



**SENTETİK AÇIKLIKLI RADAR GÖRÜNTÜLERİNDE OTOMATİK
HEDEF TANIMA**

Mahmut Esat DEMİRHAN

**YÜKSEK LİSANS TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

OCAK 2016

Mahmut Esat DEMİRHAN tarafından hazırlanan “SENTETİK AÇIKLIKLI RADAR GÖRÜNTÜLERİNDE OTOMATİK HEDEF TANIMA” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Gazi Üniversitesi Elektrik-Elektronik Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman : Doç. Dr. Özgül SALOR DURNA

Elektrik-Elektronik Mühendisliği Anabilim Dalı, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum

.....

Başkan : Doç. Dr. İlkay ULUSOY

Elektrik-Elektronik Mühendisliği Anabilim Dalı, Orta Doğu Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum

.....

Üye : Doç. Dr. Nursel AKÇAM

Elektrik-Elektronik Mühendisliği Anabilim Dalı, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum

.....

Tez Savunma Tarihi: 18/01/2016

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....
Prof. Dr. Metin GÜRÜ
Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Mahmut Esat DEMİRHAN

18/01/2016

SENTETİK AÇIKLIKLIL RADAR GÖRÜNTÜLERİNDE OTOMATİK HEDEF TANIMA
(Yüksek Lisans Tezi)

Mahmut Esat DEMİRHAN

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Ocak 2016

ÖZET

Sentetik Açıklıklı Radar (SAR) sistemleri, tüm hava koşullarında çalışabilme, gece ve gündüz görüntüleme yapabilme gibi özellikleri nedeniyle geniş bir kullanım alanı bulmaktadır. SAR sistemleri, özellikle askeri alanda keşif görevlerinde kullanılır. SAR sistemleri tarafından elde edilen görüntüler, çeşitli örüntü tanıma teknikleri kullanılarak değerlendirilir ve görüntülerdeki hedefler bu yöntemler kullanılarak tanımlanabilir. Bu çalışmada, farklı askeri araç tiplerine ait olan SAR görüntüleri için bir otomatik hedef tanıma yöntemi sunulmuştur. Görüntülerdeki hedef tipleri üç aşamadan geçirilerek sınıflandırılmıştır. Bunlar önışleme, öznitelik çıkartma ve sınıflandırma aşamalarıdır. SAR görüntülerinde karşılaşılan yüksek benek gürültüsü, ortalama filtre ve eşikleme yöntemleri uygulanarak azaltılmış, hedef bölgesi arka plandan ayrıştırılmıştır. Öznitelik çıkartma aşamasında ise piksel tabanlı öznitelikler, değiştirilmiş radyal fonksiyon (MRF – Modified Radial Function) öznitelikleri ve eliptik Fourier betimleyicileri (EFD – Elliptic Fourier Descriptors) olmak üzere üç farklı tipte öznitelik grubu oluşturulmuştur. Sınıflandırma aşamasında ise farklı sınıflandırıcılar ile sonuçlar incelenmiştir. Destek Vektör Makinelerinde (SVM – Support Vector Machines) polinomial, radyal temelli ve lineer çekirdek fonksiyonları kullanılarak sınıflandırma gerçekleştirilmiştir. Ayrıca k-En Yakın Komşu (k-NN – k-Nearest Neighbors) algoritması ile de sınıflandırma gerçekleştirilmiştir. Sınıflandırma sonuçları, hata matrisleri ve Alıcı Çalışma Karakteristiği (ROC – Receiver Operating Characteristics) eğrileri ile incelenmiş ve karşılaştırılmıştır. Bu değerlendirmeler sonucunda en yüksek doğru sınıflandırma oranına %96 ile polinomial çekirdek fonksiyonu kullanan SVM sınıflandırıcısında ulaşıldığı gözlemlenmiştir.

Bilim Kodu : 905.1.067

Anahtar Kelimeler : Destek vektör makineleri (DVM), otomatik hedef tanıma, örüntü tanıma, öznitelik çıkartma, sentetik açıklıklı radar (SAR)

Sayfa Adedi : 72

Danışman : Doç. Dr. Özgül SALOR DURNA

AUTOMATIC TARGET RECOGNITION IN SYNTHETIC APERTURE RADAR IMAGES

(M. Sc. Thesis)

Mahmut Esat DEMİRHAN

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

January 2016

ABSTRACT

Synthetic Aperture Radar (SAR) systems, having the advantages such as all weather, day and night imagery capability, have been used in many applications recently. Especially, in the military area, SAR systems are employed for the reconnaissance missions. The images collected from SAR systems can be evaluated by using pattern recognition techniques and the targets on these images can be identified. In this study, an automatic target recognition methodology is proposed for SAR images belonging to various types of military vehicles. Targets on these images are classified by implementing three steps, which are preprocessing, feature extraction, and classification. High level of speckle noise is minimized by applying averaging filters and thresholding techniques and the target area is separated out from the background. In the feature extraction step, three categories of features are proposed. Pixel-based features, Modified Radial Function (MRF)-based features and Elliptic Fourier Descriptors (EFD). Finally, the classification accuracies for Support Vector Machines (SVM) with polynomial kernel, SVM with Radial Basis Function (RBF) kernel, SVM with linear kernel, and k-Nearest Neighbors (k-NN) classifiers are compared with confusion matrices and Receiver Operating Characteristics (ROC) curves. It has been shown that, the highest classification accuracy, which is 96%, is obtained with the SVM classifier employing polynomial kernel.

Science Code : 905.1.067

Key Words : Automatic target recognition, feature extraction, pattern recognition, support vector machines (SVM), synthetic aperture radar (SAR)

Page Number : 72

Supervisor : Assoc. Prof. Dr. Özgül SALOR DURNA

TEŞEKKÜR

Bu çalışmanın gerçekleştirilmesinde, sahip olduğu bilgi birikimiyle bana her zaman yol gösteren, anlayışlı ve yardımsever yaklaşımını hiçbir zaman eksik etmeyen hocam Doç. Dr. Özgül SALOR DURNA'ya teşekkür ederim. Eğitim hayatım ve çalışmalarım boyunca desteklerini her zaman hissettiren başta annem ve babam olmak üzere, aileme ve eşime teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	x
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ.....	1
2. SAR SİSTEMLERİNE GENEL BAKIŞ.....	5
2.1. Kullanılan Veritabanı	7
3. SAR HEDEFLERİNİN SINIFLANDIRILMASI	11
3.1. Önişleme	12
3.1.1. Gürültü azaltma ve görüntünün iyileştirilmesi.....	12
3.1.2. Bölütleme (Segmentation)	14
3.2. Öznitelik Çıkartma	17
3.2.1. Piksel tabanlı öznitelikler	17
3.2.2. Değiştirilmiş radyal fonksiyon	23
3.2.3. Eliptik Fourier betimleyicileri.....	29
3.3. Sınıflandırma.....	32
3.3.1. Destek vektör makineleri	32
3.3.2. k-En yakın komşu algoritması	41
4. SINIFLANDIRMA SONUÇLARININ DEĞERLENDİRİLMESİ	43
4.1. SVM ile Sınıflandırma Sonuçları.....	45
4.1.1. Polinomiyal çekirdek fonksiyonu kullanarak sınıflandırma	45

Sayfa

4.1.2. Radyal temelli çekirdek fonksiyonu (RBF) kullanarak sınıflandırma	46
4.1.3. Lineer çekirdek fonksiyonu kullanarak sınıflandırma	47
4.2. k-NN ile Sınıflandırma Sonuçları	48
4.3. Genel Değerlendirme	50
4.4. Özniteliklerin Sınıflandırmaya Katkıları.....	52
5. SONUÇLAR.....	53
KAYNAKLAR	55
EKLER.....	59
EK-1. Polinomiyal çekirdek fonksiyonlu SVM için ROC eğrileri	60
EK-2. RBF çekirdek fonksiyonlu SVM için ROC eğrileri	63
EK-3. Lineer çekirdek fonksiyonlu SVM için ROC eğrileri	66
EK-4. 3-NN sınıflandırıcı için ROC eğrileri.....	69
ÖZGEÇMİŞ	72

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 1.1. Benzer çalışmalarla ilgili detaylar	4
Çizelge 2.1. MSTAR veritabanındaki hedef tiplerinin örnek görüntüleri	9
Çizelge 4.1. Kullanılan öznitelikler ve boyutları	43
Çizelge 4.2. Hedef tiplerine göre eğitim ve test görüntülerinin sayıları	44
Çizelge 4.3. Polinomiyal çekirdek fonksiyonlu (kübik) SVM için hata matrisi.....	46
Çizelge 4.4. Radyal temelli çekirdek fonksiyonlu SVM için hata matrisi.....	47
Çizelge 4.5. Lineer çekirdek fonksiyonlu SVM için hata matrisi.....	48
Çizelge 4.6. 3-NN sınıflandırıcı için hata matrisi	49
Çizelge 4.7. Farklı öznitelikler için doğru sınıflandırma oranları	52

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. SAR sistemlerinde sentetik açıklık	5
Şekil 2.2. SAR yanal gözlem modu	6
Şekil 2.3. SAR spotlight modu	6
Şekil 2.4. SAR tarama modu.....	7
Şekil 2.5. Alçalış açısı.....	8
Şekil 2.6. Azimut açısı.....	8
Şekil 2.7. 2S1 hedefinin farklı azimut açılarındaki SAR görüntüleri	10
Şekil 3.1. Hedef tanıma/sınıflandırma için uygulanan işlemler.....	12
Şekil 3.2. SAR sisteminde benek gürültüsü.....	13
Şekil 3.3. a) ZSU-23-4 hedefinin önışleme yapılmamış SAR görüntüsü b) Görüntünün ortalama filtresi uygulandıktan sonraki hali	14
Şekil 3.4. Bölütleme işlemi akış şeması.....	15
Şekil 3.5. a) Önışlemeden geçirilmiş görüntü b) En parlak $N \times 0,20$ adet pikselin tespit edilmesi.....	16
Şekil 3.6. Şekil 3.3'teki görüntünün bölütlenmesiyle ortaya çıkan hedef bölgesi.....	16
Şekil 3.7. Hedef alanını kapsayan en küçük dikdörtgen	18
Şekil 3.8. Herhangi bir elipsin odak noktaları, asal ve yedek eksenleri	19
Şekil 3.9. Görüntü üzerine yerleştirilmiş elips ve ona ait asal ve yedek eksenler	20
Şekil 3.10. Hedef alanını kapsayan en küçük dışbükey alan	21
Şekil 3.11. a) Negatif çarpıklık b) Pozitif çarpıklık.....	22
Şekil 3.12. Şekil konturunun (mavi) radyal fonksiyonunun bulunması	24
Şekil 3.13. Radyal fonksiyon tarafından bir açı için birden çok değer üretildiği durum	24
Şekil 3.14. Örneklem noktalarıyla merkez arasında çizilen doğrular (kırmızı).....	27

Şekil	Sayfa
Şekil 3.15. Şekil 3.14'te verilen görüntünün MRF'si	28
Şekil 3.16. Şekil 3.15'te verilen MRF sinyalinin DCT'si.....	29
Şekil 3.17. a) Şekil konturu b) Konturun EFD yöntemiyle geriçatımı	31
Şekil 3.18. İki sınıfı maksimum marjinle ayıran H_3 hiperdüzlemi ve olası diğer hiperdüzlemler (H_1 ve H_2).....	32
Şekil 3.19. Sert marjin uygulanan SVM'nin geometrik yapısı.....	33
Şekil 3.20. Yumuşak marjin uygulanan SVM'nin geometrik yapısı	37
Şekil 3.21. SVM'de çekirdek fonksiyonu kullanımı	39
Şekil 3.22. Lineer olarak ayrıştırılamayan veri kümesinin, başka bir uzaya haritalanarak ayrıştırılabilir hale dönüştürülmesi	40
Şekil 3.23. Lineer olarak ayrıştırılamayan veri kümesinin, başka bir uzaya haritalanarak ayrıştırılabilir hale dönüştürülmesi	40
Şekil 3.24. k-NN yönteminin geometrik gösterimi.....	42
Şekil 4.1. Polinomiyal çekirdek fonksiyonlu SVM için doğru sınıflandırma oranları ...	46
Şekil 4.2. Radyal temelli çekirdek fonksiyonlu SVM için doğru sınıflandırma oranları	47
Şekil 4.3. Lineer çekirdek fonksiyonlu SVM için doğru sınıflandırma oranları	48
Şekil 4.4. Farklı k değerleri için k-NN sınıflandırıcı performansı.....	49
Şekil 4.5. 3-NN sınıflandırıcı için doğru sınıflandırma oranları.....	50
Şekil 4.6. Farklı sınıflandırıcılardan elde edilen sonuçlar	50
Şekil 4.7. Bozuk görüntülerden örnekler	51
Şekil 4.8. a) D7 hedefi örnek görüntüsü b) ZIL-131 hedefi örnek görüntüsü	51
Şekil 4.9. a) 2S1 hedefi örnek görüntüsü b) ZIL-131 hedefi örnek görüntüsü.....	51

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklamalar
AFRL	Air Force Research Laboratory (Hava Kuvvetleri Araştırma Laboratuvarı)
DARPA	Defense Advanced Research Project Agency (İleri Savunma Araştırma Projeleri Ajansı)
DCT	Discrete Cosine Transform (Ayrık Kosinüs Dönüşümü)
DVM	Destek Vektör Makineleri
EFD	Elliptic Fourier Descriptors (Eliptik Fourier Betimleyiciler)
ICA	Independent Component Analysis (Bağımsız Bileşen Analizi)
k-NN	k-Nearest Neighbors (k-En Yakın Komşu)
LDC	Linear Discriminant Classifier (Lineer Diskriminant Sınıflandırıcısı)
MRF	Modified Radial Function (Değiştirilmiş Radyal Fonksiyon)
MSTAR	Moving and Stationary Target Acquisition and Recognition
PCA	Principle Components Analysis (Temel Bileşenler Analizi)
QDC	Quadratic Discriminant Classifier (Karesel Diskriminant Sınıflandırıcısı)
RBF	Radial Basis Function (Radyal Temelli Fonksiyon)
ROC	Receiver Operating Characteristics (Alıcı Çalışma Karakteristiği)
RGB	Red-Green-Blue (Kırmızı-Yeşil-Mavi)
SAR	Sentetik Açıklıklı Radar
SVM	Support Vector Machines (Destek Vektör Makineleri)

1. GİRİŞ

Sentetik Açıklıklı Radar (SAR), hava platformlarında kullanılan bir çeşit yeryüzü görüntüleme sistemidir. Tüm hava koşullarında çalışabilme, gece ve gündüz görüntüleme yapabilme gibi avantajları sebebiyle yaygın bir şekilde kullanılır. Optik sistemlerden farklı bir teknikle çalışan SAR sistemleri ile yeryüzü şekillerinin görüntülenmesi, yüzeylerin ve nesnelerin sınıflandırılması mümkündür. SAR sistemleri askeri alanda ise özellikle otomatik hedef tanıma amacıyla sıklıkla kullanılır. SAR temelli otomatik hedef tanıma sistemleri, farklı öznitelik çıkartma ve sınıflandırma teknikleriyle, akademik alanda birçok araştırmaya konu olmaktadır.

Bu çalışmada, SAR sistemlerinden alınan görüntüler üzerinden tespit edilen askeri hedef tiplerinin tanınması/sınıflandırılması amaçlanmıştır. Bunun için çeşitli örüntü tanıma/sınıflandırma teknikleri incelenmiş ve SAR görüntülerindeki hedef tiplerine yönelik bir otomatik hedef tanıma metodolojisi sunulmuştur. Geliştirilen yöntem, örnek veritabanı üzerinde test edilerek sonuçlar incelenmiştir.

Örüntü tanıma uygulamalarının bir alt başlığı olarak nitelendirilebilecek olan görüntü tanıma işlemleri, genel olarak üç aşamadan geçerek gerçekleştirilir. Bunlar önışleme, öznitelik çıkartma ve sınıflandırma işlemleridir [1]. Başarılı bir sınıflandırma sonucuna ulaşmak için öncelikle veritabanındaki görüntüler iyileştirilir. Önışleme olarak adlandırılan bu işlemin amacı görüntüdeki gürültüden kurtularak ilerleyen aşamalarda daha nitelikli bir görüntü üzerinden işlem yapmaya devam etmektir. Önışleme aşamasında ayrıca görüntü bölütleme (segmentation) işlemi de gerçekleştirilerek, görüntü üzerindeki ilgilenilen alan diğer alanlardan ayrıştırılır.

Önışlemeden geçerek iyileştirilen görüntü, kendisini diğer görüntülerden ayıran, farklı kılan ve sınıflandırılmasına imkân verecek niteliklerinin tespit edilmesi amacıyla öznitelik çıkartma işleminden geçirilir. Burada görüntüdeki sınıflandırma açısından gereksiz veya ayrıştırıcı olmayan bilgiler temizlenir. Ortaya, ilgili görüntünün ayrıştırıcı bilgilerini içeren ve öznitelik vektörü olarak adlandırılan bir veri kümesi çıkar.

Son olarak, görüntüleri ait elde edilen öznitelikler kullanılarak, daha önceden eğitim kümesindeki verilerle eğitilmiş olan çeşitli sınıflandırıcılar aracılığıyla sınıflandırma işlemi gerçekleştirilir.

Literatürde SAR görüntülerinden otomatik hedef tanıma amacıyla pek çok çalışma bulunmaktadır. Bu çalışmalarda farklı önışleme, öznitelik çıkartma ve sınıflandırma yöntemleri uygulandığı görölmektedir.

Yang ve diğeri (2005) tarafından yapılan çalışmada, SAR görüntülerinde Temel Bileşen Analizi (PCA – Principal Component Analysis), Bağımsız Bileşen Analizi (ICA – Independent Component Analysis) ve Hu momentleri teknikleri kullanılarak öznitelikler çıkartılmıştır [2]. Sonrasında Lineer Diskriminant Sınıflandırıcısı (LDC – Linear Discriminant Classifier), Karesel Diskriminant Sınıflandırıcısı (QDC – Quadratic Discriminant Classifier), k-NN ve SVM gibi yöntemler ile sınıflandırma işlemi gerçekleştirilmiştir.

Hu ve diğeri (2007) tarafından yapılan çalışmada, öznitelik çıkartmak için iki aşamalı PCA gerçekleştirilmiş, sonrasında ise “en yakın komşu” temelli bir sınıflandırıcı kullanılarak sonuçlar incelenmiştir [3].

Bhanu ve Lin (2003) tarafından yapılan çalışmada, genetik algoritma temelli bir yöntemle minimum sayıda elemandan oluşan bir öznitelik vektörü oluşturulmaya çalışılmış, sonuçlar bir Bayes sınıflandırıcısı ile incelenmiştir [4].

Ruohong ve Ruliang (2008) tarafından yapılan çalışmada, pikseller için bölütleme kriterini belirleyebilmek amacıyla Markov rastgele alanı modeli kullanılmıştır [5]. Öznitelik çıkartma işlemi için ise Gabor dalgacık (wavelet) dönüşümü kullanılmıştır.

Cheng ve diğeri (2006) tarafından yapılan çalışmada, SAR görüntülerinden öznitelik çıkartmak için, yüz ve el yazısı tanıma işlemlerinde kullanılan çekirdek (kernel) fonksiyonu temelli bir yöntem sunulmuştur [6].

Cui ve diğlerleri (2005) tarafından yapılan çalışmada, SAR görüntüsündeki hedef gölgesi ile hedef üzerindeki saçıcı noktaların süper çözünürlüklü karakterizasyonu kullanılarak, bir öznitelik kümesi oluşturulmuş ve sınıflandırma sonuçları incelenmiştir [7].

Wei ve diğlerleri (2011) tarafından yapılan çalışmada, hem hedef şeklinin, hem de hedef gölgesinin konturu (çevrit) ve şekil nitelikleri kullanılarak öznitelikler çıkartılmıştır [8]. Sınıflandırma aşaması için ise minimum mesafe temelli bir sınıflandırıcı kullanılmıştır.

Papson ve Narayanan (2006) tarafından yapılan çalışmada, görüntü bölütlenerek hedef şekli, arka plan ve hedef gölgesi ayrıştırılmıştır [9]. Daha sonra hedef gölgesinin çevriti, Gizli Markov Modeli (HMM – Hidden Markov Model) ile birlikte kullanılarak sınıflandırma işlemi gerçekleştirilmiştir.

Hou ve diğlerleri (2014) tarafından yapılan çalışmada, SAR görüntülerini bölütlemek için piksel olasılık yoğunluklarına dayalı bir yöntem kullanılmıştır [10]. Her bir piksel ve komşuluğu için istatistiksel veri elde etmek için görüntünün histogramından yararlanılmıştır.

Han ve diğlerleri (2003) tarafından yapılan çalışmada, lineer olmayan bir haritalama (mapping) yöntemi ile öznitelik uzayı daha yüksek boyutlu bir uzaya taşınarak lineer olarak ayrıştırılabilen bir öznitelik dağılımı elde edilmiştir [11]. Sonuçlar SVM ile incelenmiştir.

Yukarıda belirtilen çalışmalardaki sınıflandırılan hedef tipi sayıları, eğitim ve test kümelerindeki görüntü sayılarının oranları, sınıflandırma yöntemleri ve doğru sınıflandırma oranları Çizelge 1.1’de verilmektedir.

Çizelge 1.1. Benzer çalışmalarla ilgili detaylar

İlgili çalışma	Sınıf sayısı	Eğitim kümesi oranı	Test kümesi oranı	Sınıflandırma yöntemi	Doğru sınıflandırma oranı
Hu ve diğerleri (2007) [3]	3	% 37,39	% 62,61	İki aşamalı PCA	% 97,49
Ruohong ve Ruliang (2008) [5]	3	% 33,83	% 66,17	SVM	% 93,11
Cheng ve diğerleri (2006) [6]	3	% 54,28	% 45,72	SVM (Küçük)	% 98,30
Cheng ve diğerleri (2006) [6]	3	% 54,28	% 45,72	SVM (RBF)	% 97,62
Wei ve diğerleri (2011) [8]	3	% 33,83	% 66,17	Minimum Distance	% 94,48
Han ve diğerleri (2003) [11]	3	% 33,83	% 66,17	SVM (Lineer)	% 97,14
Papson ve Narayanan (2006) [9]	5	-	-	HMM	% 91
Yang ve diğerleri (2005) [2]	7	% 66,86	% 33,14	PCA + 3-NN	% 98,67
Yang ve diğerleri (2005) [2]	7	% 66,86	% 33,14	ICA + 3-NN	% 95,14
Yang ve diğerleri (2005) [2]	7	% 50,03	% 49,97	Hu momentleri + 3-NN	% 76,85
Yang ve diğerleri (2005) [2]	7	% 50,03	% 49,97	Hu momentleri + SVM	% 73,69
Cui ve diğerleri (2005) [7]	10	% 37,50	% 62,50	HMM	% 97,50

Bu çalışmada, 5 farklı SAR hedef tipinin ait oldukları sınıfları tespit etmek amacıyla sırasıyla önışleme, öznitelik çıkartma ve sınıflandırma işlemleri gerçekleştirilmiştir. Önışleme aşamasında SAR görüntüleri filtrelerden geçirilerek iyileştirilmiştir. Sonrasında görüntüler bölütlenerek hedef şekli diğer bölümlerden ayrıştırılmıştır. Öznitelik çıkartma aşamasında ise; piksel tabanlı öznitelikler, değiştirilmiş radyal fonksiyon öznitelikleri ve eliptik Fourier betimleyicileri olarak adlandırılan üç kategoride çeşitli öznitelikler çıkartılmıştır. Sınıflandırma aşamasında ise, öznitelik vektörleri çıkartılan SAR görüntüleri, çeşitli sınıflandırıcılar ile test edilmiştir. Görüntüleri sınıflandırmak için üç farklı çekirdek fonksiyonu ile Destek Vektör Makineleri (SVM – Support Vector Machines) sınıflandırıcısı ve k-En Yakın Komşu (k-NN – k-Nearest Neighbors) algoritması kullanılmış ve ortaya çıkan sonuçlar karşılaştırılmıştır.

2. SAR SİSTEMLERİNE GENEL BAKIŞ


Sentetik Açıklıklı Radarlar (SAR), hava platformlarında yeryüzü görüntüleme ve hedef tespiti amacıyla kullanılan radar sistemleridir. Kızılötesi veya optik sensörlerden farklı olarak, gece/gündüz ve her hava koşulunda görüntüleme yapabilme yeteneği nedeniyle askeri alanda sıklıkla kullanılır. Hava platformunun hareketiyle sentetik bir anten genişliği oluşturarak yüksek çözünürlüklü görüntü elde edilmesini sağlamaktadır.

Radar sistemlerinde menzili artırmak için uygulanan yöntemlerden birisi anten açıklığını genişletmektir. Hava platformuna entegre edilecek bir radar sistemi için, antenin fiziksel olarak belli bir boyutun üzerinde büyütülmesi mümkün değildir. SAR sistemleri bu amaca yönelik olarak, anten açıklığını sentetik olarak büyütür. Bahsedilen açıklık, hava platformunun hareket ettirilmesiyle yapay olarak sağlanır (Şekil 2.1) [12]. Platformun belli bir yönde hareket etmesiyle, istenilen uzunlukta radar sinyali gönderilip alınır. Bu sayede toplanan veri, sistem tarafından hareket eksenine boyunca tek bir antenden elde edilmiş gibi değerlendirilir. Toplanan sinyaller, platformun hareketiyle ilgili parametreler göz önünde bulundurularak çeşitli sinyal işleme teknikleriyle yüksek çözünürlüklü görüntülere dönüştürülür.




Şekil 2.1. SAR sistemlerinde sentetik açıklık [12]

SAR sistemleri, antenin tarama şekline göre genel olarak üç farklı modda görev yapar [13]. Radarın, yeryüzeyinden yansıyan elektromanyetik dalgaları hareket istikameti boyunca topladığı duruma "yanal gözlem modu" denir (Şekil 2.2).




Şekil 2.2. SAR yanal gözlem modu (V uçağın hızını temsil etmektedir) [13]

Hareket istikameti boyunca belirli bir bölgeden gelen yansımalara odaklanarak yalnızca bu bölgenin görüntüsünün oluşturulmaya çalışıldığı durum ise "spotlight (noktasal ışık) modu"dur (Şekil 2.3).



Şekil 2.3. SAR spotlight modu [13]

"Tarama modu" ise özellikle yüksek irtifalarda kullanılır. Gözlemlenecek alan sektörlere bölünür ve platform hareket ettikçe, sırasıyla yalnızca ilgili sektöre yayın yapılır (Şekil 2.4).




Şekil 2.4. SAR tarama modu [13]

2.1. Kullanılan Veritabanı


Bu çalışmada ABD Savunma Bakanlığı İleri Savunma Araştırma Projeleri Ajansı (DARPA – Defense Advanced Research Project Agency) ve Hava Kuvvetleri Araştırma Laboratuvarı (AFRL – Air Force Research Laboratory) tarafından genel kullanıma açık olarak yayınlanan MSTAR (Moving and Stationary Target Acquisition and Recognition) SAR veritabanı kullanılmıştır [14]. Literatürde MSTAR veritabanı dışında QinetiQ firması tarafından elde edilmiş bir SAR veritabanı da bulunmaktadır. Ancak hem literatürdeki yaygın kullanımı, hem de genel kullanıma açık olması nedeniyle MSTAR veritabanı tercih edilmiştir.

MSTAR veritabanı, farklı askeri araç tiplerinin çok sayıda SAR görüntüsünü içerir. Görüntüler Sandia Ulusal Laboratuvarı tarafından, X bandında (10 GHz) çalışan STARLOS sensörü kullanılarak “Spotlight SAR” modunda elde edilmiştir. 1 foot x 1 foot (30,48 cm x 30,48 cm) çözünürlükte olan bu görüntüler, 15°, 17°, 30° ve 45° alçalış açılarında (angle of depression) ve 0°-360° arasında çeşitli azimut açılarında çekilmiştir. Bu çalışmada yalnızca 15° ve 17° alçalış açısındaki görüntüler kullanılmıştır.

Alçalış açısı, SAR sistemini taşıyan hava platformu ile hedef arasındaki doğrultu (görüş hattı) ile yatay eksenin yaptığı açıdır (Şekil 2.5). Azimut açısı ise merkez noktası etrafındaki dönüş açısı olarak ifade edilebilir (Şekil 2.6).








Şekil 2.5. Alçalış açısı




Şekil 2.6. Azimut açısı

MSTAR veritabanında bulunan ve bu çalışmada kullanılan hedef tiplerinin örnek görüntüleri Çizelge 2.1’de verilmektedir.

Çizelge 2.1. MSTAR veritabanındaki hedef tiplerinin örnek görüntüleri [14]

Hedef	Tip	Optik Görüntüsü	SAR Görüntüsü
2S1	Obüs		
BTR-60	Zırhlı personel taşıyıcı		
D7	Askeri buldozer		
ZIL-131	Askeri kamyon		
ZSU-23-4	Uçaksavar top sistemi		

Kullanılan veritabanında ayrıca her bir hedef tipinin 360 derece boyunca çeşitli azimut açılarında çekilmiş görüntüleri mevcuttur. 2S1 obüsü için 15° alçalış açısında kaydedilmiş SAR görüntülerinin, azimut açısı 0° ile 90° arasında olan kısmı Şekil 2.7’de verilmiştir.



Şekil 2.7. 2S1 hedefinin farklı azimut açılarındaki SAR görüntüleri


3. SAR HEDEFLERİNİN SINIFLANDIRILMASI

Nesne tanıma/sınıflandırma işlemlerinde öncelikle eldeki ham görüntünün çeşitli görüntü işleme yöntemleri kullanılarak, uygulanacak olan öznitelik çıkartma algoritmasına uygun hale getirilmesi gerekir. Bu işlemler aşındırma (erosion), yayma (dilation), açma (opening), kapama (closing) gibi morfolojik görüntü işleme teknikleri olabileceği gibi, frekans alanında uygulanacak işlemler de olabilir. Tüm bu işlemlerin temel amacı, verideki gürültüyü ortadan kaldırmaktır. Böylece öznitelik çıkartma ve sınıflandırma aşamalarına geçildiğinde, gürültüden mümkün olduğunca arındırılmış bir veri kümesi üzerinden işlemler gerçekleştirilmiş olur. Bu amaçla gerçekleştirilen işlemler, “önişleme” olarak adlandırılır.

Önişleme aşamasından geçirilerek iyileştirilmiş olan görüntü, içerisindeki ayırt edici bilgilerin tespit edilmesi amacıyla öznitelik çıkartma işlemine sokulur. Buradaki temel amaç, ilgili sınıfı diğer sınıflardan farklı kılan, ayırtıcı veriyi ortaya çıkartmaktır. Çünkü görüntü her ne kadar önişleme aşamasından geçirilerek gürültüden arındırılmış olsa da, içerisinde hala sınıflandırma açısından gereksiz, katkı sağlamayacak kısımlar barındırır. Sınıflandırmaya herhangi bir katkısı olmayacak veya olumsuz etkisi olacak olan veri ortadan kaldırılarak, görüntüdeki ayırt edici kısımlar bırakılmalıdır. Bu amaçla gerçekleştirilen işlemler “öznitelik çıkartma” olarak adlandırılır.

Görüntüdeki öznitelikler çıkartıldıktan sonra, bu özniteliklerin oluşturduğu öznitelik vektörleri kullanılarak sınıflandırma işlemi gerçekleştirilir. Temel olarak, bir test görüntüsünün öznitelik vektörü, her bir sınıftaki eğitim (training) görüntüleri kullanılarak ortaya çıkarılmış olan o sınıfa ait öznitelik matrisi ile karşılaştırılır. Böylece, ilgili sınıfa ne kadar yakınsadığına, benzediğine bakılır. Bu şekilde; test görüntüsünün öznitelik vektörü, tüm sınıfların öznitelik matrisleri ile karşılaştırılarak en çok hangi sınıfa benzediği tespit edilerek sınıflandırma işlemi gerçekleştirilmiş olur.

Bu çalışmada SAR görüntülerindeki hedeflerin tanınması/sınıflandırılması amacıyla Şekil 3.1’de belirtilen işlemler gerçekleştirilmiştir.



Şekil 3.1. Hedef tanıma/sınıflandırma için uygulanan işlemler


3.1. Önişleme

Yüksek bir sınıflandırma oranı yakalayabilmek için öncelikle ham görüntü iyileştirilmelidir. Görüntü üzerindeki gürültü ortadan kaldırılmalı ve görüntü bölütlenerek (segmentation) öznitelik çıkartma işlemine hazır hale getirilmelidir.

3.1.1. Gürültü azaltma ve görüntünün iyileştirilmesi

SAR sistemleri kullanılarak yüksek çözünürlüklü görüntü elde edilebilmesine rağmen, bu sistemlerde bir dezavantaj olarak “benek gürültüsü” (speckle noise) oluşur (Şekil 3.2). SAR görüntülerinde 1 piksel ile ifade edilen çözünürlük hücresinin temsil ettiği yeryüzeyi, radarın sentetik açıklığına ve frekansa bağlı olarak birkaç santimetre ile onlarca metre arasında değişkenlik gösterebilir. SAR sisteminin görüntüye dönüştürerek 1 piksel ile ifade


etmeye çalıştığı yeryüzeyinin ilgili kısmının dümdüz bir zemin olma ihtimali çok yüksek değildir. Bu nedenle sistemin bir pikseli, görüntülenmek istenen yeryüzeyinin tüm detaylarını çözemeyebilir. İlgili pikselde, yüzeyden yansıyan elektromanyetik enerji, homojen olmayan farklı saçıcılardan yansıdığı için farklı faz değerlerine sahip olacaktır. Bu da o piksel için benekli bir görüntü oluşmasına neden olur ve bu durum “benek gürültüsü” olarak adlandırılır [13].



Şekil 3.2. SAR sisteminde benek gürültüsü [15]

Bu çalışmada, hedef tanımayı zorlaştıran benek gürültüsünün azaltılması için “ortalama filtresi” (averaging filter) kullanılmıştır. Bu yöntemde, öncelikle N tek sayı olmak üzere $N \times N$ boyutunda bir filtre maskesi oluşturulur. Daha sonra görüntüdeki her bir piksel değeri, bu filtre maskesi ile tanımlanan alandaki piksellerin ortalama değeriyle değiştirilir [16]. Bu çalışmada filtre maskesinin boyutu 3×3 olarak seçilmiş, böylece her bir piksel değeri, merkezinde bulunduğu 3×3 'lük çerçevedeki piksellerin değerlerinin ortalamasıyla değiştirilmiştir. Böylece benek gürültüsünün neden olduğu keskin geçişler azaltılmış, bu geçişler daha yumuşak hale getirilmiştir.

Şekil 3.3'te ZSU-23-4 uçaksavarının örnek bir görüntüsü ile üzerine ortalama filtresi uygulanması sonucu elde edilen görüntü verilmektedir.



Şekil 3.3. a) ZSU-23-4 hedefinin önışleme yapılmamış SAR görüntüsü b) Görüntünün ortalama filtresi uygulandıktan sonraki hali


Şekil 3.3'te görüldüğü gibi orijinal görüntüdeki benek gürültüsünün belirginliği, ortalama filtresi uygulandıktan sonra azalmış, piksel değerleri görüntünün tamamı için hesaplanabilecek ortalama piksel değerine yaklaşmıştır. Böylece daha yumuşak geçişlere sahip bir görüntüye ulaşılmıştır.

3.1.2. Bölütleme (Segmentation)

Bu çalışmada kullanılan SAR görüntüleri temel olarak üç kısımdan oluşmaktadır. Bunlar hedef, hedefin gölgesi ve arka plandır. Sınıflandırma işlemi için ayrıştırıcı bilgiyi içeren kısım üzerinden işlem yapmak gerekir. Bu nedenle görüntüyü oluşturan bu üç kısımdan, sınıflandırma başarımına katkı sağlayacak olan kısımlar seçilmelidir.


Bu çalışmada öznitelik çıkartma aşamasında görüntünün yalnızca hedefi içeren kısmı üzerinden işlemler gerçekleştirilmiştir. Arka plan görüntüsü yüksek miktarda benek gürültüsü içermekte ve tüm hedef tiplerinde benzerlik göstermektedir. Ayrıştırıcı bir özelliği bulunmadığından dolayı sınıflandırma işlemine herhangi bir katkı sağlamayacaktır. Hedefin gölgesini içeren kısım ise, literatürdeki bir takım çalışmalarda kullanılmış olsa da, bu çalışma kapsamında öznitelik çıkartma işleminde kullanılmamıştır. Hedefi içeren kısım ise, farklı hedef tiplerinde farklılık göstermekte ve esas ayrıştırıcı veriyi üzerinde barındırmaktadır. Bu nedenlerden dolayı, görüntüdeki hedef bölgesi bölütlenerek, gölge ve arka plan kısımlarından ayrıştırılarak öznitelik çıkartma işlemine geçilecektir.

Üzerindeki gürültü azaltılmış ve iyileştirilmiş görüntü üzerinde sırasıyla Şekil 3.4'te verilen işlemler uygulanarak hedef bölgesi ayrıştırılmıştır.



Şekil 3.4. Bölütleme işlemi akış şeması

Kullanılan MSTAR veritabanındaki SAR görüntülerinde, hedef bölgeleri genellikle yüksek parlaklığa sahip piksellerden oluşmaktadır. Parlak pikselleri ayırtmak, hedef bölgesi ile ilgili bilgi verecektir. Bu amaçla öncelikle eşikleme işlemi gerçekleştirilmiştir. Görüntüdeki piksel değerleri büyükten küçüğe doğru sıralanmıştır. Daha sonra, görüntüdeki toplam piksel sayısı N ile ifade edilirse, en yüksek parlaklığa sahip $N \times 0,20$ adet piksel tespit edilmiştir. Böylece görüntüdeki piksellerden en parlak %20'sinin koordinatı elde edilir. Görüntüdeki piksellerden en parlak %20'sine, beyazı temsil eden 255 değeri atanır. Bu çalışmada kullanılan görüntüler için, %15 ile % 30 arasındaki değerler denenerek, en iyi sonucu veren %20 seçilmiştir. Geri kalan piksellere ise siyahı temsil eden 0 değeri verilir. Böylece ilk başta gri ölçekli olan görüntü, siyah-beyaz görüntüye dönüşmüş olur. Ayrıca görüntüdeki hedef bölgesinin dışında kalan birçok kısım elenmiş olur (Şekil 3.5) [17].



a.




b.

Şekil 3.5. a) Önişlemeden geçirilmiş görüntü b) En parlak $N \times 0,20$ adet pikselin tespit edilmesi

Şekil 3.5'te görüldüğü gibi, eşikleme işlemi sonrasında, hala hedef bölgesine ait olmayan ve ayıklanması gereken pikseller bulunmaktadır. Hedef bölgesine ait olmayan pikseller tespit edilerek siyaha çevrilmelidir.

Bunun için piksellerin komşuluk (neighborhood) bilgileri kullanılmıştır. Şekil 3.5.(b)'de verilen görüntüde beyaz piksellerden oluşan birçok küme bulunmaktadır. Öncelikle bu kümelerden komşuluk sayısı 8'den düşük olanlar tespit edilerek, piksel değerleri 0'a çevrilmiştir. Böylece birbirine komşu olan en az 8 beyaz piksele sahip olmayan, yani küçük bir alana sahip olan kümeler, hedef bölgesi olamayacağı için ortadan kaldırılmıştır. Daha sonra ise geriye kalan beyaz piksel kümeleri arasından en büyük alana sahip olan küme tespit edilerek, geri kalan kümelerdeki piksel değerleri 0'a çevrilmiştir. Böylece görüntüdeki hedef bölgesi dışındaki tüm kısımlar siyaha çevrilerek bölütleme işlemi gerçekleştirilmiştir (Şekil 3.6).



Şekil 3.6. Şekil 3.3'teki görüntünün bölütlenmesiyle ortaya çıkan hedef bölgesi

3.2. Öznitelik Çıkartma

Öznitelik çıkartma, temel olarak bir örüntüdeki ayırt edici veriyi içeren alt kümelerin tespit edilmesi işlemidir. Bu işlem sonucunda sınıflandırma açısından gereksiz olan veri ortadan kaldırılmış, üzerinde işlem yapılacak olan örüntünün boyutu küçültülmüş ve sonuç olarak örüntünün karmaşıklığı azaltılmış olur.

Bu çalışmada kullanılan öznitelikler üç kategoriye ayrılabilir;

- Piksel Tabanlı Öznitelikler
- Değiştirilmiş Radyal Fonksiyon Öznitelikleri
- Eliptik Fourier Betimleyiciler

3.2.1. Piksel tabanlı öznitelikler


Piksel tabanlı öznitelikler; piksel yoğunlukları, piksellerin geometrik yerleşimi ve istatistiksel hesaplamalar kullanılarak oluşturulan öznitelik vektörlerinden oluşur. Bu tip öznitelikler görüntü tanıma uygulamalarında sıklıkla kullanılır. Piksel tabanlı öznitelikler, şeklin tanımlanmasında ve ayırt edici kısımlarının tespitinde başarılı sonuçlar vermektedir. Özellikle içerisinde keskin geçişler bulunan görüntülerde, piksel tabanlı öznitelikler yüksek oranda başarımlar sağlar.

Bu çalışmada 7 farklı piksel tabanlı öznitelik kullanılmıştır;

- Dikdörtgensellik
- Kenar oranı
- Eksen oranı
- Dışbükeylik
- Dışmerkezlik
- Ortalama
- Çarpıklık

Dikdörtgensellik

Dikdörtgensellik (rectangularity), toplam hedef alanının, bu alanı içersine alabilen en küçük dikdörtgenin alanına oranı olarak hesaplanmıştır. Bu öznelik, hedefin azimut açısından bağımsızdır. Bu nedenle aynı hedef tiplerinde benzer dikdörtgensellik değerinin elde edilmesi beklenir [18]. Şekil 3.7’de kullanılan veritabanındaki örnek hedeflerden birinin dikdörtgenselliğinin belirlenmesi için oluşturulan geometrik alan gösterilmiştir.




Şekil 3.7. Hedef alanını kapsayan en küçük dikdörtgen

Kenar oranı

Kenar oranı, dikdörtgensellik özneliğine benzer şekilde hesaplanır. Hedef alanı içersine alabilen en küçük dikdörtgenin uzun kenarının kısa kenarına oranıdır (Bkz. Şekil 3.7).

Eksen oranı

Düzlemde verilen iki noktaya uzaklıkları toplamı sabit olan noktaların geometrik yerine elips denir ve bu iki nokta elipsin odaklarıdır. Odakların yer aldığı eksen asal eksen olarak adlandırılır. Asal eksenı dik kesen ve merkez noktasından geçen eksen ise yedek eksendir. Şekil 3.8’de verilen elipsin odak noktaları F_1 ve F_2 , asal eksenı $|AA'|$ doğru parçası, yedek eksenı ise $|BB'|$ doğru parçasıdır.



Şekil 3.8. Herhangi bir elipsin odak noktaları, asal ve yedek eksenleri

Bu çalışmada, ikinci merkezselsel momentleri hedef şekli ile aynı olan elipsin eksen bilgileri öznitelik çıkartma işleminde kullanılmıştır. Olasılık kuramında merkezselsel moment, rassal bir değişkenin ortalaması etrafındaki olasılık dağılımının momentini ifade eder. Birçok kullanım alanı bulunan merkezselsel momentler, görüntü işleme uygulamalarında piksel yoğunluk dağılımlarını ele alarak ilgili şekli yorumlamak için kullanılır. Merkezselsel momentler kullanılarak bir şeklin merkezi, yönelimi, toplam alanı gibi çeşitli bilgilere ulaşılabilir [19].

$p, q = 0, 1, 2, \dots$ olmak üzere, 2-boyutlu $f(x, y)$ fonksiyonunun $(p+q)$. dereceden momentleri olan M_{pq} , Eş. 3.1 ile hesaplanır.

$$M_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^p y^q f(x, y) dx dy \quad (3.1)$$

Eş. 3.1, $I(x, y)$ piksel yoğunluk fonksiyonuna sahip gri ölçekli bir görüntü için uyarlandığında, ilgili görüntünün $(i+j)$. dereceden momentleri (M_{ij}) Eş. 3.2'deki gibi ifade edilir.

$$M_{ij} = \sum_x \sum_y x^i y^j I(x, y) \quad (3.2)$$


Görüntünün $(p+q)$. dereceden merkezselsel momentleri (μ_{pq}) ise Eş. 3.3'te verilen şekilde elde edilir.

$$\mu_{pq} = \sum_x \sum_y (x - \bar{x})^p (y - \bar{y})^q f(x, y) \quad (3.3)$$

Eş. 3.3'te $\bar{x}$ ve $\bar{y}$ şeklin merkezini ifade eder ve Eş. 3.4'teki gibi tanımlanır.

$$\bar{x} = \frac{M_{10}}{M_{00}} \quad \bar{y} = \frac{M_{01}}{M_{00}} \quad (3.4)$$


Bu çalışmada; ikinci merkezsiz momentleri hedef şekli ile aynı olan elipsin, asal ekseninin uzunluğunun yedek ekseninin uzunluğuna oranı “eksen oranı” olarak isimlendirilmiş ve öznelilik vektörüne eklenmiştir. Örneğin, Şekil 3.8'de verilen elipsin eksen oranı $|AA'|/|BB'|$ olarak ifade edilir. Şekil 3.9'da ise Şekil 3.6'daki görüntünün üzerine çizilen elips ile asal ve yedek eksenleri gösterilmiştir.



Şekil 3.9. Görüntü üzerine yerleştirilmiş elips ve ona ait asal ve yedek eksenler

Dışbükeylik

Dışbükeylik (convexity) özneliliği, hedef alanının, bu alanı içersine alan en küçük dışbükey şeklin alanına oranı hesaplanarak elde edilir. Dışbükeylik, dikdörtgensellik özneliliğinden farklı olarak, hedef şeklini birçok eğriden oluşan bir poligon ile kapsadığından, bölge içersindeki yerel farklılıkları daha detaylı temsil eder [18]. Şekil 3.10'da, örnek hedeflerden birinin dışbükeylik özneliliğinin belirlenmesi için oluşturulan geometrik alan gösterilmiştir.



Şekil 3.10. Hedef alanını kapsayan en küçük dışbükey alan

Dışmerkezlik

Bir elipsin dışmerkezliği (eccentricity), odak noktaları arasındaki uzaklığın, asal eksenin uzunluğuna olan oranıdır. Elipsin uzama (elongation) seviyesini ifade eder. Şekil 3.8’de yer alan elipsin dışmerkezliğinin hesaplanması, Eş. 3.5’te verilmiştir. Bu çalışmada, ikinci merkezsiz momentleri hedef bölgesi ile aynı olan elipsin dışmerkezliği öznitelik olarak kullanılmıştır.

$$Dışmerkezlik = e = |F_1F_2| / |AA'| \quad (3.5)$$

Ortalama

Görüntüdeki piksellerin ortalama değeridir. Hedefin azimut açısından bağımsızdır. (i,j) piksel koordinatları, $x_{i,j}$ piksel değerleri ve N toplam piksel sayısı olmak üzere, görüntünün ortalama değeri Eş. 3.6 ile elde edilir.


$$\mu = \frac{\sum_{i,j} x_{i,j}}{N} \quad (3.6)$$

Gri ölçekli veya RGB (Red-Green-Blue – Kırmızı-Yeşil-Mavi) resimlerde, ortalama değeri aynı nesne için görüntünün parlaklığı, yönelimi, ortamın aydınlığı gibi etkenlere göre değişkenlik gösterir. Ancak bu çalışmada öznitelik çıkartma aşamasından önce, mevcut görüntü ön işlemeden sonra siyah-beyaz hale çevrildiğinden, bu tip etkenler ortalama değerini değiştirmemektedir.

Görüntü siyah-beyaz olduğundan ve piksel değerleri 0 ya da 255 olduğundan, varyans değeri yüksektir. Bu durumda ortalama değeri aslında hedef alanının büyüklüğüyle ilgili bilgi vermektedir. Örneğin, siyah-beyaz bir görüntüde hedef büyüklüğü arttıkça, 255 değerine sahip, yani beyaz piksellerin sayısı artacak, buna bağlı olarak ortalama değeri de artacaktır. Yani ortalama değeri, hedefin kapladığı alan büyüdükçe 255'e, küçüldükçe 0'a yakınsayacaktır.

Çarpıklık

Çarpıklık (skewness), bir görüntüdeki piksel dağılımının asimetrisini gösterir. Piksel dağılımının düşük değerlerde yoğunlaştığı bir görüntü pozitif çarpıklığa sahipken, dağılımın yüksek değerlerde yoğunlaştığı bir görüntü negatif çarpıklığa sahiptir (Şekil 3.11) [20]. Çarpıklık Eş. 3.7 ile tanımlanır.



Şekil 3.11. a) Negatif çarpıklık b) Pozitif çarpıklık

$$\text{Çarpıklık} = \frac{\sum_i \sum_j (x_{i,j} - \mu)^3}{(n - 1)\sigma^3} \quad (3.7)$$

Eş. 3.7'de, i ve j piksel koordinatlarını, $x_{i,j}$ piksel değerlerini, μ ortalamayı, σ standart sapmayı ve n toplam satır sayısını ifade etmektedir.


Bu çalışmada, ön işlemeden geçirilerek siyah-beyaz hale dönüştürülmüş görüntünün çarpıklık değeri öznel olarak kullanılmıştır. Kullanılan görüntülerde arka plan genellikle hedef alanından daha büyüktür. Yani görüntülerdeki siyah pikseller, genellikle beyaz piksellerden daha fazladır. Bu durumda piksel dağılımları 0 değerine yakın kısımda yoğunlaşmış ve siyah piksel sayısı beyaz piksel sayısından daha fazla olduğu sürece her

görüntüde pozitif çarpıklık değeri elde edilmiştir. Çarpıklık değerinin 0'a ne kadar yakınsadığı bilgisi, hedef sınıflandırma işlemine öznitelik olarak katkı sağlayacaktır.

3.2.2. Değiştirilmiş radyal fonksiyon


Nesne tanıma problemlerinde, şeklin yöneliminin önem arz ettiği durumlarda, şekil konturunu (çevritini) Kartezyen koordinat sisteminde ifade etmek yeterli olmayabilir. Çünkü Kartezyen koordinat sisteminde konturun belirli bir noktasiyla ilgili herhangi bir açı bilgisi mevcut değildir. Bu nedenle şeklin açısai konumunu tam olarak yansıtamaz. Ayrıca kontur üzerinden işlem yaparken Kartezyen koordinat sistemini kullanmanın bir diğer dezavantajı da ölçeklendirmeye bağımlı olmasıdır. Yani, bir şeklin kontur bilgisinin Kartezyen koordinat sistemindeki ifadesi ile aynı şeklin bir miktar büyütölmüş halinin ifadesi aynı değildir. Şekil aynı örüntüye sahip olmasına rağmen, ölçeklendirme sonucunda farklı sonuçlar elde edilir.

Kartezyen koordinat sistemine bir alternatif gösterim radyal gösterimdir. Radyal gösterimde bir şeklin konturu, seçilen bir referans noktasından başlayan vektörlerle taranır. Vektörler referans noktasına göre eşit açılarla kaydırılarak, konturu kesen vektörler kümesi elde edilir. Böylece şeklin sınır noktaları kutupsal (polar) formda $r(\phi)$ şeklinde tanımlanan bir fonksiyonla ifade edilmiş olur. Burada r kontur üzerindeki noktanın referans noktasına olan uzaklığını, ϕ ise referans noktasından başlayıp kontur üzerindeki kesişim noktasına kadar uzanan vektör ile referans eksen arasındaki açıyı ifade eder (Şekil 3.12). Böylece şeklin konturu yönelimden bağımsız hale gelmiş olur. Radyal gösterim yöntemi birçok uygulamada kullanılır [21-22].



Şekil 3.12. Şekil konturunun (mavi) radyal fonksiyonunun bulunması

Ancak radyal gösterim, r vektörünün elemanları bulunurken çizilen doğruların şeklin konturunu birden fazla noktada kestiği durumlarda dezavantaj oluşturur. Referans eksenden başlatılarak eşit açılarla ilerlenerek çizilen doğrular, herhangi bir açıda şeklin konturunu birden daha fazla noktada kesebilir (Şekil 3.13). Böyle bir durumda $r(\phi)$ fonksiyonu o nokta için birden çok değer üretir ve radyal gösterim şeklin konturunu doğrudan ifade edememiş olur.



Şekil 3.13. Radyal fonksiyon tarafından bir açı için birden çok değer üretildiği durum

Bu duruma karşı, Tieng ve Boles (1997) tarafından Değiştirilmiş Radyal Fonksiyon (Modified Radial Function – MRF) önerilmiştir [23]. MRF’de, radyal gösterimin aksine vektörler eşit açılarla kaydırılmaz. Açılar sabit tutmak yerine, doğrular kontur üzerinde eşit yay uzunlukları ile ilerlenecek şekilde çizilerek, kontur üzerindeki ilerleme miktarı

sabit tutulur. Örneğin, $r(\alpha)$ doğrusunun konturu kestiği nokta P_1 , $r(\beta)$ doğrusunun konturu kestiği nokta P_2 , P_1 noktasından P_2 noktasına kontur takip edilerek ilerlendiğinde katedilen mesafe ise D olarak tanımlansın. Konturu kesen bir sonraki doğru olan $r(\phi)$ doğrusunun konturu kestiği nokta da P_3 olarak tanımlansın. Bu durumda, P_2 noktasından P_3 noktasına kontur takip edilerek ilerlendiğinde katedilen mesafe de D uzunluğunda olacaktır.

MRF’de şeklin konturu; birbirleri arasındaki yay uzunluğu eşit olacak şekilde, belirlenen sayıda örneklem noktasına bölünür. Daha sonra referans noktasından başlayıp, kontur üzerinde eşit uzaklıktaki bu örneklem noktalarını keserek sonlanan doğrular oluşturulur. MRF’de böylece r parametresine ek olarak, örneklem arasındaki yay uzunluğunu temsil eden l parametresi de oluşturulmuş olur. Şeklin konturu üzerindeki her bir örneklem noktası $x(l)$ ve $y(l)$ ikilileri ile gösterilir. x_0 ve y_0 referans noktasının koordinatlarını temsil edecek şekilde tanımlandığında,

$$\hat{x}(l) = x(l) - x_0, \quad \hat{y}(l) = y(l) - y_0 \quad (3.8)$$

elde edilir. Bu parametreler kullanıldığında şeklin MRF’si Eş. 3.9’daki gibi $r(l)$ fonksiyonu ile tanımlanır. Buna bağlı olarak açısı fonksiyon $\alpha(l)$ ise Eş. 3.10’daki gibi elde edilir.

$$r(l) = \sqrt{\hat{x}(l)^2 + \hat{y}(l)^2} \quad (3.9)$$

$$\alpha(l) = \arctan\left(\frac{\hat{y}(l)}{\hat{x}(l)}\right) \quad (3.10)$$

Bu çalışmada Eş. 3.10’da verilen açısı fonksiyon, sınıflandırma performansına herhangi bir katkı sağlamadığı gözlemlendiğinden, öznitelik olarak kullanılmamıştır.


MRF hesaplanırken referans noktasının, hedef bölgesinin kütle merkezi olarak seçilmesi, işlemi ötelemeden (translation) bağımsız hale getirir [23]. Bu nedenle bu çalışmada MRF hesaplanırken referans noktası hedef şeklin kütle merkezi olarak alınmıştır. Yani, örneklem noktalarının hedef şeklin kütle merkezine olan Öklid mesafesi hesaplanarak MRF elde edilmiştir.

Kullanılan MSTAR veritabanındaki hedef görüntüleri, 0° ile 360° arasında farklı azimut açılarına sahiptir. Açısal bağımlılığı ortadan kaldırmak için, MRF hesaplamaya hep aynı örneklem noktasından başlanmalıdır. Bu sebeple öncelikle hedef şekli ile ikinci merkezsel momentleri aynı olan elipsin, asal eksenini elde edilmiştir. Sonrasında, asal eksenin yukarı doğrultusunda konturu kestiği nokta başlangıç noktası olarak seçilmiş ve MRF bu noktadan hesaplanmaya başlanmıştır. Asal eksen konturu kesmiyorsa, asal eksenin yukarı ucuna en yakın kontur noktası başlangıç noktası olarak kabul edilmiştir. Böylece tüm görüntülerde asal eksen referans alınmış olur. Bu durum her bir SAR görüntüsünün MRF'sinin yerleştiği eksenler arasındaki açısal belirsizliği 360° 'den 180° 'ye düşürmektedir.


MRF'nin en önemli özelliğinin, konturu eşit yay uzunluklarıyla taraması olduğu önceki paragraflarda belirtilmiştir. Ancak, görüntülerdeki piksel koordinatları tam sayılardan oluşur. Bir örneklem noktasından, kontur takip edilerek belirlenmiş yay uzunluğu kadar ilerlendiği zaman, bu nokta tam sayıdan oluşan bir koordinata denk gelmiyorsa, herhangi bir piksele erişilemez. Bu durumun önlenmesi ve sabit yay uzunluğunun her koşulda sağlanabilmesi için, lineer enterpolasyon yöntemiyle kontur üzerinde aslında var olmayan piksel koordinatlarına sözde-koordinat (pseudo-koordinat) noktaları eklenmiştir. Böylece kontur üzerindeki bir örneklem noktasından, sabit bir yay uzunluğu kadar ilerlendiği zaman, sözde-koordinat noktasına varılacak, bu noktanın referans noktasına olan Öklid mesafesi hesaplanarak MRF elde edilecektir.

MRF hesaplanırken, konturu temsil edecek uygun sayıda örneklem seçilmesi önemli bir kriterdir. Küçük bir örneklem sayısı, konturun detaylarının temsil edilememesine neden olur. Örneklem sayısını büyük seçmek ise konturun detaylı bir şekilde ifade edilmesini sağlar. Ancak örneklem sayısını belirli bir eşik değerinin üzerine çıkarmanın, sınıflandırma performansına olumsuz etkisi olduğu da gözlemlenmiştir. Bunun sebebinin ise, örneklem sayısı çok büyük seçildiğinde, SAR görüntülerindeki gürültüden kaynaklanan ve ayrıştırıcı özelliği bulunmayan verilerin de MRF'ye dahil olması olarak değerlendirilmiştir. Bu anlamsız veriler, aynı hedef sınıfındaki görüntülerde bile farklılık göstermektedir. Optimum örneklem sayısını belirlemek için yapılan iteratif analizler sonucunda, en yüksek sınıflandırma oranına örneklem sayısı 32 olarak seçildiği zaman ulaşıldığı görülmüştür.

Hedef şeklinin konturu üzerinde lineer enterpolasyon yapılarak 32 adet eş mesafeli örneklem noktası alınmıştır. Her bir örneklem noktası için, o nokta ile şeklin kütle merkezi arasındaki Öklid mesafesi hesaplanarak MRF elde edilmiştir (Şekil 3.14). Böylece ilgili şekil için 32x1 boyutunda bir MRF vektörü oluşmuştur. Son olarak ölçekten bağımsızlığı (scale invariance) sağlamak amacıyla MRF vektörü, vektörün ortalama değerine bölünerek normalize edilmiştir [24]. Şekil 3.15'te Şekil 3.6'daki hedef şeklin normalize edilmiş MRF'si gösterilmiştir.



Şekil 3.14. Örneklem noktalarıyla merkez arasında çizilen doğrular (kırmızı)



Şekil 3.15. Şekil 3.14’te verilen görüntünün MRF’si

MRF’ye Ayırık Kosinüs Dönüşümü (DCT) uygulanması


SAR görüntüsünün normalize edilmiş MRF’si elde edildikten sonra, Ayırık Kosinüs Dönüşümü (Discrete Cosine Transform – DCT) işlemi uygulanmıştır. DCT, sonlu bir sinyali farklı frekanslarda salınım gösteren kosinüs sinyallerinin toplamı olarak ifade eder. Bir sinyale DCT uygulandığında, sinyalle ilgili bilgi verici çoğu bileşen birkaç katsayıda yoğunlaşır. Bu sebeple, bir sinyaldeki ayrıştırıcı verilerin çoğu, kısıtlı miktardaki DCT katsayısı ile temsil edilebilir [25-26].

Bir $x[n]$ sinyalinin DCT’si Eş. 3.11’deki gibi tanımlanır.

$$y[k] = w[k] \sum_{n=1}^N x[n] \cos\left(\frac{\pi(2n-1)(k-1)}{2N}\right), \quad k = 1, 2, \dots, N \quad (3.11)$$

$$w[k] = \begin{cases} \frac{1}{\sqrt{N}}, & k = 1 \\ \sqrt{\frac{2}{N}}, & 2 \leq k \leq N \end{cases} \quad (3.12)$$

DCT işleminin, bir sinyalin enerjisini küçük katsayılarda toplama özelliği kullanılarak, kontur sinyalinin boyutluluğunun (dimensionality) küçültülmesi amaçlanmıştır. Enerjinin çoğunun yoğunlaştığı küçük DCT katsayıları kullanılarak öznitelik vektörünün daha küçük boyutta olması sağlanmıştır. Şekil 3.16’da görüldüğü gibi, MRF sinyalinin DCT’si alındığında, küçük katsayılar enerjinin çoğunluğunu barındırmaktadır.



Şekil 3.16. Şekil 3.15’te verilen MRF sinyalinin DCT’si

Elde edilen DCT sinyalinin kaç adet katsayısının kullanılacağını belirlemek için iteratif bir şekilde farklı DCT katsayısı adetlerine göre sınıflandırma işlemi gerçekleştirilmiştir. Bu analizin sonucunda en yüksek sınıflandırma performansına 21 adet DCT katsayısı kullanıldığında ulaşılmıştır.

3.2.3. Eliptik Fourier betimleyicileri

Eliptik Fourier Betimleyicileri (Elliptic Fourier Descriptors – EFD) yönteminde, kapalı bir konturu tanımlamak için harmonik olarak ilişkili elipsler kullanılır [27]. Çevresi L olan, 2-boyutlu kapalı bir konturda, herhangi bir p noktası ile s noktası arasındaki yay uzunluğu l ile gösterilsin. Bu durumda p noktasının Kartezyen koordinatları l ’nin bir fonksiyonu olarak $X(l)$ ve $Y(l)$ olarak tanımlanır. $t=2\pi l/L$ olarak tanımlandığında, $X(l)$ ve $Y(l)$ periyodik fonksiyonları Eş. 3.12-13’te gösterildiği gibi bir Fourier açılımıyla ifade edilebilir [28].

$$\begin{bmatrix} X(t) \\ Y(t) \end{bmatrix} = \begin{bmatrix} a_0 \\ c_0 \end{bmatrix} + \sum_{k=1}^{\infty} F_k \begin{bmatrix} \cos(kt) \\ \sin(kt) \end{bmatrix} \quad (3.12)$$

$$F_k = \begin{bmatrix} a_k & b_k \\ c_k & d_k \end{bmatrix} \quad (3.13)$$

$k=0,1,2,3,\dots$, olarak tanımlandığında, F_k betimleyicileri Eş. 3.14-16'daki gibi hesaplanır.


$$a_0 = \frac{1}{2\pi} \int_0^{2\pi} X(t) dt \quad c_0 = \frac{1}{2\pi} \int_0^{2\pi} Y(t) dt \quad (3.14)$$

$$a_k = \frac{1}{\pi} \int_0^{2\pi} X(t) \cos(kt) dt \quad b_k = \frac{1}{\pi} \int_0^{2\pi} X(t) \sin(kt) dt \quad (3.15)$$

$$c_k = \frac{1}{\pi} \int_0^{2\pi} Y(t) \cos(kt) dt \quad d_k = \frac{1}{\pi} \int_0^{2\pi} Y(t) \sin(kt) dt \quad (3.16)$$

Her bir F_k betimleyicisi a_k , b_k , c_k ve d_k olmak üzere dört adet katsayıdan oluşur. Seri açılımında F_0 betimleyicisi konturun merkezine denk gelir ve a_0 ile c_0 katsayıları bu noktanın x ve y koordinatlarını temsil eder. b_0 ve d_0 katsayıları her zaman sifıra eşittir.

Görüldüğü gibi her bir F_k betimleyicisi bir elipsi ifade eden matristir. Konturun geriçatımı, $[\cos(kt) \sin(kt)]^T$ fazörlerinin çakıştırılmasıyla (superposing) ve Eş. 3.14-16'nın $[0,2\pi]$ aralığı için hesaplanmasıyla mümkün olur. Her bir fazör bir katsayı matrisine denk gelir ve harmonik numarası olan k ile orantılı olarak eğim yapar. Eğim yaparken, asal ve yedek eksenleri a_k , b_k , c_k ve d_k katsayılarıyla belirlenen elipsin sınırını tarar (Şekil 3.17) [29].



Şekil 3.17. a) Şekil konturu b) Konturun EFD yöntemiyle geriçatımı [29]

Özetle, EFD ile herhangi bir kapalı kontur, her biri bir elipsi tarayan ve simultane olarak eğim yapan fazörlerin üst üste bindirilmesi şeklinde tanımlanır. EFD'nin avantajı, az sayıda betimleyici kullanılsa bile hedef şeklini başarılı bir şekilde yansıtmasıdır [30].

Bu çalışmada, farklı sayıda eliptik Fourier betimleyiciler kullanılarak sınıflandırma performansı incelenmiştir. Bu incelemeler sonucunda en yüksek sınıflandırma performansına iki adet eliptik Fourier betimleyici öznitelik olarak kullanıldığında ulaşıldığı gözlemlenmiştir. Yukarıda bahsedildiği gibi her bir betimleyici dört adet katsayıdan oluşur. Ancak ilk betimleyici F_0 konturun merkezine denk gelmekte ve bu nedenle iki adet katsayısı görüntüden bağımsız olarak her zaman sıfır değerini almaktadır. Bu nedenle F_0 betimleyicisinden iki adet katsayı gelmektedir. Böylece F_0 betimleyicisinden iki, F_1 betimleyicisinden dört adet olmak üzere, toplam altı adet katsayı öznitelik vektörüne eklenmiştir.

3.3. Sınıflandırma


Önişleme ve öznitelik çıkartma aşamalarından sonra, elde edilen öznitelik vektörleri kullanılarak sınıflandırma işlemi gerçekleştirilir. Bu çalışmada aşağıdaki sınıflandırıcıların performansları incelenmiştir.

Bu çalışmada kullanılan sınıflandırıcılar iki kategoriye ayrılabilir:

1. Destek Vektör Makineleri (Support Vector Machines)
 - Polinomiyal Çekirdek Fonksiyonu (Kübik)
 - Radyal Temelli Çekirdek Fonksiyonu (Radial Basis Function)
 - Lineer Çekirdek Fonksiyonu
2. k-En Yakın Komşu (k-Nearest Neighbors)

3.3.1. Destek vektör makineleri

Cortes ve Vapnik (1995) tarafından önerilen Destek Vektör Makineleri (Support Vector Machines – SVM), sınıflandırma ve regresyon analizi işlemlerinde sıklıkla kullanılan bir sınıflandırıcı tipidir [31]. Temel amaç, farklı sınıfları birbirinden ayırmak için sınıflar arasında maksimum marjini sağlayacak, optimum bir hiperdüzlem bulmaktır (Şekil 3.18). Şekil 3.18’de bahsedilen maksimum marjini sağlayan hiperdüzlem H_3 ’tür. H_1 hiperdüzlemi sınıfları yanlış ayırtmakta, H_2 hiperdüzlemi ise sınıfları küçük bir marjinle ayırtılabilmektedir.




Şekil 3.18. İki sınıfı maksimum marjinle ayıran H_3 hiperdüzlemi ve olası diğer hiperdüzlemler (H_1 ve H_2) [32]

Sınıflandırılacak veri kümesindeki sınıf sayısına ve özniteliklerin düzlemdeki dağılımına göre, kullanılacak olan SVM algoritması bir takım farklılıklar gösterir. Düzlemde lineer olarak ayrıştırılabilen veri kümelerinde Sert Marjın (Hard Margin), belirli bir hata ile lineer olarak ayrıştırılabilen veri kümelerinde Yumuşak Marjın (Soft Margin) yöntemi kullanılır. Lineer olarak ayrıştırılamayan veri kümeleri için ise Lineer Olmayan SVM uygulanır.

Sert marjın (Hard margin)

Lineer olarak ayrılabilen veri kümelerinde uygulanır. $y_i = -1$ veya $y_i = +1$ olmak üzere iki sınıftan oluşan, her x_i üyesi D adet özniteliğe sahip olan L adet örnekten oluşan bir eğitim kümesinin, lineer olarak ayrıştırılabilir olduğu kabul edilsin. Yani bu durumda $x_1, x_2, \dots, x_D$ grafiklerinde çizilecek bir doğru veya hiperdüzlem, iki sınıfı birbirinden ayırabilecektir. Bu hiperdüzlem $w \cdot x + b = 0$ şeklinde ifade edilebilir. Burada w hiperdüzlemin normali, $b/\|w\|$ ise hiperdüzlem ile orijin noktası arasındaki dikey mesafedir ($\|w\|$ ifadesi w 'nin normunu gösterir).

Hiperdüzlemler en yakın noktalardan geçen doğrulara destek vektörler denir. SVM'nin amacı bu hiperdüzlemi, iki sınıfın en yakın üyelerine mümkün olan en uzak mesafede oluşturmaktır (Şekil 3.19) [31], [33].



Şekil 3.19. Sert marjın uygulanan SVM'nin geometrik yapısı [33]

SVM adımları uygulanarak, eğitim kümesini Eş. 3.17-18'de belirtilen şekilde tanımlayabilecek w ve b değişkenleri seçilecektir.

$$\begin{aligned} x_i \cdot w + b &\geq +1 & y_i = +1 \text{ için} \\ x_i \cdot w + b &\leq -1 & y_i = -1 \text{ için} \end{aligned} \quad (3.17)$$

Eş. 3.17'deki eşitsizlikler birleştirilerek Eş. 3.18 elde edilir.

$$y_i(x_i \cdot w + b) - 1 \geq 0 \quad \forall_i \text{ için} \quad (3.18)$$

Bu durumda sınıfları ayıran hiperdüzleme en yakın noktalar Destek Vektörler olarak adlandırılır ve bu noktaların geçtiği, ayırıcı hiperdüzleme paralel olan H_1 ve H_2 düzlemleri Eş. 3.19'daki gibi tanımlanır.

$$\begin{aligned} x_i \cdot w + b &= +1 & , H_1 \\ x_i \cdot w + b &= -1 & , H_2 \end{aligned} \quad (3.19)$$

Hiperdüzlemin H_1 ve H_2 düzlemlerine olan uzaklığı (d_1 ve d_2) birbirine eşittir. Bu uzaklığa SVM'nin marjini denir. Bu marjinin mümkün olduğunca büyük olması amaçlanır. $1/\|w\|$ uzunluğundaki bu marjini maksimize edebilmek için Eş. 3.18'de verilen sınırlar altında, w değerinin minimize edilmesi gerekir (Eş. 3.20).

$$y_i(x_i \cdot w + b) - 1 \geq 0 \quad \forall_i \quad \text{koşulu altında} \quad \min \|w\| \quad (3.20)$$

$\|w\|$ 'nin minimize edilmesi, $\frac{1}{2} \|w\|^2$ nin minimize edilmesine denktir. Bu geçiş, ileriki aşamalarda kullanılacak olan karesel programlama (quadratic programming) yöntemine girdi oluşturması için yapılmıştır [33]. Böylece Eş. 3.21 elde edilir.

$$y_i(x_i \cdot w + b) - 1 \geq 0 \quad \forall_i \quad \text{koşulu altında} \quad \min \frac{1}{2} \|w\|^2 \quad (3.21)$$

Verilen sınır koşulu altında minimizasyon yapabilmek için, $\alpha_i \geq 0 \quad \forall_i$ olan Lagrange çarpanları kullanılır.

$$L_P \equiv \frac{1}{2} \|w\|^2 - \alpha [y_i(x_i \cdot w + b) - 1] \quad , \forall_i \quad (3.23)$$

$$\equiv \frac{1}{2} \|w\|^2 - \sum_{i=1}^L \alpha_i [y_i(x_i \cdot w + b) - 1] \quad (3.24)$$

$$\equiv \frac{1}{2} \|w\|^2 - \sum_{i=1}^L \alpha_i y_i(x_i \cdot w + b) + \sum_{i=1}^L \alpha_i \quad (3.25)$$

Eş. 3.25'i minimize edecek w ve b değerleri ile maksimize edecek α değeri, L_P 'nin w ve b 'ye göre türevleri alınarak ve bu türevler sıfıra eşitlenerek elde edilebilir (Eş. 3.26-27).

$$\frac{\partial L_P}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^L \alpha_i y_i x_i \quad (3.26)$$

$$\frac{\partial L_P}{\partial b} = 0 \Rightarrow \sum_{i=1}^L \alpha_i y_i = 0 \quad (3.27)$$

Eş. 3.26-27, Eş. 3.25'te yerine koyulursa α değerine bağımlı ve bu α değerinin maksimize edilmesi gereken Eş. 3.30 elde edilir. Burada L_D , birincil L_P 'nin ikili (dual) formudur. İkili formda her bir girdi vektörü x_i için nokta çarpımı (dot product) kullanılır [33].

$$L_D \equiv \sum_{i=1}^L \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j x_i \cdot x_j, \quad \alpha_i \geq 0 \quad \forall_i \quad \sum_{i=1}^L \alpha_i y_i = 0 \quad (3.28)$$

$$\equiv \sum_{i=1}^L \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i H_{ij} \alpha_j, \quad H_{ij} \equiv y_i y_j x_i \cdot x_j \quad (3.29)$$

$$\equiv \sum_{i=1}^L \alpha_i - \frac{1}{2} \alpha^T H \alpha, \quad \alpha_i \geq 0 \quad \forall_i \quad \sum_{i=1}^L \alpha_i y_i = 0 \quad (3.30)$$

L_P 'yi minimize edecek w ve b değerleri türev işleminden sonra L_D eşitliğinde yer almamaktadır. Daha öncesinde L_P minimize edilmeye çalışılırken, şimdi L_D maksimize edilmeye çalışılacaktır (Eş. 3.31).

$$\max_{\alpha} \left[\sum_{i=1}^L \alpha_i - \frac{1}{2} \alpha^T H \alpha \right] , \alpha_i \geq 0 \quad \forall_i \quad \sum_{i=1}^L \alpha_i y_i = 0 \quad (3.31)$$

Konveks karesel bir optimizasyon problemi olan Eş. 3.31, karesel programlama kullanılarak çözüldüğünde α elde edilir ve bu değer kullanılarak Eş. 3.26'dan w hesaplanır. Geriye b değerinin hesaplanması kalmaktadır [33].

Eş. 3.27'yi sağlayan tüm x_s Destek Vektörleri, $y_s(x_s.w + b) = 1$ formundadır. w değerinin Eş. 3.26'daki karşılığı, bu formda yerine koyulursa Eş. 3.32 elde edilir.

$$y_s \left(\sum_{m \in S} \alpha_m y_m x_m \cdot x_s + b \right) = 1 \quad (3.32)$$

Burada S , Destek Vektör indislerini temsil eder. Eş. 3.32'de eşitliğin iki tarafı da y_s ile çarpılarak Eş. 3.33 elde edilir. $y_s^2 = 1$ (bkz. Eş. 3.17) yerine konularak Eş. 3.34 elde edilir.

$$y_s^2 \left(\sum_{m \in S} \alpha_m y_m x_m \cdot x_s + b \right) = y_s \quad (3.33)$$

$$b = y_s - \sum_{m \in S} \alpha_m y_m x_m \cdot x_s \quad (3.34)$$

Rastgele bir x_s Destek Vektörü kullanmak yerine, S boyunca tümünün ortalaması alınabilir.


$$b = \frac{1}{N_s} \sum_{s \in S} \left(y_s - \sum_{m \in S} \alpha_m y_m x_m \cdot x_s \right) \quad (3.35)$$

Bu adımlar sonucunda, ayırıcı hiperdüzlemin optimum yönelimini tanımlayan w ve b değerlerine ulaşılarak SVM oluşturulmuş olur. Herhangi bir x' noktasının ait olduğu sınıf y' , Eş. 3.36 kullanılarak elde edilir.

$$y' = \text{sgn}(w \cdot x' + b) \quad (3.36)$$

Yumuşak marjın (Soft margin)

Belirli bir hata ile lineer olarak ayrıştırılabilen veri kümelerinde kullanılır. Bu durumdaki SVM'nin geometrik gösterimi Şekil 3.20'de verilmiştir.



Şekil 3.20. Yumuşak marjın uygulanan SVM'nin geometrik yapısı [33]

Veri kümesinin tam olarak lineer bir şekilde ayrıştırılamadığı durumlarda, Eş. 3.17'de verilen sınır koşulları ξ_i yapay değişkeni (slack variable) kullanılarak bir miktar esnetilir. $\xi_i \geq 0 \quad \forall_i$ ve $i = 1, 2, \dots, L$ olmak üzere Eş. 3.37 elde edilir.

$$\begin{aligned} x_i \cdot w + b &\geq +1 - \xi_i & y_i = +1 \text{ için} \\ x_i \cdot w + b &\leq -1 + \xi_i & y_i = -1 \text{ için} \end{aligned} \quad (3.37)$$

$$y_i(x_i \cdot w + b) - 1 + \xi_i \geq 0 \quad \xi_i \geq 0 \quad \forall_i \quad (3.38)$$

Yumuşak marjın uygulanan SVM'de, marjın sınırının yanlış tarafında bulunan veri noktaları, marjından uzaklığıyla doğru orantılı olarak bir ceza parametresine sahip olur. Eş. 3.21 ile verilen fonksiyon, Eş. 3.39'a dönüştürülür [31], [33].

$$y_i(x_i \cdot w + b) - 1 + \xi_i \geq 0 \quad \forall_i \quad \text{koşulu altında} \quad \min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^L \xi_i \quad (3.39)$$

Burada C ceza parametresi ile marjinin büyüklüğü arasındaki ilişkiyi ifade eder. Lagrange çarpanları kullanılarak Eş. 3.40 elde edilir.

$$L_P \equiv \frac{1}{2} \|w\|^2 + C \sum_{i=1}^L \xi_i - \sum_{i=1}^L \alpha_i [y_i(x_i \cdot w + b) - 1 + \xi_i] + \sum_{i=1}^L \mu_i \xi_i \quad (3.40)$$

Eş. 3.40, w , b , ve ξ_i değişkenlerine göre minimize, α değişkenine göre maksimize edilir. $\alpha_i \geq 0$ ve $\mu_i \geq 0 \forall_i$ olmak üzere, L_P 'nin w , b , ve ξ_i değişkenlerine göre türevi alınır ve türevler sıfıra eşitlenir.

$$\frac{\partial L_P}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^L \alpha_i y_i x_i \quad (3.41)$$

$$\frac{\partial L_P}{\partial b} = 0 \Rightarrow \sum_{i=1}^L \alpha_i y_i = 0 \quad (3.42)$$

$$\frac{\partial L_P}{\partial \xi_i} = 0 \Rightarrow C = \alpha_i + \mu_i \quad (3.43)$$

Bu değerler Eş. 3.40'ta yerine konulduğunda, Eş. 3.30'dakine benzer şekilde L_D elde edilir. $\mu_i \geq 0 \forall_i$ ve $\alpha_i \leq C$ olduğu göz önünde bulundurularak, Eş. 3.44 hesaplanmaya çalışılır.


$$\max_{\alpha} \left[\sum_{i=1}^L \alpha_i - \frac{1}{2} \alpha^T H \alpha \right], \quad 0 \leq \alpha_i \leq C \quad \forall_i \quad \sum_{i=1}^L \alpha_i y_i = 0 \quad (3.44)$$

Burada yine karesel programlama kullanılarak α elde edilir ve bu değer kullanılarak Eş. 3.41'den w hesaplanır. Daha sonra Eş. 3.35'teki gibi b değeri hesaplanır. Ancak bu kez b 'yi hesaplamak için kullanılacak olan Destek Vektörler kümesi, $0 \leq \alpha_i \leq C$ aralığındaki i indisleri bulunarak elde edilir. Böylece SVM oluşturulmuş olur. Herhangi bir x' noktasının ait olduğu sınıf y' , Eş. 3.45 kullanılarak elde edilir [33].


$$y' = \text{sgn}(w \cdot x' + b) \quad (3.45)$$

Lineer olmayan SVM


Veri kümesinin lineer olarak ayrıştırılma imkânının olmadığı durumlar için Boser ve diğerleri (1992) tarafından çekirdek fonksiyonu (kernel function) önerilmiştir [34]. Gerçek uygulamalarda çoğunlukla veriyi lineer bir hiperdüzlem ile ayırmak mümkün olmamaktadır. Çekirdek fonksiyonları; maksimum marjınlı ayırıcı hiperdüzlemi, dönüştürülmüş bir öznelilik uzayında haritalamayı (mapping) sağlar. Hesaplama yöntemi diğer SVM yöntemleriyle temel olarak benzerlik gösterir. Ancak bu yöntemde farklı olarak, nokta çarpımlarının (dot product) yerini çekirdek fonksiyonları alır. Şekil 3.21, Şekil 3.22 ve Şekil 3.23’de lineer olarak ayrıştırılamayan örnek bir veri kümesi ve bu kümenin dönüştürülmüş bir uzaya haritalanarak ayrıştırılabilir hale gelmesinin geometrik gösterimi verilmiştir [32-33,35].



Şekil 3.21. SVM’de çekirdek fonksiyonu kullanımı [32]



Şekil 3.22. Lineer olarak ayrıştırılamayan veri kümesinin, başka bir uzaya haritalanarak ayrıştırılabilir hale dönüştürülmesi [33]



Şekil 3.23. Lineer olarak ayrıştırılamayan veri kümesinin, başka bir uzaya haritalanarak ayrıştırılabilir hale dönüştürülmesi [35]

Lineer olmayan veri kümelerinin ayrıştırılması için kullanılan çekirdek fonksiyonu yönteminde, diğer SVM yöntemlerinde elde edilen $H_{ij} = y_i y_j x_i \cdot x_j$ matrisindeki aksine $x_i \cdot x_j$ nokta çarpımının yerini çekirdek fonksiyonu alır. Veri noktaları $x \rightarrow \phi(x)$ şeklinde bir haritalama (mapping) fonksiyonu kullanılarak başka bir H uzayına taşınır. Böylece H matrisi Eş. 3.46'daki gibi ifade edilir.

$$H_{ij} = y_i y_j K(x_i, x_j) \quad K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) \quad (3.46)$$

H matrisinin içerisinde çekirdek fonksiyonu kullanılarak, lineer olarak ayrıştırılamayan iki boyutlu veri kümeleri, çekirdek fonksiyonu tarafından dolaylı olarak tanımlanan öznitelik uzayında ayrıştırılabilir hale gelir.

Sıklıkla kullanılan çekirdek fonksiyonlarından bazıları lineer çekirdek fonksiyonu, polinomiyal çekirdek fonksiyonu, radyal temelli çekirdek fonksiyonu (radial basis function – RBF) ve sigmoid çekirdek fonksiyonudur.

$$K(x_i, x_j) = x_i^T \cdot x_j \quad \text{Lineer çekirdek fonksiyonu} \quad (3.47)$$

$$K(x_i, x_j) = (x_i \cdot x_j + c)^d \quad \text{Polinomiyal çekirdek fonksiyonu} \quad (3.48)$$


$$K(x_i, x_j) = e^{-\left(\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)} \quad \text{Radyal temelli çekirdek fonksiyonu (RBF)} \quad (3.49)$$

$$K(x_i, x_j) = \tanh(ax_i \cdot x_j - \delta) \quad \text{Sigmoid çekirdek fonksiyonu} \quad (3.50)$$

3.3.2. k-En yakın komşu algoritması

Örüntü tanıma uygulamalarında sıklıkla kullanılan k-En Yakın Komşu (k-Nearest Neighbors – k-NN) algoritması, en basit sınıflandırma yöntemlerinden birisidir. Test kümesinin herhangi bir elemanı, öznitelik uzayında kendisine en yakın mesafedeki k adet komşusu incelenerek sınıflandırılır.

k-NN yönteminde eğitim işlemi, yalnızca öznitelik vektörlerini ve ilgili sınıf bilgisini kaydetmekten ibarettir. Diğer sınıflandırıcılardaki gibi eğitim kümesi kullanılarak herhangi bir model oluşturulmaz. Sınıflandırma işlemi ise, girdi olarak verilen bir test örüntüsünün öznitelik vektörüne göre öznitelik uzayında geometrik olarak hangi noktaya denk geldiğine bakılarak gerçekleştirilir. Öznitelik uzayında, test örüntüsüne en yakın k adet komşusunun hangi sınıflara ait olduğu incelenir. Bu k adet komşu arasından, test örüntüsüne en çok sayıda komşuluğu bulunan sınıf, test örüntüsünün ait olduğu sınıf olarak tahmin edilir (Şekil 3.24).



Şekil 3.24. k-NN yönteminin geometrik gösterimi [36]

k-NN yönteminde öznitelik uzayındaki noktaların birbirine uzaklığını hesaplamak için farklı yöntemler kullanılır. Bu yöntemlerden bazıları Eş. 3.51-53'te verilmektedir.

$$\sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad \text{Öklid uzaklığı} \quad (3.51)$$

$$\sum_{i=1}^k |x_i - y_i| \quad \text{Manhattan uzaklığı} \quad (3.52)$$

$$\left(\sum_{i=1}^k (|x_i - y_i|)^q \right)^{1/q} \quad \text{Minkowski uzaklığı} \quad (3.53)$$

4. SINIFLANDIRMA SONUÇLARININ DEĞERLENDİRİLMESİ

Yapılan çalışmada MSTAR veritabanındaki SAR görüntüleri öncelikle ön işleme aşamasından geçirilerek görüntüler üzerinde iyileştirme yapılmış ve bölütleme gerçekleştirilerek hedef bölgesi ayrıştırılmıştır. Bölütleme aşamaları daha önce Şekil 3.4'te açıklanmış olan işlem basamakları uygulanarak gerçekleştirilmiştir. Daha sonra bu görüntüler üzerine çeşitli öznitelik çıkartma yöntemleri uygulanarak öznitelikler elde edilmiştir. Sonuç olarak her bir görüntü için 1x34 boyutunda bir öznitelik vektörü elde edilmiştir. Bu özniteliklerin neler oldukları ve boyutları Çizelge 4.1'de verilmektedir.

Çizelge 4.1. Kullanılan öznitelikler ve boyutları

Öznitelik	Boyut
Dikdörtgensellik	1 x 1
Kenar oranı	1 x 1
Eksen oranı	1 x 1
Dışbükeylik	1 x 1
Dışmerkezlik	1 x 1
Ortalama	1 x 1
Çarpıklık	1 x 1
MRF sinyalinin DCT'si	1 x 21
Eliptik Fourier Betimleyiciler	1 x 6
Toplam	1 x 34

Bir sınıflandırıcıya girecek eğitim ve test örüntülerinin seçimi konusunda çeşitli yöntemler mevcuttur. *k*-Katlı Çapraz Doğrulama (*k*-Fold Cross Validation) yönteminde veri kümesinin tüm elemanları rastgele seçilerek *k* adet eş büyüklükte küme oluşturulur. Birinci küme test kümesi olarak seçilir ve diğer *k-1* adet küme eğitim kümesini oluşturur. Eğitim kümesi kullanılarak sınıflandırıcı eğitilir. Daha sonra test kümesi olarak seçilmiş olan birinci küme, bu sınıflandırıcıda test edilir. Bu işlemler geri kalan *k-1* adet küme için ayrı ayrı tekrarlanarak ortalama sınıflandırma performansı elde edilir.

k-Katlı Çapraz Doğrulama yönteminde, test ve eğitim kümelerini oluşturan örnekler veritabanından rastgele seçilmektedir. Bu çalışmada kullanılan MSTAR veritabanından

rastgele örnekler almak, sınıflandırıcının uygun bir şekilde eğitilmesini engelleyebilir. Çünkü MSTAR veritabanında her hedef tipi için 0° ile 360° arasındaki azimut açılarında birçok görüntü mevcuttur. Aynı hedef tipinin belirli bir azimut açısında birden çok görüntüsü mevcuttur. Böyle bir durumda eğitim kümesi için rastgele eleman seçmek, hep aynı (veya benzer) azimut açılarındaki görüntünün toplanmasına neden olabilir. Örneğin bir hedef tipi için seçilen eğitim kümesi elemanları, hep aynı θ azimut açısında olabilir. Bunun sonucunda sınıflandırıcı hep aynı azimut açısı için eğitilmiş, diğer açılar hakkında veri toplanamamış olur.

Bu nedenle bu çalışmada k-Katlı Çapraz Doğrulama yöntemi kullanılmamıştır. MSTAR veritabanında bulunan çeşitli hedef görüntüleri, “holdout” olarak da adlandırılan yöntemle eğitim ve test kümelerine ayrılmıştır. Burada veritabanının seçilen bir kısmı eğitim, bir kısmı test için ayrılır. MSTAR veritabanından eğitim ve test kümeleri oluşturulurken, hem eğitim hem test görüntülerinde, tüm azimut açılarını içerecek bir şekilde seçim gerçekleştirilmiştir. Böylece sınıflandırıcı farklı azimut açıları için de veri elde edecektir. Eğitim kümesindeki görüntüler sınıflandırıcının model oluşturması için kullanılırken, test kümesindeki görüntüler ise sınıflandırma performansını test etmek için kullanılmıştır. Bu çalışmada hedef görüntülerinin yaklaşık %70’i eğitim, %30’u test kümesine ayrılmıştır (Çizelge 4.2).

Çizelge 4.2. Hedef tiplerine göre eğitim ve test görüntülerinin sayıları

Hedef	Tip	Eğitim Görüntüsü	Test Görüntüsü
2S1	Obüs	364	154
BTR-60	Zırhlı personel taşıyıcı	244	105
D7	Askeri buldozer	364	153
ZIL-131	Askeri kamyon	353	149
ZSU-23-4	Uçaksavar top sistemi	400	170
Toplam		1725	731

4.1. SVM ile Sınıflandırma Sonuçları

SVM yöntemi ikili bir sınıflandırıcı (binary classifier) olduğundan dolayı, verilen test noktalarını +1 veya -1 şeklinde iki sınıfa ayırabilir. Bu durum “o sınıfa ait” veya “o sınıfa ait değil” olarak düşünülebilir. SVM algoritmasını çok sınıflı (multi class) sınıflandırma problemlerinde kullanabilmek için çeşitli yöntemler geliştirilmiştir. Bu çalışmada, bu yöntemlerden One-vs-One kullanılarak SVM algoritması çok sınıflı veri kümesine uygulanmıştır. One-vs-One yönteminde, N adet sınıf arasından her bir çift sınıf için farklı bir sınıflandırıcı modeli oluşturulur. Böylece toplam N adet sınıf içeren bir eğitim kümesi kullanılarak $N(N-1)/2$ adet model elde edilir. Örneğin; C_1 , C_2 ve C_3 olmak üzere 3 adet sınıfa sahip bir veri kümesinde One-vs-One yöntemi kullanıldığında (C_1, C_2) , (C_1, C_3) ve (C_2, C_3) sınıflarından oluşan üç sınıflandırıcı modeli elde edilecektir. Herhangi bir test noktası test edilirken, her bir sınıflandırıcı bu test noktasının hangi sınıfa ait olduğunu tahmin eder. Toplamda en çok oy verilen sınıf (majority voting), o test noktasının tahmin edilen sınıfı olur [37].


Üç farklı çekirdek fonksiyonu için, One-vs-One yöntemi ile SVM sınıflandırıcı kullanılarak sonuçlar incelenmiştir.

4.1.1. Polinomiyal çekirdek fonksiyonu kullanarak sınıflandırma

SVM sınıflandırıcıda farklı derecelerden polinomiyal çekirdek fonksiyonları kullanılarak sınıflandırma performansı incelenmiştir. 2. dereceden çekirdek fonksiyonu kullanıldığında %91,9, 3. dereceden (kübik) çekirdek fonksiyonu kullanıldığında %96,03, 4. Dereceden çekirdek fonksiyonu kullanıldığında %95,1 sınıflandırma oranına ulaşılmıştır. Bu nedenle bu çalışmada, en yüksek sınıflandırma oranını sağlayan 3. dereceden (kübik) polinomiyal çekirdek fonksiyonunun ürettiği sonuçlar detaylandırılmıştır. Ortaya çıkan sınıflandırma sonuçları Çizelge 4.3 ve Şekil 4.1’de verilmiştir.

Çizelge 4.3. Polinomiyal çekirdek fonksiyonlu (kübik) SVM için hata matrisi

		Tahmin Edilen Hedef Sınıfı					Doğruluk yüzdesi
		2S1	BTR-60	D7	ZSU-23-4	ZIL-131	
Gerçek Hedef Sınıfı	2S1	146	0	1	2	5	% 94,81
	BTR-60	0	103	1	1	0	% 98,10
	D7	1	0	147	2	3	% 96,08
	ZSU-23-4	1	0	1	167	1	% 98,24
	ZIL-131	2	0	8	0	139	% 93,29
Toplam sınıflandırma başarı oranı:							% 96,03




Şekil 4.1. Polinomiyal çekirdek fonksiyonlu SVM için doğru sınıflandırma oranları

4.1.2. Radyal temelli çekirdek fonksiyonu (RBF) kullanarak sınıflandırma

SVM sınıflandırıcıda radyal temelli çekirdek fonksiyonu (RBF – radial basis function) kullanıldığında ortaya çıkan sınıflandırma sonuçları Çizelge 4.4 ve Şekil 4.2’de verilmiştir.

Çizelge 4.4. Radyal temelli çekirdek fonksiyonlu SVM için hata matrisi

		Tahmin Edilen Hedef Sınıfı					Doğruluk yüzdesi
		2S1	BTR-60	D7	ZSU-23-4	ZIL-131	
Gerçek Hedef Sınıfı	2S1	139	1	3	1	10	% 90,26
	BTR-60	0	98	1	6	0	% 93,33
	D7	2	0	145	1	5	% 94,77
	ZSU-23-4	1	2	11	152	4	% 89,41
	ZIL-131	4	0	8	0	137	% 91,95
Toplam sınıflandırma başarı oranı:							% 91,79




Şekil 4.2. Radyal temelli çekirdek fonksiyonlu SVM için doğru sınıflandırma oranları

4.1.3. Lineer çekirdek fonksiyonu kullanarak sınıflandırma

SVM sınıflandırıcıda lineer çekirdek fonksiyonu kullanıldığında ortaya çıkan sınıflandırma sonuçları Çizelge 4.5 ve Şekil 4.3'te verilmiştir.

Çizelge 4.5. Lineer çekirdek fonksiyonlu SVM için hata matrisi


		Tahmin Edilen Hedef Sınıfı					Doğruluk yüzdesi
		2S1	BTR-60	D7	ZSU-23-4	ZIL-131	
Gerçek Hedef Sınıfı	2S1	135	1	3	2	13	% 87,66
	BTR-60	0	103	1	1	0	% 98,10
	D7	2	0	132	12	7	% 86,27
	ZSU-23-4	1	0	15	147	7	% 86,47
	ZIL-131	5	0	8	0	136	% 91,28
Toplam sınıflandırma başarı oranı:							% 89,33



Şekil 4.3. Lineer çekirdek fonksiyonlu SVM için doğru sınıflandırma oranları

4.2. k-NN ile Sınıflandırma Sonuçları


k-NN sınıflandırıcı için farklı k değerlerinde sınıflandırma sonuçları incelenmiştir. İteratif olarak gerçekleştirilen k-NN sınıflandırma işlemleri sonucunda, k-NN sınıflandırıcılar arasında en yüksek doğru sınıflandırma oranı 3-NN sınıflandırıcıda elde edilmiştir (Şekil 4.4). Tüm bu işlemlerde komşu noktalar arasındaki mesafe hesabı Öklid uzaklığı cinsinden yapılmıştır. 3-NN sınıflandırıcı için ortaya çıkan sınıflandırma sonuçları Çizelge 4.6 ve Şekil 4.5'te görülmektedir.



Şekil 4.5. 3-NN sınıflandırıcı için doğru sınıflandırma oranları


4.3. Genel Değerlendirme

Farklı sınıflandırıcılar için doğru sınıflandırma oranları Şekil 4.6’da toplu halde gösterilmektedir. En başarılı performansın %96,03 oran ile 3. dereceden polinomiyal çekirdek fonksiyonu kullanılan SVM sınıflandırıcısında elde edildiği görülmektedir. Ayrıca SVM (Polinomiyal çekirdek) için Alıcı Çalışma Karakteristiği (ROC – Receiver Operating Characteristics) eğrileri EK-1’de, SVM (RBF çekirdek) için ROC eğrileri EK-2’de, SVM (Lineer çekirdek) için ROC eğrileri EK-3’te, 3-NN için ROC eğrileri EK-4’te verilmiştir.




Şekil 4.6. Farklı sınıflandırıcılardan elde edilen sonuçlar

MSTAR veritabanındaki bazı görüntülerin oldukça bozuk ve gürültülü olduğu gözlemlenmiştir. Bu görüntüler, bir hedef tipinin diğer açılardaki görüntülerinden bile ayırt edilemeyecek şekilde gürültü içermektedir. Bu nedenle veritabanındaki bu görüntülerin sınıflandırma işlemini oldukça zorlaştırdıkları değerlendirilmiştir. Örnek görüntüler Şekil 4.7’de verilmektedir.




Şekil 4.7. Bozuk görüntülerden örnekler

Hata matrisleri (confusion matrix) incelendiğinde, sınıflandırıcılar tarafından diğer sınıflara nispeten birbiriyle daha çok karıştırılan hedef tiplerinin D7 – ZIL-131 ve 2S1 – ZIL-131 ikilileri olduğu görülmektedir. Bu ikililerin örnek görüntüleri Şekil 4.8 ve Şekil 4.9’da verilmektedir.



Şekil 4.8. a) D7 hedefi örnek görüntüsü b) ZIL-131 hedefi örnek görüntüsü



Şekil 4.9. a) 2S1 hedefi örnek görüntüsü b) ZIL-131 hedefi örnek görüntüsü

4.4. Özniteliklerin Sınıflandırmaya Katkıları

Bu çalışmada kullanılan piksel tabanlı özniteliklerin, MRF özniteliklerinin ve eliptik Fourier betimleyicilerin, sınıflandırma performansına olan katkıları ayrı ayrı incelenmiştir. Bunun için bu üç kategorideki öznitelikler, tüm kombinasyonlarla öznitelik vektörü olarak kullanılmıştır. Her biri için ayrı ayrı sınıflandırma işlemi gerçekleştirilerek Çizelge 4.7’de verilen sonuçlar elde edilmiştir.

Çizelge 4.7. Farklı öznitelikler için doğru sınıflandırma oranları

	P*	M*	E*	P + M	P + E	M + E	P + M + E
SVM (Polinomiyal)	% 86,32	% 57,57	% 71,41	% 88,78	% 94,39	% 85,77	% 96,03
SVM (RBF)	% 84,85	% 56,63	% 61,15	% 88,51	% 87,96	% 81,53	% 91,79
SVM (Lineer)	% 86,05	% 54,72	% 43,50	% 87,69	% 90,16	% 58,27	% 89,33
3-NN	% 83,58	% 70,73	% 55,68	% 90,15	% 85,64	% 83,99	% 92,61

P* : Piksel tabanlı öznitelikler
M* : MRF öznitelikleri
E* : Eliptik Fourier betimleyicileri

5. SONUÇLAR

Bu çalışmada MSTAR veritabanından alınan SAR görüntüleri üzerinde hedef tanıma işlemi gerçekleştirilmiştir. Farklı önişleme, öznitelik çıkartma ve sınıflandırma yöntemleri kullanılarak sonuçları analiz edilmiştir.

Önişleme aşamasında kullanılan ve 3×3 boyutundaki bir çerçevede işlem gerçekleştiren ortalama filtresinin, benek gürültüsünü azaltmada başarılı olduğu görülmüştür. Filtre maskesi için farklı boyutlar da denenmiştir. Ancak gerek işlem yükü, gerekse benek gürültüsünün azalma miktarı göz önünde bulundurulduğunda 3×3 'lük bir çerçevenin yeterli olduğu görülmüştür. Gabor, Median ve Frost filtreleri de denenmiş, ancak eldeki veritabanı için en başarılı sonuçlara ortalama filtresi ile ulaşılmıştır. Daha sonra gerçekleştirilen bölütleme işleminde ise %20'lik bir eşik değeri seçilmiş ve tüm piksellerin en parlak %20 adedi değerlendirilmiştir. Bu eşik değeri de yine farklı değerler incelenerek seçilmiştir. Bu değerin üzerinde bir eşik değeri seçildiğinde hedef bölgesine dahil olmayan alanların da değerlendirmeye girdiği gözlemlenmiştir. Daha düşük bir eşik değerinde ise hedef bölgesine ait olmasına rağmen değerlendirme dışında kalan pikseller tespit edilmiştir. Bu nedenlerden dolayı optimum bir değer olarak %20 seçilmiştir.

Öznitelik çıkartma aşamasında piksel tabanlı öznitelikler, MRF öznitelikleri ve eliptik Fourier betimleyicileri kullanılmıştır. Piksel tabanlı öznitelikler piksel yoğunlukları ve piksellerin geometrik yerleşimi üzerinden işlem yapmaktadır. Bu öznitelikler çıkartılırken, MSTAR veritabanındaki herhangi bir sınıfa ait örnek görüntülerin 360 derece döndüğü göz önüne alınmıştır. Bu nedenle normal şartlar altında yönelime göre farklı sonuçlar üretecek olan öznitelikler için, hedef şeklinin asal ve yedek eksenleri referans alınarak işlemler gerçekleştirilmiştir. Böylece hedef şekli hangi açıda olursa olsun, hedefle birlikte dönmekte olan asal ve yedek eksenler sayesinde yönelimden bağımsız hale gelinmiştir.

Daha önce çeşitli örüntü tanıma çalışmalarında kullanılmış olan MRF ise SAR görüntüleri için uyarlanmıştır. Literatürde SAR görüntüleri için MRF ile ilgili daha önce yapılmış herhangi bir çalışma bulunamamıştır. MRF yönteminin SAR görüntüleri için ilk kez bu çalışmada ele alındığı değerlendirilmektedir. Şekil özellikleri nispeten daha keskin geçişlere sahip olan görüntülerde oldukça iyi sonuçlar veren MRF'nin, birbirine çok

benzeyen SAR görüntüleri üzerinde de başarılı sonuçlar ürettiği görülmüştür. MRF'nin hesaplanmasına da hep aynı nokta (asal eksenin sağ üst köşesi) referans alınarak, 360 derece boyunca dönen hedef görüntülerindeki açısal belirsizlik 180 dereceye düşürülmüştür. Daha sonra elde edilen MRF sinyaline DCT uygulanarak, daha çok bilgi taşıyan, önemli bileşenlerin az sayıda katsayıyla ifade edilmesi sağlanmıştır.

Piksel tabanlı özniteliklere ve MRF özniteliklerine ek olarak eliptik Fourier betimleyicileri elde edilerek öznitelik vektörüne eklenmiştir. Eliptik Fourier betimleyicileri, hedef şeklini üstüste çakışan elipslerin toplamı olarak ifade etmekte olup, bu elipslere ait parametrelerden oluşan EFD katsayıları öznitelik olarak kullanılmıştır. Bu çalışmada hedef şekli, altı adet katsayıdan oluşan (tüm görüntüler için sıfır değerini üreten b_0 ve d_0 katsayıları çıkartıldığında) iki adet eliptik Fourier betimleyicisiyle ifade edilmiştir. Eliptik Fourier betimleyicilerinin az sayıda katsayı ile şekil konturunu temsil edebildiği görülmüştür.

Çeşitli sınıflandırıcılar kullanılarak yapılan çalışmaların sonuçları incelenmiştir. SVM sınıflandırıcısı polinomiyal, RBF ve lineer çekirdek fonksiyonları kullanılarak ayrı ayrı test edilmiştir. Ayrıca k-NN algoritmasının da sınıflandırma sonuçları incelenmiştir. Sınıflandırıcılar, hata matrisleri ve ROC eğrileri oluşturularak değerlendirilmiştir. Sınıflandırma işlemlerinin sonucunda en yüksek doğru sınıflandırma oranına %96,03 ile polinomiyal (kübik) çekirdek fonksiyonu kullanan SVM sınıflandırıcısında ulaşılmıştır. Ayrıca her bir öznitelik grubunun sınıflandırma performansına olan katkıları ayrı ayrı incelenmiştir.

Bu çalışmayla, birbirine oldukça benzeyen, ayrıştırılması zor, yüksek miktarda benek gürültüsü içeren SAR görüntüleri sınıflandırılmış, görüntülerdeki hedef tipleri başarıyla tespit edilmiştir. 731 adet hedef görüntüsünün ait olduğu sınıf, %96,03 gibi yüksek bir doğruluk oranıyla tahmin edilmiştir. Literatürde daha önce SAR görüntüleri için kullanılmamış olan MRF, bu çalışmada öznitelik olarak kullanılmıştır.


KAYNAKLAR

1. Zheng, L. and He, X. (2005). Classification Techniques in Pattern Recognition. *13th International Conference in Central Europe on Computer Graphics, Visualization and Computer Vision Poster Proceedings*, 77-78.
2. Yang, Y., Qiu, Y., and Lu, C. (2005). Automatic target classification experiments on the MSTAR SAR images. *Proceedings of Sixth International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing and First ACIS International Workshop on Self-Assembling Wireless Networks (SNPD/SAWN'05)*, 2-7.
3. Hu, L., Liu, J., Liu, H., Chen, B., and Wu, S. (2007). Automatic Target Recognition based on SAR images and Two-Stage 2DPCA features. *1st Asian and Pacific Conference on Synthetic Aperture Radar, APSAR*, 801-805.
4. Bhanu, B. and Lin, Y. (2003). Genetic algorithm based feature selection for target detection in SAR images. *Image and Vision Computing*, 21(7), 591-608.
5. Ruohong, H. and Ruliang, Y. (2008). SAR Target Recognition Based on MRF and Gabor Wavelet Feature Extraction. *IEEE International Geoscience and Remote Sensing Symposium, IGARSS, II*, 907-910.
6. Cheng, G., Zhao, W., Zhang, J., and Mao, S. (2006). A Practical Kernel Criterion for Feature Extraction and Recognition of MSTAR SAR Images. *8th International Conference on Signal Processing*.
7. Cui, J., Gudnason, J., and Brookes, M. (2005). Automatic recognition of MSTAR targets using radar shadow and superresolution features. *Proceedings of IEEE International Conference on Acoustics, Speech, and Signal Processing, (ICASSP '05/V)*, 589-592.
8. Wei, Z., Jie, W., and Jian, G. (2011). An efficient SAR target recognition algorithm based on contour and shape context. *3rd International Asia-Pacific Conference on Synthetic Aperture Radar (APSAR)*, 1-4.
9. Papsan, S. and Narayanan, R. (2006). Modeling of Target Shadows for SAR Image Classification. *35th IEEE Applied Imagery and Pattern Recognition Workshop, AIPR*, 3.
10. Hou, X., Yan, L., Wang, S., and Hou, B. (2014). MSTAR image segmentation with multi-phase level set based on probability density model. *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 1721-1724.
11. Han, P., Wu, R., Wang, Y., and Wang, Z. (2003). An efficient SAR ATR approach. *Proceedings of IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP '03/II)*, 429-432.
12. İnternet: Wolff, C. Radar Temelleri – Yapay Açıklıklı Radar. URL: <http://www.webcitation.org/query?url=http%3A%2F%2Fwww.radartutorial.eu%2F20.airborne%2Fab07.tr.html&date=2016-01-26>, Son Erişim Tarihi: 27.01.2016.


28. Yip, R. K. K., Tam, P. K. S., and Leung, D. N. K. (1994). Application of elliptic Fourier descriptors to symmetry detection under parallel projection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 16(3), 277-286.
29. Nicoli, L. P. (2007). *Automatic Target Recognition of Synthetic Aperture Radar Images using Elliptical Fourier Descriptors*, Master's Thesis, Florida Institute of Technology, Melbourne, Florida, 49.
30. Nicoli, L. P. and Anagnostopoulos, G. C. (2008). Shape-based recognition of targets in synthetic aperture radar images using elliptical fourier descriptors. *Proceedings of SPIE 6967, Automatic Target Recognition XVIII*.
31. Cortes, C. and Vapnik, V. (1995). Support-Vector Networks. *Machine Learning*, 20(3), 273-297.
32. İnternet: Support vector machines – Wikipedia, the free encyclopedia. URL: http://www.webcitation.org/query?url=https%3A%2F%2Fen.wikipedia.org%2Fwiki%2FSupport_vector_machine&date=2016-01-26, Son Erişim Tarihi: 27.01.2016.
33. İnternet: Fletcher, T. Support Vector Machines Explained. URL: <http://www.webcitation.org/query?url=http%3A%2F%2Fwww.tristanfletcher.co.uk%2FSVM%2520Explained.pdf&date=2016-01-26>, Son Erişim Tarihi: 27.01.2016.
34. Boser, B. E., Guyon, I. M., and Vapnik, V. N. (1992). A training algorithm for optimal margin classifiers. *COLT '92 Proceedings of the fifth annual workshop on Computational learning theory*, 144-152.
35. İnternet: Jakkula, V. Tutorial on Support Vector Machine (SVM). School of EECS, Washington State University. URL: <http://www.webcitation.org/query?url=http%3A%2F%2Fwww.ccs.neu.edu%2Fcourse%2Fcs5100f11%2Fresources%2Fjakkula.pdf&date=2016-01-26>, Son Erişim Tarihi: 27.01.2016.
36. İnternet: Osuna, Ricardo Gutierrez. Introduction to Pattern Recognition. Wright State University. URL: http://www.webcitation.org/query?url=http%3A%2F%2Fcourses.cs.tamu.edu%2Frgutier%2Fcs790_w02%2F18.pdf&date=2016-01-26, Son Erişim Tarihi: 27.01.2016.
37. Anthony, G., Gregg, H., and Tshilidzi, M. (2007). Image classification using SVMs: one-against-one vs one-against-all. *Proceedings of the 28th Asian Conference on Remote Sensing*.

EKLER

EK-1. Polinomiyal çekirdek fonksiyonlu SVM için ROC eğrileri




Şekil 1.1. 2S1 hedef tipi için ROC eğrisi (SVM-Polinomiyal çekirdek)




Şekil 1.2. BTR-60 hedef tipi için ROC eğrisi (SVM-Polinomiyal çekirdek)

EK-1. (devam) Polinomiyal çekirdek fonksiyonlu SVM için ROC eğrileri




Şekil 1.3. D7 hedef tipi için ROC eğrisi (SVM-Polinomiyal çekirdek)




Şekil 1.4. ZSU-23-4 hedef tipi için ROC eğrisi (SVM-Polinomiyal çekirdek)

EK-1. (devam) Polinomiyal çekirdek fonksiyonlu SVM için ROC eğrileri




Şekil 1.5. ZIL-131 hedef tipi için ROC eğrisi (SVM-Polinomiyal çekirdek)

EK-2. RBF çekirdek fonksiyonlu SVM için ROC eğrileri




Şekil 2.1. 2S1 hedef tipi için ROC eğrisi (SVM-RBF çekirdek)




Şekil 2.2. BTR-60 hedef tipi için ROC eğrisi (SVM-RBF çekirdek)

EK-2. (devam) RBF çekirdek fonksiyonlu SVM için ROC eğrileri




Şekil 2.3. D7 hedef tipi için ROC eğrisi (SVM-RBF çekirdek)




Şekil 2.4. ZSU-23-4 hedef tipi için ROC eğrisi (SVM-RBF çekirdek)

EK-2. (devam) RBF çekirdek fonksiyonlu SVM için ROC eğrileri




Şekil 2.5. ZIL-131 hedef tipi için ROC eğrisi (SVM-RBF çekirdek)

EK-3. Lineer çekirdek fonksiyonlu SVM için ROC eğrileri




Şekil 3.1. 2S1 hedef tipi için ROC eğrisi (SVM-Lineer çekirdek)




Şekil 3.2. BTR-60 hedef tipi için ROC eğrisi (SVM-Lineer çekirdek)

EK-3. (devam) Lineer çekirdek fonksiyonlu SVM için ROC eğrileri




Şekil 3.3. D7 hedef tipi için ROC eğrisi (SVM-Lineer çekirdek)




Şekil 3.4. ZSU-23-4 hedef tipi için ROC eğrisi (SVM-Lineer çekirdek)

EK-3. (devam) Lineer çekirdek fonksiyonlu SVM için ROC eğrileri




Şekil 3.5. ZSU-23-4 hedef tipi için ROC eğrisi (SVM-Lineer çekirdek)

EK-4. 3-NN sınıflandırıcı için ROC eğrileri




Şekil 4.1. 2S1 hedef tipi için ROC eğrisi (3-NN sınıflandırıcı)




Şekil 4.2. BTR-60 hedef tipi için ROC eğrisi (3-NN sınıflandırıcı)

EK-4. (devam) 3-NN sınıflandırıcı için ROC eğrileri




Şekil 4.3. D7 hedef tipi için ROC eğrisi (3-NN sınıflandırıcı)



Şekil 4.4. ZSU-23-4 hedef tipi için ROC eğrisi (3-NN sınıflandırıcı)

EK-4. (devam) 3-NN sınıflandırıcı için ROC eğrileri



Şekil 4.5. ZIL-131 hedef tipi için ROC eğrisi (3-NN sınıflandırıcı)

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : DEMİRHAN, Mahmut Esat
 Uyuğu : T.C.
 Doğum tarihi ve yeri : 1987, Ankara
 Medeni hali : Evli
 E-mail : mahmutesat@gmail.com

Eğitim

Derece	Eğitim Birimi	Mezuniyet tarihi
Yüksek lisans	Gazi Üniversitesi Elektrik-Elektronik Mühendisliği	2016
Lisans	Başkent Üniversitesi Elektrik-Elektronik Mühendisliği	2009
Lise	Yavuz Sultan Selim Anadolu Lisesi	2005

İş Deneyimi

Yıl	Yer	Görev
2013-halen	TÜBİTAK	Araştırmacı
2012-2013	AHM Enerji	Proje Mdr. Yrd.
2011-2012	Türk Telekom	Kablosuz Transmisyon Sist. Müh.
2010-2011	Bilim, Sanayi ve Tekn. Bakanlığı	Uzman Yrd.

Yabancı Dil

İngilizce

Yayınlar

1. Demirhan, M. E. and Arıöz, U. (2015). Huffman coding of a PCM-quantized speech signal. *IEEE 23rd Signal Processing and Communications Applications Conference (SIU)*, 160-163.



GAZİ GELECEKTİR..