

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**KENAR KORUYAN GÖRÜNTÜ AYRIŞIM YÖNTEMLERİ İLE SAR
GÖRÜNTÜLERİNDE OTOMATİK HEDEF SINIFLAMA PERFORMANSININ
ARTTIRILMASI**

YÜKSEK LİSANS TEZİ

Haldun BOZKURT

Elektrik Elektronik Mühendisliği Anabilim Dalı

Telekomünikasyon Mühendisliği Programı

Haziran 2016

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**KENAR KORUYAN GÖRÜNTÜ AYRIŞIM YÖNTEMLERİ İLE SAR
GÖRÜNTÜLERİNDE OTOMATİK HEDEF SINIFLAMA PERFORMANSININ
ARTTIRILMASI**

YÜKSEK LİSANS TEZİ

Haldun Bozkurt

504111348

Elektrik Elektronik Mühendisliği Anabilim Dalı

Telekomünikasyon Mühendisliği Programı

Tez Danışmanı: Doç. Dr. Işın ERER

Haziran 2016

İTÜ, Fen Bilimleri Enstitüsü'nün 504111348 numaralı Yüksek Lisans Öğrencisi Haldun BOZKURT, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “KENAR KORUYAN GÖRÜNTÜ AYRIŞIM YÖNTEMLERİ İLE SAR GÖRÜNTÜLERİNDE OTOMATİK HEDEF SINIFLAMA PERFORMANSININ ARTTIRILMASI” başlıklı tezini aşağıda imzaları olan jürié önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç.Dr.Işın Erer**

İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof.Dr.Ahmet Hamdi Kayran**

İstanbul Teknik Üniversitesi

Yrd.Doç.Dr.Serdar Kargın

Beykent Üniversitesi

Teslim Tarihi : **02 Mayıs 2016**

Savunma Tarihi : **09 Haziran 2016**

Oyala beni dünya,

ÖNSÖZ

B.

Tez çalışmam boyunca yol göstericiliği yapan bilgi ve tecrübesini esirgemeyen hocam Sn. Doç.Dr.İşın YAZGAN ERER'e en içten teşekkürlerimi sunarım.

Bu süreç boyunca desteğini her an desteğini hissettiren sürece ara vermek zorunda kaldığım vakitte hiçbir sorun etmeden hep yanımda olan annem Şerife BOZKURT'a, babam Seyfi BOZKURT'a ve ailemin diğer tüm fertlerine büyük müteşekkirim.

Tezin başlanmasından geliştirilmesine kadar büyük emekler ortaya koyan arkadaşım Koray SARIKAYA'ya teşekkür ederim.

Yüksek lisans sürecinde gerekli desteği sağlayan İstanbul Ulaşım A.Ş. yöneticilerine de teşekkür ederim.

Mayıs 2016

Haldun Bozkurt

İÇİNDEKİLER

Sayfa

ÖNSÖZ	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
SEMBOLLER	xiii
ÇİZELGE LİSTESİ	xv
ŞEKİL LİSTESİ	xvii
1. GİRİŞ	1
2. SENTETİK AÇIKLIKLI RADAR (SAR)	4
2.1 Amaç	4
2.2 SAR Genel Bilgiler	4
2.3 SAR Görüntüleme Teknikleri	5
2.3.1 İki boyutlu FFT yöntemi	5
3. RADAR GÖRÜNTÜ SORUNLARI	11
3.1 Benek Gürültüsü	11
3.2 Benek Gürültüsünü Bastırma	15
3.3 Detayların Korunması	15
3.4 Görüntü İyileştirme Yöntemleri	16
3.4.1 Medyan filtre	16
3.4.2 ATWT	17
3.4.3 Ağırlıklandırılmış ATWT	19
3.4.4 Bilateral filtre	21
3.5 Benek Gürültüsü Azaltma Performans Metrikleri	24
3.5.1 Eş ölçüm sayısı	24
3.5.2 Kenar koruma oranı	24
3.6 Görüntü Kalite Metrikleri	25
3.6.1 Entropi	25
3.6.2 Hedef arkaplan oranı	25
3.6.3 Ana lob genişliği	26
3.6.4 Hedef arkaplan entropi farkı	26
4. RADAR HEDEF SINIFLAMA PROBLEMİ	27
4.1 Ön Hazırlık	27
4.2 Polar Eşleme	28
4.3 Temel Bileşenler Analizi	34
4.4 Eğitim Veri Setinin Oluşturulması	36
4.5 KNN - k-En Yakın Komşuluk Algoritması	38
4.6 Destek Vektör Makineleri	40
4.6.1 Doğrusal ayrılma	40
4.6.2 Tam olarak doğrusal ayrılamama	42
4.6.3 Doğrusal ayrılamama (Çekirdek fonksiyonlar)	44

4.6.4 Mercer koşulları	45
4.6.5 Çekirdek fonksiyonu seçimi.....	45
4.6.6 Doğrusal çekirdek	46
4.6.7 Polinomik çekirdek	46
4.6.8 Radyal tabanlı çekirdek.....	46
5. DENEYSEL SONUÇLAR.....	48
5.1 MSTAR Veri Seti	48
5.2 Filtreleme Etkileri.....	53
5.3 Katsayıların Görüntülere Etkisi	55
5.4 Katsayıların Belirlenmesi	58
5.5 Sınıflama Sonuçları:	63
6. SONUÇLAR VE DEĞERLENDİRMELER	68
KAYNAKLAR.....	70
EK.A FİLTRELEMENİN HEDEF GÖRÜNTÜLERİNE ETKİSİ.....	75
EK.B SINIFLAMA KARŞILAŞTIRMA MATRİSLERİ.....	78
ÖZGEÇMİŞ.....	93

KISALTMALAR

2B	:İki Boyutlu
AR	:Auto Regression
ATWT	:A Trous Wavelet Trasnform
DVM	:Destek Vektör Makinesi
ESI	:Kenar Koruma Oranı
ENL	:Eş Ölçüm Sayısı
FFT	:Fast Fourier Transform
GHz	:Giga Hertz
IFFT	:Ters Fast Fourier Transform
ISAR	:Ters Sentetik Açıklıklı Radar
Mhz	:Mega Hertz
MLBW	:Ana saçıcı lob genişliği
MUSIC	:Multiple Signal Classification
MSTAR	:Moving and Stationary Target Acquisition and Recognition
KNN	:k-En yakın komşu algoritması
km	:Kilometre
PCA	:Principal Component Analysis
RCS	:Radar Cross Section
SAR	:Sentetik Açıklıklı Radar
TBED	:Hedef arka plan entropi farkı
TBR	:Hedef arka plan oranı

SEMBOLLER

B	: Bant genişliđi
c	: Işıđ hızı
<i>f_c</i>	: Merkez frekans
m	: Ortalama
<i>σ</i>	: Standart sapma
x	: Menzil Çözünürlüđü
y	: Çapraz menzil çözünürlüđü

ÇİZELGE LİSTESİ

Sayfa

Çizelge 5.1 : Bilateral filtre için sıralı görüntü metrik değerleri	56
Çizelge 5.2 : Ağırlıklı ATWT için sıralı görüntü metrik değerleri	58
Çizelge 5.3 : Bilateral Filtre için gürültü metriklerine göre sonuç.....	59
Çizelge 5.4 : Ağırlıklı ATWT için gürültü metriklerine göre sonuç.....	60
Çizelge 5.5 : Bilateral Filtre için görüntü metriklerine göre sonuç.....	61
Çizelge 5.6 : Ağırlıklı ATWT için görüntü metriklerine göre sonuç.....	62
Çizelge 5.7 : Sınıflama deney sonuçları.....	64
Çizelge 5.8 : DVM ile sınıflanmış filtrelenmemiş görüntü sonucu (Eğitim:%50). 65	
Çizelge 5.9 : DVM ile sınıflanmış bilateral filtre sonucu (Eğitim kümesi:%50)... 66	
Çizelge B.1 Filtersiz (KNN-%10)	78
Çizelge B.2 Medyan Filtreli (%10-KNN)	78
Çizelge B.3 ATWT (%10-KNN).....	79
Çizelge B.4 Ağırlıklı ATWT (%10-KNN).....	79
Çizelge B.5 Bilateral (%10-KNN)	79
Çizelge B.6 Filtresiz (%10-DVM)	80
Çizelge B.7 Medyan Filtreli (%10-DVM).....	81
Çizelge B.8 ATWT (%10-DVM)	81
Çizelge B.9 Ağırlıklı ATWT (%10D-DVM)	82
Çizelge B.10 Bilateral (%10-DVM).....	82
Çizelge B.11 Filtersiz (%33-KNN)	83
Çizelge B.12 Medyan Filtre (%33-KNN)	83
Çizelge B.13 ATWT (%33-KNN).....	84
Çizelge B.14 Ağırlıklı ATWT (%33-KNN).....	84
Çizelge B.15 Bilateral Filtre (%33-KNN).....	85
Çizelge B.16 Filtresiz (%33-DVM)	85
Çizelge B.17 Medyan (%33-DVM)	86
Çizelge B.18 ATWT (%33-DVM)	86
Çizelge B.19 Ağırlıklı ATWT (%33-DVM)	87
Çizelge B.20 Bilateral (%33-DVM).....	87
Çizelge B.21 Filtresiz (%50-KNN)	88
Çizelge B.22 Medyan Filtre (%50-KNN)	88
Çizelge B.23 AWT (%50-KNN)	89
Çizelge B.24 Ağırlıklı ATWT (%50-KNN).....	89
Çizelge B.25 Bilateral Filtre (%50-KNN).....	90
Çizelge B.26 Filtresiz (%50-DVM)	90
Çizelge B.27 Medyan Filtre (%50-DVM).....	91
Çizelge B.28 ATWT (%50-DVM)	91
Çizelge B.29 Ağırlıklı ATWT (%50-DVM)	92

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Yapay açıklıklı radar sistemi çalışması [3].....	5
Şekil 2.2 : M saçılma merkezine sahip hedef [5].	6
Şekil 2.3 : Model Bir Uçağın Menzil Profili [3].	7
Şekil 2.4 : Model Bir Uçağın Çapraz Menzil Profili [4].	8
Şekil 2.5 : Polar Format Algoritması ile (f, θ) domeninden (fx, fy) domenine geçiş[4].....	9
Şekil 3.1 : Tipik benek gürültüsü	12
Şekil 3.2 : WATWT yöntemiyle görüntü ayrıştırma ve birleştirme	21
Şekil 3.3 : a) $\sigma_s=100$ b) $\sigma_s=0.001$ c) $\sigma_r=100$ d) $\sigma_r=0.001$	22
Şekil 3.4 : Çokluçözünürlük bilateral süzgeçler ile görüntü ayrıştırma ve birleştirme	23
Şekil 4.1 : Log-Polar Izgara (üstte) , Polar Izgara (altta) [26].	29
Şekil 4.2 : Polar Görüntü Geometrisi [26]	30
Şekil 4.3 : F16 uçak ters SAR görüntüsü ve polar ızgarası [36].	32
Şekil 4.4 : F16 uçak ISAR görüntüsü ve polar ızgarası, döndürülmüş ve açısı.....	32
Şekil 4.5 : Şekil 4.3'e karşı gelen Polar görüntü $Ir(r)$ ve $I\theta(\theta)$: $Nr= N\theta = 50$ [36].	33
Şekil 4.6 : Şekil 4.4'e karşı gelen Polar görüntü $Ir(r)$ ve $I\theta(\theta)$: $Nr= N\theta = 50$ [36].	33
Şekil 4.7 : Temel bileşenler analizi için grafiksel gösterim [29].	35
Şekil 4.8 : Bir hedefin önerilen deneme veri setinin mimarisi [26].	38
Şekil 4.9 : KNN algoritması için görsel gösterim	39
Şekil 4.10 : Doğrusal olarak ayırma.....	41
Şekil 4.11 : Tam olarak doğrusal ayırlamama.....	43
Şekil 4.12 : Ayırma için boyut genişletme	44
Şekil 5.1 : MSTAR verileri elde edilen cisimlerin görüntüleri (a)-2S1, (b)-BRDM2, (c)-D7, (d)-SLICY, (e)-T62, (f)-ZIL-131 ve (g)- ZSU-23-4	49
Şekil 5.2 : 2S1 Rus Yapımı Tank modeli.....	50
Şekil 5.3 : BRDM-2 Zırhlı personel Taşıyıcı	50
Şekil 5.4 : D7 Arazözü	51
Şekil 5.5 : SLICY Çoklu Basit Şekli Durağan Hedef	51
Şekil 5.6 : T62 Sovyet Savaş Tankı	52
Şekil 5.7 : ZIL-131 Askeri Kamyon.....	52
Şekil 5.8 : ZSU-23-4 Askeri Tank	53
Şekil 5.9 : Filtresiz ve filtrelenmiş görüntüler için örnekleri (ZIL131)	54
Şekil 5.10 : Bilateral filtre çıkışlarının σ_r ve σ_s değerleriyle değişimi (ZIL131).	55
Şekil 5.11 : Ağırlıklı ATWT sonucunun σ değeriyle değişimi ($\sigma = 0.2, 0.8, 2.1$)	57
Şekil 5.12 : Bilateral filtre için Benek Gürültüsü Metrikleri Değişimi	58
Şekil 5.13 : Ağırlıklı ATWT için Benek Gürültüsü Metrikleri Değişimi	59
Şekil 5.14 : Bilateral filtre için Görüntü Metrikleri Değişimi	60
Şekil 5.15 : Ağırlıklı ATWT için görüntü metrikleri değişimi	61
Şekil 5.16 : Bilateral Filtre çıkışları için değişim grafiği	62
Şekil 5.17 Ağırlık ATWT için değişim grafiği	63
Şekil A.1 2S1	75

Şekil A.2 BDRM 2.....	75
Şekil A.3 D7.....	76
Şekil A.4 Slicy	76
Şekil A.5 T62	77
Şekil A.6 ZSU2	77

KENAR KORUYAN GÖRÜNTÜ AYRIŞIM YÖNTEMLERİ İLE SAR GÖRÜNTÜLERİNDE OTOMATİK HEDEF SINIFLAMA PERFORMANSININ ARTTIRILMASI

ÖZET

Radar teknolojisi ikinci dünya savaşının kaderini belirlemiş ve bu zamana kadar çok büyük bir aşama kaydetmiştir. Özellikle son dönemde gelişen teknolojilerden biri radar teknolojileriyle görüntülemenin yapılmasıdır. Yapay olarak açıklık oluşturma tekniği ile oluşturulan bu görüntülere SAR görüntüleri denir. SAR görüntüleri her türlü hava koşulunda ve her durumda alınabildikleri için kullanılması ve değerlendirilmesi büyük önem arz etmektedir. SAR görüntülerinin en büyük kullanım alanlarından biri de görüntülenen hedeflerin belirlenmesi. Fakat bu işlem SAR görüntülerinin doğasında bulundurduğu yüksek bozucu etkiler gereği problemli olmaktadır. Bu etkilerin giderilmesinin daha kolay ve daha yüksek başarımlı bir sınıflama sağlaması beklenmektedir.

Radar görüntüleri hedefin belirli bir frekans bandı ve açı aralığında taranarak elde edilen geri yansıyan işaretlerin işlenmesi ile oluşturulur. Hedef ile radar doğrultusu menzi eksenini buna dik olan doğrultu da çapraz menzil eksenini oluşturur. Menzil ve çapraz menzil çözünürlüğü sırasıyla kullanılan frekans bandına ve gözlem açı aralığına bağlıdır. Uygulamada bu değerlerin çok yüksek tutulmaması oluşturulan radar görüntülerinde çözünürlük problemine neden olmaktadır. Ayrıca geri yansıyan işaretlerden görüntü oluşturmak için kullanılan Fourier dönüşümü de geri planda yan lob problemine neden olur. Ayrıca görüntüdeki bir çözünürlük hücresine karşı düşen hedef parçasında farklı yapıların bulunması geri yansıyan işaretlerin girişimine neden olur ve bu etki de radar görüntüsü üzerinde benek gürültüsü olarak adlandırılan tanecikler şeklinde kendini gösterir. Tüm bu bozucu etkiler radar görüntüleri ile elde edilebilecek hedef sınıflama performansını sınırlamaktadır.

Benek gürültüsü etkileri ve istatistikleri iyice çıkarılmış bir gürültü çeşididir. Bu gürültüyü bastırmak için çeşitli yöntemler önerilmiş ve kullanılmıştır. Gürültü bastırmada en önemli hususlardan biri de detayların korunmasıdır, zaten düşük çözünürlüklü olarak elde edilen görüntülerdeki detaylar içeriğinin tespit edilebilmesi için büyük önem taşımaktadır. Görüntü bastırma işlemleri genellikle yumuşatma yaptıkları için bu detayların korunması sorun olmaktadır. Bu sebeple en önemli detaylardan biri olan kenarların korunması için kenar koruma özellikli filtreler benek gürültüsünün bastırılması için kullanılmaktadır. Bu filtreler bölgesel medyan değeri bularak piksel içeriğini bu medyan değer ile değiştiren medyan filtre, bir tür dalgacık dönüşümü ile kenarların korunmasını sağlayan ATWT, bu dalgacık dönüşümü için yoğunluk parametresi barındıran ağırlıklı ATWT ve hem yoğunluk hem de pikseller arası ilişkinin miktarının parametrelerini barındıran bilateral filtredir.

Filtrelerin performansları görüntülerin kendinden nitel olarak anlaşılabilirse de bunların nicel olarak ölçülebilmesine de yarayan görüntü metrikleri bulunmaktadır. Bu metriklerden bir kısmı görüntünün değişimini, bir kısmı hedef üzerindeki değişiklikleri belirlerken bir kısmı da benek gürültüsünün ne kadar kaldırıldığının göstergesini verir.

SAR görüntüleri hedef sınıflama için benzersiz bir fırsat sunar. Başlangıçta bu işlem insanlar tarafından görüntülerin sınıflanması ile yapılırken zaman içinde bilgisayar teknolojisindeki ilerleme ve bilgisayar bilimlerindeki gelişmeler ile birlikte otomatik olarak bilgisayarlar tarafından yapılmaya başlanmıştır. Bunun için çeşitli otomatik tanıma algoritmaları önerilmiş ve geliştirilmiştir. Kim ve diğerleri tarafından önerilen yöntem ile hızlı bir şekilde hedeflerin tanınması yapılabilmektedir. Bu yöntemle göre dönme etkilerini azaltma amaçlı alınan görüntü, menzilde ve çapraz menzilde sıkıştırılır ve buna PCA ile özetlenmiş görüntü de eklenerek öznitelik çıkartılır. Daha sonra bu öznitekiller sınıflama işlemine tabi tutulur. Tezde sınıflama işlemi iki farklı makine öğrenmesi yöntemi kullanılarak gerçekleştirilmiştir. Bu yöntemlerden birincisi çok basit yapıda olan KNN sınıflayıcısıdır. Burada eğitim kümesinde bulunan özniteliklerden, sınıflanması istenen görüntüye en yakın k adet komşu hesaplanır, en çok komşulukta öznitelik barındıran sınıfa sınıflanması istenen görüntü de dahil edilir. Daha sofistike bir yöntem olarak karşımıza çıkan destek vektör makineleri (DVM) özellikle lineer ya da düşük düzlemlerde ayrışması zor olan kümelerde yüksek boyuta taşıma yöntemiyle sınıflayabilen bir yapıdadır.

Bu çalışmada radar görüntülerindeki bozucu etkilerin azaltılması dolayısıyla sınıflama performansının artırılması için kenar koruyan görüntü ayrışmaları sınıflama öncesi radar görüntülerine uygulanmış bozucu etkiler detay görüntülere aktratılmış sadece kalıntı görüntüler sınıflama için kullanılmıştır. Kenar koruyan ayrışmaların performansları büyük ölçüde parametrelere bağlı olduğu için farklı yaklaşımlar kullanılarak parametreler öncelikle gürültü ve görüntü metrik değerlerinin optimizasyonu sağlanarak belirlenmiş, farklı bir yaklaşım olarak da doğrudan sınıflama yüzdesini en iyileyecek şekilde seçilmiştir. Elde edilen değerler MSTAR veri setinin sınıflamasında kullanılmıştır.

Sınıflama deneyinde kullanılan MSTAR veri seti Sandia National Laboratory tarafından hazırlanmış 7 farklı kara hedefine ait 298'ar görüntü içeren bir veri setidir. Görüntüleme x bandında yapılmış her bir görüntü $1,5^o$ aralıklarla görüntülenmiştir.

Filtrelenmiş görüntülerin sınıflama performansları beklendiği üzere artmıştır, yöntemin sofistikelik seviyesi arttıkça performansta da artma görülmüştür. Özellikle parametre ile kontrol edilebilen ağırlıklı ATWT ve bilateral filtre çok daha iyi sınıflama sonuçları vermiştir. Bunlardan iki parametre içeren bilateral filtre sınıflama performansını önemli bir ölçüde arttırmıştır.

Kenar koruyan görüntü ayrışmalarına dayalı önışleme yöntemleriyle radar hedef sınıflama oranını arttırdığı gösterilmiştir. Tanıma oranının artırılması için ayrıştırma sisteminin parametrelerinin sınıflama için optimize edilmesine dayanır. Böylelikle fazlalık olan bilgi gürültüyle birlikte detay düzlemine aktarılırken, tanıma işlemi için gereken ayırıcı detayların kalıntı görüntüde kalması sağlanır. Bu gerekli bilgiyi taşıyan kalıntıların sınıflama için kullanılması tanıma oranlarının optimum düzeyde olmasını sağlar.

INCREASING AUTOMATIC TARGET RECOGNITION RATE OF SAR IMAGES VIA EDGE PRESERVING IMAGE DECOMPOSITION

METHODS

SUMMARY

Radar technology determined the flow of the second world war and since it took far away from where it started. By the developing technology radar systems are available to use in remote sensing and imagery. Synthetic apertures created by moving targets or moving radars are able to create SAR images. This imaging technic is widely available regardless of weather and lumination conditions. One of the biggest application of this images is remote target recognition. But the nature of radar imagery puts some challenges into this process. Highly corrupting effects present in radar images make them problematic for recognition algorithms. Some processes are proposed and defined to come over this effects. Suppression of this effects are expected to increase the classification performance of target recognition algorithms.

Radar images are created in high frequency region within a wide frequency band sweep. Synthetic aperture is created during the movement of the radar in this sweep period. Scattering pulses are collected to create range profiles in complex plane. Since the sweep is not in a completely linear area range profiles are taken to the Cartesian plane from cylindrical plane via interpolation and rearrangement methods. At this point received data is in cartesian plane as range profiles in a matrix. Here it must be given attention to high frequency regions in the data which are located away from the center are mostly noise. To overcome this noise windowing is applied to the data and suppress the noise cumulated in high frequency. As final step an inverse FFT is applied to create images itself as range and cross range in two dimensions.

Creation of the image includes the cascading steps listed. In this process not only applied to scatterers coming from target but also to the scatterers coming from side effects and especially from earth in the ground target imaging. During these complicated computations especially background scatterers present in ground targets are cumulated and pitches into significant noise effects. This significant effects get present in image as a granular texture in total called speckle noise. Speckle noise is well known and well-studied noise type. There are various approaches studied and proposed in order to suppress speckle noise. Since its presence is in the wide frequency bands and these approaches includes mostly filtering technics. One of the most important aspects of the speckle suppression technics should be protection of the target details. SAR images are already in the low resolution, protection of the details in the images have a huge importance in recognition of the targets in the images. Speckle suppression filters mostly work via smoothing operation which could be problematic for detail preserving. Especially edges and fine lines are mostly gets erased or become unnoticeable after smoothing operation. To prevent this there are edge preserving filters present which are eligible to be used in speckle suppression. These filters are median filter which replaces the value of the pixel with the median of the frame region, a shift invariant application of wavelet transform ATWT that protects edges; another variant of this wavelet with a parameter to set

intensity of the operation called weighted ATWT, and a filter consists with two parameters one to consider intensity and another one sets the effect of neighboring pixels on the operated pixel called bilateral filter.

Effects of the filters on the images can be assessed visually, but this will be a highly qualified and subjective assessment. In order to achieve a better assessment and success an objective evaluation we need to employ some quantitative measures. There are some metrics defined to measure state of SAR images, while some of them takes care of the image general like entropy some of them takes account of target area like main lobe width, some of the metrics solely focuses on speckle reduction like equivalent number of looks, and some like edge save index focuses on the edges present in the images and tracks the changes among them.

Since SAR is operational regardless of the weather conditions and since it can extract more information it is really suitable for target recognition applications. While recognition is performed by the human operators at the beginning as the technological developments in the information processing and computer applications this task is left to computers with the automatic target recognition. To perform automatic target recognition various methods are suggested. There are some criterions should be better to taken care while choosing the ATR method, first one of course the recognition precision, but the computational load and applicability to different mediums are also contributes towards suitability. The ATR method proposed by Kim et. al. is easily implementable with an ease of computation. According to this method images are processed to get feature vectors. Each image is summed vertically and horizontally and an additional PCA compressed summary of the image are used together to create feature vector in one dimension. This feature vector creation procedure is repeated for each images in the data set. Feature vectors extracted are split into two parts one part is used for training group for the classification algorithm and the rest is used as test group which is classified through the algorithm to see its performance. As classification algorithms two different algorithms uses different approaches are used to verify the consistency of the results. KNN k-Nearest neighborhood algorithm calculates k number of the closest neighbors and tags the test vector as the majority target. It is a really simple and reliable algorithm. Other algorithm is a more sophisticated algorithm support vector machine (SVM) which brings non linearly separable targets to higher dimension and makes a classification through it.

MSTAR dataset used in experiment is a data set prepared for US Air Force by Sandia National Laboratory, later it made public for the research purposes. Data set contains various images, targets taken in various scenarios. But in the volume we are interested there are 7 different targets each with the 298 images taken from various angles. Images are taken in X band and each image has a 1.5° difference to the following image.

Noise suppressed images via filtering technics had an increase in the classification performance as it is expected. Also a more sophisticated classifier resulted a better classification in a harmony with the simple classifier. Especially weighted ATWT and bilateral filter those are parameter optimized filters made a bigger increase in the classification results. Bilateral filter that consists two parameters outperformed weighted ATWT and resulted a significant increase in classification performance.

1. GİRİŞ

SAR görüntülerinin, görüntülenen hedeflerin makro özelliklerini yüksek ayıricılıkta barındırmaları ve her türlü hava koşulunda yüksek performanslı olarak alınabilmeleri otomatik hedef sınıflama uygulamalarında çokça kullanılmalarının en büyük nedenleri arasındadır.

SAR görüntüleri hedef sınıflama uygulamalarında çokça kullanılmakla birlikte sınıflama performansını etkileyen bozucular barındırırlar. Bu bozucuların üstesinden gelmek için çözünürlük artırma [1] ve gürültü bastırma [7] gibi yöntemler kullanılarak sınıflama başarımı yükseltilmeye çalışılır.

Çözünürlük artırma yöntemleri genellikle geri saçılan alandan görüntüye geçişte farklı yöntemlerin daha geniş spektrumda tarama yapması esasına dayanır[8]. Bu tür yöntemler sınıflama başarımına katkı sağlamalarına rağmen işlem yükü açısından yoğunluk içerirler.

Gürültü bastırma yöntemleri genellikle SAR görüntülerinde tipik olarak beliren benek gürültüsünü azaltmaya yönelik yöntemlerdir. Bu yöntemler genellikle alınmış görüntüler üzerinde filtreleme yapılması esasına dayanır. Bu işlem için medyan filtre gibi standart filtreler önerildiği gibi dalgacık tabanlı filtreler de geliştirilmiştir. Burada filtreler için en büyük sorun tekdüze alanların düzgün temizlenememesi ve detayların kontrolsüz olarak yumuşamaya uğramasıdır [11,12,19].

Otomatik hedef tanıma uygulamaları genellikle görüntünün içeriğinin tespit edilebilmesi için bir makine öğrenmesi algoritmasına girdi olarak verilmesi yolu ile yapılır. Bu işlemin bellek ve işlem gücü açısından ekonomik olması için görüntü yerine görüntüyü temsil edecek niteliklerin sınıflama algoritmalarına verilmesidir. Bunun için çeşitli yöntemler önerilmiştir [33,35,36]. Öznitelik çıkarma işlemi olarak adlandırılan bu yöntemlerin en büyük kısıtlarından biri genel olarak uygulanabilir olmamaları, belirli veri setlerini sınıflamak üzere geliştirilmiş olmalarıdır. İyi bir

öznitelik çıkarma işleminin kolaylıkla ve yüksek doğrulukla farklı verilere uygulanabilir olması beklenmektedir.[37]

Bu çalışmada bilinmeyen bir cismin SAR görüntüsünün tanımlanması ve sınıflandırılması için performans artırılması amaçlanmış bunun için de SAR görüntülerinde tipik olarak bulunan benek gürültüsünün bastırılması amaçlanmıştır. Bu işlemin daha yüksek performans verebilen bir yapıda olması için değişken parametreleri bulunan filtrelerin kullanılabileceği savunulmuştur.

Tezde veri seti olarak hedeflenen sorunların ve uygulanan yöntemlerin sınanabileceği MSTAR veri setinden alınan hedef görüntüleri kullanılmıştır. Alınan 7 adet hedef yerde ve durağan durumda iken hareketli bir radar tarafından görüntülenmiştir.

Çalışmada öncelikle yapay açıklıklı radarlar ile ilgili bilgi verilmiş, radar kullanarak görüntü oluşturma presibi anlatılarak, görüntü oluşumunda hangi işlemlerden geçtiği verilmiştir.

Üçüncü bölümde SAR görüntülerinde tipik olarak beliren benek gürültüsü açıklanmış ve istatistiksel özellikleri verilmiştir. Benek gürültüsü bastırmanın niçin önemli olduğu ve nasıl yapılabileceği açıklandıktan sonra tezde gürültü bastırma işlemi için kullanılan filtreler verilmiştir, bunlar standart filtrelerden olan ve bene gürültüsü bastırmada sıklıkla kullanılan medyan filtre, dalgacık tabanlı bir dönüşüm olan ATWT, ATWT'nin yoğunluk niteliğinin değiştirilebildiği ağırlıklı ATWT ve kenar koruyan bir yapıya sahip olan bilateral filtredir. Bölümün devamında detay korumanın ne anlama geldiği ve görüntüleri nasıl etkilediği açıklandıktan sonra görüntü kalite metrikleri ve gürültü performans metrikleri verilmiştir. Görüntü kalite metrikleri olarak entropi, hedef arka plan oranı, ana lob genişliği ve hedef arkaplan entropi farkı tanımlanmış, benek gürültüsü metrik olarak da gürültü seviyesini veren eş ölçüm sayısı, kenarların ne kadar korunduğu gösteren kenara koruma oranı verilmiştir.

Dördüncü bölümde radar hedef sınıflama problemi anlatılmış, burada öznitelik çıkarma için gereken işlemler görüntülerin polar eşlemeden geçirilmesi, temel bileşenler analizinin yapılması ve veri setinin hazırlanması olarak sıralanmıştır. Sonrasında sınıflama için kullanılan makine öğrenmesi algoritmaları KNN ve DVM detaylandırılmış, DVM algoritması için çekirdek seçiminin hangi kriterlere dayandığı ve çekirdek seçiminin nasıl yapıldığı aktarılmıştır. Deneysel sonuçlarda öncelikle

kullanılan MSTAR veri setinin özellikleri anlatılarak, içeriği açıklanmıştır. Devamında filtrelerin bu veri setinden alına görüntüler üzerinde yaptığı etkiler incelenerek bulgular paylaşılmıştır. Tezde incelenen parametre içeren filtrelerin parametre değişimlerinin görüntülerde oluşturduğu etki de bu bölümde incelenmiş sonrasında bu parametrelerin sınıflamaya göre optimize edilmesi katsayıların belirlenmesi başlığında gösterilmiştir. Son olarak da verilen filtreler ile işlemden geçirilmiş görüntülerin farklı eğitim kümesi boyutlarıyla verilen iki makine öğrenmesi algoritmasıyla sınıflanması yapılmış elde edilen bulgular paylaşılmıştır.

Tüm bulgular en son sonuç ve değerlendirmeler bölümünde açıklanmıştır.

2. SENTETİK AÇIKLIKLI RADAR (SAR)

2.1 Amaç


Bu bölümde SAR ile ilgili genel bilgiler sunulacaktır.

2.2 SAR Genel Bilgiler

Geleneksel radar sistemlerinin çözünürlük kısıtları önemli boyutlardadır. Bu radarlarda menzil çözünürlüğünü (range resolution) arttırmak için darbe süresini kısaltmak gerekmektedir. Ancak darbe süresinin kısalması işaret-gürültü oranını azaltmaktadır. Geleneksel radar sistemlerinde arzu edilen çözünürlüğü yakalamak için pratikte gerçekleştirilemeyecek anten boyutları gerekmektedir.[1]

Yapay açıklıklı radar (synthetic aperture radar-SAR), geleneksel radar sisteminin kısıtlarını fiziksel gerçekleştirilebilirlik açısından makul düzeye çekmek için geliştirilmiştir. Yapay açıklıklı radar sistemlerinde, bir uydu veya bir uçak ile taşınan radar, mümkün olduğunca sabit bir hızla belirli bir yönde hareket ettirilmektedir. Radar, ileri yönlü hareketi esnasında belirli bir süre boyunca belirli sayıda darbe göndermektedir. Radar tarafından gönderilen darbelere ait yansıyan işaretler yine radar tarafından toplanmaktadır. Toplanan işaretler uygun bir biçimde kaydedilmekte ve birleştirilmektedir. Bu sayede yapay açıklık oluşturulmaktadır. Platformun hızı ve toplam darbe gönderme süresi yapay açıklığın boyunu belirlemektedir. Yapay açıklıklı radar yönteminde her nokta daha uzun süre gözlenmektedir (Şekil 2.1). Bu sayede platformun ilerleme yönüne paralel olan azimut doğrultusunda aynı boydaki gerçek açıklıklı bir antene göre daha yüksek çözünürlük elde edilir[2]. SAR görüntüsü oluşturmak için kullanılan geleneksel yöntem hesaplama kolaylıkları ve hızı nedeniyle 2 boyutlu Fourier dönüşümüdür. Menzil ve çapraz menzil çözünürlükleri ölçüm yapılan frekans bant genişliği ve açı gözlem aralığı ile doğru orantılı olduğundan bu değerlerin kısıtlı olduğu durumlarda 2 boyutlu Fourier Dönüşümü düşük çözünürlük sunar. Bu koşullarda Fourier dönüşümü yerine yüksek çözünürlüklü spektral kestirim yöntemlerinin kullanılması SAR görüntüsünün çözünürlüğünü arttırmaktadır. Autoregressive Model (AR), MUSIC (Multiple Signal Classification)[4-5] bu yöntemlerden ikisidir. Bu yöntemlerin Fourier Dönüşümü Yöntemi'ne göre en büyük

avantajları dar bant koşullarında bir birine yakın saçılma noktalarını ayırt edebilmesidir[6]. MUSIC (Multiple Signal Classification) metodu elde edilen verinin özilişki matrisinin sinyal ve gürültü özvektörlerinin dikliğine dayanmaktadır [4]. AR Modelleme ise 2-boyutlu kartezyen frekans spektrumunun 2-boyutlu lineer kestirimine (linear prediction) dayanmaktadır [5].



Şekil 2.1 : Yapay açıklıklı radar sistemi çalışması [3]

2.3 SAR Görüntüleme Teknikleri

2.3.1 İki boyutlu FFT yöntemi


2-boyutlu SAR görüntüsü görüntülenmek istenen hedefin menzil ve çapraz menzil profilinin işlenmesi sonucu elde edilmektedir. 2-boyutlu FFT yöntemi frekans domaininde toplanan verileri ters Fourier dönüşümü ile konum domainine çevirerek görüntünün elde edilmesini sağlar. Frekans bant genişliği ve hedefin izlendiği açı aralığı yeterince geniş olduğunda bu yöntem yeterli çözünürlüğü sağlayabilmektedir. Burada görüntü çözünürlüğü frekans bant genişliği ve izlenen açı aralığıyla doğru orantılı olarak artar. Pratikte yüksek bant genişliğini ve geniş açı aralığını sağlamak çoğu zaman mümkün olmadığından bu yöntemin kullanım alanı daralmaktadır.[1]

SAR görüntülerini elde etmek için genellikle frekans domainindeki datadan 2-boyutlu Fourier dönüşümü ile konumsal domaine geçilir. Bu dönüşüm işlemini sağlıklı bir şekilde yapabilmek için hedefin ya da SAR platformunun doğrusal olmayan hareketinden kaynaklı problemlerin giderilmesi, faz ayarlamalarının, menzil hizalama

(range alignment) işlemlerinin ön işlem olarak yapılması gerekmektedir. Bu çalışmada bu problemlerin giderildiği, elde olan ham datanın bu işlemlerden geçirildiği varsayılmıştır.

ISAR görüntüsü elde etmek en sık kullanılan yöntem 2 Boyutlu Fourier Dönüşümü'dür. Fourier dönüşümü Hızlı Fourier Dönüşümü (FFT – Fast Fourier Transform) ile gerçekleştirildiğinde hem işlem zamanı hem de bu işlemin hesaplama yükü açısından büyük bir tasarruf yapılmış olunur [7].

ISAR sistemlerinde menzil ve çapraz menzil profilinin elde edilip görüntünün gerçek zamanlı oluşturulabilmesi için genelde frekans atlamalı (chirp) darbeler kullanılmaktadır. Görüntü elde edilmesinde kullanılacak iki boyutlu veri, hedefe farklı frekans ve açı aralıklarıyla yollanan elektromanyetik dalganın hedefin saçılma noktalarından ulaşip saçılması sonrasında radar tarafından toplanmasıyla oluşur (Şekil 2.2).




Şekil 2.2 : M saçılma merkezine sahip hedef [5].

Verici antenden yayımlanan dalga formu, yansıtıcı cisimden yansyarak radar alıcısına ulaşır ve dalga yayılım hızından hedefin menzil profili oluşturulur. Eğer gönderilen dalga formu zaman domenindeyse, hedeften yansıyan ve alıcı anten tarafından toplanan sinyal 1 boyutlu menzil profilini oluşturur. Ancak gönderilen dalga formu

frekans darbeleri (chirp) şeklindeyse, 1 boyutlu menzil profili toplanan bu sinyalin Ters Fourier dönüşümüyle oluşturulur.

Şekil 2.3’de görüldüğü üzere radar anteninden gönderilen dalgalar, hedefin saçılma merkezlerinden saçılıma uğrar. Eğer saçılma merkezleri radara göre farklı konumlarda olurlarsa bu merkezlerden saçılan dalgalar radara farklı zaman dilimlerinde ulaşacağından hedefin menzil profili oluşturulmuş olur. Ancak aynı uzaklık üzerindeki birden fazla saçılma merkezi tek bir saçılma merkezi olarak görüleceğinden menzil profiline de bu şekilde yansiyacaktır. Bu durum da sadece menzil profili kullanılarak hedef hakkında ayrıntılı bir bilgi edinmemin mümkün olmadığını göstermektedir[3].



Şekil 2.3 : Model Bir Uçağın Menzil Profili [3].


Gönderilen dalganın bant genişliği B , ışık hızı c ile ifade edildiğinde menzil çözünürlüğü Δx aşağıdaki bağıntıyla hesaplanır.

$$\Delta x = \frac{c}{2B} \quad (2.1)$$

((2.1) bağıntısından da görüldüğü üzere menzil çözünürlüğü sinyalin bant genişliğine bağlıdır ve dalganın şeklinden bağımsızdır[8]. Bunun yanında menzil örnekleme sayısı N olmak üzere radarın gözlemleyeceği alan x_{max} aşağıda belirtilen bağıntıyla bulunur.

$$X_{\max} = N \cdot \Delta x \quad (2.2)$$

((2.2) bağıntısına göre hedefin tamamının gözlemlenebilmesi için $x_{\max}$ değerinin en az hedefin boyu kadar olması gerekmektedir[3]. Çapraz menzil profili radar tarafından farklı açı aralıklarında gönderilen ve hedefin saçılma merkezlerinden saçılan elektromanyetik dalgaların toplanması sonucu elde edilmektedir.



Şekil 2.4 : Model Bir Uçağın Çapraz Menzil Profili [4].


f_c merkez frekansı, Ω gözlem açı genişliği olmak üzere çapraz menzil çözünürlüğü Δy aşağıdaki gibi ifade edilir.

$$\Delta y = \frac{c}{2 f_c \Omega} \quad (2.3)$$

(2.3) bağıntısında görüldüğü gibi çapraz menzil çözünürlüğünün iyileşmesi için gözlem açısı genişliğinin artması gerekmektedir. Çapraz menzil örnekleme sayısı M olmak üzere radarın çapraz menzilde gözlemleyebileceği alan $y_{\max}$ da;

$$Y_{\max} = M \cdot \Delta y \quad (2.4)$$

bağıntısıyla gösterilir. Menzil profilinde olduğu gibi hedefin çapraz menzilde tamamının görüntülenebilmesi için $Y_{\max}$ yeteri kadar büyük seçilmelidir [3].



Şekil 2.5 : Polar Format Algoritması ile (f, θ) domeninden (f^x, f^y) domenine geçiş[4].

Radar görüntüsü, hedefin sınırlı sayıda sağılma merkezi ve bu sağılma merkezlerinin etkileşimi sonucu toplanan veriler toplamı olarak tanımlanabilir. Hedeften yansıyan sinyaller hedefin her sağılma merkezinden sağılan kompleks yapıdaki sağılma sinyalleri olarak temsil edilir. d sağılma merkezinden oluşan ve M adet frekans f_m ($m = 0, 1, \dots, M - 1$) ve N adet açı θ_n ($n = 0, 1, \dots, N - 1$) değerinde ölçülen radar hedefinden sağılan sinyal aşağıdaki gibi ifade edilir.

$$x'(m, n) = \sum_{k=1}^d s_k \cdot e^{j 4 \pi \frac{f_m}{c} (x_k \cos \theta_n - y_k \sin \theta_n)} + u(m, n) \quad (2.5)$$

Bu ifadede s_k k 'nci sağılma merkezinin kompleks sağılma yoğunluğunu, x_k ve y_k k 'nci sağılma merkezinin alınan referans noktasına göre iki boyutlu konumunu, c ışık

hızını ve $u(m, n)$ ek gürültüyü ifade eder. Bu gürültünün genellikle sıfır ortalamalı ve varyanslı (σ^2) beyaz Gaussian gürültüsü olduğu varsayılmaktadır [4].

Şekil 2.5’de görüldüğü üzere frekans – açı (f, θ) domenine eşit aralıklarla dağılmış radar verisi uzamsal (kartezyen) domende eşit aralıklarla dağılmış veriyi tam olarak karşılayamaz [5]. Bilindiği üzere iki boyutlu radar görüntüleme işleminde frekans domeni menzil profilini, açı domeni ise çapraz menzil profilini oluşturmaktadır. 2.5 bağıntısından da açıkça görüleceği üzere iki fourier dönüşüm çifti ($f \cos \theta \leftrightarrow x, f \sin \theta \leftrightarrow y$) f ve θ ’ye göre birbirinden ayrılabilir durumda değildir. Ölçülen veri dar açı ölçüm aralığında aralığında olduğunda küçük açılar yaklaşımından ($\cos \theta \approx 1$ ve $\sin \theta \approx \theta$) faydalanılarak veri ayrılabilir fourier çiftlerine dönüştürülebilir. Ancak bu yaklaşım sonucu elde edilen görüntüde odaklama sorunu oluşur. Odaklanmış görüntü Şekil 2.5’te gösterildiği üzere frekans-açı domenindeki verinin ayrılabilir değişkenleri $f^x = f \cos \theta$ ve $f^y = f \sin \theta$ kullanılarak polar format algoritması ile kartezyen koordinatlara (rectangular grid) interpolate edilmesiyle elde edilir. Bu işlemler sonucunda denklem aşağıdaki şekilde yeniden yazılabilir.

$$x'(m, n) = \sum_{k=1}^d s_k \cdot e^{j \frac{4\pi}{c} (f_m^x x_k - f_n^y y_k)} + u(m, n) \quad (2.6)$$

Şekil 2.5’te görüldüğü üzere polar format algoritması ile interpolasyon yapılmış veri artık f^x ve f^y doğrultusunda eşit artım aralıklarıyla kartezyen koordinata yayılmıştır. Bu veriye Fourier dönüşümü uygulandığında klasik radar görüntüsü elde edilebilir [4]. Görüntü iyileştirme için “sıfır ekleme”, “pencereleme” gibi yöntemler kullanılabilir [3].

3. RADAR GÖRÜNTÜ SORUNLARI

Teorik olarak SAR sistemleri mesafeden bağımsız olarak hedeflerin menzil boyunca çözünürlüklü görüntülemesini yapabilmesi uzaktan algılama ve belirleme için çok cazip bir nitelikler. Bununla birlikte SAR görüntüleri saçılan ve geri yansıyan elektromanyetik işaretlerin artarda birçok seviyede işlenmesi ile oluşturulur bu işlemler sırasında görüntü benek gürültüsüne açık hale gelmektedir. Görüntüde benek gürültüsünün yüksek olması hem insan operatörler hem de otomatik hedef algılama algoritmaları için görüntü içeriğinin anlaşılmasını ve sınıflanmasını güç hale getirir. Benek gürültüsünü bastırmak için farklı yöntemler teklif edilmiştir, bunlardan en çok kullanılan iki yöntemden birincisi görüntülerin alınırken farklı açılardan elde edilen saçıcılar üzerinden ilişkisiz olan kısımların hesaplanarak benek gürültüsünün bulunmasıdır[10]. Diğer yöntem ise hali hazırda alınmış ve hesaplanmış görüntülerden benek gürültüsünün süzülmesidir[11-12]. İlk kategoride bulunan yöntemler teorik olarak başarılı olsalar aynı miktarda görüntü elde edebilmek için çok daha geniş bir bantta tarama yapmak mecburiyeti getirdiklerinden pratik olarak tercih edilmezler, öte yandan alınmış görüntülerin işlenmesi farklı yöntemlerin ve karşılaştırmaların kullanılabilmesine imkân verdiği için tercih edilir olmuştur. İkinci kategoride bulunan yöntemlerin en büyük problemi, süzme işlemi sırasında benek gürültüsü ile beraber görüntüye ait detayların silinmesi, kenarlar gibi belirleyici niteliklerin yumuşayarak belirsiz hale gelmesi, hedef tanıma için belirleyici/ayırıcı olan işaretlerin de bastırılmasıdır[9]. Bu sorunla başa çıkabilmek için görüntü içeriğinin korunmasını sağlayan süzgeçler kullanılması tercih edilir.

3.1 Benek Gürültüsü

Uygun sürekli elektromanyetik dalgaya maruz bırakılan nesnelerin kendilerine has tanecikli bir yapıda görüntülendikleri tespit edilmiştir. Şekil 3.1'de tekdüze bir yansıtıcıdan alınan bu tipik desen görülmektedir. Bu fazlasıyla karmaşık desenin görüntülenmesi cismin makro yapısıyla bir ilgisi bulunmamaktadır. Bu yapı düzensiz ve

kaotik görülmekle birlikte olasılık ve istatistik yöntemlerle yaklaşık olarak modellenebilir durumdadır.

Bu tanecikli yapı ilk olarak lazer görüntüleme alanındaki çalışmalarda ortaya konulmuştur. Sürekli dalga ile görüntülenen nesnelerden gerçekleşen yansımalar birçok saçıcı neden olmaktadır. Uzak mesafedeki bir gözlem noktasına yayılan bu yansımalar mikroskobik olarak farklı dalga boylarında gerçekleşen farklı gecikmeler barındırmaktadırlar. Bozulmaya uğramış bu dalgaların girişimiyle oluşan desen benek gürültüsü olarak adlandırılmaktadır[12].



Şekil 3.1 : Tipik benek gürültüsü

Bu tür gürültü ile her türlü geçirgen yapı yöntemiyle görüntüleme yapan sistemlerde sık sık karşılaşılmaktadır. Yayıcı kaynak ile aydınlatılan bölge geçirgen saydamlığa sahip ise, bu yapı içine giren dalga fazlasıyla karmaşık ve düzensiz bir yapıya ulaşır. Bu tür saydam yapıların görüntülenmesinde de çok sayıda faz kaymasına uğramış dalgaların üst üste binmesi ile oluşan salınımlı parlamalar görülür.

Başlangıçta görülen benek gürültüsü tipleri lazer görüntülemenin ve fiziğin araştırma alanında bulunurken günümüzde modern görüntüleme tekniklerinin çoğunda ortaya

çıkmakta ve incelenmektedir. Bunların içinde radar astronomi, yapay açıklıklı radarlar ve akustik görüntüleme örnek verilebilir.

Yansıtıcı yüzeyin mikroskobik özelliklerini bilemememiz nedeniyle benek gürültüsünün özelliklerini istatistik düzeyde incelemek gereklidir. Bahsi geçen istatistikler aynı mikroskobik özelliklere sahip farklı mikroskobik özellikler barındıran malzemelerden üretilmiş cisimlerin ölçülmesi ile elde edilmiştir. Bunun için gözlem uzayında (x,y,z) konumuna yerleştirilen bir sensör bulunsun, burada ölçülen parlamalar tam olarak tahmin edilebilir değildir fakat kabaca düzlem üzerindeki istatistiksel özellikleri tarif edilebilir[12].

Benek gürültüsünün istatistiksel özelliklerini çıkarabilmek için öncelikle bir takım sadeleştirici varsayımlar yapılması gerekir. Şöyle ki (x,y,z) konumundan gözetlenen olay mükemmel olarak polarize olmuş ve monokromatik etkidir sadece bir dalga boyunu yansıtır. Bu şartlar altında karmaşık değerli analitik sinyali denklem (3.1)'deki hali ile ifade edebiliriz. Denklemde burada v frekans ve $A(x, y, z)$ kompleks fazör değeridir.

$$u(x, y, z; t) = A(x, y, z) \exp(i^2(\pi)vt) \quad (3.1)$$

$$A(x, y, z) = |A(x, y, z)| \exp[l(\theta)(x, y, z)] \quad (3.2)$$

(x,y,z) 'deki doğrudan izlenebilir parlama miktarı denklem 3.3'te verilmiştir

$$I(x, y, z) = \lim_{t \rightarrow \infty} \frac{1}{T} \sigma_{-T/2}^T \quad (3.3)$$

Belki de benek gürültüsünün en önemli istatistiksel özelliklerinden biri de I parlamasının olasılık dağılımıdır. Bu noktada ne miktarda parlaklık ne miktarda karanlık alan göreceğimiz rasgele değişme (random walk)[13] konusunda benzeşmektedir.

(x, y, z) noktasında ölçülen kompleks genlik değeri ölçüm düzleminde gelen tekil saçıcı alanlarının toplama katkı sağladığı bir sonuç olarak görülebilir. Böylelikle alanın fazör genliği denklem (3.4) ile ifade edilir.

Burada $|a_k|$ ve ϕ_k sırasıyla k numaralı saçıcı alanından alınan genlik ve faz değerleri katkısıdır. N ise buraya etkiye bulunan alanların toplam sayısıdır.

$$A(x, y, z) = \sum_{k=1}^N |\alpha_k| \exp(i\phi_k) \quad (3.4)$$

Bu noktada bu tekil saçıcı alanlar konusunda iki varsayımda bulunulur

(i) K numaralı saçıcı alanından gelen genlik ve faz değerleri birbirinden ve diğer saçıcı noktalarından gelen genlik ve faz değerlerinden tamamen bağımsızdır.

(ii) K numaralı saçıcıdan gelen faz Kartezyen düzlemin ilk bölümünde bulunan $(-\pi, +\pi)$ arasında bir noktaya gelme olasılığı uniformdur.

$$p(I) = \begin{cases} (1/\bar{I}) \exp(-I/\bar{I}), & I \geq 0 \\ 0, & \text{diğerleri} \end{cases} \quad (3.5)$$

Bu iki varsayım altında problemimizin random walk problemi ile olan benzerliği tamamlanmış olur. N yeterince büyük bir sayı olmak üzere N sayıda tekil katkı $a(x, y, z)$ 'deki karmaşık alanın gerçek ve imajiner parçaları bağımsız, sıfır ortalamalı ve Gauss rasgele değişkenleri olarak eşit olarak dağılmış ve parıldama I , negatif ekponansiyel istatistiklere uyumlu ise olasılık yoğunluk fonksiyonu formu 3.6'daki hali alır. Burada I ortalama ya da beklenen parıldamadır.

Parıldamanın verilen bir eşik değeri I_t 'yi geçme olasılığı

$$P(I > I_t) = \exp\left(-\frac{I_t}{\bar{I}}\right), \quad I_t \geq 0 \quad (3.6)$$

Negatif üstel dağılımın en önemli özelliği tam olarak ortalamasına eşit olan standart sapma değeridir. Böylelikle polarize benek gürültüsü için denklem (3.7)'deki hale ulaşır.

$$C = \sigma_I / \bar{I} \quad (3.7)$$

Buradan anlaşılacağı üzere tipik benek gürültüsü ortalamanın belirgin bir bölüntüsüdür.

3.2 Benek Gürültüsünü Bastırma

Uzamsal filtreleme benek gürültüsü etkilerini azaltmak için çokça kullanılan bir yaklaşımdır. Bu tür filtreleme belirtilen pikselin çevresinde bulunan piksellerin gözden geçirilmesiyle yapılan bir uyarlamalı filtreleme işlemidir. İyi bir filtrenin şu özellikleri barındırması gerekmektedir:(1) istatistiksel olarak homojen olan bölgelerde benek gürültüsünün kaldırılması, (2) özneliliklerin korunması (3) radyometrik korunum. Görsel yorumun yanında farklı filtreleri değerlendirmek için nicel ölçümleme yapmak da önemlidir. Böyle bir kıstas geliştirmek için fazlaca çalışma yapılmış olmakla birlikte[15-16] bu çalışmalar genellikle görüntünün geometrik faktörleri, gürültü seviyeleri, kenar çevresindeki gri geçişleri gibi değişkenleri incelemektedir. Fakat bunların yanında özellikle benek gürültüsünün giderilmesinde farklı filtrelerin performanslarını ölçebilmek ön plana çıkan yöntemler de mevcuttur[14].

3.3 Detayların Korunması

En temel görüntü iyileştirme sorunlarından biri görüntünün ince detayları korunurken gürültünün kaldırılmasıdır. Bu sorun özellikle yayılım miktarının azaltılması istenen makine görüntülemesi, uzaktan algılama gibi alanlarda çok daha önemli bir hale gelmektedir. Bu tür görüntülerin ortak özelliklerinden olan keskin kenarlara ek olarak çoğunlukla fazlaca bilgi taşıyan farklı yönelimlerde olan ince kenarlar da bulunur.

Lineer süzgeçlerin görüntü iyileştirmedeki işlevleri iyi anlaşılmıştır; bu tür süzgeçler iyi bir gürültü bastırma yapmalarına rağmen kenarları yayılmasına ve ince çizgilerin yayılmasına neden olur. Bu tür süzgeçler işaret ve gürültü istatistiklerine göre optimize edilebilir. Fakat bu tür uygulamalar hesaplama yükleri açısından gerçek zamanlı uygulamalar için tercih edilmezler.

Farklı bir süzgeç yaklaşımı ise sıralı istatistik olarak bilinen yaklaşımdır. En bilinen yöntemlerden biri tezde açıklanan medyan süzgeç yapısıdır. Bu tür yaklaşımda tüm görüntü aynı kabul edilmez; belirli bölge içindeki yerel istatistiklere odaklanılır. Lokalde karşılaşılan bozucular işleme alınırken bulundukları bölgede azınlık oldukları varsayılır ve kaldırılması sağlanır, bununla birlikte görüntünün detay özellikleri kendi aralarında değerlendirilerek özellikle hedef tanınması gibi uygulamalarda önem arzeden niteliklerin korunum sağlanır.

3.4 Görüntü İyileştirme Yöntemleri

Görüntü iyileştirme çoğu zaman gürültünün azaltılması ve gerekli niteliklerin, görüntü detayların görüntüde korunması arasında gerçekleşen bir dengelemedir. Özellikle YAR görüntüleme gibi çok düşük çözünürlük yüksek fonksiyon oranına sahip görüntüleme bu yöntemlerin optimum verimle çalışabilmesi azami ehemmiyet barındırır. Gürültü türü belirlenemediği durumlarda örnek bir gürültü verisi üzerinden istatistiksel modelleme yoluna gidilebilir [21,22]. Bu modelleme tekniklerinin başarılı olduğu durumlar olsa da hem gerektirdikleri işlem gücü hem de özellikle YAR görüntülerinde baskın gürültü olarak karşımıza çıkan benek gürültüsünün istatistiksel özelliklerinin bilinmesi bu yöntemleri pratik olmaktan uzak tutar. Görüntü içeriğinin anlaşılması için kenar ve ince detayların iyice anlaşılır duruma gelmesi gereklidir, bu da gürültünün sadece dar bir bantta süzülmesi gerekliliğini beraberinde getirir. Geniş bantlı işlemler görüntünün keskinliğini fazlaca kaybetmesine ve görüntüde yanılmalara neden olur. Benek gürültüsünün istatistiksel özellikleri nedeniyle geniş bantta işleme tabi tutulması ciddi oranda düşüşünü sağlamaktadır [20]. Bu nedenle benek gürültüsünü giderirken aynı zamanda görüntü detaylarının korunması önemlidir; özellikle hedeflerin kenar özelliklerinin korunması, otomatik tanıma algoritmasının performansına büyük katkı sağlamaktadır.

3.4.1 Medyan filtre

Bir boyutlu dalga formlarının medyan filtrelenmesi Tukey[27] tarafından önerilmiş o zamandan beri özellikle bir boyutlu gürültünün yumuşatılması için kendine çokça uygulama alanı bulmuş bir tekniktir. Gürültü yumuşatmada medyan filtre kullanımı özellikle olağan dışı parlamaları dışarıda bırakması nedeniyle klasik lineer filtreye göre çok daha etkin bir sonuç verir. Aynı zamanda medyan filtre monotonik kenarları koruma özelliğine sahiptir, lineer alçak geçiren filtrede olduğu gibi keskin kenarları dağıtmaz. Bu nedenle medyan filtre kenar operasyonu uygulamadan önce görüntüyü yumuşatmak için sıklıkla kullanılır zira lineer filtre kullanımı kenarlarda bilgi kaybına yol açar.

Genellikle iki boyutlu uygulamalarında medyan filtreleme için ($M \times M$) boyutlarına sahip kare bir pencere kullanılır. Görsel içindeki her nokta $M \times M$ boyutlu pencere

içinde bulunan medyan değer ile değiştirilir. Gürültünün göreceli olarak eş dağıldığı görüntülerde bir miktar yumuşama ile birlikte etkin bir gürültü kaldırma işlemi uygulanmış olur [28].

3.4.2 ATWT

ATWT (a trous wavelet transform) bir tür ayırık dalgacık tabanlı dönüşümdür. Dalgacık(wavelet) tabanlı teknikler görüntüleri kaba görünüm ve birkaç “detay” bandına ayıran hesaplama gücü etkin olan zaman frekans ayrışım yöntemleridir.

Bu yöntemlerde öteleme ile değişmezlik (shif-invariance) özelliğini sağlayamaması gürültü bastırma işlemlerinde performans kaybına yol açabilmektedir. Bu özelliği sağlamak için önerilen yöntemlerden biri de ATWT olmuştur.

Dalgacık dönüşümünde temel olarak, görüntünün kaba kısmı görselin temel özelliklerini korurken, detay görüntüler ya da dalgacık bantları bu kaba kısmı tamamlar böylelikle görüntünün tüm bilgisi korunmuş olur. Bu ayrışım aşağıda belirtilen bir set yüksek ve alçak geçiren filtreler ile gerçekleştirilir. Farklı çözünürlük seviyeleri için kullanılan temel fonksiyonlar tek bir ana fonksiyondan -ölçeklendirme fonksiyonu φ - genişleme ve geçiş kullanılarak elde edilir. Bu fonksiyon genişleme denklemini sağlar[23]

$$\varphi(x) = \sum_k h_k \times \varphi(2x - k)$$

ya da

(3.8)

$$\varphi_j(x) = \sum_k h_k \times \varphi_{j-1}(2x - k)$$

Denklem (3.8) konvolüsyon çekirdeği olan φ 'nin kendisinin ötelenmiş durumlarının lineer toplamı olarak yazılabileceğini belirtir. h_k ise ortaya çıkan dalgacık fonksiyonlarının şekillerini ve niteliklerini belirleyen alçak geçiren filtre katsayılarıdır. Denklemde verilen ikinci form $j \rightarrow \infty$ iterasyonu yapılırken $j-1$ seviyesinden sonraki j seviyesine geçişte kullanılan φ 'yi verir. Dahası φ sıfıra bütünleşmiş olur. Detay seviyesini oluşturmak için temel fonksiyonu ψ 'ye karşılık gelen fonksiyon şu şekilde verilir

$$\psi(x) = \sum_k g_k \times \varphi(2x - k) \quad (3.9)$$

g_k yukarıda bahsi geçen h_k parametresiyle ilişik olan yüksek geçiren filtre parametresidir. Burada ψ 0'a bütünleşir[24]. Buna göre detay dalgacıkların önemli bir niteliği olan sıfır ortalamalı olma özelliğine erişilir. Sonuçta elde edilen dalgacık (3.10) ile verilen denklemi sağlar.

$$\frac{1}{2}\psi(x/2) = \varphi(x) - \frac{1}{2}\varphi(x/2) \quad (3.10)$$

Bu şartları sağlayacak birden fazla muhtemel fonksiyon bulunmasına rağmen hepsinin farklı karakteristiklere sahiptir bu nedenledir ki hepsi aynı oranda her uygulama için uygun değildir[25].

ATWT ise ölçekleme fonksiyonu olarak kübik B-spline kullanan iki boyutlu ayrık dalgacık dönüşümüdür. Kübik B-spline yapısı ile çekirdek yönden bağımsızlık, öteleme ile değişmezlik ve yumuşaklık gibi özellikler sağlanır, bu fonksiyon denklem (3.11)'de gösterilen iki boyutta 5x5'lik maske konvolüsyonuna denk gelir:

$$h_0(q) = \begin{bmatrix} 1 & 4 & 6 & 4 & 1 \\ 4 & 16 & 24 & 16 & 4 \\ 6 & 24 & 48 & 24 & 6 \\ 4 & 16 & 24 & 16 & 4 \\ 1 & 4 & 6 & 4 & 1 \end{bmatrix} \quad (3.11)$$

Dönüşümün uygulanması a trous (delikli) olarak adlandırılan bir ortogonal olmayan dönüşüm ile sağlanır. Avantajları ötelemekten etkilenmemesi ve görüntünün her aşamada aynı boyutta kalmasıdır. Uygulamada temel olarak her bir adımda görüntü arasına 2^{i-1} adet sıfır eklenmiş kübik B-spline filtreden geçirilir, burada i filtrenin derecesini gösterir aynı zamanda bu eklenen sıfırlar delikli yapıyı andırır [26]. $F^k h_0$ k. sırada yumuşatılmış görüntü olmak üzere W^k dalgacık katsayıları şu şekilde hesaplanır

$$W^k = F^k - F^k h_0 \quad (3.12)$$

Aynı şekilde orijinal görüntüye de

$$F^0 = F^{k_{max}} + \sum_k W^k \quad (3.13)$$

Şeklinde ulaşılabilir.

3.4.3 Ağırlıklandırılmış ATWT

Daha önce de ifade edildiği gibi, alt örnekleme çoklu çözünürlük ayrışmaları, zamanla değişmezlik özelliğini sağlamadıkları gibi, sınıflama sonuçlarında düşük performansa neden olmaktadır. Bunu engellemek için [55]'te kenar koruyan dalgacıkları ATWT yardımıyla gerçekleştirmeyi önermiştir. I orijinal görüntü, p görüntüdeki ilgili pikselin konumunu, S piksellerin komşuluğunu ve q , bu komşuluktaki piksellerin yerini ifade etsin. Bu durumda bir I görüntüsünün p pikselinin ağırlıklı ATWT çıkışı şu şekilde verilebilir [55].

$$W[I]_p = \frac{1}{K} \sum_{q \in S} h_0(q) c_{\sigma_r}(p, q) I_q \quad (3.14)$$

Burada, k normalizasyon parametresini ifade eder.

$$k = \sum_{q \in S} h_0(q) c_{\sigma_r}(p, q) \quad (3.15)$$

Ağırlıklandırma fonksiyonu ise aşağıdaki biçimde verilebilir .

$$c_{\sigma_r}(p, q) = \frac{1}{\sigma_r^2} \exp\left(-\frac{[I]_p^2 + [I]_q^2}{\sigma_r^2}\right) \quad (3.16)$$

$h_0(q)$, ATWT dönüşümünde de kullanılan B_3 kübik spline süzgecine karşı düşmektedir.

$$h_0(q) = \begin{bmatrix} 1 & 4 & 6 & 4 & 1 \\ 4 & 16 & 24 & 16 & 4 \\ 6 & 24 & 48 & 24 & 6 \\ 4 & 16 & 24 & 16 & 4 \\ 1 & 4 & 6 & 4 & 1 \end{bmatrix} \quad (3.17)$$

Bu dönüşüm yardımıyla, bilateral süzgece yakın sonuçlar elde etmekle beraber, tek parametre kullanıldığı için, işlemsel olarak daha hızlı bir yöntem geliştirilmiş olmaktadır [55]. $c_{\sigma_r}(p, q)$ ağırlıklandırma fonksiyonu, p pikseli ile q pikseli arasındaki

benzerlik azaldıkça, q pikselinin etkisini azaltır. Buradaki S komşuluğu ise B_3 maskesinin boyutuna eşittir (5×5).

i. seviyedeki yaklaşıklık altbantlarına aşağıdaki denklemle ulaşmak mümkündür.

$$W^i[I]_p = \frac{1}{K} \sum_{q \in S} h_{i-1}(q) c_{\sigma_r}^{i-1}(p, q) W^{i-1}[I]_q \quad (3.18)$$

Zamanla değişmezlik özelliğini sağlamak için, her i seviyesinde bikübik maskenin aralarına 2^{l-1} adet “0” yerleştirilir ve σ_r parametresi her seviyede iki katına yükseltilir ve (5.6) aşağıdaki şekile dönüşür[31].

$$c_{\sigma_r}^{i-1}(p, q) = \frac{1}{2\pi(2\sigma_r)^2} \exp\left(-\frac{([I]_p - [I]_q)^2}{2}\right) \quad (3.19)$$


i. seviye detay altbandını bulmak için aşağıdaki denklem kullanılabilir.

$$E^i[I] = W^{i-1}[I] - W^i[I] \quad (3.20)$$

$W^0[I]$ orijinal görüntüye karşı düşer. L seviyeli bir ayrıştırmadan, orijinal görüntüyü yeniden elde etmek için aşağıdaki denklem kullanılır.

$$I = \sum_{i=1}^L E^i[I] + W^L[I] \quad (3.21)$$

WATWT ile 2 seviyeli görüntü ayrıştırma/birleştirme Şekil 3.2 de görülmektedir.



Şekil 3.2 : WATWT yöntemiyle görüntü ayrıştırma ve birleştirme

3.4.4 Bilateral filtre

Bilateral süzgeçler, tıpkı Gauss süzgeçleri gibi yumuşatma (smoothing) yaparlar. Gauss süzgeçlerinden en önemli farkları ise, yumuşatma işlemini gerçekleştirirken, yakın piksel değerlerini de göz önüne alarak kenar bilgilerini korumalarıdır[29,30]. Bilateral süzgeç, yakın pikselleri uzağa tercih ederken, hem geometrik yakınlık hem de görsel benzerlikleri dikkate alan bir yoğunluk değeri birleşimi oluşturur. Geometrik yakınlık, uzamsal benzerliği ifade ederken, görsel benzerlik, spektral benzerliği ifade eder[31]. Dolayısıyla bilateral süzgeç, uzamsal ve spektral iki Gauss süzgecinin bir bileşimi olarak görülebilir. I giriş görüntüsü, p görüntüde süzgece girecek olan pikselin konumunu, q süzgeçte kullanılacak komşu pikselleri ifade etmek üzere, bir I görüntüsünün p pikselinin bilateral süzgeç çıkışı aşağıdaki şekilde verilebilir [31].

$$BF[A]_p = \frac{1}{W_p} \sum_{q \in S} G_{\sigma_s}(\|q - p\|) G_{\sigma_r}(\|A_p - A_q\|) A_q \quad (3.22)$$

Normalizasyon parametresi:

$$W_p = \sum_{q \in S} G_{\sigma_s}(\|q - p\|) G_{\sigma_r}(\|A_p - A_q\|) \quad (3.23)$$

Ve Gaussian çekirdek:

$$G_{\sigma}(x) = \exp\left(-\frac{x^2}{2\sigma^2}\right) \quad (3.24)$$

burada G_{σ_s} uzamsal Gauss çekirdeğini ifade eder ki; uzak piksellerin etkisini düşürür ve G_{σ_r} yoğunluk Gauss çekirdeğini ki; S komşulukta bulunan q pikselinin yoğunluk değeri p den farklıysa etkisini düşürür. S komşuluk değeri genellikle p pikselini merkez alan bir karesel pencereye karşı düşer. Gürültü kaldırma uygulamalarında bu pencere 3x3 veya 5x5 olarak alınır.



Şekil 3.3 : a) $\sigma_s=100$ b) $\sigma_s=0.001$ c) $\sigma_r=100$ d) $\sigma_r=0.001$

Süzgeç çıkışını asıl etkileyen ise Gauss çekirdeklerinin içerisindeki σ_r ve σ_s (uzaklık parametresi ve uzamsal parametre) parametreleridir. Büyük σ_r değerleri, bilateral süzgecin Gauss yumuşatmaya yaklaşmasına sebep olur.

Çünkü σ_r arttıkça, piksellerin değer farkı göz ardı edilir. Büyük σ_s değerleri ise büyük detayların kaybolmasına neden olur. Her iki parametrenin “0” a birlikte veya ayrı ayrı yaklaşması durumunda neredeyse hiç yumuşatma olmaz [30]. Sabit σ_r altında küçük ve büyük değerli σ_s ile elde edilen süzgeç çıkışları Şekil 3.3 a,b’de görülürken sabit değerli σ_s ile değişen değerli σ_r ’nin süzgeç çıkışına etkisi Şekil 3.3 c,d’de gösterilmiştir. Bilateral süzgeç çıkışı, yumuşatma işlemi yaptığından, orijinal görüntünün tıpkı atrous dalgacık dönüşümü (ATWT) ayrışımında olduğu gibi

yaklaşıklık altbandını elde etmek için kullanılabilir. Detay altbandını elde etmek için, ATWT ye benzer şekilde orjinal görüntüden yaklaşıklık altbandı çıkarılır (3.25)

Tek seviye ayrışımın yetersiz kaldığı yerlerde, Şekil 3.4'te gösterilen önceki


$$D[I]_p = [I]_p - BF[I]_p \quad (3.25)$$

çıkışların sonraki aşamaların girişlerini oluşturduğu bir görüntü piramidi oluşturulabilir. Bu süzgeç yapısı oluşturulurken dikkate alınması önemli konulardan biri de zamanla değişmezlik özelliğinin sağlanmasıdır. Bunu sağlayabilmek için bilateral süzgecin her adımında, uzamsal σ_r parametresi iki katına çıkarılırken, uzaklık parametresi σ_s yarıya indirilerek öteleme işlemlerinin etkisi kompanse edilmiş olur.

Bilateral piramidin her seviyedeki detay altbantlarına (3.26)'da verilen denklem ile ulaşmak mümkündür.

$$D^i[I]_p = BF^{i-1}[I]_p - BF^i[I]_p \quad (3.26)$$

Burada, i , filtre sırasını gösterir, başlangıç değeri olarak $BF^0[I]_p=1$ olur. L seviyeli



Şekil 3.4 : Çokluçözünürlük bilateral süzgeçler ile görüntü ayrıştırma ve birleştirme
bir ayrıştırmadan, orjinal görüntüye (3.27)'de verilen denklem kullanılarak ulaşılabilir.

$$I = \sum_{i=1}^L D^i[I]_p + BF^L[I]_p \quad (3.27)$$

Bilateral piramitlerle iki seviye ayrışım ve geri besleme yapısı Şekil 3.4'te verilmiştir.

3.5 Benek Gürültüsü Azaltma Performans Metrikleri

3.5.1 Eş ölçüm sayısı

Yapay açıklıklı radarlarda görüntülerin ölçüm, formatlama ve son işlem sırasında ne kadar ortalandığını belirten bir parametresidir. Çoklu ölçüm benek gürültüsünün üstesinden gelmek amacıyla uygulanır[17]. Eş ölçüm sayısı (Equivalent number of looks- ENL) değeri genellikle görüntüdeki benek gürültüsünün tamamen etkisi altına aldığı ve diğer etkilerin ihmal edilebilir seviyede katkıda bulunduğu homojen bölgeler kullanılarak hesaplanır burada çapraz menzil sabit olarak kabul edilir. Bu koşullar yansıma katsayılarının kompleks Gaussian[18] dağılımında olmasını sağlar. Bu istatistiksel modelde ENL basit görüntü istatistikleri olarak kestirilebilir. Temel olarak görüntüdeki gürültü miktarını vermektedir, büyük değerleri fazla gürültü anlamına gelmektedir.

Yaklaşık olarak ENL hesabı şu şekilde verilir:

$$ENL = A \left(\frac{\text{mean}(M')}{\text{std}(M)} \right)^2, A = \begin{cases} 1, & \text{yoğunluk biçimi} \\ \frac{4}{\pi} - 1, & \text{genlik biçimi} \end{cases} \quad (3.28)$$

3.5.2 Kenar koruma oranı

Benek gürültüsü kaldırma işlemleri genellikle yumuşatma sağlayan- yüksek frekansları süzerek alçak geçiren yapıda olan filtreler ile yapıldığı için bu tür filtreler genellikle görüntüye ait en önemli özniteliklerden olan kenarları zayıflatmaya meyilli olur. Bu işlem bir kenarın filtrelemeden önce barındırdığı keskinliğin hesaplanması ve sonrasında hesaplanan keskinliğinin karşılaştırılması olarak hesaplanır. Bunun için görüntü iki parçaya ayrılarak iki bölgenin de ayrı ayrı olarak kenar değerler hesaplaması yapılır böylelikle kenar keskinliği iki bölgenin de ortalama değerinden bağımsız olarak hesaplanmış olur[19]. Denklem 3.29'da verilen bu metrik kenar koruma oranı (Edge save index-ESI) olarak adlandırılır. Büyük değerleri görüntünün daha fazla dağılmış kenarları olduğunu belirtir.

$$ESI_H = \frac{\sum_{i=1}^m \sum_{j=1}^{n-1} |M'_{i,j+1} - M'_{i,j}|}{\sum_{i=1}^m \sum_{j=1}^{n-1} |M_{i,j+1} - M_{i,j}|} \quad (3.29)$$

$$ESI_V = \frac{\sum_{i=1}^n \sum_{j=1}^{m-1} |M'_{i+1,j} - M'_{i,j}|}{\sum_{i=1}^n \sum_{j=1}^{m-1} |M_{i+1,j} - M_{i,j}|}$$

3.6 Görüntü Kalite Metrikleri

İşleme tabi tutulan görüntüler gözle görünmede değişikliğe mutlaka uğramış olacaktır, insan tarafından bakılan görüntülerin hangisinin daha iyi hale geldiği çok çabuk anlaşılabilir. Matematiksel bir yaklaşım sonucu gerçekleştirilen bu işlemler için nitel yaklaşımlar performans karşılaştırılması için yeterli olamamaktadır bu sebeple nicel yaklaşımlara da ihtiyaç duyulmaktadır. Bu bölümde incelenen yapay açıklıklı radar görüntüleri için hesaplanan genel ve özel metrikler bu ihtiyacı karşılamak üzere sıklıkla kullanılmaktadır.

3.6.1 Entropi

Entropi görüntüye uygulandığında görüntü piksel değerlerindeki geçiş hızı farkını verecektir. YAR görüntülerinde bu görüntü keskinliğini ifade edecektir. Daha keskin görüntüler gürültüden temizlenmiş olduğu için piksel değerleri arasındaki fark daha az olacak ve entropi de daha düşük olacaktır. Diğer taraftan çok düşük entropi değeri bilgi kuramı gereği az bilgi taşınması anlamına gelecek ve görüntülerin tanınması için gerekli olan niteliklerin de görüntüden silinmiş olduğunu anlamına gelecektir [32]. $p(i)$ görüntünün gri skaladaki piksel yoğunluk histogramı ve G de gri seviyelerin sayısı olmak üzere entropi hesabı şu şekilde verilebilir:

$$ENT = - \sum_{i=0}^G p(i) \log_2(p(i)) \quad (3.30)$$

3.6.2 Hedef arkaplan oranı

Hedef arkaplan oranı (target to background ratio-TBR), hedefi temsil eden piksellerin arkaplana göre ne kadar vurgulandığını belirleyen bir ölçüttür. Şu şekilde ifade edilir

$$TBR = 20 \log_{10} \left(\frac{\max_{i \in \tau} (|f)_i|}{(1/N_B) \sum_{j \in B} |(f)_j|} \right) \quad (3.31)$$

Burada N_B , B olarak tanımlanan arkaplan bölgesindeki piksel sayısını belirtir. τ hedef bölgesini içeren piksellerin bulunduğu küme, f işleminden geçirilmiş görüntü ve $(f)_i$, $(f)_j$ i ve j noktalarındaki piksel değerleridir [33]. Büyük değerleri görüntünün büyük bir kısmının hedef olduğu, küçük değerleri ise hedefin görüntünün küçük bir kısmında yer aldığını belirtir.

3.6.3 Ana lob genişliği

Görüntünün etkin çözünürlüğünün ölçülmesi için kullanılan yöntemlerden biri de ana saçıcı lobunun 3dB düşüş gösterdiği yere kadar olan genişliğinin hesaplanmasıdır. Buradan elde edilen metrik ana lob genişliği (main lobe width - MLBW) olarak adlandırılır. Bunun için öncelikle hedefin bulunduğu alana yoğunlaşılır. İşleminden geçirilmiş görüntü üzerinde ve hedefin olduğu bilindiği bölgede en yüksek değeri barındıran piksel ana saçıcı noktası olarak alınır. Ana saçıcı noktasından itibaren 3dB düşüş gösteren yere kadar olan piksellerin sayısı, ana lob genişliğini verir [34]. Büyük değerleri ana saçıcının yayıldığını gösterir, genellikle fazla yumuşamaya uğrayan görüntülerde ana saçıcının diğer saçıcılarla birleştiği anlaşılır.

3.6.4 Hedef arkaplan entropi farkı

Hedef arkaplan entropi farkı (target to background entropy difference – TBED) gri seviyede hesaplanan bu metrik hedef bölgesi olarak belirtilen alanda hesaplanan entropi ve arka plan olarak belirtilen alanda hesaplanan entropi arasındaki farkın hesaplanmasıyla elde edilir. $E(x)$ belirtilen x alanının entropisini ifade etmek üzere

$$TBED = |E(S) - E(B)| \quad (3.32)$$

Olarak hesaplanır. Entropi ölçütü dağılımın uniformluğunu verir, böylelikle görüntünün tekdüzelik eğilimi bulunur. 1.0'a yaklaşan büyük bir entropi değeri bölgede farklı gri seviyelerinin çok olduğunu belirtir. TBED metriğinin düşük değerlerde olması hedef ve arkaplan gri dağılımlarının çok benzer olduğunu gösterir. Böyle bir durumda hedefin arkaplandan ayrılabilmesi çok daha zor hale gelir [35].

4. RADAR HEDEF SINIFLAMA PROBLEMİ

Radar hedef sınıflama işlemi için Kim ve diğerleri [36] tarafından önerilen yöntemden yola çıkılarak makine öğrenmesi algoritmaları yardımıyla sınıflama yapan bir uygulama düzenlenmiştir. Yapılan işlemlere tezde ele alınan konuyla ilgili olarak görüntülerin öznitelikleri çıkarılmadan önce filtreleme adımı eklenmiştir.

4.1 Ön Hazırlık

Bir 2B ISAR görüntüsü şu şekilde tanımlanır:

$$I_0(x_i, y_j) \quad i = 1, 2, \dots, N \quad j = 1, 2, \dots, M \quad (4.1)$$

Denklem (4.1)'de bahsi geçen (x, y) orijinal ISAR görüntü düzleminde alt menzil ve çapraz menzili ifade eder. M ve N ilgili boyutun piksel sayısıdır [7]. Ön hazırlık aşamasında görüntünün bölütleme ve normalleştirilmesini yapılır. Bölütleme sürecinde hedefin cevabı, gürültü içeren görüntünün geri kalanından ve saçılma cevabından elde edilir. Böylece hedefi kendi arka planından ayırmak kolay olur. Bu amaçla ortalama eşik değerini ISAR görüntü düzleminin orijinal alt menzil ve çapraz menzil boyutuna uygun olarak kabul edip basit bir metot şeklinde yazılırsa:

$$I'_0 = \frac{1}{MN} \sum_{i=0}^M \sum_{j=0}^N I_0(x_i, y_j) \quad (4.2)$$

Böylece eşik değerinin üstünde kalan sinyal seviyeleri hedef piksellerimiz olarak belirlenir.

Yukarıdaki bölütleme adımları SAR görüntülerinde cismin bazı bölgelerinde ayrıca uygulanabilir ve görüntünün pikselleri azaltılabilir. Giriş koşullarına bağlı olarak Jet Motoru Modülasyonu (JEM), çoklu yansımalar ve rezonans saçılma bölütlemeleri uygulanabilir. Ancak hedefin ana gövdesinden gelen ayırıcı piksellerin zarar görmeden alınmasına dikkat edilmelidir. Eğer sadece ayırıcı pikselleri tespit edip bunların haricinde kalanları belirleyerek ayırırsak ISAR sınıflandırmanın doğruluğunda farklı bir başarı elde edebiliriz. Diğer gelişmiş bölütleme yöntemleri kenar algılamalı ve histogram tabanlı bölütlemedir. Bu metotlardan da yararlanılabilir

[37]. Ancak geniş bir dinamik aralığa sahip olması ve ISAR görüntülerin yansıtıcı özelliği nedeniyle performansları çok güvenilir değildir.

Sonuç olarak verimli bir bölütleme geliştirmek için çok zor bir algoritma kurulması gerekmektedir. Bu algoritma sayesinde gürültü ve dağınıklık yanıtlarının yanı sıra cismin kusursuzca çıkarılması sonucuna ulaşılabilir. Bu nedenle daha ileri bir araştırma gereklidir. ISAR görüntülerin sinyal seviyesi değerlerini azaltmak için radar ve hedef arasında farklı mesafeler doğacaktır [38]. ISAR görüntüsünü normalleştirmek için bütün enerjisini kullanması beklenen bir durumdur. Bu durum için oluşturduğumuz denklem şu şekildedir:


$$I_n(x_i, y_i) = \frac{I_0(x_i, y_i)}{\sum_{i=1}^M \sum_{j=1}^N I_0(x_i, y_j)} \quad (4.3)$$

Formüldeki $I_0(x_i, y_i)$ bölütleme sonrası ISAR görüntüsüdür. Sonuç olarak ISAR görüntünün kendi sinyal seviyelerinden ziyade sınıflandırma için göreceli şeklinden yararlanılır [36].

4.2 Polar Eşleme

Farklı yönelim ve ölçeklemelerle doku görüntülerinin sınıflandırılması örüntü tanıma topluluklarında ve bilgisayarlı görüntü işlemede dikkatleri üzerine çekmiş bir konudur. İşleyebilir yönelimler ve ölçek değişiklikleri için bir dizi teoriler önerilmiştir. Log-kutup eşleme(LPM) bunlardan bir tanesidir [36, 39, 40]. Yeniden örnekleme sürecini içinde barındıran bir görüntünün LPM si uzay içinde değişen log-kutup ızgarası kullanır ve log-kutup görüntü elde edilir (LPI). LPI koordinat, dönme ve orijinal koordinatlarda ölçek sapmaları, çeviri varyantı gibi basit değişimler ile gözlemlenir. ISAR görüntü sınıflandırmada LPM uygulamak için LPI' in dönüşme invaryantı bir başka işlem olarak sağlanmalıdır. Ayrıca ızgara çevresi etrafında daha az önem verilen çevrenin merkezinden örnekleme noktalarına doğru doğrusal olmayan radyal düzenlemeler bilgi kaybına yol açabilir. ISAR görüntülerinde görüntü merkezinden uzak saçılma merkezleri genellikle kenar yapılarından kırılımlı saçılma mekanizmalarıyla alakalı olabilir. Bu merkezler sınıflandırma için faydalı bilgiler muhafaza eder. Bu nedenle LPM başarılı bir sınıflandırma performansı ihtiyacını karşılamak için yeterli bilgi miktarını vermeyebilir. Bunun için polar eşleme işlemi

LPM yerine görüntüyü yeniden örneklemek için kullanılır. LPM ve polar eşleme ızgarası Şekil 4.1’de gösterilmiştir.




Şekil 4.1 : Log-Polar Izgara (üstte) , Polar Izgara (altta) [26].

Şekilden de anlaşılacağı üzere yarıçap çevre kenarı yönünde hareket eder. Kutup haritalama LPM den daha iyi bir ızgaraya sahiptir. Çünkü r yönündeki örnekleme aralığı yarıçapın bağımsızlığıyla alakalıdır. Polar eşleme kullanarak görüntü ile alakalı $I(x,y)$ değerini yeniden elde edilir. Buna göre:

$$I_p(r_m, \theta_n) \quad m = 1, 2, \dots, N_r \quad n = 1, 2, \dots, N_\theta \quad (4.4)$$

ifadesi belirlenir. 4.4 ifadesinde gördüğümüz N_r şekilde r yönünde bulunan örnekleme sayıdır. N_θ ise θ yönünde olanlardır. Polar görüntüye karşı gelen geometri Şekil 4.2’ de gösterilmiştir.



Şekil 4.2 : Polar Görüntü Geometrisi [26]

r_m ve θ_n ise ISAR görüntünün koordinatı (x,y) ile ilgilidir:

$$(x_k, y_k) = (x_c, y_c) + (r_m \cos \theta_n, r_m \sin \theta_n)$$

$$m = 1, 2, \dots, N_r$$

$$n = 1, 2, \dots, N_\theta$$

$$k = 1, 2, \dots, N_r N_\theta$$

(4.5)

$$r_m = R_{min} + (m - 1) \Delta r$$

(4.6)

$$\theta_n = -\pi + (n - 1) \Delta \theta$$

(4.7)

$$\Delta r = \frac{R_{max} - R_{min}}{N_r - 1}$$

(4.8)

$$\Delta \theta = \frac{2\pi}{N_\theta - 1}$$


(4.9)

Yukarıdaki denklem (4.5)'de, kutup eşlemenin orta noktası gösterilir. Bu nokta önceden işlenmiş bir ağırlık merkezi olarak seçilmiştir. Δr ve $\Delta \theta$ sırasıyla r ve θ ya doğru örnekleme aralıklarıdır. R_{max} en büyük örnekleme çerçevesinin yarıçapıdır. Bu


yarıçap hedeften alınan cevaba göre çok dikkatli seçilmiş olmalıdır. R_{max} , (x_c, y_c) ve (x_c, y_c) 'nin dış hedef pikseli arasında hesaplanabilir. Çünkü piksele karşılık gelen hedef yanıtı ön işleme aşamasında belirlenmiştir. R_{min} en küçük örnekleme çemberinin yarıçapıdır ve rasgele küçük bir değer seçilebilir. $R_{min} = 0$ seçmek yaygın ve kullanışlı bir yoldur. Eğer örnekleme çözümlemeleri Δr ve $\Delta \theta$ geniş olursa, alt örnekleme meydana gelir. Böylece, hedef sınıflama için çok fazla faydalı bilgi içeren, polar görüntü sonuçlandırmada orijinal görüntü kaybedilmiş olabilir. Buna karşılık aşırı örnekleme durumunda polar görüntünün boyutluluğu önemli ölçüde artırılır. Bu işlemi yapmamız için ise bir sonraki bölümlerde değineceğimiz algoritmaya bazı hesaplamalar yapılması gerekecektir [40].

Şekil 4.2'de (r_m, θ_n) olarak belirtilen polar bir görüntünün piksel değerini elde etmek için belirtilen değerler, orijinal ISAR görüntüsünden denklem (4.5)'teki (x_k, y_k) piksel değeri referans alınarak belirlenmiştir. Ancak (4.5)'teki (x_k, y_k) 'da orijinal ISAR görüntüsünün pikselleri konumlandırılmamıştır. Bu yüzden (x_k, y_k) den daha doğru piksel değerleri hesaplanarak uygun bir interpolasyon düzeni oluşturulması arzu edilir. Literatürde birçok interpolasyon yöntemi mevcuttur. Bu çalışmada doğrusal bir interpolasyon yöntemi uygulanmıştır. Yüksek dereceden polinomlara dayalı interpolasyon yöntemleri de uygulanabilir [36, 40].

Şekil 4.3 ve Şekil 4.4'te bir F16 uçak modelinin ISAR görüntüleri ilgili yuvarlak ızgaralar üzerine bindirilmiş şekilde gösterilmektedir. Şekil 4.3 ve Şekil 4.4'deki görüntüyü elde etmek için -15 ve 15 derecelik açıları kapsayan 8.4 – 12.4 GHz arasında küçük aralıklarla elde edilmiş RCS verileri ölçülmüştür. Ölçülen frekans yönü etki alanı verileri Kartezyen frekans spektrumuna interpolate edilmiştir. Daha sonra ISAR görüntüleri oluşturmak için 2B ters hızlı Fourier (IFFT) uygulanmıştır. Daha önce belirtilen ön işleme algoritması bu şekilleri elde etmek için kullanılmıştır. Şekil 4.4'deki görüntüde dikkat edilmesi gereken nokta Şekil 4.3'ün alt ölçeklenmiş ve döndürülmüş olmasıdır. Bu döndürülme açısı 45 derece ve ölçek oranı $1/\sqrt{2}$ dir. Etkin bir ISAR sınıflandırma şeması Şekil 4.3 ve Şekil 4.4'deki hedefleri aynı sınıfa alarak sınıflandırmaktadır. Bu hedefi gerçekleştirmek için polar eşleme yöntemini Şekil 4.3 ve Şekil 4.4'deki gibi polar ızgaraları da ekleyerek uyguladık. Elde edilen görüntüler Şekil 4.5 ve Şekil 4.6'da gösterilmiştir.




Şekil 4.3 : F16 uçak ters SAR görüntüsü ve polar ızgarası [36].




Şekil 4.4 : F16 uçak ISAR görüntüsü ve polar ızgarası, döndürülmüş ve açısı

Şekil 4.5 ve Şekil 4.6'yı karşılaştırsak iki kutup görüntüsü θ yönüne doğru kaymalar hariç benzerdir. Beklendiği gibi iki görüntü arasında θ yönündeki yer değiştirme miktarı $\pi/4$ e eşittir. Bunun aksine bu iki görüntü arasında r yönünde hemen hemen hiç fark yoktur. Bu sonuç bize kutup eşleme işlemi sonucunda ölçek değişmezliğini elde ettiğimizi ve dönme varyantının θ yönünde dönüşme varyantına dönüştüğünü

göstermektedir. Pratikte ölçek değişmezliği polar eşlemede R_{max} in uygulanabilir bir şekilde belirlenmesine atfedilir [36, 40].



Şekil 4.5 : Şekil 4.3'e karşı gelen Polar görüntü $I_r(r)$ ve $I_\theta(\theta)$: $N_r = N_\theta = 50$ [36].



Şekil 4.6 : Şekil 4.4'e karşı gelen Polar görüntü $I_r(r)$ ve $I_\theta(\theta)$: $N_r = N_\theta = 50$ [36].

4.3 Temel Bileşenler Analizi

Temel bileşenler analizi (Principal Components Analyses), çok değişkenli analizin en eski ve en çok bilinen tekniğidir. İlk kez Pearson tarafından kullanılan teknik daha sonra bağımsız olarak Hotelling tarafından geliştirilmiştir. Temel bileşenler analizi ile değişkenlerin bileşkeleri diyebileceğimiz daha az sayıda yeni değişkenler ya da temel bileşenler oluşturulur. Temel bileşenler birbirinden bağımsızdırlar. Böylece değişkenler arası bağımlılık yapısı da ortadan kaldırılmaktadır. Ayrıca temel bileşenler analizi çoklu doğrusal bağlantı probleminde literatürde önerilen çözümlerden biridir.

Çok değişkenli görüntü sınıflandırma algoritmalarında p tane hedefe ilişkin q tane değişken (özellik) incelenmektedir. Bu değişkenlerden birçoğunun birbiriyle ilişkili ve değişken sayısının (q) çok büyük olması, çeşitli değerlendirmeler yapılmasını güçleştirmektedir. Böyle durumlarda temel bileşenler analizi başvurulacak en önemli tekniktir. Değişkenler setinin varyant kovaryans yapısını, bu değişkenlerin doğrusal birleşimleri vasıtasıyla açıklayarak, veri indirgenmesi ve yorumlanmasını sağlayan, çok değişkenli bir istatistik yöntemidir. Genel olarak değişkenler arasındaki bağımlılık yapısının yok edilmesi ve boyut indirgeme amacıyla kullanılan bu teknik başlı başına bir analiz olduğu gibi başka analizler için veri hazırlama tekniği olarak da kullanılmaktadır. Yöntemde karşılıklı bağımlılık yapısı gösteren, ölçüm sayısı p olan q adet değişken; doğrusal, ortagonal ve birbirinden bağımsız olma özelliklerini taşıyan k ($k \leq q$) tane yeni değişkene dönüştürülür [41].

Her biri p ölçümünde q değişkenin oluşturduğu bir sistem düşünüldüğünde, sistemin toplam değişkenliği q , değişkenin tümü tarafından açıklanır. Toplam değişkenliğin önemli bir kısmı k ($k \leq q$) bileşen tarafından açıklandığı durumlarda, k bileşen orijinal q değişkeni temsil edebilir. Bu durumda p ölçümdeki q değişken, önemli bir bilgi (varyant) kaybına neden olunmaksızın, p ölçümündeki k değişkene indirgenmiş olur. Söz konusu k adet yeni değişken, orijinal değişkenlerin bazı kısıtlamalara bağlı kalınarak oluşturulmuş çeşitli doğrusal birleşimleridir.


Temel bileşenler analizi ile ulaşılması istenilen ilk sonuç; $X_1, X_2, \dots, X_q$ gibi q tane değişkeni, önemli bir bilgi kaybına neden olmaksızın, bu değişkenleri temsil edebilen daha az sayıda değişkene indirmek ve değişkenlere etki eden genel nedensel faktörleri elde etmektir. Bunun için kurduğumuz düzeni basit bir halde Şekil 4.7'de

gösterebiliriz. Daha sonra indirgenmiş yeni değişkenler ile çalışmanın amacı doğrultusunda çeşitli sonuçlara ulaşılabacaktır [41].

Temel bileşenler analizi ile asıl elde etmek istediğimiz değerler görüntü matrisimizin sıkıştırılmış halini elde etmektir. Orijinal değişkenlerden nispeten daha az sayıda mümkün olduğunca temel bileşen elde etmek için şöyle bir yaklaşım kullanılır:

$$y = A^T x \quad (4.10)$$

Denklem (4.10)'da görülen $y = [y_1, y_2, \dots, y_N]^T$ ifadesi temel bileşenler analizi ile bileşen sayısı azaltılmış özellik vektörüdür. A $M \times N$ boyutunda x öznelilik matrisini



Şekil 4.7 : Temel bileşenler analizi için grafiksel gösterim [29].

y 'ye dönüştürme matrisidir. Temel bileşenler analizinin temel amacı $y_1^T, y_2^T, \dots, y_N^T$ dizisini oluşturmaktır. PCA A 'nın ortonormal bir matris ($A_i^T \cdot A_j = \delta_{ij}$) olduğunu varsayarsak Y (C_y)'nin kovaryans matrisi diyagonal hale getirilmiştir. Pratikte A matrisinin bileşenleri basitçe kovaryans matrisleri kullanılarak hesaplanır. Kovaryans matrisi C_x şu şekilde gösterilir:

$$C_x = \frac{1}{K} \sum_{k=1}^K x(k)x^T(k) \quad (4.11)$$

C matrisinin öz değeri ve öz vektörleri Φ ve Λ şu şekilde hesaplanır:

$$C_x \Phi = \Phi \Lambda \quad (4.12)$$

Denklem (4.12)'de verilen $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_N)$ ve $\lambda_1, \lambda_2, \dots, \lambda_N$ öz değerlerdir. Bu değerler azalan sırada sıralandığı durumda yani $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_N$ olduğunda N boyutlu öz vektör matrisi A aşağıdaki gibidir:

$$A = [\Phi_1, \Phi_2, \dots, \Phi_N] \quad (4.13)$$

Bu işlemler neticesinde PCA normalize edilmiş ve veri miktarı sıkıştırılmış görüntüyü ve gürültüsü azaltılmış bir öz nitelik vektörü sağlamış olur. Temel bileşen yükleri, temel bileşenlerin değişkenlere varyant katkısını gösteren ağırlıklardır ve temel bileşenleri değişkenlerin hangi ağırlıklarla tanımladıklarını göstermektedir. Temel bileşenler ortogonal seçileceğinden δ_{ij} ağırlıkları değişkenler ile temel bileşenler arasındaki korelasyon katsayısıyla orantılıdır. δ_{ij} i'inci değişkenin j'inci temel bileşendeki ağırlığıdır.

Uygulamalarda birkaç temel bileşen, toplam değişkenliğin %80'inden büyük bir oranını açıklayabiliyorsa, bu bileşenler büyük bir bilgi kaybına neden olmaksızın orijinal q değişkenin yerini alabilir. Ayrıca, değeri 1'den küçük olan öz değerlere karşılık gelen temel bileşenler, istatistiksel olarak önemsiz bilgi taşıdıklarından değerlendirme dışı bırakılır [41].

4.4 Eğitim Veri Setinin Oluşturulması

Önerdiğimiz algoritma yardımıyla sınıflandıracağımız hedefin öznitelik vektörü üç kısımdan oluşmaktadır. *r-çalışılan görüntü*, *θ -çalışılan görüntü* ve PCA ile elde edilmiş *sıkıştırılmış kutupsal görüntü*. Polar görüntünün r ekseninde oluşturulan öznitelik vektörü $I_r(r)$ ile gösterilirse, eşitliği:

$$I_r(r) = \int_{-\pi}^{\pi} I_p(r, \theta) = \sum_{n=1}^{N_\theta} I_p(r_m, \theta_n) \quad (4.14)$$

şeklinde elde edilir. Görüntünün θ yönündeki 1 boyutlu görüntüsünün öznitelik vektörü $I_\theta(\theta)$ ile gösterilirse eşitliği:


$$I_\theta(\theta) = \int_{R_{min}}^{R_{max}} I_p(r, \theta) = \sum_{m=1}^{N_r} I_p(r_m, \theta_n) \quad (4.15)$$

Denklem (4.14) ve (4.15)'te gördüğümüz $I_r(r)$ ve $I_\theta(\theta)$ ifadeleri N_r ve N_θ ile aynı boyuttadırlar. Bu boyutlar $N_r \times N_\theta$ şeklindedir ve polar görüntüden daha küçüktür. $I_r(r)$ ve $I_\theta(\theta)$ ifadelerinin tipik görüntüleri Şekil 4.5 ve Şekil 4.6'da bir F16 uçak modeli için gösterilmiştir. $I_r(r)$ ve $I_\theta(\theta)$ bize sınıflandırma adımlarında fayda sağlayacaktır. Bu fayda sadece polar görüntünün dönüşüm sabitlerini sağlamada değil, aynı zamanda bilinmeyen cisimlerin sınıflarını belirlemede kullanacağımız öznitelik uzayını azaltma işleminde kullanılacaktır.

Daha önce tartışıldığı gibi, ayrıştırıcı bilgilerin kaybını azaltmak; polar görüntüde orijinal piksel değerinin tamamının kullanılmasına karşı arzu edilen bir durumdur [42]. Ancak bu işlem öznitelik vektörünün çok geniş boyutlarda olmasına neden olabilir. Çünkü N_r ve N_θ orijinal ISAR görüntüde saçılma mekanizmasını içeren çoğu durum için küçük olamaz. Bu yüzden, $N_r \times N_\theta$ boyutlu polar görüntünün $I_p(r_m, \theta_n)$ değerini elde etmek için sıkıştırılması gerekir. Sıkıştırma işlemi sonucunda boyut azaltılabilir. Bu işlem temel bileşenler analizi yardımıyla sağlanır [43, 44]. Genel olarak 2B bir görüntü sınıflandırma için faydalı bilgiler içerir. PCA bu faydalı bilgileri daha düşük boyutta elde edilmesini sağlar. Böylelikle gereğinden fazla olan öznitelik vektörleri daha küçük boyuta indirgenir. Ayrıca, sıkıştırılmış görüntü ile orijinal görüntü arasındaki bilgi kaybı küçük temel-alan hatasının hassasiyeti sayesinde en aza indirilir.

Temel bileşenler analizi ve önerdiğimiz polar format algoritması sayesinde eğitim veri setinin çıkarılması Şekil 4.8'de gösterilmiştir. Şekilde görüldüğü üzere p'nci hedefe ait q'ncu gözlem açısına kadar olan her görüntü üç adet alt özellik bileşeni içermektedir: $f_1(p, q)$, $f_2(p, q)$, $f_3(p, q)$. Bu alt özellik fonksiyonlarından $f_1(p, q)$ bizim r ekseninde oluşturulan öznitelik vektörüne $I_r(r)$ 'ye karşılık gelir. $f_2(p, q)$ θ

yönündeki 1 boyutlu görüntüsünün öznitelik vektörüne $I_\theta(\theta)$ iken, $f_3(p, q)$ da temel bileşenler analizi yardımıyla sıkıştırılmış görüntünün öznitelik vektörünü ifade eder. Böylece bütün öznitelik boyutlarını saklanmış olur. Bunların sayıları $(N_r + N_\theta + l)$ 'ye eşittir. l burada PCA ile azaltılmış öznitelik vektörünün boyutudur [36].



Şekil 4.8 : Bir hedefin önerilen deneme veri setinin mimarisi [26].

4.5 KNN - k-En Yakın Komşuluk Algoritması


ABD Hava Kuvvetleri Hava Hekimliği Okulu'nun 1951 yılındaki yayınlanmamış bir raporunda Fix ve Hodges tarafından patent tanıma alanında kullanılmak üzere parametrik olmayan bir yöntem tanıtılmış ve o zamandan itibaren bu yöntem k-En yakın komşuluk algoritması (K-Nearest Neighbor Algorithm) olarak adlandırılmıştır. k-En yakın komşuluk algoritması daha sonra 1967'de Cover ve Hart tarafından geliştirilmiştir. Geliştirilen sınıflandırma algoritması sayesinde, yeni kabul yaklaşımları (Hellman, 1970), Bayes hata oranının geliştirilmesi (Fukunaga & Hostetler, 1975), uzaklık ağırlıklı yaklaşımlar (Dudani, 1976; Bailey & Jain, 1978), esnek hesaplama yöntemleri (Bermejo & Cabestany, 2000) ve bulanık yöntemler (Jozwik, 1983; Keller et al, 1985) de dâhil pek çok yeni araştırma ortaya çıkmıştır [44].

Kısaca KNN olarak ifade edilen k-En yakın komşuluk algoritması (K-Nearest Neighbor) sınıflandırma algoritmasının temelinde “birbirine yakın olan nesneler muhtemelen aynı kategoriye aittir” mantığı yatar. Algoritmanın amacı, yeni bir

nesneyi özelliklerinden faydalananak önceden sınıflandırılmış örnekler yardımıyla sınıflandırmaktır [45]. Hangi sınıfa ait olduğu bilinmeyen nesne sınıma örneği, önceden sınıflandırılmış nesneler ise öğrenme örnekleri olarak adlandırılır. KNN algoritmasında sınıma örneğinin öğrenme örneklerine olan uzaklıkları hesaplanır ve en yakınındaki k adet örnek çoğunlukla hangi sınıfa aitse sınıma örneğinin de o sınıfa ait olduğu düşünülür.

Şekil 4.9’da KNN algoritmasının mantığı ve uzaklıkların hesaplanması görsel olarak ifade edilmiştir. Burada dikkat edilmesi gereken k sayısına bağlı olarak sınıflandırmanın farklı sonuçları olabileceğidir.

K-Nearest Neighbor algoritması kolay anlaşılabilir bir algoritma olduğu için uygulaması basittir. Sayısal veriler üzerinde uygulanması kategorik verilere oranla daha kolaydır. Ayrıca gürültüye sahip veriler için de olumlu sonuçlar ortaya koyar. Fakat algoritmada kullanılacak verilerin saklanması hafızada fazla yer kaplar. KNN’in bir diğer dezavantajı da yeni bir nesneyi sınıflandırırken diğer nesnelere olan uzaklığının hesaplanması ve karşılaştırılmasının zaman almasıdır.



Şekil 4.9 : KNN algoritması için görsel gösterim

Algoritma yüksek gürültü altındaki verilerde bile çok yüksek bir performans göstermesine rağmen hem k parametresinin hem de uzaklık hesaplama yönteminin belirlenmesine ihtiyaç duyar, bununla birlikte her bir örnek için tek tek uzaklık hesaplama ihtiyacı olması performans açısından dezavantaj oluşturur.

Sınıflandırma işlemine başlamadan önce, bütün verilerin sayısal değerlere dönüştürülmesi ve en yakın kaç tane komşuya bakılacağına yani k sayısının belirlenmesi gerekir. Bir örneğin sınıflandırılması için sınıfı bilinen örnekler seçilir. Sınama örneğinin sınıfını belirlerken öğrenme örnekleri kümesindeki örneklere olan uzaklıkları hesaplanır ve en yakın k tane örnek seçilir. Uzaklık hesaplanırken Öklid, Manhattan, Minkowski gibi farklı uzaklık ölçütlerinden yararlanmak mümkündür fakat çoğunlukla Öklid uzaklık ölçütü kullanılır. Daha sonra, seçilen k tane örnek arasında hangi sınıfa ait örnek sayısı en fazlaysa sınama örneği de bu sınıfa aittir denir.

Öğrenme kümesindeki örnekler x_i , sınama örneği x_q ile gösterilmek üzere KNN yöntemini, yakın olan örneklerin ağırlığını artırarak $w = \frac{1}{d(x_q, x_i)^2}$ formülü ile uzaklık ağırlıklı KNN yöntemi haline getirmek de mümkündür.


4.6 Destek Vektör Makineleri

Klasik istatistik, doğru modelin formunun bilindiğini varsayıp, amacı modelin parametrelerini belirlemek olarak görürken; istatistiksel öğrenme teorisi modelin formunun bilinmediğini kabul etmekte ve doğru olabilecek modeller arasından en iyi modelin bulunmasını hedeflemektedir[46]. Destek vektör makineleri(DVM), istatistiksel öğrenme teorisi ve yapısal riski en aza indirme ilkesine dayanan, sınıflandırma ve eğri uydurma problemlerinin çözümü amacıyla Vapnik tarafından ortaya atılmış bir öğrenme yöntemidir [47]. Bu öğrenme yöntemi denetimli öğrenme yöntemi kapsamına girer. Denetimli öğrenmede, eğitim aşamasında verilerin sınıf etiketleri yani hangi sınıfa ait oldukları bellidir. DVM' nin asıl yaptığı iş kendine girdi olarak gelen verileri 2 sınıfa ayırmaktır. DVM; doğrusal ayrılma, tam olarak doğrusal ayrılama ve doğrusal ayrılama olmak üzere 3 ana başlığa sahiptir.

4.6.1 Doğrusal ayrılma

N adet elemandan oluşan eğitim veri kümesi $D = \{(x_i, y_i), i = 1..N\}$ olduğu kabul edilirse buradaki $y_i \in \{-1, +1\}$ sınıf etiketi $\vec{x}_i \in R^n$ olup n boyutlu uzayda herhangi bir örnektir. $f(\vec{x}) = \vec{w}^T \vec{x} + b$ ifadesinde ki $\vec{w}^T$ karar fonksiyonun normalini, $\vec{x}$ ifadesi bu doğru üzerinde bulunan noktaları, b ise eğilim değerini göstermektedir. Amaç $\vec{w}^T$ ve b' yi eğitim verileri yardımıyla bulmaktır, yani sistemi eğitmektir. Tüm

destek vektör makinelerinde amaç Şekil 4.9 de olduğu gibi verileri 2 sınıfa ayırmaktır. Şekil 4.9 'da kesikli çizgiler ile ifade edilen doğrular üzerindeki vektörler destek vektör olarak isimlendirilir ve yumuşak ayırım çizgisi bu vektörler üzerinden geçer. İki yumuşak ayırım çizgisinin ortasındaki doğru ise sert ayırımdır ve $f(\vec{x}) = \vec{w}^T \vec{x} + b = 0$ fonksiyonuyla çizilir.



Şekil 4.10 : Doğrusal olarak ayırma

$f(\vec{x}) = \vec{w}^T \vec{x} + b$ ifadesindeki $\vec{w}^T$ ve $\vec{x}$ vektörel büyüklüklerdir (4.16)'da verilen denklemin sadeleşmiş halini verir.

$$f(\vec{x}) = \vec{w}^T \vec{x} + b \quad (4.16)$$

$f(\vec{x}) = \vec{w}^T \vec{x} + b \geq 1$ durumunda $y_i = 1$ ve $f(\vec{x}) = \vec{w}^T \vec{x} + b \leq -1$ durumunda $y_i = -1$ 'dir. İki fonksiyonu $y_i(w^T x + b) \geq 1$ şeklinde kısaltabiliriz. Bu ayırma işleminin kistası *sınır* değerini maksimum yapmak ve bu sayede en iyi ayırma sahip olmaktır. Veri setini sınıflara ayırabilecek sonsuz sayıda çoklu düzlem çizilebilmesine karşın, amaç bilinmeyen veri seti ile karşılaşıldığında sınıflama hatasını en küçük yapacak aşırı düzlemi seçmektir. Bunun için maksimum sınırlı aşırı düzlem tekniği önerilmiştir. *Sınır* değerinin büyüklüğü genelleme kabiliyetini artırır. x_1 değeri $f(\vec{x}) = \vec{w}^T \vec{x} + b = 1$ fonksiyonu üzerinde bir nokta ve x_3 değeri $f(\vec{x}) = \vec{w}^T \vec{x} + b = -1$ fonksiyonu üzerinde bir noktadır.

Sınır değerini tespit etmek üzere,

$$\vec{w}^T x_1 + b = +1 \quad (4.17)$$

$$\vec{w}^T x_1 + b = -1 \quad (4.18)$$

Şeklinde verilen denklemlerden (4.17) nolu denklem ile -1 ile çarpılarak (4.18) numaralı denklem ile toplandığında elde edilen ifade $x_1 = x_3 + \lambda \cdot w$ şeklinde yazıldığında, ifadeden $\lambda = 2\vec{w}^2$ 'ye ulaşılır. Burada maksimum değeri istenen λ için $1/\lambda$ değerinin minimum değeri bulunmalıdır. Buradaki sınırlama ise $y_i(w^T x_i + b) - 1 \geq 0, y_i \in \{-1, +1\}$ dir. Optimizasyon problemi, verilen bazı kısıtlamalar altında bir fonksiyonun maksimumunu ya da minimumunu bulmadır [48]. Bu optimizasyon problemi Lagrange denklemleri kullanılarak çözülebilir ve sonuçta denklem (4.19) oluşur.

$$L(w, b, a) = \frac{1}{2} w^T w - \sum_i a_i [y_i (w^T x_i + b) - 1], a_i \geq 0, \forall i \quad (4.19)$$

Bu problem “Karush–Kuhn–Tucker (KKT)” in denklem (4.20) ve denklem (4.21)’deki şartları kullanılarak çözülür.

$$\frac{\partial L}{\partial w_j} = 0, \forall j \quad (4.20)$$

$$\frac{\partial L}{\partial b_j} = 0, \forall j \quad (4.21)$$


Bu denklemler kullanıldıktan sonra $\sum_i a_i y_i = 0, a_i \geq 0, \forall i$ kısıtları altında denklem (4.22)’deki haline dönüşür.

$$L(a) = \sum_i a_i - \frac{1}{2} \sum_i \sum_j a_i a_j y_i y_j x_i^T x_j \quad (4.22)$$

4.6.2 Tam olarak doğrusal ayırlamama

Veriler bazı durumlarda % 100 performansla ayırlamayabilir. Verilerin sınır içerisine düştüğü (Şekil 4.10 daki mavi renkli çember) durum ayırlamama ve sert ayrılma

çizgisinin karşı tarafına düştüğü (Şekil 4.11 deki mavi renkli yıldız) durum da yanlış ayrılma olarak adlandırılır. Bu durumlarda, doğruların minimum hata ile ayırma sağlayacak şekilde ayarlanması gerekir [49].



Şekil 4.11 : Tam olarak doğrusal ayrılama

Yukarıda anlatılan sorunların çözümü için $y_i(w^T x + b) \geq 1$ kısıt değeri altında denklem 4.11'deki hale gelir.


$$y_i(w^T x_i + b) \geq 1 - \xi_i, \xi_i \geq 0, \forall i \quad (4.23)$$

Buradaki ξ_i gevşek değişken olarak isimlendirilir. ξ_i gevşek değişkeni bir x_i örneğinin sınırdan olan sapma uzaklığıdır. Ayrılabilirlik durumunda $\xi_i, 0 \leq \xi_i < 1$ ve yanlış sınıflandırma durumunda $\xi_i, \xi_i \geq 1$ olur. Doğrusal ayrılama durumunda aynı doğrusal ayrılma olduğu gibi maksimum *sınır* bulunmaya çalışılır. Sapma değerlerinin eklenmesiyle minimum denklem $0.5 * ||w||^2 + C \sum \xi_i^2$ şeklini alır. Buradaki 'C' düzenleme parametresi olarak isimlendirilir ve bu değer sınır genişliğini doğrudan etkiler. Tam olarak doğrusal ayrılama optimizasyon problemi doğrusal ayrılabilir durumda olduğu gibi Lagrange denklemi ve KKT şartlarıyla çözülür. Denklemin çözümleri yapıldığında tam olarak doğrusal ayrılma yani yumuşak ayrılma

$y_i(w^T x_i + b) \geq 1 - \xi_i$ denkleminin elde edilmiş olunur ve artık sisteme gelen veriler bu formüle göre sınıflandırılabilir.

4.6.3 Doğrusal ayırlamama (Çekirdek fonksiyonlar)

Gerçek dünyada veriler çoğunlukla doğrusal olarak ayrılamazlar, böyle durumlarda destek vektör makinesi Şekil 4.12 deki gibi girdi uzayını ϕ fonksiyonu ile daha yüksek boyutlu bir uzaya taşıyarak burada doğrusal ayırma işlemlerini uygular.



Şekil 4.12 : Ayırma için boyut genişletme

Girdi uzayının daha yüksek boyutlu uzaya taşınması için $\Phi(x)^T \Phi(x_i) = K(\vec{x}, \vec{x}_i)$ şeklinde bir çekirdek fonksiyonu kullanılır. Bu durumda yeniden düzenlenen Lagrange fonksiyonu (4.24)'teki gibi ifade edilir.

$$\begin{aligned} \sum_i a_i - \frac{1}{2} \sum_i \sum_j a_i a_j y_i y_j x_i^T x_j \Phi(x)^T \Phi(y) \\ = \sum_i a_i - \frac{1}{2} \sum_i \sum_j a_i a_j y_i y_j x_i^T x_j K(x, y) \end{aligned} \quad (4.24)$$

Çekirdek düzenlemesi yapılarak dönüştürülmüş uzaydaki $\Phi(x)$ vektörü yerine girdi uzayındaki verilerden oluşan bir çekirdek fonksiyon oluşturularak işlemler gerçekleştirilir. Çekirdek fonksiyon kullanarak iç çarpım hesaplamak, dönüştürülmüş nitelik seti $\Phi(x)$ kullanarak hesaplamaya kıyasla daha kolaydır ve maliyeti düşüktür [50].

Çekirdek fonksiyonları sınıflandırma probleminin gereksinimine göre seçilir. Örneğin, eğer sınıflandırma problemi doğrusal olarak ayrılabilir bir eğitim verisine sahipse doğrusal çekirdek $k(x, y) = x \cdot y$ kullanılabilir. Eğer sınıflandırma problemi girdi uzayında bir kuadratik sınıflandırma yüzeyine sahipse ikinci dereceden bir polinomik çekirdek $k(x, y) = x \cdot y^2$ kullanılabilir. Eğer bu çekirdek fonksiyonu kullanılırsa özellikler uzayında sınıflandırma yüzeyi doğrusal olacaktır. Girdi uzayındaki daha karmaşık sınırlandırma yüzeylerindeyse daha yüksek dereceli polinomial çekirdekler veya daha karmaşık olan çekirdekler, örneğin gaussian çekirdek, özellikler uzayında doğrusal bir ayırıcı yüzey bulmak için denenebilir. Her fonksiyon özellikler uzayında iç çarpıma sahip değildir. Bir çekirdek fonksiyonunun özellikler uzayında iç çarpımının tanımlı olması için Mercer koşullarını sağlaması gerekmektedir [52].

4.6.4 Mercer koşulları

Belirli koşullar altında özellikler uzayındaki bir iç çarpım girdi uzayında da aynı çekirdek fonksiyona (4.25) sahiptir [53]:

$$k(x, y) = \Phi(x)\Phi(y) \quad (4.25)$$

Eğer K simetrik pozitif tanımlı bir fonksiyon ise, (4.26) ve (4.27)'de belirtilen Mercer koşullarını sağlıyor denir [53].

$$k(x, y) = \sum_k^{\infty} a_k \Phi(x)\Phi(y), a_k \geq 0 \quad (4.26)$$

$$\iint k(x, y)g(x)g(y)dxdy > 0 \quad (4.27)$$

Verili fonksiyonlar sağlanıyor ise çekirdek fonksiyonu özellikler uzayında iç çarpıma sahiptir denir.

4.6.5 Çekirdek fonksiyonu seçimi

DVM modeli tasarlanırken en önemli olan konulardan birisi kullanılacak olan çekirdek fonksiyonu ve seçilen çekirdekte kullanılan parametrelerin belirlenmesidir. Tüm çekirdek fonksiyonlarını ve parametrelerini eğitim verisi üzerinde uygulamak çok doğru bir davranış değildir çünkü bu durum aşırı uyum sorununa sebep olabilir.

Çekirdek seçimi için en uygun yöntem önceki çalışmalar hakkında bilgi edinmektir. Örneğin geçmiş çalışmalarda ikinci dereceden bir polinomik çekirdek kullanılmışsa DVM tasarımına buradan başlamak en doğru yol olacaktır [54]. Modelin doğruluğu ve karmaşıklığı açısından parametre seçimi çok önemlidir. Birçok paket program parametre seçimini otomatik olarak yapar. Otomatik olarak parametre seçiminin yapılması ise hücre arama (grid search) yöntemi ile sağlanır [52].

4.6.6 Doğrusal çekirdek

x ve y 'nin iç çarpımları doğrusal çekirdeği (4.28) tanımlamaktadır.

$$k(x, y) = x' \cdot y \quad (4.28)$$

Bu bir doğrusal sınıflandırıcıdır ve eğitim verisinin doğrusal olup olmadığının testi için kullanılır.

4.6.7 Polinomik çekirdek

Polinomik çekirdek (4.29) doğrusal olmayan ilişkiyi modellemek için kolay ve verimli yöntemlerden bir tanesidir. Rakam tanıma modellerinde kullanımları yaygındır.

$$k(x, y) = (yx' \cdot y + r)^d \quad (4.29)$$

Polinomun derecesi arttıkça aşırı uyum ile karşılaşma olasılığı artmaktadır. Ayrıca derece yükseldikçe sınıflandırma yüzeyi daha karmaşık bir hale gelmektedir. r değeri 0 olduğunda bu kernel fonksiyonu homojen polinomial kernel olarak adlandırılırken, r değeri 0'dan büyük bir değer aldığında homojen olmayan polinomial kernel adını almaktadır.

4.6.8 Radyal tabanlı çekirdek

Sıklıkla tercih edilen çekirdek fonksiyonlarından biridir. σ parametresi ayırma hiper düzleminin şeklini kontrol eder. σ arttıkça DVM sayısı artar ve bu da genelleştirmenin azalmasına sebep olur. Çok kısa zamanda ve çok düşük bir işlem gücüyle yüksek boyutlu uzaylara çıkılabilir. Dolayısıyla bu çekirdeğin kullanımında σ seçimi büyük önem taşımaktadır. Çapraz doğrulama yöntemi izlenerek σ aranmalıdır. Çekirdeğin tercih edilen gösterimleri şu iki denklem ile verilebilir:

$$k(x, y) = e^{-\left(\frac{|x-y|^2}{2\sigma^2}\right)} \quad (4.30)$$

$$k(x, y) = e^{-\gamma|x-y|^2} \quad (4.31)$$

(4.31) denklemini ele alındığında $\gamma = \frac{1}{2\sigma^2}$ olduğu görülür dolayısıyla aranan parametre σ yerine γ olur, çoğu hesaplama tekniğinde γ parametresi kullanılır. [51]

5. DENEYSEL SONUÇLAR

5.1 MSTAR Veri Seti

Makalede kullanılan veriler Sandia National Laboratory (SNL)'nin STARLOS sensörü tarafından Ocak 1998'de kaydedilmiştir. Bu verilerin toplanması, hareketli ve sabit hedef elde etme ve tanıma (Moving and Stationary Target Acquisition and Recognition - MSTAR) programı kapsamında DARPA ve Air Force Research Laboratory (AFRL) tarafından desteklenmiştir. Veriler, X bant aralığında çalışan YAR sisteminin spotlight modunda toplanmıştır. Veriler HH polarizasyonunda toplanmış olup görüntü oluşturmak için hedeften geri yansıyan sinyallerin genlik bilgisi kullanılmıştır.

Şekil 5.1'de gösterilen verilerde, 2S1 Rus yapımı tank (a), BRDM2 Zırhlı personel taşıyıcı (b), D7 Arozözü (c), SLICY Çoklu basit şekilli duran hedef (d), T62 Sovyet savaş tankı (e), ZIL131 model Askeri kamyon (f) ve ZSU-23-4 model askeri tank (g) hedefleri olmak üzere toplam 7 değişik modelde hedef mevcuttur.

Bu 7 farklı model hedefin verileri 15° azimut açılarıyla toplanmıştır. Her bir hedef için $1,5^\circ$ 'lik açıyla 298'er adet toplanan, toplamda 2806 adet görüntü kullanılmıştır. Sınıflamaları karşılaştırmak için görüntülerin %10'u, %33ü ve %50'si olmak üzere üç farklı ölçekte eğitim kümesi oluşturulmuş, geriye kalan veri ise test amaçlı kullanılmıştır. Her veri değişik piksel büyüklüklerinde olup araçlar genelde oluşan görüntünün ortasındadır. Bu görüntüler içerisindeki araçların kapsadığı alan ise yaklaşık olarak 40×40 pikseldir. Daha öncede belirtildiği gibi amacımız; görüntü içerisinde hedef olabilecek bölgeleri tespit ederek bu bölgelerde bulunan nesneleri tanımlamaktır. Aynı görüntü içerisinde birkaç hedefin bulunduğu görüntüler, hedefleri gizlenmiş görüntüler ve hedef olmayıp da hedefmiş gibi görünen bölgeler içeren görüntüler mevcut olmadığı için, sadece farklı piksel verileri kullanılarak uygulamalar gerçekleştirilmiştir. Şekil 5.2'de 2S1'e ait 158×158 piksel değerinde araç modeli için örnek görüntüler dört değişik açı tipi için verilmiştir.



(a)



(b)



(c)



(d)



(e)



(f)




(g)


Şekil 5.1 : MSTAR verileri elde edilen cisimlerin görüntüleri (a)-2S1, (b)-BRDM-2, (c)-D7, (d)-SLICY, (e)-T62, (f)-ZIL-131 ve (g)- ZSU-23-4

Şekil 5.3'deki BRDM-2 zırhlı personel taşıyıcı 128*129 piksel değerine sahiptir. 5.4'te D7 arozözü 177*178 piksel değerindedir. 5.5'de SLICY sabit duran geometrik şekilli hedefi 54*54 piksel değerindedir. Şekil 5.6'te T62 model Sovyet savaş tankı


172*174 piksel deęerindedir. Őekil 5.7’de ZIL-131 askeri kamyon 192*193 piksel deęerinde ve 5.8’de 158*158 piksel deęerinde SAR grntleri gsterilmiřtir.




Őekil 5.2 : 2S1 Rus Yapımı Tank modeli




Őekil 5.3 : BRDM-2 Zırhlı personel Tařıyıcı




Şekil 5.4 : D7 Arazözü




Şekil 5.5 : SLICY Çoklu Basit Şekli Durağan Hedef



Şekil 5.6 : T62 Sovyet Savaş Tankı



Şekil 5.7 : ZIL-131 Askeri Kamyon



Şekil 5.8 : ZSU-23-4 Askeri Tank

5.2 Filtreleme Etkileri


Tezde temel olarak SAR görüntüleme açıklanmış, görüntü üzerinde bulunan problemlerden bahsedilmiş ve daha iyi sınıflama performansı için bilgi koruyan filtrelerin yapısı incelenmiştir. Sonuçlar kısmında daha önce bahsedilen filtrelerin görüntü üzerindeki etkileri ve bunların göstergesi olan metrik değişimleri verilecek daha sonra bu filtrelerin sınıflama performansına olan etkileri gösterilecektir.

Burada parametreleri bulunan ağırlıklandırılmış ATWT ve bilateral filtre için verilen değerler sınıflama oranı için optimize edilmiş değerlerdir.

Metrikleri verilen görüntü sınıflama içinde kullanılacak olan MSTAR veri setinden alınmış, ZIL131 askeri sevkiyat kamyonuna ait görüntüdür. Görüntü boyutu 192x193 piksel ve görüntüleme açısı 138° hedef açısı 359°, görüntüleme menzili 5km'dir. Görüntü hareketli bir hava aracından spotlight modunda alınmıştır.

Şekil 5.9'da ZIL131 askeri kamyonuna ait bir YAR görüntüsü ve buna ait filtrelenmiş görüntüler verilmiştir. Şekil 5.9 a)'da görüntünün kendisi, b)'de medyan filtreden geçirilmiş hali, c)'de ATWT sonucu d)'de ağırlıklandırılmış ATWT sonucu ve e)'de bilateral filtreden geçirilmiş sonuç verilmiştir. Görüntüler göz ile rahat algılanabilmeleri için normalize edilmiştir.


Burada filtrelerin etkileri kolaylıkla seçilebilmektedir, nicel bir incelemeye girişilecek olursa bulgular şu şekilde karşılaştırılabilir. İlk görüntüde bulunan benek gürültüleri ortada bulunan hedefin çevresinde rastgele olarak dağılmış şekilde görülebilmektedir. İkinci görüntüde alınan sonuçta medyan filtre benek gürültülerini belli bir seviyede kaldırırken hedef kenarlarında belirgin bir yumuşama olmamıştır. ATWT sonucunda oluşan görüntüde benek gürültüsünün daha güçlü bir şekilde bastırıldığı görülmektedir. Ağırlıklı ATWT’de benek gürültüsü neredeyse tamamen kaldırılmıştır fakat bununla birlikte hedefin ana loblarında bir seviye düşüşü görülmektedir. Bilaretal filtre sonucunda ise hedef bölgesi ve hedef değerleri maksimum ölçüde korunurken benek gürültüsünün etkileri istenilen ölçüde bastırılabilmiştir. Burada bilaretal filtrenin ve ağırlıklı filtrenin katsayıları sınıflama performansını optimize edecek şekilde seçilmiş bu optimizasyon işlemi ilgili bölümde ayrıca verilmiştir.



Şekil 5.9 : Filtresiz ve filtrelenmiş görüntüler için örnekleri (ZIL131)

5.3 Katsayıların Görüntülere Etkisi

Bilaeral filtre katsayılarının incelenmekte olan radar görüntüsüne etkisi Şekil 5.10'da gösterilmiştir. Burada görüntü değişkenlerin çapraz değişimine tabi tutulmuştur. σ_s için 0,2; 0,8 ve 5 değerleri σ_r için 0,2; 1,2 ve 5 değerleri uygulanmıştır. İlk görüntü en düşük katsayıların kullanıldığı görüntü olup bu görüntünün asıl görüntüye yakın olduğu ve tüm gürültü unsurlarının hala mevcut olduğu gözlenmektedir. σ_r değeri düşük değer olarak verilen 0,2 değerinde sabit tutulup σ_s değeri arttırılmaya başlandığında mevcut durumda çok büyük değişiklikler gözlenmemektedir, fakat dikkatli bir inceleme sonucunda detayda bulunan parıldamalar azalmış durumdadır.



Şekil 5.10 : Bilateral filtre çıkışlarının σ_r ve σ_s değerleriyle değişimi (ZIL131)

σ_r değeri büyütüldüğünde görüntüde daha belirgin değişimler yaşanmaya başlamıştır, benek gürültüsü oranında azalma farkedilebilir bir düzeye gelmiştir. Bu durumda σ_s arttırıldığında ise benek gürültüsündeki bastırmalar hızlı bir şekilde artmaktadır

detaydaki parıldamalar hızla sönmekte arka plandan gelen karıştırma etkileri azalmaktadır fakat bununla birlikte ana saçıcının tepe noktası olarak belirlenen görüntüdeki maksimum değer de etkilenmekte ve hızla düşmektedir. Böyle bir durum hedefe ait güçlü özelliklerin de bastırılmaya başlandığı göstermektedir.

Çizelge 5.1 : Bilateral filtre için sıralı görüntü metrik değerleri


		$\sigma_s = 0,2$	$\sigma_s = 1,2$	$\sigma_s = 5$
$\sigma_r = 0,2$	TBR	28.4316	28.4316	28.4316
	Entropi	4.6392	4.6392	4.6392
	TBED	0.0689	0.0689	0.0689
	MLBW	229	229	229
	ENL	1.4407	1.4407	1.4407
	ESI	1.7704	1.7704	1.7704
$\sigma_r = 0.8$	TBR	26.5777	23.5171	23.1620
	Entropi	3.8158	3.8183	3.8183
	TBED	0.1274	0.1324	0.1323
	MLBW	306	499	566
	ENL	3.0794	3.4217	3.4291
	ESI	0.7517	0.7442	0.7441
$\sigma_r = 5$	TBR	20.6257	14.7889	14.8822
	Entropi	3.0562	3.0874	3.0897
	TBED	0.2503	0.3007	0.3031
	MLBW	247	6994	7116
	ENL	8.2785	7.9710	7.8010
	ESI	0.3639	0.3720	0.3734

σ_r değeri uç değer olarak verilebilecek 5 seviyesine getirildiğinde benek gürültüsünün neredeyse tamamen bastırıldığını söylemek mümkündür, beraberinde beklendiği üzere hedef üzerinde fazlaca yumuşama(smoothing) olmasına neden olmuştur. Görüntünün kendisinde 1.0 baz olarak alınan maksimum değer burada 0,45 seviyesine kadar düşmüştür bu seviyede işlem silme işlemine dönüşmeye başlamıştır. Burada σ_s

değerinin arttırılması daha yüksek bir silmeyi de beraberinde getirmektedir. Burada hedefin maksimumu iyice azalırken hedef sınırları belirginliğini iyice kaybetmekte ve hedef üzerindeki farklı saçıcıların verileri birbiri ile karışarak birleşmeye başlamaktadır.

Çizelge 5.1 de Şekil 5.10'daki sonuçlara ait görüntü metrikleri yine aynı sırada verilmiştir. Yukarıda görsel olarak vardığımız kanı ve sonuçlar burada nicel olarak da teyit edilmektedir. σ_r 'nin düşük değerleri için σ_s 'in çok fazla bir etkisi yok iken σ_r değeri arttırıldığında görüntünün σ_s değişikliklerine de tepkisi artmaktadır. Burada dikkat edilmesi gereken hususlardan biri de TBED olarak verilen hedef arka plan entropi farkı değeridir, bu değer daha önce belirtildiği gibi hedefin arka plandan ayrılabilmesi oranının gücünü göstermekte olup katsayıların artması ile artmaktadır.

Görüntülerin incelenmesiyle de anlaşılabileceği üzere bu büyük ölçüde arka planda buluna gürültülerin bastırılması ile ilgilidir. Her ne kadar ilk aşamada bu değer in hedefin tanınmasına katkı sağlayacağı düşünülecek olsa da bu tek başına hedefin otomatik tanıma algoritması tarafından tanınabilir olmasını belirtmekten uzak olacaktır. Zira yüksek filtre katsayıları yumuşatma işlemini bir noktada silme işlemine dönüştürerek benek gürültüsü ile birlikte hedefin belirginliğini ve hedefin tanıma detaylarını da azaltmaktadır.



Şekil 5.11 : Ağırlıklı ATWT sonucunun σ değeriyle değişimi ($\sigma = 0.2, 0.8, 2.1$)

Ağırlıklı ATWT filtre daha önce izah edildiği gibi tek bir değişkeni bulunmaktadır, elde edilen görüntüler Şekil 5.11'de gösterilmiştir burada σ değeri sırasıyla 0,2; 0,8 ve 2,1 olarak alınmıştır. Görsel incelemede ilk dikkati çeken unsurlardan biri düşük benek gürültüsüdür. Düşük σ değerinden itibaren bütün görüntülerde benek gürültüsü güçlü bir şekilde bastırılmaya başlanmıştır, bu güçlü bastırmanın etkisi olarak da maksimum değerler çok yüksek genliklere ulaşamamaktadır. 0,8 değerine gelindiğinde oranla

önceki değere çok daha yüksek bir benek gürültüsü bastırması gözlenebilmektedir, burada maksimum değer biraz daha kırılmış olsa da hedefin saçıcıları birbirinden hala ayrı durmaktadır. σ değeri 2,1 mertebesine çıkarıldığında artık saçıcılar birbirine girmeye başlamıştır, ana lob yayılma göstermektedir.


Verilen görüntüler ile ilgili Çizelge 5.2'de verilen metrikler incelendiğinde görsel inceleme sonuçları bir kez daha teyit edilmektedir. Bilateral filtreye benzer şekilde burada da hedef arka plan entropi farkı (TBED) oranında iyileşme görülmektedir.

Çizelge 5.2 : Ağırlıklı ATWT için sıralı görüntü metrik değerleri

	$\sigma_s = 0,2$	$\sigma_s = 0,8$	$\sigma_s = 2,1$
TBR	23.1056	18.3404	18.2121
Entropi	3.4018	3.4084	3.4091
TBED	0.1860	0.1975	0.1982
MLBW	317	2652	2894
ENL	5.1939	5.282	5.255
ESI	0.5110	0.5122	0.5120

5.4 Katsayıların Belirlenmesi

Katsayıların belirlenmesi için iki türlü yaklaşım geliştirilebileceği açıktır bunlardan birincisi görüntülerin iyileştirilmesinin sınıflama başarımını da artıracığından yola çıkarak yüksek oranlı metrikleri seçmek, bir diğer yaklaşım da direk olarak sınıflamanın ne olduğuna bakarak katsayıların seçilmesidir.



Şekil 5.12 : Bilateral filtre için Benek Gürültüsü Metrikleri Değişimi


Bu yaklaşım için öncelikle ENL ve ESI metrik değerleri çıkarılarak normalize edilir, burada ENL değeri gürültü seviyesi ESI değeri de kenarların düzeltilen gürültüyle olan farkını verdiği için tamamlayıcı metrikler olarak alınabilir. Normalize eğrilerin birbirini kesiştiği nokta optimum olarak alınır,

Bilateral filtre için σ_r ve σ_s değerleri için çıkarılmış ENL ve ESI değerlerinin örtüşmesi Şekil 5.12'deki gibi hesaplanmıştır. Burada kesişim eksenini bir eğri üzerinde çıkmış ve eğri üzerinde 0'a en yakın nokta büyük değerler bozulmasından uzak olacağı sebebiyle seçilmiştir. Bu durumda seçilen değerler $\sigma_r = 0.5$ ve $\sigma_s = 0.8$ 'dir. Bu değerler için 30 elemanlık kümenin sınıflama sonuçları Çizelge 5.3'te verilmiştir.

Çizelge 5.3 : Bilateral Filtre için gürültü metriklerine göre sonuç.

KNN sonucu	73.63
DVM sonucu	76.51
Ortalama	75.07

Ağırlıklı ATWT için Şekil 5.13'te gösterilen nokta $\sigma = 0.6$ noktasıdır, bu durumda 30 adet görüntü için hesaplanan sınıflama değeri Çizelge 5.4'te verilmiştir.



Şekil 5.13 : Ağırlıklı ATWT için Benek Gürültüsü Metrikleri Değişimi

Aynı yaklaşımın devamında işlemler görüntü metrikleri için de yapılır, bunun için iki anlamlı metrik entropi ve TBR olduğu kabul edilmiştir; zira kaldırılan gürültü ile birlikte, gürültünün entropiye yaptığı katkı azalacağı entropi değeri azalacak, bununla

birlikte yumuşayan hedef bölgesi görüntü üzerinde daha büyük bir alan kaplamaya başlaması hedefin görüntü üzerinde ne kadar alan kapladığını veren TBR değeri büyümeye devam edecektir.


Bilateral filtre için σ_r ve σ_s değerleri için çıkarılmış entropi ve TBR değerlerinin örtüşmesi Şekil 5.14'deki gibi hesaplanmıştır. Burada kesişim eksenini bir eğri üzerinde çıkmış ve eğri üzerinde 0'a en yakın nokta büyük değerler bozulmasından uzak olacağı sebebiyle seçilmiştir. Bu durumda seçilen değerler $\sigma_r = 0.7$ ve $\sigma_s = 1$ 'dir. Bu değerler için 30 elemanlık kümenin sınıflama sonuçları Çizelge 5.5'te verilmiştir.

Ağırlıklı ATWT için Şekil 5.15'te gösterilen nokta $\sigma = 1$ noktasıdır, bu durumda 30 adet görüntü için hesaplanan sınıflama değeri Çizelge 5.6'da verilmiştir.

Çizelge 5.4 : Ağırlıklı ATWT için görüntü metriklerine göre sonuç.

KNN sonucu	%70.90
DVM sonucu	%76.38
Ortalama	%73.64

Diğer yaklaşım olarak da Bilateral filtreye ve ağırlıklı ATWT'ye ait katsayılar sınıflamayı optimum yapacak şekilde seçilmiştir. Burada bilateral filtre için çapraz tarama ağırlıklı ATWT için de lineer tarama yapılmıştır.



Şekil 5.14 : Bilateral filtre için Görüntü Metrikleri Değişimi


Bilateral özelinde öncelikle σ_s değeri atanmış bu değer sabit iken σ_r değeri değiştirilerek sınıflayıcı performansı takip edilmiştir. Tarama aralıkları σ_s için [0,1;2] aralığında ve σ_r için [0,1;2,5] aralığında alınmıştır. İşlemler hız ve kolaylık açısından 7 hedef içeren küme için her kümeden alınan 30 görüntünün 15'inin eğitim 15'inin de test olarak kullanılmasıyla gerçekleştirilmiştir. Bu tarama işlemi sadece KNN sınıflayıcı ile gerçekleştirilmiş olup daha sonra SVM için de aynı eğriye uyumlu sonuçlar alındığı gözlenmiştir. Sınıflama sonuçlarının kendi tutarlılığı için de Monte Carlo validasyonu kullanılmıştır.

Çizelge 5.5 : Bilateral Filtre için görüntü metriklerine göre sonuç.

KNN sonucu	73.56
DVM sonucu	76.80
Ortalama	75.10

Bilateral filtre çıkışında elde edilen sınıflama oranları düşük yoğunluklu kümenin etkilerini azaltmak amacıyla hareketli ortalamaları alındıktan sonra Şekil 5.17'deki hale gelmiştir.

Burada elde edilen sonuçlar doğrultusunda σ_r değerinin değişiminin sınıflamaya olan etkisinin σ_s değerinden çok daha keskin olduğu anlaşılmaktadır. Sınıflamanın maksimum olduğu noktalar incelendiğinde en yüksek oranın ve $\sigma_r=1,2$; ve $\sigma_s=0,8$ olduğu bölgenin çevresinde bulunduğu anlaşılmaktadır, böylelikle merkez nokta olan $\sigma_r=1,2$; ve $\sigma_s=0,8$ değerleri optimum nokta olarak seçilir.




Şekil 5.15 : Ağırlıklı ATWT için görüntü metrikleri değişimi

Ağırlıklı ATWT filtreleme için bilateral filtrede kullanılan yaklaşıma benzer şekilde işleme girilmiştir. Yalnız burada görüntülerin süzülmesine ve sınıflamaya etki eden değişken bilateral filtrelemedeki gibi iki değil sadece bir adettir bu sebeple çapraz tarama yerine sade bir lineer tarama kullanılmıştır. Burada σ tarama aralığı $[0,5;5]$ aralığında alınmıştır, artım aralıkları 0,1'dir. Bilateral filtrede olduğu gibi burada da işlem kolaylığı için 7 sınıfa ait görüntülerden 30'ar adet alınarak bunlardan 15 adedi eğitim kümesini oluşturmak için diğer 15 tanesi de test kümesi için kullanılmıştır.

Çizelge 5.6 : Ağırlıklı ATWT için görüntü metriklerine göre sonuç.


KNN sonucu	%71.20
DVM sonucu	%76.58
Ortalama	%73.89

Bu testlerin tamamlanması sonucunda elde edilen grafik Şekil 5.16'da gösterilmiştir. Burada elde edilen sonucu yorumlamak bilateral filtre sonucunu yorumlamaktan çok daha kolay olacaktır. Bilateral filtre için iki değişkenin optimizasyonu için yüzeyde tarama yapılırken burada tek değişken için bir grafik elde edilmiştir. Sınıflayıcı olarak yine KNN kullanılmış SVM sınıflayıcısı için grafiğin tutarlı olduğu görülmüştür. Sınıflama sonuçlarının kendi tutarlılığı için de Monte Carlo validasyonu kullanılmıştır. Grafikten açıkça seçilebileceği üzere $\sigma = 0,8$ değeri maksimum sınıflama performansına sahiptir.



Şekil 5.16 : Bilateral Filtre çıkışları için değişim grafiği

Biri görüntü iyileşmesini sağlamak diğeri de sınıflama oranları yükseltmek üzere denenilen iki farklı yaklaşımla çıkarılan katsayılar için sınıflama performansı yüksek olan sınıflama optimizasyonu sonucu olmuştur. Bu nedenle sınıflama sonuçları bu optimizasyon sonucu elde edilen değerler deney için kullanılmıştır.



Şekil 5.17 Ağırlık ATWT için değişim grafiği

5.5 Sınıflama Sonuçları:

Görüntüler üzerindeki bozucu gürültü etkileri bastırmak üzere kullanılan filtrelerin düzelttikleri görüntüler iki farklı algoritma vasıtasıyla sınıflanarak bu filtrelerin sınıflama başarımları üzerindeki etkileri incelenmiştir. Kullanılan filtrelerden olan ağırlıklı ATWT filtre değişkeni σ için $\sigma = 0,8$ olarak alınmış ve bilateral filtre değişkenleri olan σ_r ve σ_s için $\sigma_r=1,2$; ve $\sigma_s=0,8$ olarak alınmıştır.

Sınıflama performanslarının derinlemesine incelenebilmesi için eğitim kümesinin farklı büyüklüklerde olduğu sınıflamalar yapılmıştır. Kullanılan veri setinde yedi sınıf bulunup her bir sınıfa ait 298 adet farklı açılardan alınmış görüntüler bulunmaktadır. İlk deney için görüntülerin %10'u eğitim olarak kullanılmıştır, geriye kalan görüntüler test kümesine dahil edilmiştir.. İkinci deney için görüntülerin %33'ü eğitim verisi olarak kullanılmış yine geriye kalanları test kümesine dahil edilmiştir. Üçüncü deney için de tüm verilerin %50'si eğitim amacıyla, geriye kalan %50'si de test amacıyla kullanılmıştır. Algoritma olarak $k=5$ değerine sahip Manhattan uzaklığı kullanan KNN sınıflayıcı ve radyal çekirdekli DVM kullanılmıştır. Sınıflamaların validasyonu ve

rastgelelikten gelecek olan eksi ve artı katkıları ortadan kaldırmak için Monte Carlo validasyon yöntemi kullanılmıştır. Tüm deneyler ve kullanılan yöntemler için alınan sınıflama sonuçları Çizelge 5.7’de gösterilmiştir.

Sınıflamada en yüksek başarı bilateral filtre ile alınan sonuç ile sağlanmıştır. Burada kontrol edilebilen iki adet parametrenin bulunması büyük bir katkı sağlamaktadır. Tüm filtreleme yöntemleri filtresiz sınıflamaya üstünlük sağlamış durumdadır. Bilateral filtreden sonra en başarılı yöntem ağırlıklı ATWT olmuştur, yine burada yöntemin parametre değiştirme ile optimize edilebilir olması uygun bir değer seçmeye imkân sağlamıştır.

Çizelge 5.7 : Sınıflama deney sonuçları.

		Filtresiz	Medyan	Atwt	Ağırlıklı	Bilateral
Eğitim: %10	KNN	%65.30	%65.62	%65.78	%66.03	%66.59
	DVM	%68.61	%71.57	%71.77	%73.27	%73.66
Eğitim: %33	KNN	%79.73	%80.79	%80.22	%81.11	%81.41
	DVM	%83.87	%85.80	%85.90	%86.06	%86.97
Eğitim: %50	KNN	%83.55	%84.07	%84.24	%85.00	%85.43
	DVM	%87.56	%88.88	%88.93	%89.09	%90.13

Parametresiz filtreleme yöntemleri olan medyan filtre ve ATWT yöntemleri birbirlerine yakın sonuçlar vermiş fakat ATWT algoritması tutarlı bir şekilde daha yüksek sonuç vermiştir.

DVM algoritmasının esnek ve sofistike yapısı her durumda KNN algoritmasına göre üstünlük sağlamıştır, özellikle eğitim kümesinin gelişmesi DVM ile yapılan sınıflamada çok daha yüksek bir sınıflama artışına yol açmıştır, aynı şekilde filtresiz görüntülerin iki algoritma arasındaki farkı filtrelenmiş görüntülerin algoritmalar arasındaki farkından daha düşüktür. Bu da filtrelemenin DVM gibi yüksek boyutlarda arama yapan algoritmalara küçük farklarla yüksek boyutlarda avantaj sağladığını

göstermektedir. Tabloda dikkat çeken bir başka husus eğitim kümesi genişledikçe filtreli yöntemlerdeki sınıflama artışının filtresiz yöntemle göre daha fazla artış göstermesi olmuştur.

Hangi hedefin nasıl sınıflandığını gösteren karşılaştırma matrisi filtrelenmemiş görüntülerin KNN ile sınıflandırılma deneyi sonuçları için Çizelge 5.8’de verilmiştir. Burada eğitim kümesi %50’dir. Doğru sınıflama oranı ise %87.56 olarak hesaplanmıştır.

Çizelge 5.8 : DVM ile sınıflanmış filtrelenmemiş görüntü sonucu (Eğitim:%50).

DVM	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	132	3	1	5	2	6	0
BRDM2	1	140	0	3	2	3	0
D7	0	0	135	6	1	1	6
SLICY	2	0	4	142	0	0	1
T62	8	0	3	1	121	12	4
ZIL131	8	5	2	4	8	119	3
ZSU23	1	0	7	3	5	2	131

Burada özellikle ZIL131 hedefinin ve T62 hedefinin sınıflanmasında en yüksek oradan fireler olduğu görülmektedir. Slicy hedefi yüksek oranda sorunsuz olarak sınıflanabilen hedef olmuştur. BDRM2 hedefinin sınıflanmasında da yüksek sayılabilecek bir başarı yakalanmıştır, 2S1 hedefinde Slicy ve ZIL131 hedefi olarak sınıflandığı parçaları bulunmaktadır. D7 hedefinin yanlış sınıflanmış bölümünün bir kısmı Slicy ve yine aynı miktarda kısmı ZSU23 olarak sınıflanmıştır. T62 hedefinin yanlış olarak tanınan büyük bir kısmı ZIL131 hedefi olarak işaretlenmiştir. ZIL131 hedefinin yanlış sınıflanmış kısımlarına ait detay olarak bunların dört hedef arasında yakın sayılarda dağılmış olması vardır. Son olarak ZSU23 hedefinin bir kısmının D7 olarak sınıflandığı anlaşılmaktadır.

DVM ile sınıflanan ve görüntülerin %50sinin eğitim için ayrıldığı bilateral filtre ile işlenmiş görüntülerin sınıflama sonucu oluşturulan karşılaştırma matrisi Çizelge 5.9’da verilmiştir, burada test işlemlerinde doğru sınıflama oranı %90,13’tür, bu oran deneyler sırasında ulaşılan en iyi sınıflama sonucudur.

Çizelge 5.9’da görüldüğü üzere hedeflerin çoğu hassas şekilde belirgin bir karışıklık olmadan sınıflanmıştır, fakat T62 hedefi ZIL131 hedefleri arasında küçük çaplı da olsa karşılıklı bir karışma gözlemlenmektedir. En ayırık hedef olan SLICY hedefi en yüksek başarıyla sınıflanan hedef olmuştur. ZIL131 en başarısız olarak sınıflanan hedef olmuş bir kısmı T62 hedefi olarak bir kısmı da 2S1 hedefi olarak sınıflandırılmıştır.

Çizelge 5.9 : DVM ile sınıflanmış bilateral filtre sonucu (Eğitim kümesi:%50).

DVM	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	137	2	1	2	4	3	0
BRDM2	4	134	0	2	5	2	2
D7	0	0	139	4	0	1	5
SLICY	1	0	1	142	0	3	2
T62	1	0	0	0	129	10	9
ZIL131	11	4	0	1	11	119	3
ZSU23	1	0	6	1	7	2	132

Bilateral filtre, filtresiz hale göre %3’e yakın bir sınıflama başarıımı iyileşmesi sağlamıştır, hedefler özelinde bu başarımları karşılaştıracak olursak 2S1 hedefinin filtresiz sınıflamada Slicy ve ZIL131 olarak sınıflanan bir kısmı doğru sınıflanmıştır. BDRM2 hedefi için ufak bir sorun göze çarpmaktadır, bilateral filtre sonuçlarında bu hedef için sınıflama başarıımı düşmüştür, hedeflerin bir kısmı 2S1 ve T62 hedefi olarak sınıflanmıştır. D7 hedefinin filtresiz durumda Slicy olarak işaretlenen görüntüleri doğru sınıflanmaya başlanmıştır. Slicy hedefi için herhangi bir değişiklik olmamış aynı oranda sınıflanmaya devam etmiştir. T62 hedefinde yüksek oranlı bir düzelme görülmüş ve özellikle 2S1 olarak işaretlenen görüntülerin düzgün sınıflanması

sağlanmıştır. ZIL131 hedefi her iki durumda da en düşük oranla sınıflanan görüntü olmuştur, filtre işlemi bu hedef için düzeltme sağlamamıştır, iki durumda da aynı oranda sınıflama yapılmıştır. ZSU2 hedefi için de filtreli ve filtresiz görüntülerinin sınıflanması arasında çok belirgin bir fark oluşmamış her iki durumda da sınıflama oranı neredeyse aynı yüzde ile gerçekleşmiştir.

6. SONUÇLAR VE DEĞERLENDİRMELER

SAR görüntülerinin gece ve gündüz farketmeksizin her türlü hava koşulunda alınabilir olması, bu görüntüleri hedef tanınma uygulamaları için çok önemli bir kaynak yapar. Ancak SAR görüntülerinin alınması sırasında oluşan benek gürültüsü ve yan lob gibi bozucu etkiler sınıflama algoritmalarının performanslarını sınırlandırmaktadır. Çeşitli yöntemler ile benek gürültüsünün bastırılması ya da görüntünün iyileştirilmesi hedefin geri plandan ayırılabilirliğini artırır, dolayısıyla sınıflama performansı iyileşir. Bu nedenle tez çalışmasında radar gürültüleri sınıflama öncesinde çeşitli görüntü ayrıştırma teknikleri ile bir dizi detay görüntü ve kalıntı görüntüye çevrilmiş, bozucu etkilerin detay görüntülerinde kalması sağlanarak, sadece kalıntı görüntüler sınıflama için kullanılmıştır.

Görüntü ayrışmaları için sabit katsayılı ATWT, ağırlıklı ATWT ve bilateral filtre kullanılmıştır. ATWT dalgacık dönüşümü tabanlı olarak görüntüyü bir dizi detay görüntü ve kalıntı görüntüsüne dönüştürme işlemi yapar. Bilateral filtre ise konumsal ve genlik domeninde iki Gauss süzgeçten oluşur ve içerdiği konum ve genlik parametreleri kullanılarak istenmeyen bilginin detay görüntülere geçişi kontrol edilebilir. Ağırlıklı ATWT’de ise klasik ATWT çekirdek fonksiyonu sadece genlik domeninde bir Gauss süzgeç ile birleştirilerek görüntü ayrışımı tek bir kontrol ile gerçekleştirilir. Bunların yanında benek gürültüsü gidermede klasik yaklaşımlardan olan medyan filtre, karşılaştırma amacıyla kullanılmıştır. Gerek bilateral filtrede gerek ağırlıklı ATWT’de parametrelerin seçimi ayrıştırma sonucunu büyük ölçüde etkiler. Dolayısıyla amaçlanan işleme uygun parametre seçimi gerçekleştirilmelidir. Bu tez çalışmasında radar hedef sınıflama performansının artırılması hedeflendiği için iki farklı yaklaşım izlenmiştir: birincisi görüntü üzerindeki bozucu etkilerin (benek gürültüsü, yan lob) giderilme performansını ölçen gürültü giderme metrikleri ve görüntü kalite metrikleri ve ikinci olarak doğrudan sınıflama performansı en iyileme kriteri olarak kullanılmıştır.

Öncelikli yaklaşım olarak filtrelenen görüntülerin, gürültü metrikleri incelenmiş, optimum olmaları gereken noktalar belirlenerek bu noktalara karşılık gelen katsayılar

ile sınıflama yapılmıştır. Devamında aynı işlem görüntü metrikleri için yapılmış yine buradan görüntülerin en iyi olduğunu belirten katsayılar ile sınıflama işlemi yapılmıştır. Son olarak ise kullanan yöntemler için parametreler sınıflamaların maksimum olması için optimize edilmiştir.

Tartışılan tüm yaklaşımların, önışleme yapılmamış görüntülerin sınıflandırılmasına göre sınıflama performansı üzerinde, iyileştirme yaptığı görülmüştür. Ancak en iyi performans doğrudan sınıflama yüzdesinin en iyileme kriteri olarak kullanıldığı durum için elde edilmiştir. Sınıflama işlemi sonuçların tutarlılığının teyit edilebilmesi için basit bir yaklaşım olan KNN ve daha sofistike bir yöntem olan DVM sınıflayıcıları ile yapılmış ve bu iki yöntem de bir biri ile tutarlı sonuçlar vermiştir.

Yöntem parametre optimizasyonuna dayandığı için tek parametrelili yöntem, iki parametrelili yönteme göre daha düşük performans göstermiştir. Ayrıştırma yönteminin parametrelerinin artmasıyla birlikte optimizasyon serbestliği arttığı için daha yüksek başarılı sonuç elde edilebilmiştir.

Çalışmanın devamında daha farklı kenar koruyan görüntü ayrışım tekniklerinin sınıflama üzerindeki etkisi incelenebilir. Ayrıca bu çalışmada daha iyi performans veren iki parametrelili yöntemin kullanılması işlem yükü açısından sorun oluşturmuştur, bunun için daha az parametre içeren, daha farklı görüntü ayrışimleri önerilerek sınıflama öncesi kullanılması düşünülmektedir..

KAYNAKLAR

- [1] **Sarıkaya, K.** (2014). *2-boyutlu seyrek özbağımlı modelleme ile radar hedef sınıflandırma* (Yüksek lisans tezi). İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- [2] **Deliormanlı, S.** (2009). *Yapay Açıklık Radar Ham Verilerinden Görüntü Oluşturulması*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi.
- [3] **Özdemir, C.** (2012). Inverse synthetic aperture radar imaging with Matlab algorithms, Wiley, pp. 107
- [4] **Odendaal, J. W., Bernard, E. ve Pistorius, C. W. I.** (1994). *Two-Dimensional Superresolution Radar Imaging Using the MUSIC Algorithm*, IEEE Transactions on Antennas and Propagation, Vol. 42, No. 10.
- [5] **Gupta, I. J.** (1994). *High Resolution Radar Imaging Using 2-D Linear Prediction*, IEEE Transactions on Antennas and Propagation, Vol. 42.
- [6] **Walton E. ve Moghaddar A.** (1991). *High Resolution Imaging of Radar Targets Using Narrow Band Data*, IEEE AP Soc. Int. Symp., Londra.
- [7] **Park, J. I. ve Kim, K. T.** (2010). *A Comparative Study on ISAR Imaging Algorithms for Radar Target Identification*, Progress in Electromagnetics Research, Vol. 108, 155-175.
- [8] **Mensa, D.L.** (1991). High resolution radar cross section imaging, Artech House
- [9] **Lee, J.S.,** (1981) Speckle analysis and smoothing of synthetic aperture radar images. Comput. Graph. Image Process., 17: 24-32
- [10] **Porcello et al.** (1976) Speckle reduction in synthetic aperture radars, J. Opt. Soc. Am. 66, 1305-1310.
- [11] **Guenther et al.** (1978). Digital processing of speckle images, Proceedings of 1978 Conference on Pattern Recognition and Image Processing, Chicago, Ill, pp. 85-90.
- [12] **Goodman, J.W.** (1976). Some fundamental properties of speckle, J. Opt. Soc. Amer. 66, No. 1145-1150.
- [13]. **Pearson, K.** (1906). *A Mathematical Theory of Random Migration*, Draper's Company Research Memoirs, Londra, Biometric Ser. III.
- [14] **Xie, H., Ulaby, F. T., Pierce, L. E., & Dobson, M. C.** (1999). Performance metrics for SAR speckle-suppression filters. In *Geoscience and Remote Sensing Symposium, 1999. IGARSS'99 Proceedings. IEEE 1999 International* (Vol. 3, pp. 1540-1542). IEEE
- [15] **Durand, J. M., Gimonet, B. J., & Perbos, J. R.** (1987). SAR data filtering for classification. *Geoscience and Remote Sensing, IEEE Transactions on*, (5), 629-637.
- [16] **Hagg, W., & Sties, M.** (1996). The EPOS speckle filter: a comparison with some well-known speckle reduction techniques. *International Archives Of Photogrammetry And Remote Sensing*, 31, 135-140.

- [17] **Anfinsen, S. N., Doulgeris, A. P., & Eltoft, T.** (2009). Estimation of the equivalent number of looks in polarimetric synthetic aperture radar imagery. *Geoscience and Remote Sensing, IEEE Transactions on*, 47(11), 3795-3809.
- [18] **Lee, J. S., Hoppel, K., & Mango, S. A.** (1992). Unsupervised estimation of speckle noise in radar images. *International Journal of Imaging Systems and Technology*, 4(4), 298-305.
- [19] **Yan, Y., Zhou, Y., & Li, C. S.** (2002, July). Quantitative assessment of speckle filters for SAR images. In *Second International Conference on Image and Graphics* (pp. 428-433). International Society for Optics and Photonics.
- [20] **Moulin, P.** (1993). A wavelet regularization method for diffuse radar-target imaging and speckle-noise reduction. *Journal of Mathematical Imaging and Vision*, 3(1), 123-134.
- [21] **Snyder, D. L., O'Sullivan, J. A., & Miller, M. I.** (1989). The use of maximum likelihood estimation for forming images of diffuse radar targets from delay-Doppler data. *Information Theory, IEEE Transactions on*, 35(3), 536-548.
- [22] **Moulin, P., O'Sullivan, J. A., & Snyder, D. L.** (1992). A method of sieves for multiresolution spectrum estimation and radar imaging. *Information Theory, IEEE Transactions on*, 38(2), 801-813.
- [23] **Strang, G.** (1989). Wavelets and dilation equations: A brief introduction. *SIAM review*, 31(4), 614-627.
- [24] **Heil, C. E., & Walnut, D. F.** (1989). Continuous and discrete wavelet transforms. *SIAM review*, 31(4), 628-666.
- [25] **Stenborg, G., & Cobelli, P. J.** (2003). A wavelet packets equalization technique to reveal the multiple spatial-scale nature of coronal structures. *Astronomy & Astrophysics*, 398(3), 1185-1193.
- [26] **Wegner, F. V., Both, M., & Fink, R. H. A.** (2006). Automated detection of elementary calcium release events using the a trous wavelet transform. *Biophysical journal*, 90(6), 2151-2163.
- [27] **Tukey, J. W.** (1977). Exploratory data analysis.
- [28] **Narendra, P. M.** (1981). A separable median filter for image noise smoothing. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, (1), 20-29.
- [29] **Paris, S., Kornprobst, P. ve Tumblin, J.** (2009). Bilateral Filtering: Theory and Applications, *Foundations and Trends in Computer Graphics and Vision*, 4 (1), 1-73
- [30] **Hu, J. ve Li, S.** (2012). The multiscale directional bilateral filter and its application to multisensor image fusion, *Information Fusion*, 13(3), 196-206.
- [31] **Kaplan, N.H.**, 2015. Yeni Çoklu Çözünürlüklü Görüntü Ayırışimleri ile Çoklu Spektral ve Pankromatik Uydu Görüntülerinin Füzyonu. Doktora Tezi. İstanbul: İstanbul Teknik Üniversitesi.

- [32] **Wang, J., & Liu, X.** (2006). SAR minimum-entropy autofocus using an adaptive-order polynomial model. *Geoscience and Remote Sensing Letters, IEEE*, 3(4), 512-516.
- [33] **Benitz, G. R.** (1997). High-definition vector imaging. *Lincoln Laboratory Journal*, 10(2), 147-170.
- [34] **Cetin, M., Karl, W. C., & Castanón, D. A.** (2003). Feature enhancement and ATR performance using nonquadratic optimization-based SAR imaging. *Aerospace and Electronic Systems, IEEE Transactions on*, 39(4), 1375-1395.
- [35] **Clark, L. G., & Velten, V. J.** (1991). Image characterization for automatic target recognition algorithm evaluations. *Optical Engineering*, 30(2), 147-153.
- [36] **Kim, K. T., Seo, D. K., and Kim, H. T.,** (2005). *Efficient classification of ISAR images*, *IEEE Trans. Antennas Propag.*, 53, 1611-1621.
- [37] **Reed, T. R. and Buf, J. M. H.,** (1993). *A review of recent texture segmentation and feature extraction techniques*, *CVGIP: Image Understanding*, 57, 359-372.
- [38] **Park, S.H., and Kim, K.T.,** (2010). *Segmentation of ISAR Images of Targets Moving in Formation*, *IEEE Trans. Antennas and Propag.*, 48, 2099-2108.
- [39] **Park, S.H., Kim, H.T., and Kim, K. T.,** (2011). *Cross-Range Scaling Algorithm for ISAR Images Using 2-D Fourier Transform and Polar Mapping*, *IEEE Trans. Antennas and Propag.*, 49, 868 – 877.
- [40] **Li, H. J., and Yang, S. H.,** (1993). *Using range profiles as feature vectors to identify aerospace objects*, *IEEE Trans. Antennas Propag.*, 41, 261–268.
- [41] **Abujarad, F., G. Nadim, and A. Omar,** (2007). *Ground penetrating radar signal processing for landmine detection*, Diss. Otto-von-Guericke-Universität Magdeburg, Universitätsbibliothek.
- [42] **Petersen, M. E., de Ridder, D., and Handels, H.,** (2002). *Image processing with neural networks—a review*, *Pattern Recognition*, 35, 2279–2301.
- [43] **Fukunaga, K.,** (1990). *Introduction to Statistical Pattern Recognition*, Academic, New York.
- [44] **Peterson, L.E.,** (2009). *K-nearest neighbor*. *Scholarpedia*, 4(2):1883..
- [45] **Teknomo, K.,** (2012). *K Nearest Neighbors Tutorial*. Online Edition
- [46] **Tolun, S.,** (2008). Destek Vektör Makineleri: *Banka Başarısızlığının Tahmini Üzerine Bir Uygulama* (Doktora tezi) İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, 275, İstanbul.
- [47] **Vapnik, V.,** (1995). *The Nature of Statistical Learning Theory*. Springer-Verlag, 187, NewYork.
- [48] **Cristianini, N., Taylor J. S.,** (2000). *An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods*. Cambridge University Press, 198, Cambridge.


- [49] **Ateş, N.** (2014) *Destek vektör makineleri ve Gauss karışım modeli ile istenmeyen e-postaların tespiti*, (Yüksek lisans tezi) Süleyman Demirel Üniversitesi, Isparta, Fen Bilimleri Enstitüsü
- [50] **Aydoğan, Ü.**,(2010). Destek Vektör Makinelerinde Kullanılan Çekirdek Fonksiyonların Sınıflama Performanslarının Karşılaştırılması. Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, (Yüksek lisans tezi), Ankara.
- [51] **Karakaynak, Z.** (2014). *Destek Vektör Makineleri ile Sınıflandırma ve Görüntü Tanıma Üzerine Bir Uygulama*. (Yüksek Lisans Tezi) Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul
- [52] **Burges, C.J.C.**, (1998). A Tutorial on Support Vector Machines for Pattern Recognition, *Data Mining and Knowledge Discovery* 2, 121-167
- [53] **Ivanciuc, O.**, (2007). Applications of Support Vector Machines in Chemistry. In: *Reviews in Computational Chemistry*, Volume 23, Eds.: K. B. Lipkowitz and T. R. Cundari. Wiley-VCH, Weinheim, 291–400.
- [54] **Boswell, D.** (2002). *Introduction to Support Vector Machines*, Caltech University, USA.
- [55] **Hanika, J., Dammertz, H. ve Lensch, H.** (2011). Edge-Optimized À-TrousWavelets for Local Contrast Enhancement with Robust Denoising, *Pacific Graphics*,30 (7), 1879-1886.

EKLER


EK A FİLTİRLEMENİN HEDEF GÖRÜNTÜLERİNE ETKİSİ

EK B SINIFLAMA KARŞILAŞTIRMA MATRİSLERİ






EK.A FİLTERLEMENİN HEDEF GÖRÜNTÜLERİNE ETKİSİ








Şekil A.1 2S1








Şekil A.2 BDRM 2








Şekil A.3 D7



Şekil A.4 Slicy



Şekil A.5 T62



Şekil A.6 ZSU2

EK.B SINIFLAMA KARŞILAŞTIRMA MATRİSLERİ

%10 eğitim kümesi, KNN sınıflayıcı

Çizelge B.1 Filtersiz (KNN-%10)

KNN	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	125	50	4	10	4	23	7
BRDM2	22	192	0	2	3	15	1
D7	20	2	192	33	15	4	32
SLICY	24	3	3	192	1	8	1
T62	26	6	3	6	170	18	48
ZIL131	39	16	9	23	42	185	21
ZSU23	13	0	58	3	34	16	159

Çizelge B.2 Medyan Filtreli (%10-KNN)

KNN	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	150	3	1	9	6	7	1
BRDM2	17	226	0	0	1	4	0
D7	13	3	194	20	18	14	41
SLICY	5	2	1	208	5	2	4
T62	26	9	5	1	161	19	38
ZIL131	50	24	8	24	28	199	17
ZSU23	8	2	60	7	50	24	168

Çizelge B.3 ATWT (%10-KNN)

KNN	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	154	20	6	33	26	29	15
BRDM2	41	223	0	1	1	7	0
D7	9	1	211	19	13	9	56
SLICY	6	3	1	188	0	1	3
T62	29	8	8	6	166	26	41
ZIL131	14	12	14	8	28	168	12
ZSU23	16	2	29	14	35	29	142

Çizelge B.4 Ağırlıklı ATWT (%10-KNN)

KNN	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	114	6	8	1	8	14	6
BRDM2	42	219	0	0	0	43	0
D7	11	0	216	93	12	47	1
SLICY	29	3	0	215	0	7	2
T62	28	18	11	13	166	43	17
ZIL131	29	19	14	25	11	110	14
ZSU23	16	42	0	65	32	8	159

Çizelge B.5 Bilateral (%10-KNN)

KNN	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	114	6	8	1	8	14	6
BRDM2	42	219	0	0	0	43	0
D7	11	0	216	93	12	47	1
SLICY	29	3	0	215	0	7	2
T62	28	18	11	13	166	43	17
ZIL131	29	19	14	25	11	110	14
ZSU23	16	42	0	65	32	8	159

Eğitim kümesi:%10 DVM Sınıflayıcı

Çizelge B.6 Filtresiz (%10-DVM)

DVM	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	137	27	3	16	51	26	9
BRDM2	11	210	1	6	12	24	5
D7	4	0	185	16	4	7	53
SLICY	16	2	11	236	0	3	1
T62	4	0	8	5	173	40	39
ZIL131	15	14	5	24	30	166	15
ZSU23	1	0	27	24	18	21	178

Çizelge B.7 Medyan Filtreli (%10-DVM)

DVM	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	186	9	4	10	39	16	5
BRDM2	20	223	0	3	9	9	5
D7	4	0	225	17	2	1	20
SLICY	6	5	9	225	7	14	3
T62	27	2	5	6	199	23	7
ZIL131	29	20	8	32	38	140	2
ZSU23	2	6	55	4	59	15	128

Çizelge B.8 ATWT (%10-DVM)

DVM	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	171	19	10	12	32	24	1
BRDM2	2	229	0	3	12	9	14
D7	6	0	195	26	11	9	22
SLICY	8	6	18	221	1	12	3
T62	9	0	7	6	204	14	29
ZIL131	36	9	9	9	40	156	10
ZSU23	7	0	26	14	37	15	170

Çizelge B.9 Ağırlıklı ATWT (%10D-DVM)

DVM	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	195	26	0	32	0	25	0
BRDM2	3	228	1	13	5	1	0
D7	1	0	189	4	8	30	37
SLICY	2	0	4	258	0	5	0
T62	16	1	2	2	188	26	34
ZIL131	15	57	8	6	25	153	5
ZSU23	2	0	37	63	13	1	162

Çizelge B.10 Bilateral (%10-DVM)

DVM	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	156	42	5	9	34	16	7
BRDM2	9	223	2	4	3	27	1
D7	3	0	218	3	4	6	35
SLICY	5	3	17	237	0	6	1
T62	7	1	16	1	189	33	22
ZIL131	23	28	6	7	39	158	8
ZSU23	3	0	35	4	28	10	189

Eğitim kümesi:%33 KNN Sınıflayıcı

Çizelge B.11 Filtersiz (%33-KNN)

KNN	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	164	6	1	10	4	4	2
BRDM2	2	179	0	0	0	8	0
D7	1	2	152	6	3	3	17
SLICY	2	2	1	172	0	1	0
T62	10	2	12	3	159	18	17
ZIL131	17	7	6	8	20	160	14
ZSU23	3	1	27	0	13	5	149

Çizelge B.12 Medyan Filtre (%33-KNN)

KNN	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	142	7	0	8	0	9	0
BRDM2	4	180	0	1	0	1	0
D7	2	1	172	9	8	8	19
SLICY	6	0	0	167	1	3	1
T62	13	1	2	0	147	6	20
ZIL131	29	8	8	9	24	162	14
ZSU23	3	2	17	5	19	10	145

Çizelge B.13 ATWT (%33-KNN)

KNN	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	147	1	1	6	6	7	2
BRDM2	6	174	0	1	0	7	0
D7	1	1	162	7	1	3	18
SLICY	7	3	0	176	0	4	0
T62	9	1	5	4	151	10	15
ZIL131	21	17	6	2	19	158	20
ZSU23	8	2	25	3	22	10	144

Çizelge B.14 Ağırlıklı ATWT (%33-KNN)

KNN	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	147	1	1	6	6	7	2
BRDM2	6	174	0	1	0	7	0
D7	1	1	162	7	1	3	18
SLICY	7	3	0	176	0	4	0
T62	9	1	5	4	151	10	15
ZIL131	21	17	6	2	19	158	20
ZSU23	8	2	25	3	22	10	144

Çizelge B.15 Bilateral Filtre (%33-KNN)

KNN	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	160	2	1	3	10	14	0
BRDM2	4	170	0	2	1	4	0
D7	4	0	171	11	6	6	19
SLICY	2	3	0	174	1	3	1
T62	15	4	5	1	152	8	24
ZIL131	10	18	7	6	10	158	8
ZSU23	4	2	15	2	19	6	147

Eğitim kümse: %33 DVM sınıflayıcı

Çizelge B.16 Filtresiz (%33-DVM)

DVM	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	160	2	1	3	10	14	0
BRDM2	4	170	0	2	1	4	0
D7	4	0	171	11	6	6	19
SLICY	2	3	0	174	1	3	1
T62	15	4	5	1	152	8	24
ZIL131	10	18	7	6	10	158	8
ZSU23	4	2	15	2	19	6	147

Çizelge B.17 Medyan (%33-DVM)

DVM	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	165	1	2	6	10	15	0
BRDM2	4	184	0	2	3	5	1
D7	0	0	174	7	1	2	15
SLICY	2	2	1	187	0	5	2
T62	6	0	3	0	161	15	14
ZIL131	6	5	2	4	20	161	1
ZSU23	0	0	13	4	20	2	160

Çizelge B.18 ATWT (%33-DVM)

DVM	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	169	1	2	11	8	7	1
BRDM2	7	181	0	2	3	5	1
D7	2	0	167	13	5	2	10
SLICY	1	2	4	185	1	3	3
T62	5	0	2	5	163	11	13
ZIL131	14	8	1	5	23	145	3
ZSU23	2	0	10	9	11	3	164

Çizelge B.19 Ağırlıklı ATWT (%33-DVM)

DVM	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	188	2	0	1	6	2	0
BRDM2	6	165	0	0	8	15	5
D7	0	1	185	5	2	0	6
SLICY	0	2	1	194	0	1	1
T62	0	0	3	0	162	8	26
ZIL131	17	10	1	3	23	140	5
ZSU23	0	12	9	2	4	4	159

Çizelge B.20 Bilateral (%33-DVM)

DVM	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	182	2	2	0	3	7	3
BRDM2	2	184	0	4	3	4	2
D7	2	0	180	4	0	2	11
SLICY	2	0	0	194	0	3	0
T62	3	0	2	3	162	10	19
ZIL131	4	4	3	6	16	164	2
ZSU23	1	0	11	4	5	2	176

Çizelge B.21 Filtresiz (%50-KNN)

KNN	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	122	5	1	2	6	10	0
BRDM2	0	140	0	0	0	1	0
D7	1	1	131	4	3	2	10
SLICY	3	0	0	138	0	3	0
T62	4	0	3	0	123	6	15
ZIL131	16	2	4	3	10	124	8
ZSU23	3	1	10	2	7	3	116

Çizelge B.22 Medyan Filtre (%50-KNN)

KNN	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	129	4	1	2	7	4	1
BRDM2	0	134	0	0	1	2	0
D7	0	0	140	4	2	4	12
SLICY	2	2	0	132	0	2	1
T62	2	1	1	2	116	12	15
ZIL131	11	5	2	5	10	119	7

ZSU23	5	3	5	4	13	6	113
-------	---	---	---	---	----	---	-----

Çizelge B.23 AWT (%50-KNN)

KNN	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	129	4	1	0	8	4	3
BRDM2	2	136	0	1	0	2	0
D7	0	0	132	5	5	3	13
SLICY	2	1	3	137	0	3	2
T62	2	1	1	2	110	9	16
ZIL131	13	6	2	1	13	124	3
ZSU23	1	1	10	3	13	4	112

Çizelge B.24 Ağırlıklı ATWT (%50-KNN)

KNN	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	128	2	0	0	4	9	1
BRDM2	2	135	0	0	0	7	0
D7	2	1	139	4	7	21	3
SLICY	0	0	0	135	0	0	0
T62	9	3	3	1	116	4	18
ZIL131	8	6	3	7	13	120	10

ZSU23	0	2	4	2	9	7	107
-------	---	---	---	---	---	---	-----

Çizelge B.25 Bilateral Filtre (%50-KNN)

KNN	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	125	2	0	8	3	5	1
BRDM2	0	136	0	0	0	2	0
D7	1	0	132	5	2	3	13
SLICY	1	1	0	130	0	1	1
T62	8	5	2	4	115	12	15
ZIL131	12	4	3	113	1	22	0
ZSU23	2	11	2	1	16	4	119

Eğitim:%50, DVM:Sınıflayıcı

Çizelge B.26 Filtresiz (%50-DVM)

DVM	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	132	3	1	5	2	6	0
BRDM2	1	140	0	3	2	3	0
D7	0	0	135	6	1	1	6
SLICY	2	0	4	142	0	0	1
T62	8	0	3	1	121	12	4

ZIL131	8	5	2	4	8	119	3
ZSU23	1	0	7	3	5	2	131

Çizelge B.27 Medyan Filtre (%50-DVM)

DVM	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	137	1	1	0	4	6	0
BRDM2	2	141	0	1	3	1	1
D7	0	0	133	4	1	2	9
SLICY	2	1	0	142	0	3	1
T62	5	1	0	0	126	10	7
ZIL131	14	5	0	3	9	117	1
ZSU23	0	0	5	1	4	3	136

Çizelge B.28 ATWT (%50-DVM)

DVM	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	134	0	1	5	6	3	0
BRDM2	3	138	0	3	2	3	0
D7	0	0	136	5	3	2	3
SLICY	0	3	3	139	1	3	0
T62	3	0	2	1	124	6	13

ZIL131	11	3	2	2	7	120	4
ZSU23	1	0	3	5	10	1	129

Çizelge B.29 Ağırlıklı ATWT (%50-DVM)

DVM	2S1	BRDM2	D7	SLICY	T62	ZIL131	ZSU23
2S1	140	1	0	1	5	2	0
BRDM2	2	141	0	0	2	2	2
D7	0	0	139	3	1	1	5
SLICY	1	1	1	144	0	1	1
T62	2	0	0	0	132	4	11
ZIL131	11	4	3	3	17	107	4
ZSU23	0	0	12	2	3	7	125

ÖZGEÇMİŞ

Ad-Soyad : Haldun Bozkurt
Doğum Tarihi ve Yeri : 1988, Alaplı
E-posta : haldun.bozkurt@hotmail.com

ÖĞRENİM DURUMU:

Lisans : 2012, İTÜ, Elektrik-Elektronik Fakültesi, Elektronik Mühendisliği

MESLEKİ DENEYİM:

- 2012'den beri İstanbul Ulaşım A.Ş.'de çalışmaktadır.

YAYINLAR ve SUNUMLAR:

- Erer, I., Sarıkaya, K. & Bozkurt, H. (2014, September). Enhanced radar imaging via sparsity regularized 2D linear prediction. In *Signal Processing Conference (EUSIPCO), 2014 Proceedings of the 22nd European* (pp. 1751-1755). IEEE.
- Sarıkaya, K., Bozkurt, H., & Erer, I. (2014). Seyreklik Güdümlü Doğrusal Öngörü ile Yüksek Çözünürlüklü Radar Görüntüleme/High Resolution Radar Imaging with Sparsity Driven Linear Prediction. *EMO BİLİMSEL DERGİ*, 4(8), 47-55.
- Bozkurt, H., Erer, I., (2016) Çoklu Çözünürlüklü Bilateral Filtre ile İyileştirilmiş Radar Hedef Tanıma. *Sinyal İşleme Uygulamaları Kurultayı (SİU), 2016, Zonguldak*