanın küçük bir kısmını saptamışlardır. Bu sebeple doğru tespit edilen kara pikseli yüzdesini bulmak için bölütleme sonucunda harita ile çakışan piksel sayısı oranının, referans görüntüde bulunan kara pikseli sayısına oranı kullanılmıştır, çizelge 4.3'te elde edilen değerler bulunmaktadır.

Çizelge 4.1-4.3'te bulunan sonuçlar incelediğinde türeve dayalı kenar saptama yöntemlerinin hem kara tespit oranları düşük hem de hatalı tespit ettikleri piksel sayıları fazladır. Alan büyümesi yöntemi sadece çekirdek pikselinin bulunduğu bölgeyi bölütleyebildiği için hatalı piksel saptama sayısı düşüktür ancak doğru kara pikseli tespit yüzdesi çok çok düşük olduğundan kullanıma uygun değildir, su seti bölütlemesi içinde benzeri bir durum geçerlidir. Alan ayırma-birleştirme yönteminde bölütleme yapabilmek için görüntünün dörderlik parçalara ayrılması ve bu parçaların birleştirilemesinden kaynaklı olarak görüntü üzerinde kalan ayırma çizgileri yöntemin

sonucu olumsuz yönde etkilemektedir. Global, optimal ve otsu eşikleme yöntemlerine bakıldığında haritaya göre saptanan kara tespit yüzdesi en büyük olan global eşiklemedir, ancak global eşiklemede hatalı piksel sayısı da fazladır. Bunların arasından her yönden daha iyi sonuç veren yöntem Otsu eşiklemesidir. Çizelge 4.2-4.3'e bakıldığında global eşiklemenin kara saptama yüzdesi ile Otsu eşiklemesi ile elde edilen kara noktaları sayısı arasındaki fark ile deniz olduğu halde kara olarak saptanan piksel sayısından oldukça azdır. Bu sebeple Otsu yönteminin iyi çalıştığı söylenilmektedir.

Görüntü işleme uygulamalarında kullanılan ve bölüm 2.3.1'de bahsedilen görüntü bölütleme yöntemlerinin başarımını ölçmek için kullanılan performans analizi metriklerden alınan sonuçlar çizelge 4.4'te verilmiştir.

Çizelge 4.4 Bölütleme yöntemlerinin performans değerlendirmesi

	1.Derece türeve dayalı	2.Derece türeve dayalı	Global Eşikleme	Optimal Eşikleme	Otsu Eşiklemesi	Alan Büyüme	Alan Ayır-Birleştir	Su Seti
DICE	0.316	0.0601	0.6153	0.6340	0.6341	0.0564	0.3043	0.5164
RI	0.9715	0.9343	0.9823	0.9854	0.9853	0.9823	0.9544	0.9836
MI	0.0217	0.0200	0.0204	0.0200	0.0199	0.0202	0.0200	0.0198
KAP	0.3024	0.0343	0.6067	0.6266	0.6267	0.0550	0.2856	0.5083
AUC	0.6743	0.5330	0.8829	0.8453	0.8484	0.5153	0.7577	0.7384
AVD	0.0072	0.0190	0.0043	0.0031	0.0032	0.0081	0.0076	0.0046

Çizelge 4.4 incelendiğinde bölütleme performansları değerlendirilirken kullanılan ölçütlerin sonucu ile çizelge 4.1-4.3 arasında farklılıkların bulunduğu görülmektedir.

Performans analizi sonuçları ile kıyaslanıldığında en yüksek başarım elde edilen bölütleme yöntemleri aynıdır. Ancak performans analizi yöntemlerinde örneğin rand indeksi (RI) metriğinde tüm yöntemlerden alınan sonuçlar % 90 tespit başarımı göstermektedir. Bu oran doğru kara tespiti yüzdesi sonuçlarına göre çok büyüktür ve ayrıca böyle bir oran kara tespitinin sadece bölütleme ile çok yüksek bir doğrulukta gerçekleştiğini ifade etmektedir. Ancak bölütleme sonuçları incelendiğinde bu metriğin hatalı sonuç üretmiş olduğu anlaşılmaktadır. Bunun sebebi rand indeksi metriğinin bağlı olduğu değişkenlerden birinin doğru negatif sayısı yani deniz noktaları sayısı olmasıdır. Çalışmada kullanılan görüntü boyutunun çok büyük olması ve bu görüntülerde denizin büyük bir yer kaplamasından dolayı rand indeksi metriği sonucu büyük çıkmıştır. Bu sebeple başarım ölçütü seçerken kullanılan materyale uygun ölçütler belirlenmelidir, çalışma kapsamında kullanılan görüntülerde deniz pikseli sayısının kara pikseli sayısından çok çok büyük olması, doğru negatif sayısı kullanılan bir metrik ile ölçülen başarımın hatalı olabileceği anlamına gelmektedir. Bu sebeple çizelge 4.1-4.3'ün elde edildiği başarım metriklerin kullanmak daha uygun olmaktadır.

Çizelge 4.5 Kargaşa haritasına ait başarım analizi sonuçları

Kara Tespit Yüzdesi Ortalama Değeri	Kara Tespit Yüzdesi Standart Sapma Değeri	Kara Olarak Tespit Edilen Deniz Pikseli Yüzdesi Ortalama Değeri	Kara Tespit Yüzdesi Standart Sapma Değeri	Kara Olarak Tespit Edilen Deniz Pikseli Sayısı Ortalama Değeri	Kara Olarak Tespit Edilen Deniz Pikseli Sayısı Standart Sapma Değeri
86.1095	3.7603	0.4800	0.1825	1574	13.5138

Kargaşa haritalarında doğru tespit edilen kara yüzdelerine ait ortalama ve standart sapma değerleri çizelge 4.5'te verilmiştir. Kargaşa haritasını oluşturmak için 110 tane çerçeve kullanılmıştır. Burada dikkat edilmesi gereken şöyle bir durum vardır: Yinelemeyle oluşturulan kargaşa haritalarında, şekil 3.10, ilk 7 tarama boyunca doğru kara bölgesi saptama oranında pek fazla değişiklik gözlemlenmemiştir, çünkü hem taramalar arasındaki değişimler azdır hem de filtreleme işlemi ile bu değişiklikler kargaşa haritasına yavaşça aksettirilmektedir. Ayrıca yaklaşık 20 tarama sonrasında bu saptama oranları bir değere yakınsamışlardır. Bu sebeple bazı bölütleme yöntemlerinde ilk 20 çerçeve boyunca standart sapma değerleri çok büyükken, sonrasında

küçülmüşlerdir. İlk 20 çerçevedeki ani değişimden kaçınmak için, çizelge 4.5'te 20. taramadan itibaren elde edilen ortalama ve standart sapma değerleri verilmiştir. Kargaşa haritası ile kara tespiti, bölütleme ile kara tespitine göre daha iyi sonuçlar vermektedir.

Çizelge 4.6 Tüm özniteliklerin kullanıldığı sınıflandırma

Karar Ağacı	Doğrusal SVM	Doğrusal Olmayan SVM	3 Komşuluklu KNN	10 Komşuluklu KNN
%82.5	%82.5	%68.8	%80	%73.8

Çizelge 4.7 Seçilen özniteliklerin kullanıldığı sınıflandırma doğruluğu

Karar Ağacı	Doğrusal SVM	Doğrusal Olmayan SVM	3 Komşuluklu KNN	10 Komşuluklu KNN
%83.8	%86.3	%86.3	%88.8	%76.8

Çizelge 4.6-4.7 incelendiğinde seçilmiş öznitelikler ile çalışmanın sınıflandırma performansını iyileştirdiği görülmektedir, bu durum özellikle doğrusal olmayan SVM sınıflandırmasında bariz bir şekilde ortadadır. Bunun yanı sıra 3 ve 10 komşuluk kullanılan KNN sınıflandırması sonuçları arasında fark bulunmaktadır. Bölüm 2.7.3'te anlatıldığı üzere k parametresinin yüksek tutulması fazla uyuma neden olmuş, sınıflar arası ayrım iyi yapılamamıştır. Bunların yanı sıra burada gösterilmese de karar ağaçlarında maksimum dallanma sayısı çok küçültülünce sınıflandırıcı performansı düşmektedir, ancak belli bir dallanma sayısının üzerinde ne kadar büyük bir dallanma sayısı seçilirse seçilsin sınıflandırma performansı değişmemektedir, çünkü dallanma sayısı artırılsa bile sorulabilecek soru sayısı artmadığı için performans etkilenmez. Çalışma kapsamında sınıflandırma işlemi en iyi sonucu veren, seçilmiş öznitelikler, öklit mesafesi ve üç komşuluk kullanan KNN sınıflandırıcısı ile yapılmıştır. Çizelge 4.6 incelendiğinde sınıflandırma ile bölütleme yöntemlerine göre daha iyi sonuçlar alındığı görülmektedir.

5. TARTIŞMA VE SONUÇ

Tez kapsamında radar video görüntülerinden görüntü işleme teknikleri kullanılarak karaların belirlenmesi üzerine çalışma yürütülmüştür. Çalışmada kaynak olarak deniz radarlarından elde edilen video ve bu videodan elde edilen video çerçeveleri ile çalışılmıştır. Bir deniz aracı veya kara üzerinde bulunan deniz radarları, çevresindeki hedefleri saptamak, navigasyon veya çarpışmadan kaçınma gibi amaçlarla kullanılmaktadırlar. Bu radarlar iletilen sinyal ile yansıyan sinyal arasında geçen süreyi kullanarak hedeflere ait menzil bilgisini elde ederken, aynı zamanda mekanik dönme yaparak açı bilgisini elde etmektedir. Yansıyan sinyalin enerjiside menzil ve açı bilgisine göre plan pozisyon göstergesi üzerine konumlandırılarak görüntüler elde edilmişlerdir. Üzerinde çalışılan video durağan bir radar ile çekilmiş olup, her çerçevesi aynı noktalar arasını resmetmektedir. Ancak açı bilgisinde ufak sapmalar olan çerçevenin aynı görüntüyü vermesinden dolayı karaların sabit olması gerekliliğine rağmen, karaların da deniz gibi hareketli gözükmelerine sebep olmuştur.

Tez kapsamında kara bölgelerinin saptanması ile hedef takibi sırasında karalardan gelen güçlü yansımaların yok edilerek hedef tespit olasılığının arttırılması, gemi için rota belirlenmesi, kıyı sınırlarının korunması sorunlarına çözüm amaçlanmaktadır. Literatürde kargaşa haritası oluşturma, uzun süreli ölçümler ile kara ve deniz istatistiklerinin belirlenmesi temeline dayanan çalışmalar bulunmaktadır, ancak ulaşılabilen literatürde görüntü işleme tekniklerinin kullanıldığı, radar videolarında karasal bölgelerin saptanması ile ilgili bir çalışma ile karşılaşılmamıştır. Tez kapsamında, literatürden farklı olarak kara bölgelerinin saptanması için görüntü işleme tekniklerinden yararlanılmıştır.

Karaların saptanması için geliştirilen çalışmada, radar videosu üzerindeki piksel yeğinlikleri arasındaki farkın çok fazla olmasından dolayı öncelikle veri normalizasyonu işleminden yararlanılmıştır. Yüksek yeğinlik farkının olduğu veride, literatürden yararlanılarak logaritmik ölçekleme kullanılmış ve piksel değerleri 0-1 arasına taşınarak görüntü işlemeye uygun hale getirilmiştir. Problemin bu aşamadan sonrası çıkıntı saptanması işlemine dönüşmüştür. Çıkıntı saptanması, tüm veri yerine

ilgilenilen veri kısımlarına odaklanılmasına yardımcı olmaktadır. Video verisinin kullanıldığı literatür çalışmalarında çıkıntı saptanması statik yani ve dinamik olmak üzere iki başlık altında incelenmiştir. Statik çıkıntı için her video çerçevesindeki görsel çıkıntı bilgisi çıkartılırken, dinamik çıkıntı için zamanda sıralı ardışık çerçeveler arasındaki çıkıntı bilgisi çıkartılmaktadır. Literatürde tüm videoya ait çıkıntı saptanması çalışmalarının temeli statik ve dinamik çıkıntıların ayrı ayrı saptanarak, daha sonra birleştirilmelerine dayanmaktadır. Çalışma kapsamında, literatürden farklı olarak öncelikle çerçevelere ait statik belirgin noktalar saptanmış, daha sonra bu noktaların ardışık çerçevelerde takip edilmeleri ile dinamik çıkıntı saptanmıştır. Statik belirginliğin saptanmasında görüntü bölütleme yöntemlerinden yararlanılmıştır. Bölütleme yöntemlerini başarım analizi yapılmıştır. Kara saptamada iyi performans gösteren bölütleme tekniği belirlenmiştir. Bunun yanı sıra veri sayısı fazla olduğunda kargaşa haritası oluşturularak, bu haritada kara bölgesi saptama başarımı incelenmiştir. Sonuç olarak kargaşa haritasının kara bölgelerini saptamada bölütlemeden daha iyi olduğu görülmüştür. Elimizde bulunan verinin kısıtlı olması durumunda kara tespiti yaparken optik akış yönteminden yararlanılmıştır. Optik akış vektörleri ardışık iki çerçeve arasındaki piksellerin x ve y yönündeki hız ve açı bilgisini bulundurmaktadır. Çalışma kapsamında sonuca ulaşabilmek adına ham veri çerçevelerinden termal gürültü elenerek optik akış kullanılmıştır. Termal gürültüyü eleme işlemi bir çeşit bölütleme tekniği olarak gözükmektedir, fakat termal gürültü elenirken bölütleme sonuçlarında olduğu gibi kara bölgelerinin bir kısmı değil tamamı bölütlenmiş olur. Kısacası kara tespiti % 100'dür. Eğer verinin açı ölçümünde kaymalar yaşanmasaydı, karalara ait optik akış sonucu sıfır çıkar ve buraya kadar yapılan işlemlerle kara bölgeleri tespit edilmiş olurdu. Ancak açı kaymasından dolayı optik akış ile kara bölgelerinde de hareket saptanmıştır. Ancak bu hareket kargaşa bölgesindeki hareketten yapısal olarak farklıdır. Bu farklılıktan yararlanılarak sınıflandırma yapılması amaçlanmıştır. Sınıflandırma işlemine ön hazırlık olması açısından öznitelik çıkarmak gerekmiştir. Yapılan literatür taraması sonucunda optik akış vektörlerini kullanarak sınıflandırma yapılan çalışmalarda sıklıkla kullanılan zaman alanı öznitelikleri tüm optik akış çerçevelerinden her bir piksel noktası için çıkarılmışlardır. Elde edilen öznitelik uzayından sınıflandırma performansını düşürecek veya etkilemeyecek olanlar elenerek öznitelik seçimi işlemi gerçekleştirilmiştir. Öznitelik seçimi hem sınıflandırma performansının artırılması hem

de öznitelik uzay vektörünün boyutu azaltılmıştır. Öznitelik seçimi literatürde verimli sonuçlar alındığı belirtilen hibrit yöntemler kullanılarak yapılmıştır. Çalışmanın son aşaması olan sınıflandırma için deneysel bir çalışma yapılarak birçok sınıflandırıcı kullanılmış ve performansı en yüksek sınıflandırıcı saptanmıştır. Deneysel bir çalışma yapılmasının sebebi sınıflandırma yöntemlerinin her uygulamada farklı sonuçlar oluşturmasından kaynaklanmaktadır. Seçilen eğitim verisi bir çok sınıflandırıcı tarafından eğitilip test edilmiş, en yüksek oranda sınıflandırma performansına sahip KNN sınıflandırıcısı ile kara bölgelerinin yüksek oranda saptanabildiği gözlemlenmiştir. Ayrıca yeni bir veri eklendiğinde alınan sınıflandırma performansı hemen hemen aynı kalmaktadır.

Tez çalışmasında elde edilen sonuçlar varlığında, radar videolarında karasal alanların, diğer radar çalışmalarında olduğu gibi üzerinde çalışılan ortam nesne istatistiklerinin belirlenilmesine ihtiyaç duyulmaksızın bilgisayarla görme ve makine öğrenmesi yöntemleri ile saptanabileceği gözlemlenmiştir. Kıyı güvenliği, hedef takibi, harita bulunmadığında seyir rotası belirlemek gibi önemli uygulamalarda kara bölgelerini saptamanın bu uygulamaların başarımlarını arttıracağı düşünülmektedir.

İlerleyen zamanlardaki çalışmalarımızda alan büyümesi yöntemi için tohum pikselinin farklı noktalarda seçilmesi ile başarımın incelenmesi üzerine ve ayrıca zamansal ve uzamsal çıkıntıların birleştirilmesi yani bölütleme sonuçları ve optik akış vektörlerinin sınıflandırılması yöntemlerinin birleştirilmesi ile çıkıntı saptaması oranının yükseltilmesi için çalışılacaktır.

KAYNAKLAR

Ahola, L. and Esa, R. 2001. Data Mining Case Studies İn Customer Profiling. VTT lnfonnation Technology Research Report, TIEI-2001-29.

Al-amri, S., Kalyankar, N.V. and Khamitkar, S.D. 2010. Image Segmentation by Using Edge Detection. International Journal on Computer Science and Engineering, 10(3), 804- 807.

Amaldi, E. and Kann, V. 1998. On the approximation of minimizing non zero variables or unsatisfied relations in linear systems. Theoretical Computer Science, 209:237–260.

Amoda, N. and Kulkarrni, R. 2013. Image Segmentation and Detection using Watershed Transform and Region Based Image Retrieval. International Journal of Emerging Trends & Technology in Computer Science, 1(2), 70-74.

Anala, M., Jabeen, F. and Thakur, V. 2014. MATLAB Implementation of Scan-to-Scan Discriminator for the Detection of Marine Targets, International Journal of Engineering Research and Development, Volume 10, Issue 11, pg. 51-63.

Anonymous. 2000. Web Sitesi: https://earth.esa.int, Erişim Tarihi: 15.03.2017.

Anonymous. 2008. Web Sitesi: http://akizilkaya.pamukkale.edu.tr, Erişim Tarihi: 10.11.2016.

Anonymous. 2013. Web Sitesi: http://www.cs.cmu.edu/~chongw/citeulike/ docs/ doc 7325.html, Erişim Tarihi: 22.12.2016.

Anonymous. 2014. Web Sitesi: http://gim.unmc.edu/dxtests/ROC3.htm, Erişim Tarihi: 28. 09. 2017

Baker, S., Scharstein, D., Lewis, J., Roth, S., Black, M. and Szelski. A Database and Evaluation Methodology for Optical Flow. 2011. Int J Comput Vis (2011) 92: 1–31.

Belaid, L. and Mourou, Walid. 2009. A Watershed Transformation Algorithm. Image Analysis & Stereology, 28(1), 93-102.

Bishop, C. 1995. Neural Networks for Pattern Recognition. Clarendon Press, 487, Oxford.

Breiman, L., Friedman, J., Stone, C. and Olsen, R. 1984. Classification and Regression Trees.

Burton, A. and Radford, J. 1978. Thinking in Perspective: Critical Essays in the Study of Thought Processes, Law Book Co of Australasia, 232, Australasia.

Calow, D. and Lappe, M. 2007. Local Statistics Of Retinal Optic Flow For Self-Motion Through Natural Sceneries. Computation in Neural Systems December , vol. 18(4), pp. 343–374.

Chang, L., Yuen, P. and Qiu, G. 2009. Object motion detection using information Theoretic spatio-temporal saliency. Pattern Recognition, volume 42, no. 11, pp. 2897–2906.

Chaudhuri, D. and Agrawal, A. 2010. Split-and-merge Procedure for Image Segmentation using Bimodality Detection Approach. Defence Science Journal, 60(3), 290-301.

Chomboon, A., Chuhai, P., Teerarassamee P., Kerdprasop K. and Kerdprasop N. 2015. An Empirical Study of Distance Metrics for k-Nearest Neighbor Algorithm. Proceedings of the 3rd International Conference on Industrial Application Engineering.

Cortes, C. and Vapnik, V. 1995. Support Vector Networks. Machine Learning, 20, pp. 1-25.

Dawkins, M., Cain, R. and Roberts, S. 2012. Optical Flow, Flock Behaviour and Chiken Welfare. Animal Behaviour, Volume 84, Issue 1, July, pp. 219-223.

Dong, Y., Pourazad, T. and Nasiopoulos P. 2016. Human Visual System-based Saliency Detection for HDR Content, IEEE Transactions On Multimedia, Volume 18, April.

EL Allaoui, M., Nasri, M., Merzougui, M. and El Hitmy, M. 2012. Medical Image Segmentation By Region Evolutionary Approach. The 3rd International Conference on Multimedia Computing and Systems, 47(24), 24-28.

Fang, Y., Wang, Z., Lin, W. and Fang, Z. 2014. Saliency Incorporating Spatiotemporal Cues and Uncertainty Weighting. IEEE Transactions On Image Processing, Volume 23, No. 9, September

Ghosh, A. 2006. Optimum Choice Of K İn Nearest Neighbor Classification. Computational Statistics & Data Analysis 50, pp. 3113 – 3123.

Gonzales, R. and Woods, R. 2009. Digital Image Processing. Pearson Education, 943, New Jersey

Guill'en A., Sorjamaa, A. and Rubio, G. 2009. Mutual Information Based Initialization Forward-Backward Search for Feature Selection in Regression Problems. International Conference on Artificial Neural Networks, pp. 1-9.

Guill'en, A., Sorjamaa, A., Rubio, G., Lendasse, A. and Rojas, I. 2009. Mutual Information Based Initialization of Forward-Backward Search for Feature Selection in Regression Problems. International Conference on Artificial Neural Networks, pp 1-9.

Gupta, P. and Sharma O. 2015. Feature Selection: An Overview. International Journal of Information Engineering and Technology (IMPACT: IJIET) ISSN(EApplied Vol. 1, Issue 1, 25-36

Gupta, P. and Sharma, O. 2015. Feature Selectıon: An Overvıew. International Journal of Information Engineering and Technology,Vol. 1, Issue 1.

Guyon, I. and Elisseeff, A. 2003. An Introduction to Variable and Feature Selection. Journal of Machine Learning Research, 1157-1182.

Hanley, J. and McNeil, B. 1982. The Meaning and Use of the Area under a Receiver Operating Characteristic (ROC) Curve. Radiology, Vol. 143, 29–36.

Haralick, R. and Saphiro, L. 1984. Image Segmentation Techniques. Computer Vision, Graphics and Image Processing 29, 100-132.

Hildreth, E. 1983. The Measurement Of Visual Motion. , Ph.D. Dissertation, Department of Electrical Engineering and Computer Science, MIT, Cambridge.

Hildreth, E. 1984. Computations Underlying The Measurement Of Visual Motion, Artificial Intelligence, Vol. 23, pp. 309-354.

Horn B. and Schunk B. 1981. Determining Optical Flow. Artifical Intelligence, Vol. 17, Isuues 1-3, pp. 185-203.

Islam, R., Khan, S. and Kim, J. 2016. Discriminant Feature Distribution Analysis-Based Hybrid Feature Selection for Online Bearing Fault Diagnosis in Induction Motors. Journal of Sensors, Vol. 2016, 16 pages.

Itti, L., Koch, C. and Niebur, E. 1998. A Model of Saliency-Based Visual Attention for Rapid Scene Analysis. IEEE Transactions On Pattern Analysis And Machine Intelligence, Volume 20, No. 11, November.

Jadhav, J. 2014. Moving Object Detection and Tracking for Video Survelliance. International Journal of Engineering Research and General Science Volume 2, Issue 4, June-July.

Joseph, G. 2005. Fundementals of Remote Sensing. Universities Press, 486.

Jovic, A., Brkic, K. and Bogunovic, N. 2015. A Review Of Feature Selection Methods with Applications. Information and Communication Technology, Electronics and Microelectronics (MIPRO), 38th International Convention on.

Jun, W. and Dongdong, W. 2012. Ship Target Segmentation in ISAR Images, International Conference on Information Technology and Software Engineering, Volume 212, Springer, Berlin, Heidelberg.

Kamel, W. and El-Zaart, Ali. 2013. Edge Detection in Radar Images Using Weibull Distribution, Journal on Soft computing Artificial intelligence and applications(IJSCAI), Beyrut.

Kaufmann, M. 2001. Filters, Wrappers And A Boosting-Based Hybrid For FeatureSelection. International Conference on Machine Learning (ICML-2001), San Francisco, pp. 74– 81, 2001.

Kaya, M. 2014. Gen İfade Verilerinde Öznitelik Seçimi Ve Sınıflandırma. Yüksek Lisans Tezi Bilgisayar Mühendisliği, Gazi Üniversitesi Fen Bilimleri Enstitüsü.

Kesrarat, D. and Patanavijit V. 2011. Tutorial of Motion Estimation Based on Horn-Schunk Optical Flow Algorithm in MATLAB. AU Journal of Technology, Vol. 15(1), p. 8-16.

Kim, W., Jung, C. and Kim, C. 2011. Spatiotemporal Saliency Detection and Its Applications in Static and Dynamic Scenes. IEEE Transactions On Cırcuits And Systems For Video Technology, Volume 21, No. 4.

Kohavi, R. and John, G. 1997. Wrappers for feature subset selection. Journal Artificial Intelligence, Volume 97, Issue 1-2, pp. 273-324.

Kuang, Y. 2009. A Comparative Study on Feature Selection Methods and Their Applications in Causal Inference. Department of Computer Science, Faculty of Science, Lund University, Tez Çalışması, pp. 70.

Kumar, R. and Indrayan, A. 2011. Receiver Operating Characteristic (ROC) Curve for Medical Researchers. Indian Pediatrics, Volume, 277-287, April.

Ladha, L. 2011. Feature Selection Methods and Algorithms. International Journal on Computer Science and Engineering (IJCSE).

Li, W., Chang, H., Lien, K., Chang, H., Chiang, Y. and Wang, F. 2013. Exploring Visual and Motion Saliency for Automatic Video Object Extraction. IEEE Transactions on Image Processing, Mart

Li, Y., Ma, Y. and Zhang, H. 2003. Salient Region Detection and Tracking in Video. Multimedia and Expo, ICME '03. Proceedings. 2003 International Conference on, IEEE, 2003.

Liu, H. and Wu, C. 2014. Color Image Segmentation Algorithms Based on Granular Computing Clustering. International Journal of Signal Processing and Pattern Reconition Vol.7, No.1, 155-168.

Liu, T., Sun, J., Zheng, N., Tang, X. and Shum, H. 2007. Learning to Detect A Salient Object. 2007 IEEE Conference on Computer Vision and Pattern Recognition, CVPR '07.

Mahfaza, B. R. 2005. Radar Systems Analysis and Design using MATLAB. Chapman and Hall/CRC, 664, USA.

Malhotra, R. 2008. Detection And Segmentatıon Of Movıng Objects in Vıdeo Using Optical Vector Flow Estimation. Mater Thesis, Electrical Engineering.

Martínez, F., Manzanera, A. and Eduardo, R. 2012. A Motion Descriptor Based on Statistics of Optical Flow Orientations for Action Classification in Video-Surveillance. Int. Conf. on Multimedia and Signal Processing (CMSP'12), Dec, Shanghai, China. pp.267 – 274.

Mather, P. and Tso, B. 2001. Classification Methods for Remotely Sensed Data. CRC Press, 1st Edition, 352, December.

Muja, R. 2012. Multidimensional Very High Resolution SAR Signal Processing for Monitoring Energetic Structures. Diploma Project.

Muthukrishnan, R. and Radha, M. 2011. Edge Detection Techniques for Image Segmentation. International Journal of Computer Science & Information Technology 3(6), 259-267.

Nercessian, S., Panetta, K. and Agaian, S. 2010. Multi-scale Image Fusion using the Parameterized Logarithmic Image Processing Model. Systems Man and Cybernetics (SMC), IEEE International Cnference.

Ng, A. 1998. On Feature Selection: Learning With Exponentially Many İrrelevant Features As Training Examples. 15th International Conference on Machine Learning, pp. 404–412, San Francisco.

Oakes, M. and Abhayaratne, C. 2012. Visual Saliency Estimation for Video. Image Analysis for Multimedia Interactive Services (WIAMIS), 13th International Workshop on.

Parabha, S. and Kumar, S. 2016. Performance Evaluation of Image Segmentation using Objective Methods. Indian Journal of Science and Technology, Vol 9(8), February.

Peng, O., Cheung, Y., You, X. and Tang, Y. 2016. Hybrid of Local and Global Saliencies for Detecting Image Salient Region and Appearance. IEEE Transactions On Systems, Man , And Cybernetics: Systems, April.

Priyanga, V., Haritha, M. and Jyothi,R. 2015. Transformation of Variables in Regression Analysis. Presentations & Public Speaking.

Rajiv, K. and Arthanariee, M. 2014. Performance Evaluation and Comparative Analysis of Proposed Image Segmentation Algorithm. Indian Journal of Science and Technology, Vol. 7(1), 39–47.

Ratna, P. and Neelima, G. 2012. Image Segmentation by using Histogram Thresholding. International Scientific Engineering and Technology, 2(1), 776-779.

Ren, Z., Gao, S., Chia, L. and HungTsang, W. 2014. Region-Based Saliency Detection and Its Application in Object Recognition. IEEE Transactions On Circuits And Systems For Video Technology, Volume 24, No. 5, May.

Serra, J. 1982. Image Analysis and Mathematical Morphology. Academic Press, London.

Skolnik, M. Introduction to Radar Systems. McGraw-Hill Publications, 3rd Edition, 672, London.

Subudhi, B., Thangaraj, V., Sankarakingham, E. and Ghosh, A. 2016. Tumor or Abnormality Identification from Magnetic Resonance Images using Statistical Region Fusion based Segmentation. Magnetic Resonans Imaging Volume 34, Issue 9, pp. 1292-1304, November.

Swets, J. 1979. ROC Analysis Applied to the Evaluation of Medical Imaging Techniques.Invest Radiol, Volume 14, 109-121.

Taha A., Hanbury A. and Toro, O. 2014. Metrics for Evaluating 3D Medical Image Segmentation: Analysis, Selection and Tool. BMC Medical Imaging, Vol. 15(1).

Taha, A., Hanbury, A. and Toro, O. 2014. A formal method for selecting evaluation metrics for image segmentation. IEEE International Conference on Image Processing (ICIP), pp. 932-936, October.

Taha, A., Hanbury, A. and Toro, O. 2015. Visual Concept Extraction Challenge inRadiology(VISCERAL)/Evaluate Segmentation. European Commission under the Information and Communication Technologies (ICT) Theme of the 7th Framework Programme for Research and Technological Development, May.

Theodoris, S. and Koutroumbas, K. 2009. Pattern Recognition. Elseiver Inc., 967, USA.

Tsai, D., Lee, Y. and Matsuyama, E. 2008. Information Entropy Measure for Evaluation of Image. Journal of Digital Imaging, Vol. 21, No. 3, 338-347.

Unnikrishnan, R., Pantofaru, C. and Hebert, M. 2007. (6) Toward Objective Evaluation of Image Segmentation Algorithms. IEEE Transactıons On Pattern Analysİs And Machİne Intellİgence, Vol. 29, No. 6.

Vala, H. and Baxi, A. 2013. A Review on Otsu Image Segmentation Algorithm. International Journal of Advanced Research in Computer Engineering & Technology (IJARCET) Volume 2, Issue 2, February .

Vatani, N., Borges, P. and Roberts, J. 2014. On the Use of Optical Flow for Scene Change Detection and Description. Journal of Intelligent & Robotic Systems June, Volume 74, Issues 3-4, pp. 817-846.

Wang, W. and Shen, J. 2015. Saliency Using Local Gradient Flow Optimization and Global Refinement. IEE Transactions On Image Processing, Volume 24, No. 11, November.

Warren D. and Strelow E. 1985. Electronic Spatial Sensing for the Blind: Contributions from Perception. Springer, 521, California.

Wedel, A. and Cremers, D. 1978. Stereo Scene Flow for 3D Motion Analysis. Springer Publishing Company, Incorporated, 137 , Munchen.

William, R. 1971. Objective Criteria for the Evaluation of Clustering Methods. Journal of the American Statistical Association, 66(336):846– 850.

Wolpert, D. 1996. The Lack of a Prior Distinctions Between Learning Algorithms and the Existence of a Priori Distinctions Between Learning Algorithms. Neural Computation 8, pp. 1341–1390,1391–1421.

Xess, M. and Agnes, A. 2014. Analysis of Image Segmentation Methods Based on Performance Evaluation Parameters. International Journal of Computational Engineering Research, Vol. 4, Issue 3.

Yıldız, O., Tez, M., Bilge H., Akçayol, M. ve Güler, İ. 2012. Meme Kanseri Sınıflandırması İçin Veri Füzyonu ve Genetik Algoritma Tabanlı Gen Seçimi. Journal of the Faculty of Engineering and Architecture of Gazi University Cilt 27, No 3, Vol 27, No 3, pp. 659- 668.

Zhang, X., Luo, S. and Meur, O. 2014. Superpixel-Based Spatiotemporal Saliency Detection. IEEE Transactions on Circuits and Systems for Video Technology, Volume 24, Issue

EK 1 Karmaşıklık Matrisi

Genel doğru verisinin kullanıldığı bir çalışmada performans ölçümü için sadece doğru saptanmış noktaların sayısına veya yüzdeliğine bakılması doğru bir yaklaşımmış gibi gözükse de yanlıştır. Örneğin bölüm 3.2.7'de sınıflandırma sonuçları değerlendirilirken sadece doğru saptanan kara noktalarının sayısına göre sınıflandırıcıya karar verilmesi hatalara sebep olabilmektedir. Doğru saptanan kara noktalarının yanı sıra doğru saptanan deniz ve karmaşa noktaları sayılarına ve bu bölgelerin yanlış saptanma sayılarına da bakılarak tüm çalışma için bir sonuç elde edilmelidir. Bu sebeple performans değerlendirmesi yapılırken kesinlik, hassasiyet ve doğruluk analizlerinin de yapılması gerekmektedir. Karmaşıklık matrisi genel doğru ve tahmin edilmiş veri hakkında bilgi sağlayan bir sistemdir. Yani bu matris kullanılan algoritmanın performansının görselleştirilebilmesini sağlamaktadır. Karmaşıklık matrisleri doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif sayılarının satır ve sütunlarında bulunduğu genellikle $2 * 2$'lik yapılardan oluşmaktadırlar.

Tez kapsamında, şekil 1'de verilen tahmin sonucu bölütleme sonucuna denk düşmektedir. Bölütlemenin performansını değerlendirilirken kullanılan DP, YN, YP, DN parametrelerinin çalışma kapsamındaki tanımları aşağıdaki gibidir.

Pozitif (P): Karasal alana ait piksel olması durumu

Negatif (N): Arka plan pikseli olması durumu

Gerçek Pozitif (DP): Doğru olarak tespit edilen karasal alan piksellerinin sayısı

Yanlış Pozitif (YP): Arka plan pikseli olduğu halde karasal alan pikseli olarak saptanan piksellerin sayısı

Doğru Negatif (DN): Doğru olarak tespit edilen arka plan piksellerinin sayısı

Yanlış Negatif (YN): Karasal alan pikseli olduğu halde arka plan pikseli olarak saptanan piksellerin sayısı

		Genel Doğru		
		Pozitif	**Negatif**	
Tahmin Sonucu	**Pozitif**	DP	YP	$Kesinlik\ (Precision) = DP/(DP+YP)$
	Negatif	YN	TN	
		$Hassasiyet\ (Recall/Sensitivity) = DP/(DP+YN)$		$Doğruluk (Accuracy) = (DP+DN)/(DP+DN+FP+FN)$

Şekil 1 Karmaşıklık matrisi

Bölüm 2.3.1'de yapılan literatür çalışması sonucunda DICE benzerlik katsayısı, Rand indeksi, çiftli bilgi, RoC eğrisi altında kalan alan ve ortalama mesafe metrikleri bölütleme performansını değerlendirmek için seçilmişlerdir. Bu metrikler tanımlarında karmaşıklık matris elemanlarını bulundurmaktadırlar. Bu metrikler hakkında aşağıda açıklama bulunmaktadır.

DICE benzerlik katsayısı

DICE benzerlik katsayısı uzamsal örtüşme tabanlı bir ölçüttür. Uzamsal örtüşmeye dayalı metrikler bölütlenmiş görüntüdeki bölütlerin, temel doğru görüntü ile aynı hizada olmasını değil, bölütlenmiş görüntünün piksellerinin ne oranda ön veya arka plan olarak doğru saptandığının ölçütü vermektedir.

M temel doğru görüntüdeki sıfır olmayan pikseller ve N bölütlenmiş görüntüdeki sıfır olmayan pikseller olarak ele alındığında:

$$DC = \frac{2|M \cap N|}{|M|+|N|} = \frac{2DP}{2DP+YP+YN} \quad (1)$$

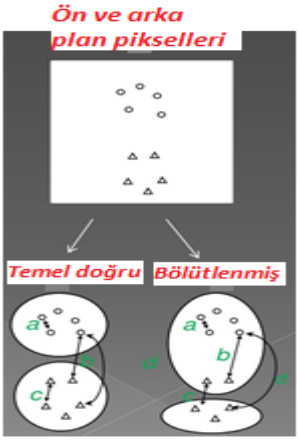
Elde edilen sonuçlar 0-1 arasındadır, sonucun bire yaklaşması bölütleme performansının çok iyi olduğunu göstermektedir.

Rand Index (RI)

Çift sayma tabanlı bir yöntem olan Rand indeksi iki veri kümesi arasındaki benzerliğin ölçütüdür. Bu ölçüt temel doğru ve bölütlenmiş görüntüdeki aynı noktaya denk gelen piksel çiftlerinin aynı etikete, ön plan veya arka plan, sahip olup olmadıklarına bakarak benzerlik hakkında bilgi vermektedir. Doğru olarak saptanan ön plan piksel çiftleri ile doğru olarak saptanan arka plan piksel çiftleri toplamının tüm piksellere oranıdır.

$$RI = \frac{a+d}{a+b+c+d} = \frac{DP+DN}{DP+DN+YP+YN} \quad (2)$$

$a+d$ iki görüntü arasındaki benzerliği, $c+b$ iki görüntü arasındaki farklılığı ifade etmektedir (Prabha ve Kumar 2016). RI değeri 1'e yaklaştıkça bölütlemenin performansının iyileştiği söylenebilmektedir. a temel doğru ve bölütlenmiş görüntüde, aynı piksel konumunda bulunan, aynı kümede olan piksel çifti sayısını ifade etmektedir, bu tanım doğru pozitif tanımıyla aynıdır. b, temel doğru görüntüde farklı ve bölütlenmiş görüntüde aynı kümede yer alan piksel çifti sayısını ifade eder, bu tanım yanlış pozitif tanımıyla aynıdır. c, temel doğru görüntüde aynı ve bölütlenmiş görüntüde farklı kümede yer alan piksel çifti sayısını ifade eder, bu tanım yanlış negatif tanımıyla aynıdır. d, hem temel doğru hem de bölütlenmiş görüntüde farklı kümede yer alan piksel çifti sayısını ifade eder, bu tanım doğru negatif tanımıyla aynıdır. şekil A.2'de RI parametrelerinin saptanması ile ilgili bir örnek bulunmaktadır. Böylelikle Rand Index aşağıdaki gibi de ifade edilebilir.



Şekil 2 Rand Indeksi parametreleri gösterimi (Rand 1971)

Çiftli bilgi (MI)

Bilgi teorisi tabanlı bir yöntem olan iki değişken arasındaki çiftli bilgi, bir değişkenin öteki hakkında sahip olduğu bilgi miktarını ifade etmektedir, değerinin bire yaklaşması bölütleme sonucunun iyi olduğunu göstermektedir. Çiftli bilgi hesaplanırken görüntülerin marjinal ve ortak entropilerini kullanmaktadır.

Entropi bir sinyal veya görüntüde belirsizliğin ne kadar olduğunu tanımlamakta kullanılmaktadır, başka bir deyişle bir sinyal veya görüntüden elde edilen bilgi miktarıdır(Tsai vd. 2008). Görüntü tarafından iletilen bilginin nicel bir ölçütüdür. Bu sebeple bölütleme sonucu elde edilen görüntü ve gerçek görüntüyü karşılaştırarak görüntü kalitesini anlamada kullanılmaktadır. Marjinal ve ortak entropi aşağıdaki gibi formülize edilir:

$$H(S) = -\sum_{i=1}^{n} p(S_i) * \log_2 p(S_i) \quad (3)$$

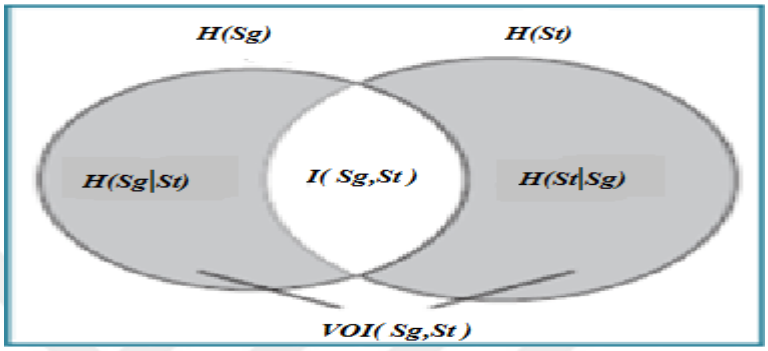
$$H(S_1, S_2) = -\sum_{i=1}^{n} p(S_1^i, S_2^j) * \log_2 p(S_1^i, S_2^j) \quad (4)$$

$p(x, y)$ ortak olasılığı, S^i görüntü bölütlemede oluşan bölütleri ve $p(S^i)$ bu bölütlerin görüntü içindeki olasılığını ifade etmektedir.

Çiftli bilgi aşağıdaki gibi formülize edilir:

$$MI(S_g, S_t) = H(S_g) + H(S_t) - H(S_g, S_t) \quad (5)$$

S_g temel doğru görüntüyü, S_t bölütlenmiş görüntüyü ifade etmektedir.



Şekil 3 Bilgi teorisi tabanlı ölçütlerin gösterimi (Xess 2014)

RoC eğrisi altında kalan alan (AUC)

Alıcı İşletim Karakteristik Eğrisi (ROC) bölütlenmiş ve temel doğru görüntülerin piksel tabanlı olarak karmaşıklık matrisi yardımı ile karşılaştırılmasına dayanmaktadır. ROC eğrisi eksenlerinde doğru pozitif oranı ve yanlış pozitif oranını bulunduran bir grafiktir, dolayısı ile bu eğri duyarlılık ve özgüllük arasındaki dengenin ölçütüdür denilmektedir (Kumar 2011, http://www.cs.cmu.edu/~chongw/citeulike/ docs/ doc 7325.htm, 2013).

AUC ise doğruluğu ölçmek için ROC eğrisini skaler bir değere indirgeyerek kullanılan bir ölçüttür (Parabha ve Kumar 2016). Başka bir deyişle, ROC eğrisi üzerindeki tüm noktaları özetler (Swets 1979 ve Hanley 1982). Bu yöntemin sonucu 0 ve 1 arasında normalize bir değerdir. AUC değerinin yüksek olması bölütleme performansının yüksek olduğunu gösterir.

$$AUC = \int_x^y f(a)da \quad (6)$$

X ve ye minimum ve maksimum eksen noktalarını, $f(a)$ ise eğrinin altını ifade eden bir fonksiyonu göstermektedir.

$$AUC = 1 - \left(\frac{FPR+FNR}{2}\right) \quad (7)$$

$$FPR = YP/(YP + DN) \quad (8)$$

$$FNR = YN/(YN + DP) \quad (9)$$

Ortalama mesafe (AVD)

Mesafe tabanlı ölçütler görüntüler arasındaki farklılıkları göstermek için kullanılmaktadırlar. Eğer tüm görüntünün doğruluğu, sınır çizgileri gibi, önemli ise kullanılması daha uygun gözükmektedir (Taha ve Hanbury 2015). Ortalama mesafe, diğer adı ile ortalama Hausdorff mesafesi, Hausdorff mesafesi ile elde edilen tüm noktaların ortalamasını kullanmaktadır. Hausdorff mesafesi büyük ön olan nesnesi haricinde oluşan küçük nesnelere (outliers) karşı oldukça hassastır (Taha vd. 2014). Ortalama mesafe ise bu duruma karşı daha az hassas ve daha çok karalı bir ölçüttür, bu sebeple Haussdorff mesafesi yerine kullanılmaktadır. AVD aşağıdaki gibi formülize edilir:

$$AVD(S_g, S_t) = \max(d(S_g, S_t), d(S_t, S_g)) \quad (10)$$

$$d(S_g, S_t) = \frac{1}{N}\sum_{a\in A}^{min}{}_{b\in B}\|a - b\| \quad (11)$$

$\|a - b\|$, temel doğru ve bölütlenmiş görüntü pikselleri arasındaki öklit mesafesini ifade etmektedir.

ÖZGEÇMİŞ

Adı Soyadı : Sümeye Nur AKAYDIN

Doğum Yeri : İzmir

Doğum Tarihi: 20/06/1991

Medeni Hali : Evli

Yabancı Dili : İngilizce

Eğitim Durumu

Lise : Kenan Evren Anadolu Lisesi (2009)

Lisans : İzmir Üniversitesi Mühendislik Fakültesi Elektronik ve Haberleşme Mühendisliği Bölümü (2014)

Yüksek Lisans: Ankara Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı (Şubat 2015-Ocak 2018)

Çalıştığı Kurum ve Yıl :

Ankara Üniversitesi Fen Bilimleri Enstitüsü Elektrik –Elektronik Mühendisliği Bölümü Araştırma Görevlisi (2015 - …)