T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

KENAR KORUYUCU FİLTRELER KULLANARAK SAR GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

Barış AKKUŞ

YÜKSEK LİSANS TEZİ
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

Danışman
Doç. Dr. Ali Can KARACA

İkinci Danışman
Öğr. Gör. Dr. Ahmet ELBİR

Ocak, 2026

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

KENAR KORUYUCU FİLTRELER KULLANARAK SAR GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

Barış AKKUŞ tarafından hazırlanan tez çalışması 12.01.2026 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Doç. Dr. Ali Can KARACA
Yıldız Teknik Üniversitesi
Danışman

Öğr. Gör. Dr. Ahmet ELBİR
Yıldız Teknik Üniversitesi
İkinci Danışman

Jüri Üyeleri

Doç. Dr. Ali Can KARACA, Danışman
Yıldız Teknik Üniversitesi _____

Dr. Öğr. Üyesi Erkan USLU, Üye
Yıldız Teknik Üniversitesi _____

Dr. Öğr. Üyesi Zeki KUŞ, Üye
Fatih Sultan Mehmet Vakıf Üniversitesi _____

Danışmanım Doç. Dr. Ali Can KARACA sorumluluğunda tarafımca hazırlanan "Kenar Koruyucu Filtreler Kullanarak Sar Görüntülerinin Sınıflandırılması" başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Barış AKKUŞ

İmza

Sevgili Aileme

TEŞEKKÜR

Yüksek Lisans eğitimim süresince ve tez çalışmamın tüm aşamalarında akademik bilgi ve tecrübeleriyle çalışmalarımı yönlendiren, yardım, destek ve sabrını hiçbir zaman esirgemeyen değerli hocam ve tez danışmanım Doç. Dr. Ali Can KARACA'ya en içten teşekkürlerimi sunarım. Karşılaştığım güçlüklerde sergilediği yol gösterici tutumu, sahip olduğu engin bilgi birikimi ve vizyoner akademik yaklaşımı, bakış açımı genişletmiş ve bu tez çalışmasının başarıyla tamamlanmasında belirleyici rol oynamıştır.

Ayrıca, tezimin her aşamasında katkılarını esirgemeyen, bilimsel ve manevi desteğini her zaman yanımda hissettiğim eş danışmanım Öğr. Gör. Dr. Ahmet ELBİR'e şükranlarımı sunarım. Kıymetli önerileri, yapıcı eleştirileri ve bilimsel birikimi ile çalışmamın metodolojik altyapısını güçlendirmiş, araştırma sürecinin daha sistematik ve verimli bir şekilde ilerlemesine önemli katkılar sağlamıştır.

Bu süreç boyunca doğrudan ya da dolaylı olarak desteklerini hissettiğim Bilgisayar Mühendisliği Bölümü'ndeki değerli çalışma arkadaşlarıma da anlayışları, katkıları ve motive edici yaklaşımları için teşekkürlerimi sunarım.

Son olarak, tez çalışmam süresince ve yaşamımın her döneminde gösterdikleri koşulsuz sevgi, anlayış, manevi destek ve bana duydukları güvenle bugünlere gelmemde büyük pay sahibi olan aileme en içten teşekkürlerimi sunarım. İyi ki varsınız.

Barış AKKUŞ

İÇİNDEKİLER

SİMGE LİSTESİ vii

KISALTMA LİSTESİ ix

ŞEKİL LİSTESİ xii

TABLO LİSTESİ xiv

ÖZET xv

ABSTRACT xvii

1 GİRİŞ 1

1.1 Temel Bilgiler . . . 1

1.2 Literatür Araştırması . . . 8

1.2.1 Kenar Koruyucu Filtreler . . . 9

1.2.2 Geleneksel Makine Öğrenmesi Yaklaşımları . . . 12

1.2.3 Derin Öğrenme Tabanlı Yöntemler . . . 14

1.3 Motivasyon . . . 18

1.4 Tezin Ana Hatları . . . 20

2 VERİ KÜMELERİ 21

2.1 Veri Kümelerinin Tanıtımı . . . 21

2.1.1 SFBay_L Veri Kümesi . . . 23

2.1.2 SFBay_C Veri Kümesi . . . 24

2.1.3 Flevo_L Veri Kümesi . . . 25

2.1.4 Flevo_C Veri Kümesi . . . 26

3 YÖNTEM 28

3.1 Algoritma Detayları . . . 29

3.2 Girdi Kanalları . . . 35

3.3 Kenar Koruyucu Filtreler . . . 37

3.3.1 Bilateral Filter . . . 37

3.3.2 Fast Global Smoother . . . 39

3.3.3 Domain Transform 40
3.4 Temel Bileşenler Analizi 42
3.5 Sınıflandırıcılar 44

4 DENEYSEL ÇALIŞMALAR 48
4.1 Performans Değerlendirme Kriterleri 49
4.1.1 Genel Doğruluk 50
4.1.2 Makro Ortalama Kesinlik 50
4.1.3 Makro Ortalama Duyarlılık 51
4.1.4 Makro Ortalama F1-Skoru 51
4.1.5 Cohen's Kappa Katsayısı 52
4.1.6 Hesaplama Süreleri 52
4.2 K-katlı Çapraz Doğrulama Deney Protokolü 53
4.3 Kenar Koruyucu Filtre Hiperparametreleri 53
4.4 Deneysel Sonuçlar 55
4.4.1 Filtresiz Klasik Makine Öğrenmesi Yöntemlerinin Karşılaştırılması 55
4.4.2 Kenar Koruyucu Filtre Sonrası Klasik Makine Öğrenmesi Yöntemlerinin Karşılaştırılması 56
4.4.3 Sınıflandırma Haritalarının Görsel Analizi 57
4.4.4 PCA Sonrası Kenar Koruyucu Filtreler ile SVM Sonuçlarının Değerlendirilmesi 60
4.4.5 PCA Sonrası SVM için Tekrarlı Deneylerin Değerlendirilmesi 62
4.4.6 100-Katlı Stratified Çapraz Doğrulama Sonuçlarının Değerlendirilmesi 63
4.4.7 Genel Karşılaştırma: Filtresiz, EPF+SVM ve EPF+PCA+SVM 64
4.4.8 Literatür ile Karşılaştırmalı Değerlendirme 67

5 SONUÇ 70

KAYNAKÇA 72

TEZDEN ÜRETİLMİŞ YAYINLAR 80

SİMGE LİSTESİ

d	Bilateral Filtrede Komşuluk Çap Parametresi
W_p	Bilateral Filtre Normalizasyon Terimi
κ	Cohen's Kappa Katsayısı
I	Çok Kanallı Giriş Görüntüsü
$\tilde{I}$	Çoklu-Parametreli Çıktıların Birleştirildiği Yığıt Temsil
$^\circ$	Derece
a_i	Domain Transform Özyinelemeli Geçişinde Geri Besleme Katsayısı
$c_t(\cdot)$	Domain Transform Birikimli Dönüşüm Fonksiyonu
d_i	Domain Transform Dönüştürülmüş Alan Mesafesi
V	Düşey (Vertical) Polarizasyon Bileşeni
λ	Düzgünleştirme Ağırlığı (FGS)
m_N	Eğitim Yamalarından Toplanan Toplam Piksel Örneği Sayısı
$E(\mathbf{u})$	FGS Enerji Fonksiyonu
f_i	FGS Enerji Fonksiyonunda Giriş Ölçüm Değeri
u_i	FGS Enerji Fonksiyonunda Hedef Çıktı Değeri
$\hat{I}$	Filtrelenmiş Görüntü Çıktısı
Θ	Filtre Parametre Ailesi
X	Görüntü Sütun Yönü
Y	Görüntü Satır Yönü
p_o	Gözlenen Uyum Olasılığı
σ_H	Hedef Yumuşatma Ölçeği (DT)
$\Im\{\cdot\}$	İmajiner Kısım
$\mathrm{Tr}(\cdot)$	İz (Trace)

C	Kanal Sayısı Veya SVM Düzenleme Katsayısı
w_{ij}	Kenar Duyarlı Ağırlıklar
$\mathbf{T}$	Koherens Matrisi
$\mathcal{N}$	Komşuluk Küme İlişkisi
$\mathbf{k}$	Pauli Tabanlı Saçılma Vektörü
k	PCA Hedef Boyutu
$\mathbf{W}$	PCA Dönüşüm Matrisi
$P_i^{(k)}$	PCA Sonrası İndirgenmiş Yama
$\Omega(p)$	Piksel p İçin Komşuluk Penceresi
p, q	Piksel Konum İndisleri
σ_r	Radyometrik Benzerlik (Aralık) Parametresi
p_e	Rastlantısal Uyum Olasılığı
γ	RBF Çekirdeği Parametresi (SVM)
$\Re\{\cdot\}$	Reel Kısım
f	Seçilen Kenar Koruyucu Filtre Türünün Filtreleme Fonksiyonu
K	Sınıf Sayısı
$\mathbf{S}$	Saçılma Matrisi
σ_s	Uzamsal Ölçek Parametresi
W	Yama (Patch) Boyutu
H	Yatay (Horizontal) Polarizasyon Bileşeni
σ_c	Yoğunluk/Renk Ölçeği Kenar Duyarlılığının Parametresi

KISALTMA LİSTESİ

ALOS-1	Gelişmiş Arazi Gözlem Uydusu-1
AMSE-LSTM	Çok Ölçekli Bağlam Kodlayan LSTM Tabanlı Yaklaşım
ANLM	Uyarlamalı Yerel Olmayan Ortalamalar
AIRSAR	Havadan Taşınan Sentetik Açıklıklı Radar Sistemi
AUC	Eğri Altında Kalan Alan
BF	Bilateral Filtre
BM3D	Blok Eşleştirme Ve 3-Boyutlu Filtreleme
CART	Sınıflandırma Ve Regresyon Ağaçları
C-band	C Bandı (Mikrodalga Frekans Bandı)
CENL	Hata Bakış Sayısı İlişkisi Ölçütü
CNN	Evrişimsel Sinir Ağı
CRF	Koşullu Rassal Alan
CSAR	Dairesel Sentetik Açıklıklı Radar
CV	Çapraz Doğrulama
CV-MsAtViT	Karmaşık Değerli Çok Ölçekli Dikkat Tabanlı Görsel Dönüştürücü
dB	Desibel
DC-CNN	Çift Kanallı Evrişimsel Sinir Ağı
DRLSE	Mesafe Düzenlileştirmeli Seviye Kümesi Evrimi
DT	Domain Transform Tabanlı Filtre
EPE	Kenar Koruma Değerlendirme Ölçütü
EPF	Kenar Koruyucu Filtre
EPFs	Kenar Koruyucu Filtreler
EP-MRF	Kenar Koruyucu Markov Rassal Alan

Extra Trees	Aşırı Rastgele Ağaçlar
FCM	Bulanık C-Ortalama Kümeleme
FGS	Hızlı Küresel Yumuşatıcı
Flevo_C	Flevoland C-band SAR Veri Kümesi (RADARSAT-2)
Flevo_L	Flevoland L-band SAR Veri Kümesi (AIRSAR)
GAN	Çekişmeli Üretici Ağ
GBM	Gradyan Artırmalı Makine
GCN	Graf Evrişimsel Ağ
GF	Rehberli Filtre
GLCM	Gri Seviye Eş-Oluşum Matrisi
GT	Yer Gerçeği
H-CapsNet	Hiyerarşik Kapsül Ağı
HH	Yatay Gönderim–Yatay Alım Polarizasyon Kanalı
HSI	Hiperspektral Görüntüleme
HV	Yatay Gönderim–Düşey Alım Polarizasyon Kanalı
IQEM	Görüntü Kalite Değerlendirme Çerçevesi
KNN	K-En Yakın Komşu
L-band	L Bandı (Mikrodalga Frekans Bandı)
LDA	Doğrusal Ayırıcı Analiz
LightGBM	Hafif Gradyan Artırmalı Makine
LR	Lojistik Regresyon
LULC	Arazi Kullanımı / Arazi Örtüsü
MCPT	Konvolüsyon + Paralel Dönüştürücü Tabanlı Yaklaşım
ML	Makine Öğrenmesi
MRF	Markov Rassal Alan
MWGCN	Çok Ağırlıklı Graf Evrişimsel Ağ
NASA/JPL	ABD Ulusal Havacılık Ve Uzay Dairesi
NLM	Yerel Olmayan Ortalamalar
OA	Genel Doğruluk

PCA	Temel Bileşen Analizi
PCA-EPFs	PCA Tabanlı Kenar Koruyucu Filtreleme Çerçevesi
PolSAR	Polarimetrik Sentetik Açıklıklı Radar
QDA	İkinci Dereceden Ayırıcı Analiz
Quad	Tam-Kutuplu Ölçüm (Dört Polarizasyon Kanalı)
RBF	Radyal Tabanlı Fonksiyon
RBF-SVM	RBF Çekirdekli Destek Vektör Makineleri
RF	Rastgele Orman
ROC	Alıcı İşletim Karakteristiği Eğrisi
SAR	Sentetik Açıklıklı Radar
SFBay_C	San Francisco Bay C-band SAR Veri Kümesi (RADARSAT-2)
SFBay_L	San Francisco Bay L-band SAR Veri Kümesi (AIRSAR)
ScanSAR	Geniş Alan Kapsama Odaklı SAR Modu
SDF2Net	Sığdan Derine Özellik Füzyonu Ağı
SFBay_C	San Francisco Bay C Bandı Veri Kümesi
SFBay_L	San Francisco Bay L Bandı Veri Kümesi
SPCNN	Süperpiksel Tabanlı Evrişimsel Sinir Ağı
SPAN	Toplam Saçılma Gücü
Spotlight	Yüksek Çözünürlüklü Odaklı SAR Modu
Stripmap	Şerit Haritalama SAR Modu
SVM	Destek Vektör Makinesi
Transformer	Dönüştürücü Tabanlı Mimari
U-Net	U-Net Tabanlı Ağ Mimarisi
VH	Düşey Gönderim–Yatay Alım Polarizasyon Kanalı
VV	Düşey Gönderim–Düşey Alım Polarizasyon Kanalı
WLS	Ağırlıklı En Küçük Kareler
X-band	X Bandı (Mikrodalga Frekans Bandı)
XGBoost	Aşırı Gradyan Artırma

ŞEKİL LİSTESİ

Şekil 1.1 Pasif optik algılama ile aktif SAR algılamanın kavramsal karşılaştırması 2
Şekil 1.2 SAR uzaktan algılama sisteminin genel çalışma prensibi ve görüntü oluşturma süreci 2
Şekil 1.3 Platform hareketiyle sentetik açıklığın oluşturulmasına dayanan SAR çalışma mantığı 3
Şekil 1.4 SAR bantlarının (X, C, L) dalga boyuna göre nüfuz/duyarlılık karakteristiklerinin şematik karşılaştırması 4
Şekil 1.5 SAR polarizasyon kanalları (HH, HV, VH, VV) ve temel saçılım mekanizmalarıyla ilişkisine dair şematik gösterimi 5
Şekil 1.6 Stripmap, Spotlight ve ScanSAR temel görüntüleme modlarının şematik gösterimi 6
Şekil 1.7 (a) Orijinal SAR görüntü ile (b) benek gürültülü SAR görüntüsünün görsel karşılaştırması 7
Şekil 1.8 Guided Filter ve Bilateral Filter kullanılarak elde edilen detay vurgulama çıktılarının karşılaştırması 10
Şekil 1.9 Guided Filter ve Fast Guided Filter kullanılarak elde edilen detay vurgulama sonuçlarının karşılaştırılması 10
Şekil 1.10 Spektral, mekansal ve hiyerarşik yapı bilgisini birlikte kullanan birleşik çekirdek tabanlı SVM ile hiperspektral görüntü sınıflandırmaya ait tipik işlem akışı 13
Şekil 1.11 Çift kanallı konvolüsyonel ağ ve kenar koruyucu Markov Rastgele Alan temelli PolSAR sınıflandırma mimarisi 16
Şekil 2.1 SFBay_L veri kümesi için Pauli RGB gösterimi (solda) ve sınıf etiketleriyle birlikte karşılık gelen GT kümesi (sağda) gösterilmiştir 23
Şekil 2.2 SFBay_C veri kümesi için Pauli RGB gösterimi (solda) ve sınıf etiketleriyle birlikte karşılık gelen GT kümesi (sağda) gösterilmiştir 24
Şekil 2.3 Flevo_L veri kümesi için Pauli RGB gösterimi (solda) ve sınıf etiketleriyle birlikte karşılık gelen GT kümesi (sağda) gösterilmiştir 25
Şekil 2.4 Flevo_C veri kümesi için Pauli RGB gösterimi (solda) ve sınıf etiketleriyle birlikte karşılık gelen GT kümesi (sağda) gösterilmiştir 26
Şekil 3.1 Önerilen yöntemin akışı 30

Şekil 3.2 Flevoland SAR sahnesinden örnek kanal görünümleri: T_{11}, Re$\{T_{12}\}$ ve Im$\{T_{12}\}$ 31
Şekil 3.3 BF ile üç farklı yumuşatma düzeyi: düşük yumuşatma (solda), orta yumuşatma (ortada), yüksek yumuşatma (sağda). 32
Şekil 3.4 Bilateral filtreleme örneği 38
Şekil 3.5 FGS uygulamasının görsel etkisi: (a) giriş görüntüsü ve (b) FGS çıktısı (yakınlaştırılmış bölgelerle birlikte) 40
Şekil 3.6 DT ile kenar duyarlı yumuşatmanın kavramsal karşılaştırması . . 41
Şekil 3.7 Temel Bileşenler Analizi algoritmasının adım adım gösterimi . . . 43
Şekil 4.1 (a) GT, (b) KNN ve (c) BF+KNN ile elde edilen sınıflandırma sonuçlarının karşılaştırılması. 58
Şekil 4.2 (a) GT, (b) SVM ve (c) BF+ SVM sınıflandırma sonuçlarının karşılaştırılması. 59
Şekil 4.3 (a) GT, (b) KNN ve (c) DT + KNN sınıflandırma sonuçlarının karşılaştırılması. 59
Şekil 4.4 (a) GT , (b) RF ve (c) FGS+ RF sınıflandırma sonuçlarının karşılaştırılması. 60

TABLO LİSTESİ

Tablo 2.1 Çalışmada kullanılan karşılaştırmalı SAR sahneleri için sistem, bant, edinim tarihi ve geliş açısı bilgileri 23
Tablo 2.2 Çalışmada kullanılan SAR veri kümeleri ve temel istatistikler . . 23
Tablo 2.3 SFBay_L veri kümesi için sınıf bazında eğitim ve test piksel sayıları 24
Tablo 2.4 SFBay_C veri kümesi için sınıf bazında eğitim ve test piksel sayıları 25
Tablo 2.5 Flevo_L veri kümesi için sınıf bazında eğitim ve test piksel sayıları 26
Tablo 2.6 Flevo_C veri kümesi için sınıf bazında eğitim ve test piksel sayıları 27
Tablo 4.1 K sınıflı bir problem için genel karmaşıklık matrisi gösterimi . . 49
Tablo 4.2 EPF yöntemleri için üç seviyeli (düşük–orta–yüksek) hiperparametreler 55
Tablo 4.3 Filtreleme öncesinde geleneksel makine öğrenmesi yöntemlerinin dört farklı veri kümesi üzerindeki OA sonuçları . . 56
Tablo 4.4 BF/FGS/DT sonrası ML yöntemlerinin dört veri kümesindeki OA sonuçları ve filtresiz duruma göre ortalama artış (ΔOA) . . . 57
Tablo 4.5 PCA sonrası kenar koruyucu filtreler ile SVM modelinin dört veri kümesi üzerindeki genel doğruluk (OA) sonuçları 61
Tablo 4.6 PCA sonrası SVM için 10 tekrarlı deneylerde genel doğruluk (OA) ortalama $\pm$ standart sapma sonuçları 63
Tablo 4.7 SFBay_C veri kümesi için 100-katlı Stratified çapraz doğrulama sonuçları (Ortalama $\pm$ Std) 64
Tablo 4.8 Dört SAR veri setinde filtresiz en iyi üç ML, EPF+SVM ve EPF+PCA+SVM yöntemlerinin OA karşılaştırması 66
Tablo 4.9 Seçili çalışmalar ile EPF+PCA+SVM yönteminin SFBay_C/L ve Flevo_C/L veri kümelerinde OA ve eğitim oranı karşılaştırması 69

ÖZET

Kenar Koruyucu Filtreler Kullanarak SAR Görüntülerinin Sınıflandırılması

Barış AKKUŞ

Bilgisayar Mühendisliği Anabilim Dalı
Yüksek Lisans Tezi

Danışman: Doç. Dr. Ali Can KARACA
İkinci Danışman: Öğr. Gör. Dr. Ahmet ELBİR

Sentetik Açıklıklı Radar (SAR) sistemleri, her türlü hava koşulunda veri sağlayabilmeleri ve yüzeylerin yapısal ayrıntılarını ortaya çıkarabilmeleri nedeniyle uzaktan algılamada önemli bir yere sahiptir. Ancak SAR sistemleri koherent (eşfazlı) görüntüleme yapısına sahip olup aynı çözünürlük hücresindeki çoklu yansımaların girişimi benek gürültüsüne neden olur. Bu gürültü sınıf sınırlarını bulanıklaştırarak doğruluğu düşürüp özellikle kentsel–tarımsal ayrımı zorlaştırır. Bunu yanında geri saçılım dalga boyu, polarizasyon ve hedef geometrisine bağlı değiştiğinden aynı sınıf içinde ölçümler farklılaşabilir. Bu yüzden, gürültüyü bastırırken kenar bütünlüğünü koruyan kenar koruyucu filtrelerin sınıflandırma öncesi kullanımı kritiktir. EPF'ler komşu pikselleri homojenleştirerek sınıf içi varyansı azaltır ve arazi örtülerinin daha yüksek doğrulukla ayrılmasını destekler. Bu tezde, benek gürültüsünü bastırma ve sınıf sınırlarını koruma amacıyla kenar koruyucu filtrelerin SAR sınıflandırmasına etkileri incelenmektedir. Bu kapsamda kenar koruyucu filtreleme yaklaşımları, dört karşılaştırmalı veri kümesi (SFBay_C, SFBay_L, Flevo_C, Flevo_L) üzerinde sistematik olarak analiz edilmiştir. SVM, RF ve KNN tabanlı sınıflandırıcılarda filtreleme öncesi ve sonrası performanslar kapsamlı biçimde karşılaştırılmıştır. EPF kullanımının özellikle SVM tabanlı sınıflandırmalarda genel doğrulukta (OA) belirgin artışlar sağladığı görülmüştür. Dahası yer gerçeğine (GT) daha yakın, daha düzgün sınıflandırma haritaları ürettiği gözlemlenmiştir. Bu bulgular üzerine inşa edilen ikinci aşamada, EPF ile işlenmiş SAR verisi PCA ile daha kompakt bir özellik uzayına indirgenmiş ve yama tabanlı

temsil kullanılarak SVM ile sınıflandırılmıştır. Önerilen PCA+EPF+SVM yöntemi, dört veri kümesinde yaklaşık %97–%99 genel doğruluk aralığına ulaşmıştır. Ayrıca sınıflandırma için çok az örnek seçilmesi durumunda, eğitim kümesi aynı sınıfı yeterince temsil edemediğinden performansın düşmesi beklenen bir sonuçtur. Bu tezde kullanılan EPF ve PCA adımları, sınırlı örnekle öğrenilen karar sınırlarını daha kararlı hale getirerek az etiketli senaryolarda dahi yüksek doğruluk ve hesaplama açısından yönetilebilir bir çerçevenin mümkün olduğunu göstermektedir. Sonuç olarak tez, EPF tabanlı ön-işlemenin boyut azaltma ve geleneksel makine öğrenmesi ile bütünleştirilmesiyle; benek gürültüsü bastırma ve sınıf ayrışmasını aynı anda iyileştiren güçlü ve uygulanabilir bir SAR görüntü sınıflandırma yaklaşımı sunmaktadır.

Anahtar Kelimeler: SAR görüntü sınıflandırma, benek gürültüsü, kenar koruyan filtreler, makine öğrenmesi, temel bileşen analizi.

ABSTRACT

Classification Of SAR Images Using Edge Preserving Filters

Barış AKKUŞ

Department of Computer Engineering
Master of Science Thesis

Supervisor: Assoc. Prof. Dr. Ali Can KARACA
Second supervisor: Lect. PhD Ahmet ELBİR

Synthetic Aperture Radar (SAR) systems play a crucial role in remote sensing due to their ability to provide data acquisition under all weather conditions and to reveal structural details of the Earth's surface. However, SAR systems employ a coherent imaging mechanism, in which the interference of multiple scatterers within the same resolution cell gives rise to speckle noise. This noise blurs class boundaries, degrades classification accuracy, and particularly complicates the discrimination between urban and agricultural areas. In addition, backscattering characteristics depend on factors such as wavelength, polarization, and target geometry, leading to significant measurement variability even within the same class. Therefore, the use of edge-preserving filters (EPFs) prior to classification is critical, as they suppress noise while maintaining edge integrity. By homogenizing neighboring pixels, EPFs reduce intra-class variance and facilitate more accurate discrimination of land-cover types. In this thesis, the effects of edge-preserving filters on SAR image classification are systematically investigated with the aim of suppressing speckle noise while preserving class boundaries. In this context, edge-preserving filtering approaches are systematically analyzed on four comparative datasets (SFBay_C, SFBay_L, Flevo_C, Flevo_L). The performances before and after filtering are comprehensively compared for SVM, RF, and KNN-based classifiers. It is observed that the use of EPFs provides notable increases in overall accuracy (OA), particularly in SVM based classifications. Moreover, it is observed that they produce smoother classification maps that are closer to the ground truth (GT). In

the second stage built upon these findings, EPF-processed SAR data are reduced to a more compact feature space using PCA and classified with SVM using a patch based representation. The proposed PCA+EPF+SVM method achieves an overall accuracy range of approximately 97%–99% across the four datasets. In addition, when very few samples are selected for classification, a decrease in performance is an expected outcome since the training set cannot sufficiently represent the same class. The EPF and PCA steps used in this thesis demonstrate that even in low labeled scenarios, high accuracy and a computationally manageable framework are possible by making the decision boundaries learned from limited samples more stable. In conclusion, the thesis presents a powerful and practical SAR image classification approach that simultaneously improves speckle noise suppression and class separability by integrating EPF based preprocessing with dimensionality reduction and traditional machine learning.

Keywords: SAR image classification, speckle noise, edge-preserving filters, machine learning, principal component analysis.

1
GİRİŞ

1.1 Temel Bilgiler

Yeryüzü ve arazi örtüsünün izlenmesi; çevresel değişimlerin anlaşılması, doğal kaynakların sürdürülebilir yönetimi, tarımsal üretimin planlanması ve kentleşme süreçlerinin sağlıklı biçimde değerlendirilebilmesi açısından önemli bir yere sahiptir. Bu kapsamda, uzaktan algılama yaklaşımları; geniş alanlarda düzenli, hızlı ve tekrarlanabilir gözlem yapmayı mümkün kılarak modern arazi örtüsü çalışmalarının temel odağı haline gelmiştir. Uzaktan algılama sistemleri, hedefi aydınlatan enerji kaynağına göre pasif ve aktif sensörler olarak sınıflandırılabilir. Pasif sensörler, dışardan bir enerji kaynağına (çoğunlukla Güneş) bağlı olarak çalışırken, aktif sensörler elektromanyetik dalgayı kendileri göndererek hedeften geri saçılan sinyali ölçerek çalışır [1]. Bu sınıflama, gözlem sürekliliği ve atmosfer koşullarına duyarlılık açısından uzaktan algılama uygulamalarının değerlendirilmesinde belirleyici temel bir rol üstlenmektedir. Pasif optik algılamada bulut oluşumu ve aydınlatma koşulları belirleyici sınırlamalar oluştururken, aktif uzaktan algılama yaklaşımları enerji kaynağını kendisi ürettiği için atmosfer koşullarına daha düşük duyarlılıkla daha düzenli ve tekrarlanabilir gözlem imkanı sunar [1].

Aktif sistemlerde sensör, elektromanyetik dalgayı hedef yüzeye gönderir ve hedeften geri saçılan sinyali ölçerek yüzeyin fiziksel özelliklerine ilişkin bilgi üretir. Bu sayede, yüzeyin yapısal özellikleri ile nem gibi fiziksel durumlarına duyarlı ölçümler elde edilebilir [1]. Aktif uzaktan algılama içinde yer alan başlıca teknolojiler arasında radar tabanlı sistemler öne çıkmakta olup, bu sistemler mikrodalga bölgesindeki çalışma prensipleri sayesinde optik sistemlerden farklı bir fiziksel mekanizma üzerinden yüzey özelliklerini temsil etmeyi amaçlar [1]. Bu çerçevede, radar tabanlı yaklaşımların önemli bir örneği olan Sentetik Açıklıklı Radar (Synthetic Aperture Radar, SAR) algılama, bulutluluk ve aydınlatma koşullarından daha az etkilenerek her türlü hava koşulunda ve gece–gündüz veri üretme olanağına sahiptir. Bu temel fark, Şekil 1.1' de pasif ve aktif

algılama yaklaşımlarının kavramsal karşılaştırması üzerinden açık bir biçimde görülmektedir.

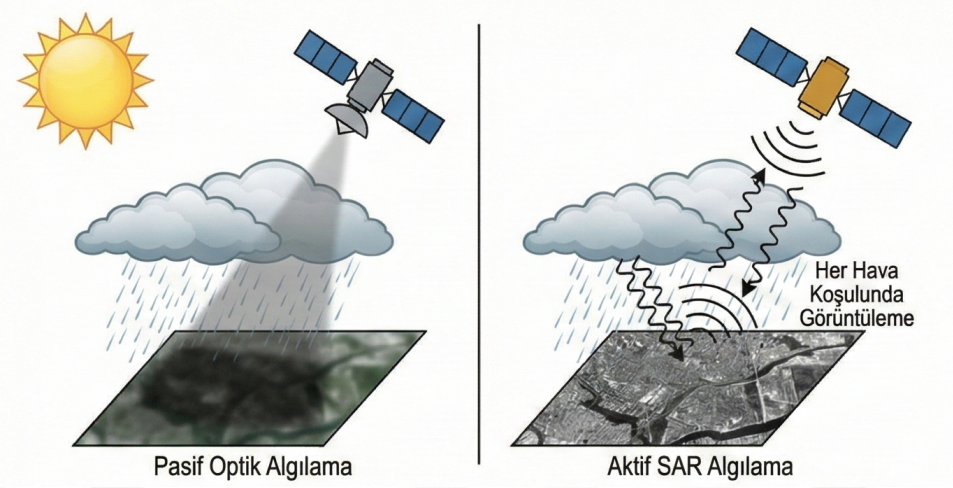

Şekil 1.1 Pasif optik algılama ile aktif SAR algılamanın kavramsal karşılaştırması

Radar verilerinin arazi örtüsü amaçlı kullanımına yönelik klasik çalışmalar, SAR görüntülerinin arazi sınıflandırması ve bazı yüzey özelliklerinin kestirimi açısından güçlü bir potansiyele sahip olduğunu göstermektedir [2]. SAR görüntüleme sürecinde uydu platformu ve anten tarafından hedefteki alan aydınlatılmakta, geri saçılan sinyaller kaydedilmekte ve izleyen aşamada sinyal işleme adımlarıyla görüntü oluşturulmaktadır. Bu genel işleyişin kavramsal çerçevesi Şekil 1.2'de sunulan sistem şeması üzerinden görülmektedir.

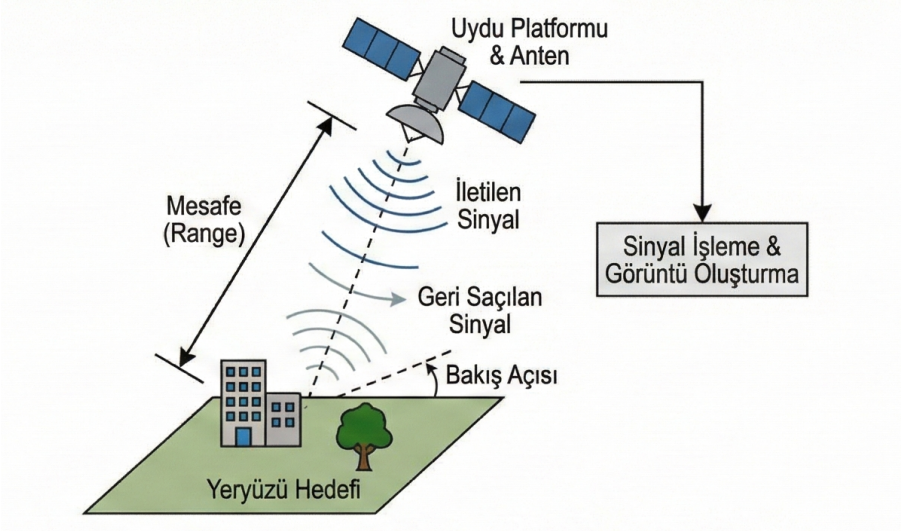

Şekil 1.2 SAR uzaktan algılama sisteminin genel çalışma prensibi ve görüntü oluşturma süreci

Radar görüntüleme sistemlerinde, yüksek uzamsal çözünürlük gereksinimi, gerçek açıklıklı radar sistemlerinde anten boyutunun büyütülmesi zorunluluğu nedeniyle

hava ve uzay platformlarında ağırlık, hacim ve maliyet gibi pratik kısıtların oluşmasına sebebiyet vermektedir. Bu sınırlılıkları aşmak üzere geliştirilen SAR yaklaşımı, platform hareketi ve koherent görüntüleme prensiplerini birlikte kullanarak "sentetik" bir açıklık oluşturur. Bu sayede, taşınabilir anten boyutlarıyla yüksek çözünürlüklü radar görüntülerinin elde edilmesini sağlar. SAR'ın çalışma mantığı, Şekil 1.3'te gösterildiği üzere, tek bir anda büyük bir antene sahip olmak yerine, küçük bir antenle uçuş boyunca ardışık ölçümler alarak bu ölçümleri sonradan bir araya getirme prensibine dayanır. Bu süreç adım adım şu şekilde gerçekleşir: İlk olarak radar, yüzeye elektromanyetik bir darbe gönderir ve hedeften geri saçılan sinyali alıcıda ölçer. Bu ölçüm yalnızca sinyalin şiddetini değil, aynı zamanda sinyalin faz bilgisini de içerir. Faz bilgisinin korunarak ölçülmesi koherent ölçümün temel özelliğidir. Ardından platform uçuş hattı boyunca ilerledikçe aynı hedef bölge, farklı konumlardan tekrar tekrar aydınlatılıp her konumda geri dönen sinyal yeniden kaydedilir. Uçuş hattı boyunca birden fazla konumdan alınan bu koherent ölçümler, faz bilgileri dikkate alınarak birlikte değerlendirildiğinde platformun farklı noktalarda yaptığı ölçümler tek bir büyük anten açıklığıyla yapılmış gibi davranacak biçimde birleştirilebilir. Böylece anten fiziksel olarak büyütülmeden, platform hareketi sayesinde sentetik olarak büyütülmüş bir açıklık etkisi elde edilir. Bu mekanizma, gerçek anten küçük kalsa bile yüksek uzamsal çözünürlüğün nasıl sağlandığını açıklayan temel fikri oluşturmaktadır. SAR'ın radar teknolojisinin gelişiminde dönüştürücü bir rol üstlendiği ve yüksek çözünürlüklü görüntüleme açısından temel bir yaklaşım sunduğu geleneksel literatürde vurgulanmaktadır [3].

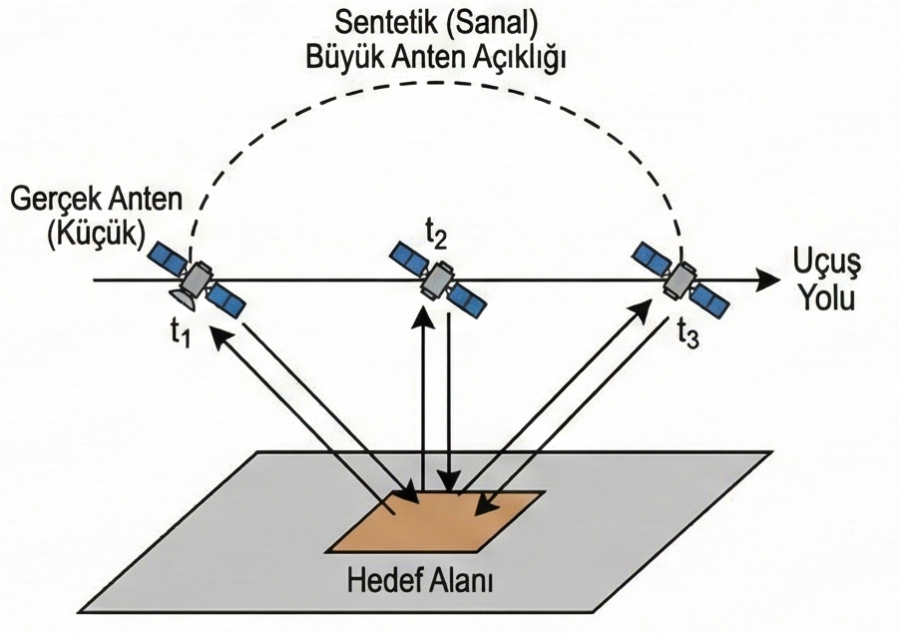

Şekil 1.3 Platform hareketiyle sentetik açıklığın oluşturulmasına dayanan SAR çalışma mantığı

SAR sistemlerinde elde edilecek fiziksel bilginin niteliği; büyük ölçüde kullanılan dalga boyu, polarizasyon konfigürasyonu ve seçilen görüntüleme moduna bağlıdır. Elektromanyetik dalganın frekansına bağlı olarak hedef içerisine ilerleyebilme kapasitesi ve geri saçılım karakteristiği değişebilmektedir. Bu durum, elektromanyetik spektrumdaki farklı bantların farklı yüzey/örtü koşullarına duyarlılığını etkilemektedir [1, 4]. Bu ilişkinin kavramsal özeti Şekil 1.4 üzerinde gösterilmiştir. Uygulamalarda en sık kullanılan bantlar X-, C- ve L-bandıdır. Bu bantlardan X-bandı daha çok üst yüzey pürüzlülüğüne duyarlı iken, C-bandı tarımsal alanlar ve orta ölçekli arazi örtüsü analizlerinde dengeli bir duyarlılık sergilemektedir. L-bandı ise daha uzun dalga boyu sayesinde bitki örtüsüne ve yüzeyin sığ katmanlarına daha yüksek nüfuz yeteneği sergileyerek orman, biyokütle ve tarımsal ürün dokusu değerlendirmelerinde belirgin bir üstünlük göstermektedir [1].

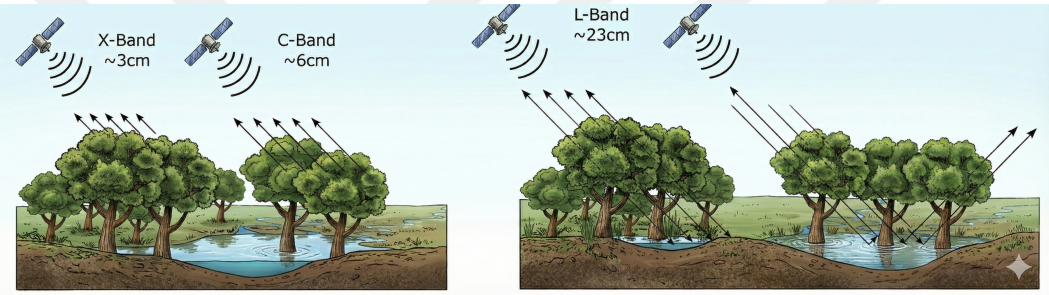

Şekil 1.4 SAR bantlarının (X, C, L) dalga boyuna göre nüfuz/duyarlılık karakteristiklerinin şematik karşılaştırması

Radar geri saçılımının bir diğer belirleyici faktörü polarizasyondur. Farklı polarizasyon kanallarının (HH, HV, VH, VV) hedefin geometrik yapısı ve saçılım mekanizmasıyla ilişkisinin genel çerçevesi Şekil 1.5'te gösterilmiştir. Elektromanyetik dalganın yatay (H) ve düşey (V) bileşenleri ile HH, HV, VH ve VV gibi farklı polarizasyon kombinasyonları elde edilmektedir. Polarizasyon durumu, hedefin geometrik yapısı ile saçılım mekanizmasına bağlı olarak geri saçılımın bilgi içeriğini anlamlı ölçüde farklılaşmaktadır[1, 5]. Benzer polarizasyonlar (HH, VV) çoğunlukla yüzey ve çift sıçramalı saçılıma duyarlı iken, çapraz polarizasyonlar (HV, VH) hacim saçılımının baskın olduğu bitki örtüsü gibi hedeflerin ayırt edilmesinde önemli rol oynamaktadır [1]. Bu nedenle, bant ve polarizasyon tercihlerinin birlikte değerlendirilmesi önem taşımaktadır. Bu yaklaşım, SAR tabanlı sınıflandırma ve zamansal izleme çalışmalarında daha güvenilir ve fiziksel olarak anlamlı sonuçlar üretilmesini desteklemektedir [4, 5].

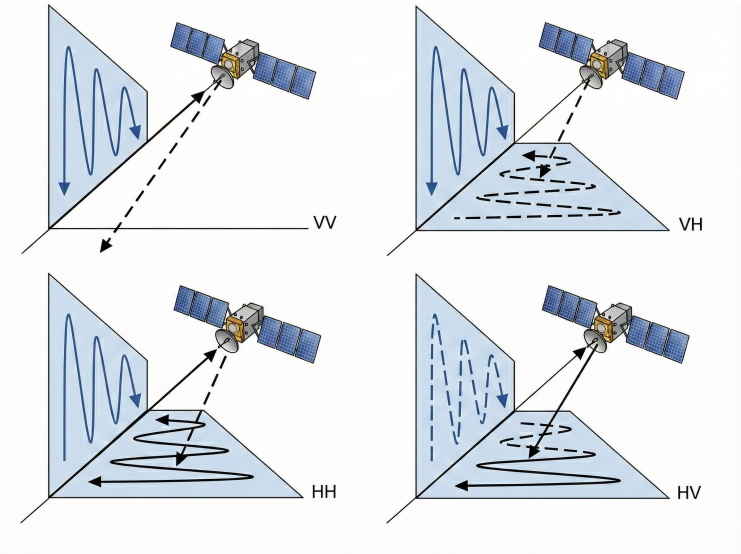

Şekil 1.5 SAR polarizasyon kanalları (HH, HV, VH, VV) ve temel saçılım mekanizmalarıyla ilişkisine dair şematik gösterimi

Bunun yanında SAR sistemleri, çözünürlük ile alan kapsamı arasındaki tasarım tercihine ve uygulamanın gereksinimlerine bağlı olarak çeşitli görüntüleme modlarında çalıştırılabilmektedir. Geniş alanların sistematik izlenmesi için kullanılan Stripmap modunda, radar demeti sabit bir geometrik yapı ile yüzeyi tarayarak sürekli bir şerit görüntü üretir. Yüksek mekansal çözünürlük gerektiren uygulamalarda Spotlight modunda, ilgi alanı uçuş boyunca sürekli aydınlatılarak daha ayrıntılı görüntüler elde edilmektedir. Buna karşılık ScanSAR yaklaşımı, daha geniş alanların kısa sürede kapsanmasına olanak tanıyan bir gözlem stratejisi sunmakta olup bölgesel ya da küresel düzeydeki izleme çalışmalarında tercih edilmektedir [4]. Bu görüntüleme modlarının şematik karşılaştırması Şekil 1.6'da verilmiştir. Bu modlar, pratik SAR veri üretiminde sahne türü ve uygulama hedeflerine uygun gözlem stratejisinin belirlenmesi açısından önem taşımaktadır. Bu temel modlara ek olarak, belirli bir hedef bölgenin farklı bakış açılarından gözlemlenmesini sağlayan dairesel SAR (CSAR) ve çoklu yüksekliklerden veri toplamayı esas alan genişletilmiş CSAR yaklaşımları, üç boyutlu yapı ve derinlik bilgisinin elde edilmesinde kullanılabilmektedir. Ayrıca tam polarimetrik SAR (PolSAR) sistemleri, farklı polarizasyon durumlarında ölçülen geri saçılımı birlikte değerlendirerek yüzey, hacim ve çift sıçramalı saçılım mekanizmalarının ayrıştırılmasına katkı sağlamaktadır. Böylece tarım, orman, buz örtüsü ve kentsel alan analizleri gibi uygulamalarda daha fiziksel temelli ve yorumlanabilir çıktılar üretmektedir [1, 5].

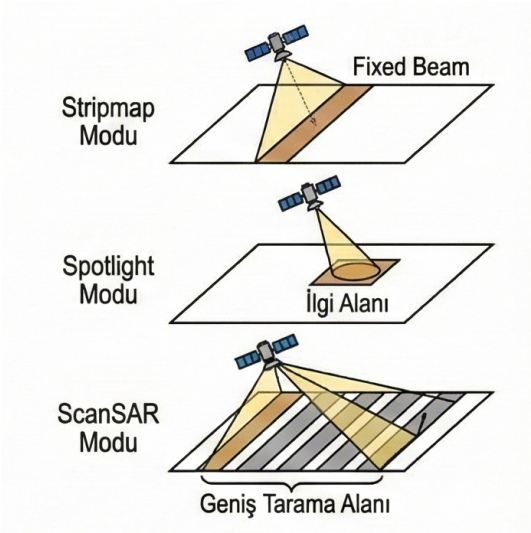

Şekil 1.6 Stripmap, Spotlight ve ScanSAR temel görüntüleme modlarının şematik gösterimi

SAR görüntülerinde sınıflandırma performansını kısıtlayan en temel etkenlerden biri, koherent görüntüleme mekanizmasının bir sonucu olarak ortaya çıkan benek gürültüsüdür [6–8]. SAR sistemleri, geri saçılan sinyalin yalnızca genliğini değil aynı zamanda faz bilgisini de koruyarak ölçmektedir. Bununla birlikte, aynı çözünürlük hücresi içerisinde yer alan çok sayıdaki saçıcıdan dönen sinyaller fazlarına bağlı olarak birbirleriyle yapıcı ve yıkıcı girişime uğrar [9, 10]. Bu girişim sürecinde yüzey, fiziksel olarak homojen olsa dahi, piksel yoğunluklarında rastlantısal dalgalanmalar oluşmasına sebebiyet verir. Bu durum benek gürültüsü olarak adlandırılır [8, 9].

Benek gürültüsü, homojen bölgelerde sınıf içi değişkenliği yapay biçimde artırarak istatistiksel sınıf dağılımlarını bozar [6, 8]. Bunun yanı sıra, farklı arazi örtüsü türlerini ayıran sınır bölgelerinde geri saçılım karakteristiklerinin bulanıklaşmasına neden olup sınıf sınırlarının belirginliğini azaltır [8, 9]. Bu etki, özellikle kentsel yapılar, tarım alanları ve heterojen yüzeylerin bulunduğu sahnelerde sınıflandırma doğruluğunu anlamlı düzeyde düşürebilir [6, 8].

Orijinal SAR görüntüsü ile benek gürültü etkisi altındaki SAR görüntüsü arasındaki görsel fark, Şekil 1.7'de gösterildiği üzere bu problemin pratikteki karşılığını açık biçimde ortaya koymaktadır. Bu bağlamda benek gürültüsünü bastırma çalışmalarında temel amaç, gürültü seviyesini azaltmanın yanı sıra, sınıfları ayırt eden kenar yapılarının ve anlamlı yerel detayların korunmasını sağlamaktır. Benek gürültüsü tabanlı filtrelemenin sınıflandırma başarımı üzerindeki etkisini ele alan geleneksel çalışmalar, bu yaklaşımın yöntemsel çerçevesini sunmaktadır [11].

Bu kuramsal çerçeve, kenar koruyucu filtrelerin (EPF-Edge-Preserving Filter)

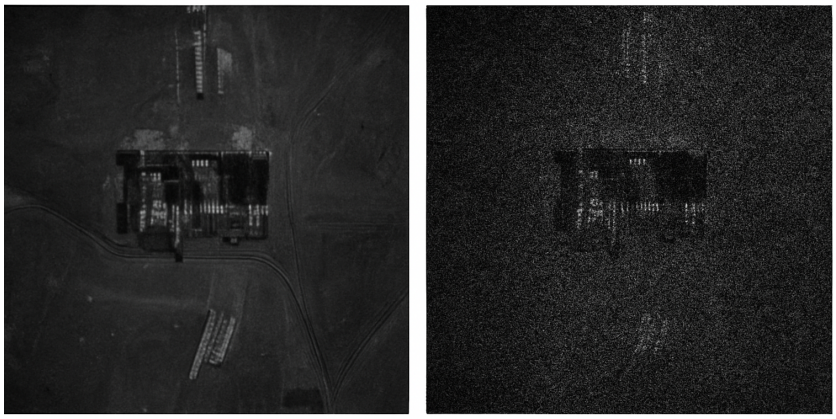

(a) (b)

Şekil 1.7 (a) Orijinal SAR görüntü ile (b) benek gürültülü SAR görüntüsünün görsel karşılaştırması

SAR sınıflandırma sürecinde neden daha önemli bir ön işleme adımı olarak değerlendirildiğini açıklamaktadır. EPF'ler, SAR görüntülerindeki benek gürültüsünden kaynaklanan rastgelelikleri baskılamayı hedefler. Bunu yaparken, arazi örtüsü sınıflarını ayıran sınırların ve anlamlı yerel yapıların korunmasını amaçlar. Bununla birlikte, sınıflandırma başarımını sınırlayan etmenler yalnızca benek gürültüsü ile sınırlı değildir. SAR sisteminin yayımladığı elektromanyetik dalgaya yüzeylerin verdiği geri saçılım tepkisi, dalga boyu ve polarizasyona bağlı olarak değişmektedir. Ayrıca bu tepki, hedefin geometrik–fiziksel özelliklerine bağlı biçimde karmaşık ve belirsiz bir yapı sergilemektedir [11, 12].

Bu tezde söz konusu motivasyon doğrultusunda, SAR görüntülerinde benek gürültü etkisini azaltırken sınıf sınırlarını korumayı amaçlayan modern EPF yaklaşımlarından Bilateral Filter (BF), Domain Transform (DT) ve Fast Global Smoother (FGS) sistematik olarak değerlendirilmiştir. EPF sonrası elde edilen yüksek boyutlu, çok kanallı/mekansal temsillerin kontrol edilebilir hale getirilmesi gerekmektedir. Bu yüzden sınıflandırmanın daha seçici bir uzayda gerçekleştirilmesi amacıyla Temel Bileşen Analizi (Principal Component Analysis, PCA) gibi boyut indirgeme yöntemlerinin kullanılması, literatürdeki genel eğilimle uyum göstermektedir [13]. Sonuç olarak EPF ile daha kararlı hale getirilen SAR temsilleri, Destek Vektör Makineleri (Support Vector Machine, SVM), Rastgele Ormanlar (Random Forest, RF) ve k-En Yakın Komşu (Nearest Neighbor, KNN) gibi geleneksel makine öğrenmesi yöntemleriyle birleştirilerek sınırlı eğitim verisi ve kısıtlı etiketli örneklerin bulunduğu senaryolarda hem benek gürültüsü kaynaklı sınıf içi değişkenliğin azaltılması hem de sınıf sınırlarının korunması açısından daha

güvenilir bir arazi örtüsü sınıflandırma performansına ulaşılması amaçlanmıştır.

1.2 Literatür Araştırması

Bu bölümde, SAR görüntü sınıflandırmasına yönelik güncel literatür özetlenmektedir. Literatürdeki çalışmaların önemli bir bölümü, benek gürültüsünün etkilerini bastırmaya yönelik ön işleme ve filtreleme stratejilerine odaklanmaktadır [6, 14–16]. Bunun yanında, sınırlı etiketli senaryolarda güçlü genelleme sunan geleneksel makine öğrenmesi yöntemleri yaygın biçimde kullanılmaktadır [17–20]. Son yıllarda ise derin öğrenme tabanlı yöntemler, uzamsal bağlamı etkin biçimde modelleyebildikleri için literatürde öne çıkmış ve birçok veri kümesinde yüksek doğruluklara ulaşmıştır. Ancak bu başarı çoğunlukla yüksek miktarda etiketli veriye ve yoğun eğitim süreçlerine bağlıdır. Bu nedenle az etiketli senaryolarda performansın kararsızlaşması ve hesapsal karmaşıklığın artması temel sınırlayıcılar olarak öne çıkmaktadır. Ayrıca çok sayıda hiperparametreye duyarlılık, sahneye bağlı performans değişimlerini artırabilmektedir. Bu durum etiket maliyeti ve hesaplama yükü gibi pratik kısıtların literatürde sıkça vurgulanmasına yol açmaktadır.

Bu çerçevede, kenar koruyucu filtreler, benek gürültüsünü bastırırken sınıf sınırlarını ve yerel dokuları korumayı amaçlayan bir ön işleme yaklaşımları grubu olarak dikkat çekmektedir. BF, guided/fast guided, FGS, DT, NLM/ANLM ve BM3D gibi yöntemler gürültü–kenar dengesi açısından karşılaştırmalı biçimde değerlendirilmektedir. EPF'ler belirlenen hiperparametre ayarlarında sınıf içi değişkenliği azaltarak daha kararlı temsiller üretebilmektedir. Bununla birlikte, filtre türü ve parametre seçiminin sahne içeriğine duyarlı olması, veri kümeleri arasında tutarlı bir denge kurmayı zorlaştırabilmektedir. SVM, RF ve KNN gibi geleneksel yöntemler ise öznitelik çıkarımı ve ön-işleme ile birlikte kullanıldığında özellikle az etiketli koşullarda güçlü bir seçenek sunmaktadır. Bununla birlikte, çekirdek ve hiperparametre ayarları ile sahneye bağlılık, performans üzerinde belirleyici olabilmektedir. Derin öğrenme yaklaşımları yüksek doğruluklar sunsa da çoğu zaman daha yüksek hesaplama maliyeti, GPU gereksinimi ve daha fazla etiketli veri ihtiyacı gibi kısıtlar doğurmaktadır. Bu yüzden EPF ile MRF/CRF ve komşuluk duyarlı mekanizmaları birleştiren hibrit yaklaşımların önemi artmaktadır. Böylece, tez kapsamında önerilen yöntemin dayandığı temel yaklaşımlar, literatürdeki güçlü ve zayıf yönleriyle birlikte bütüncül bir çerçeve içinde sunulmaktadır.

1.2.1 Kenar Koruyucu Filtreler

SAR görüntülerinde sınıflandırma probleminin dayandığı temel zorluk, koherent görüntüleme yapısından kaynaklanan benek gürültüsüdür. Benek gürültüsü, homojen alanlardaki varyansı artırarak sınıf içi dağılımı genişletir ve sınırları bulanıklaştırarak sınıflandırma doğruluğunu düşürür [6, 21]. Bu etki, özellikle az etiketli ve eğitim verisi sınırlı senaryolarda daha da belirginleşmektedir. Sınıf içi varyansın artmasıyla eğitim kümesinde görülen örnekler, test kümesindeki aynı sınıfa ait örnekleri yeterince temsil edememektedir. Bu durum, eğitim ile test arasındaki dağılım uyumsuzluğunu artırarak sınıflandırıcının genelleme gücünü zayıflatmakta ve performansın düşmesine yol açmaktadır. Bu nedenle, hem gürültüyü bastıran hem de sınıf sınırlarını koruyan kenar koruyucu filtreler, SAR literatüründe kritik bir rol oynamaktadır [4, 6, 14–16]. Kenar koruyucu filtreler, gürültü azaltma sürecinde kenar yapıları ve anlamlı yerel ayrıntıları mümkün olduğunca korumayı amaçlayan yöntemlerdir. Bu yaklaşımlar zaman içinde farklı perspektiflerle geliştirilmiştir. Bu yaklaşımlardan en yaygın kullanılanlar arasında BF, DT, FGS, GF (Guided Filter) tabanlı filtreler ve Fast GF gibi hız odaklı türevler öne çıkmıştır [15, 16, 22–26]. Bu tez kapsamında, benek gürültüsü kaynaklı sınıf içi değişkenliği azaltırken sınıf sınırlarını mümkün olduğunca koruyabilmek için EPF ailesinden BF, DT ve FGS yöntemleri temel alınmıştır.

Bilateral filtre, geleneksel gürültü giderme filtrelerine kıyasla gürültü bastırma sırasında kenar ve yerel detayların korunmasını daha iyi dengeleyebilmektedir. Bu nedenle hem görsel kaliteyi hem de nicel performans ölçütlerini olumlu yönde etkileyebildiği literatürde gösterilmiştir [22]. Uzamsal yakınlık ile yoğunluk benzerliğini birlikte dikkate alan ağırlıklandırma yapısı sayesinde homojen bölgelerde benek gürültü etkisinin azaltılmasına katkı sağlarken, belirgin kenar bölgelerinde gereksiz yumuşamayı azaltacak biçimde tasarlanmıştır. Bu nedenle bilateral filtre, benek gürültüsü bastırma ve kenar koruma dengesini birlikte ele alan temel EPF yaklaşımlarından biri olarak değerlendirilmektedir.

Bilateral ve Guided filtre gibi kenar koruyucu filtrelerin, gürültü bastırma sırasında kenar ve ince detaylar üzerindeki etkisi literatürde sıklıkla görsel karşılaştırmalar üzerinden tartışılmaktadır. Örneğin, Şekil 1.8'de yer alan karşılaştırma, aynı sahne üzerinde GF ve BF çıktılarının detay vurgulama davranışlarını ortaya koymaktadır. Bu tür örnekler, parametre ayarlarının kenar korunumu ile düzgünleştirme düzeyi arasındaki dengeyi doğrudan belirlediğini ortaya koymaktadır [23].

GF ve DT ise benek gürültüsü bastırma sürecinde kenar ve ince yapıların korunmasını hedefleyen modern kenar koruyan filtreler arasında yer almaktadır. Doğrusal zamanlı veya hesaplama açısından verimli çözüm yapıları sayesinde,

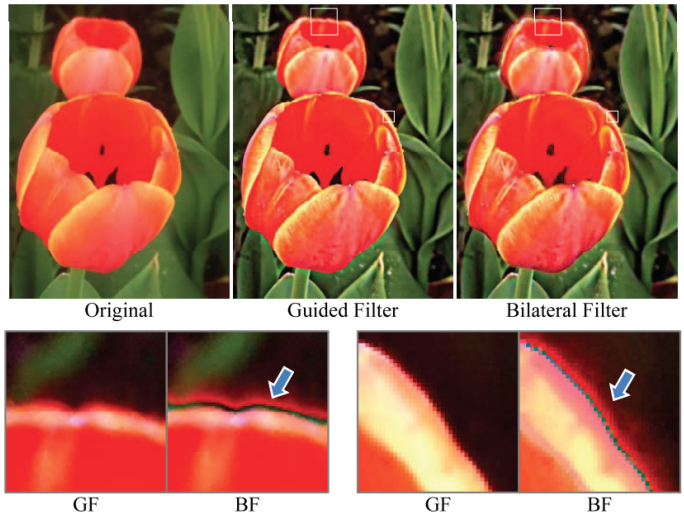

Şekil 1.8 Guided Filter ve Bilateral Filter kullanılarak elde edilen detay vurgulama çıktılarının karşılaştırması

pratik uygulamalarda işlem maliyeti ile çıktı kalitesi arasında uygulanabilir bir denge sağlamaktadır [23, 24]. GF filtresi, rehber görüntü üzerinden yerel doğrusal bir model kurarak kenar bölgelerinde taşma etkisini sınırlayan bir yumuşatma üretir. DT ise kenar bilgisiyle uyumlu bir dönüşüm uzayı tanımlayarak filtreleme işlemini bu uzayda daha verimli biçimde gerçekleştirmeye imkan sağlar. Fast GF yaklaşımı, GF'nin prensibini koruyarak alt örnekleme tabanlı bir hızlandırma mekanizması sunmaktadır. Bu sayede, büyük boyutlu görüntülerde hesaplama maliyetini azaltmayı hedeflemektedir. Literatürde Şekil 1.9'da verilen örnekte olduğu gibi, GF ve Fast GF çıktılarının aynı görüntü üzerinde karşılaştırılması, hızlandırma adımına rağmen kenar ve detay korunumu karakteristiğinin büyük ölçüde korunduğunu göstermektedir [25].

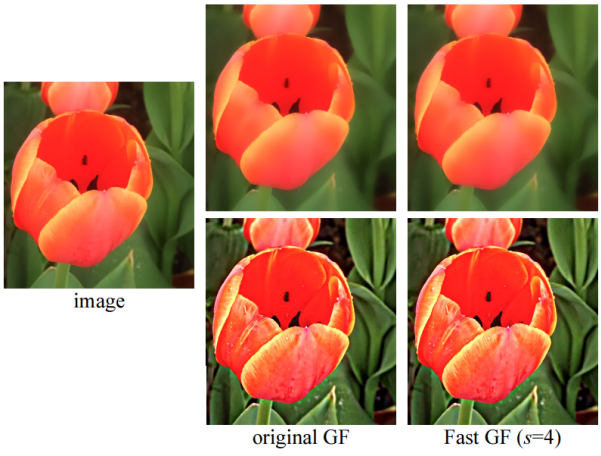

Şekil 1.9 Guided Filter ve Fast Guided Filter kullanılarak elde edilen detay vurgulama sonuçlarının karşılaştırılması

FGS (Fast Global Smoother), WLS (Weighted Least Squares) temelli küresel yumuşatma yaklaşımını esas alıp hesaplama maliyetini azaltarak WLS tabanlı yöntemlere kıyasla yaklaşık 30 kat hız kazanımı sağlayabildiği bildirilen kenar koruyucu bir filtredir [26]. Min ve ark., yöntemi homojen olmayan Laplasyen ile kurulan doğrusal bir problem üzerinden yumuşatma ve bunu izleyen düzeltme aşaması olmak üzere iki kademeli bir çözüm olarak tanımlamaktadır [26]. Ayrıca Reich ve ark., FGS'nin global ölçekte gürültüyü bastırırken kenar ve ince ayrıntıları koruyup Gauss benzeri filtrelerin ürettiği bulanıklığı sınırlayarak kalite ve hız dengesinde avantaj sunduğunu vurgulamaktadır [27].

EPF yöntemlerine yönelik derleme ve kıyaslama çalışmalarında da Gaussian bulanıklaştırma, anizotropik difüzyon, bilateral/trilateral filtre ve guided filter gibi yaklaşımların matematiksel dayanakları ve parametrelerin gürültü bastırma ile kenar korunumu dengesine etkisi literatürde ayrıntılı biçimde incelenmektedir [15, 16].

Hiperspektral görüntülerde, EPF'ler genellikle spektral sınıflandırıcıdan elde edilen olasılık haritaları üzerinde mekansal düzgünlüğü artırmak için son işlem adımı olarak kullanılmaktadır [28, 29]. EPF + PCA tabanlı yöntemler, hem spektral hem de mekansal bilgiyi koruyan temsiller üretmektedir. Süper piksel temelli PCA yöntemleri ise homojen bölgelerde gürültü etkisini azaltırken sınıf içi tutarlılığı artırmaktadır [30, 31]. SVM tabanlı hiperspektral sınıflandırma, sonuçlarıyla birlikte düşünüldüğünde [17], boyut indirgeme ile EPF'nin birlikte kullanılması, sınıflandırma algoritmalarının daha kompakt ve gürültüye dayanıklı bir özellik uzayında çalışmasını sağlayan önemli bir adım olarak ortaya çıkmaktadır [28–31].

SAR için özelleşmiş EPF çalışmalarında, uzamsal ve polarimetrik mesafeyi birlikte kullanan bilateral mesafe temelli filtreler ile kenar, köşe ve ince yapıların geleneksel filtrelere göre daha iyi korunduğu gösterilmiştir [32]. Farklı gürültü bastırma filtrelerinin karşılaştırıldığı çalışmalarda bilateral, guided ve özellikle Adaptive NLM gibi yöntemlerin hem eşdeğer bakış açısı hem de sınıflandırma doğruluğu açısından dengeli performans sunduğu belirtilmektedir [18, 33]. SAR filtrelerini hem benek gürültüsünü bastırma hem de kenar koruma yönüyle aynı anda değerlendiren IQEM gibi bütünleşik ölçütler sayesinde, EPF'lerin yalnızca görsel kaliteye göre değil, sınıflandırma başarımına etkileri açısından da nesnel biçimde karşılaştırılması mümkün hale gelmiştir [20]. Tarımsal alanlarda yapılan güncel analizlerde, filtrelerin SVM ve Wishart gibi sınıflandırıcılarla birlikte değerlendirilmesi, benek gürültüsü bastırma ve kenar koruma dengesinin nihai doğruluk üzerindeki etkisini açık bir şekilde göstermektedir [19, 34].

EPF'lerin segmentasyon modellerine gömülü kullanımı da yaygındır. Deniz yüzeyi petrol sızıntısı bölütlemede bilateral filtre tabanlı ceza terimine sahip DRLSE modelleriyle, benek gürültüsü bastırılırken sınır bulanıklığı azaltılmakta ve RADARSAT-2 verilerinde yüksek doğrulukta segmentasyon elde edilmektedir [35]. Tam kutuplu verilerde Lee filtresi ve geliştirilmiş aktif kontur modellerinin, petrol sızıntısı sınırlarının ayrıştırılmasında karşılaştırılan alternatif yaklaşımlara kıyasla daha yüksek performans skorları ürettiği gösterilmiştir. Seviye kümesi tabanlı yaklaşımların da benzer değerlendirme ölçütleri altında rekabetçi skorlar elde ettiği belirtilmiştir [36, 37].

Özetle; BF, FGS, DT, GF, Fast GF, NLM/ANLM, BM3D ve benzeri EPF'ler, SAR ve PolSAR görüntülerinde benek gürültüsünü azaltırken sınıf sınırlarını koruyan güçlü araçlar olup sınıflandırma ve segmentasyon yöntemleriyle birlikte kullanıldıklarında anlamlı performans sağladıkları literatürde açıkça gösterilmektedir. [18–20, 22–26, 32, 33, 35].

EPF tabanlı yaklaşımlar güçlü bir benek gürültüsü bastırma ve kenar koruma çerçevesi sunmalarına rağmen bu kazanımların farklı sahneler ve veri kümeleri arasında aynı düzeyde korunması çoğu zaman garanti edilememektedir. Filtre türü ile parametre ayarlarına duyarlılık; sahnenin saçılım karakteristiği, sınıf içi heterojenlik ve arazi örtüsü geçişlerinin yapısı gibi etkenlerle birlikte değerlendirildiğinde, gürültü azaltma ile sınırların korunumu arasındaki dengenin tutarlı biçimde sürdürülebilmesi zorlaşmaktadır. Dolayısıyla, farklı koşullar ve sahne türleri altında kararlı ve genellenebilir performans sunan EPF yapılandırmalarının belirlenmesi ile sahneye uyumlu parametre seçiminin sistematik biçimde gerçekleştirilmesi, literatürde halen açık bir araştırma problemi olarak görülmektedir.

1.2.2 Geleneksel Makine Öğrenmesi Yaklaşımları

SAR görüntü sınıflandırmasında geleneksel makine öğrenmesi yöntemleri, yüksek boyutlu öznitelik uzaylarıyla başa çıkabilme ve sınırlı etiketli senaryolarda kararlı performans sergileyebilme özellikleri nedeniyle uzun yıllar temel araçlar olarak kullanılmıştır [38, 39]. Bununla birlikte, geleneksel SVM yaklaşımının daha zengin bağlam bilgisiyle güçlendirilmesi amacıyla birleşik çekirdek tabanlı bakış açısı, ilgili alanda belirleyici bir araştırma yönelimi oluşturmuştur. Birleşik çekirdekli SVM yaklaşımında spektral ve uzamsal bilgi, gerektiğinde hiyerarşik yapı bilgisiyle birlikte, tek bir çekirdek kurgusu içinde bütünleştirilmektedir. Böylece, sınırlı etiketli senaryolarda sınıflar arası ayırt ediciliğin güçlendirilmesi amaçlanmaktadır [40]. Bu tür çekirdek tabanlı yaklaşımlar pratikte güçlü genelleme

sunabilse de, çekirdek bileşenlerinin ve hiperparametrelerin sahneye ve veri tipine duyarlılığı nedeniyle farklı veri kümeleri arasında en iyi yapılandırmanın doğrudan aktarılabilirliği her zaman sağlanamayabilmektedir. Bu bağlamda, uzaktan algılama literatüründe özellikle yüksek boyutlu hiperspektral veriler üzerinde SVM'nin, az sayıda eğitim örneğiyle dahi yüksek sınıflandırma doğruluğu elde edebildiği gösterilmiştir [17]. Bu tür SVM tabanlı sınıflandırma çalışmalarında spektral, mekansal ve hiyerarşik bilgi birlikte ele alınabilmekte olup söz konusu bilgilerin birleşik çekirdek (composite kernel) altında bütünleştirildiği tipik işlem akışı Şekil 1.10'da şematik olarak gösterilmektedir [40]. Bu özellik, SVM tabanlı yaklaşımların daha sonra polarimetrik SAR gibi karmaşık ve istatistiksel olarak değişken veri türlerine de başarıyla uyarlanmasının önünü açmıştır. Nitekim PolSAR verileri için kompleks Wishart dağılımına dayalı istatistiksel sınıflandırıcılar uzun süre yaygın biçimde tercih edilmiştir [21].

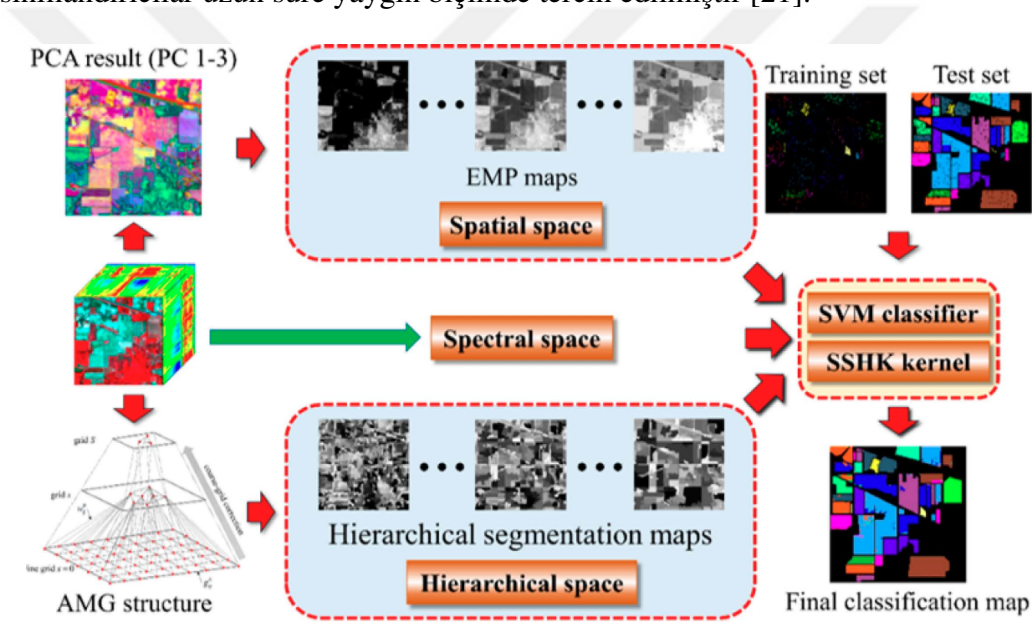

Şekil 1.10 Spektral, mekansal ve hiyerarşik yapı bilgisini birlikte kullanan birleşik çekirdek tabanlı SVM ile hiperspektral görüntü sınıflandırmaya ait tipik işlem akışı

Kentsel SAR sahnelerinde, bulanık kümeleme ve SVM'nin ardışık kullanıldığı yaklaşımlarda, istatistiksel ve GLCM tabanlı doku özellikleriyle simülasyon ve gerçek RADARSAT-2 verilerinde yüksek doğruluklar elde edildiği gösterilmektedir [41].

Benek gürültü filtreleri ile geleneksel sınıflandırıcıların birlikte kullanımı da literatürde sistematik olarak incelenmiştir. Flevoland veri kümesinde yapılan çalışmalarda, farklı benek gürültüsü filtrelerinin RBF-SVM ile birlikte kullanımı sonucunda benek gürültüsünü bastırma ve doğruluk arasında dengeli sonuçların elde edilebildiği gösterilmektedir [18]. IQEM çerçevesi ile filtrelerin CENL ve EPE gibi ölçütlere göre birlikte değerlendirilmesi, sınıflandırma öncesi filtrenin seçimini

daha nesnel hale getirmektedir [20]. ALOS-1 L-band San Francisco verisi üzerinde farklı benek gürültü filtrelerinin hem SVM hem de Wishart sınıflandırıcılarla birlikte analiz edilmesi, filtrenin seçiminde yalnızca genel doğruluğun (OA) yeterli bir ölçüt olmadığı belirtilmektedir. Dahası benek gürültüsü bastırma ile kenar, doku ve yerel yapıların korunumu arasındaki dengenin de gözetilmesi gerektiği açık bir şekilde ortaya konmaktadır [19]. Bununla birlikte, aynı bulgular filtre performansının sahne içeriğine ve parametre ayarlarına yüksek derecede duyarlı olduğunu göstermektedir. Farklı arazi örtüsü sınıfları için optimum ayarların değişebilmesi, yöntemlerin genellenebilirliği açısından belirli sınırlılıkları beraberinde getirmektedir. Tarımsal sahnelerde yapılan güncel değerlendirmelerde benzer şekilde, aynı filtrenin farklı ürün türleri, ekim desenleri ve bitki gelişim evreleri altında tutarlı sonuçlar üretmeyebildiğini ortaya koymaktadır. Bu durum benek gürültüsü ve sınıf sınırı korunumu dengesinin sahneye özgü olarak yeniden ayarlanmasını gerektirdiğini göstermektedir [34].

Genel olarak; SVM, RF, KNN ve benzeri geleneksel makine öğrenmesi yöntemleri, uygun öznitelik çıkarımı, boyut indirgeme ve EPF tabanlı ön-işleme adımlarıyla birleştirildiğinde SAR sınıflandırmasında yüksek doğruluk değerlerine ulaşabilmektedir. Ayrıca, hesaplama maliyeti ve yorumlanabilirlik bakımından incelendiğinde derin öğrenme tabanlı yaklaşımlara göre önemli kazanımlara sahip olduğu görülmektedir [17–21].

1.2.3 Derin Öğrenme Tabanlı Yöntemler

Son yıllarda derin öğrenme, SAR ve PolSAR görüntü sınıflandırmasında önemli bir araştırma alanı haline gelmiştir. Güncel çalışmalar incelendiğinde CNN, Transformer tabanlı modeller ve graf tabanlı yaklaşımların belirgin biçimde öne çıktığı görülmektedir [42–44]. Bu yaklaşımlar, benek gürültüsü, karmaşık saçılım yapıları ve sınırlı etiketli veri gibi zorluklara rağmen yüksek doğruluk sonuçları gösterebilmektedir. Literatürde uzamsal tutarlılığı artırmak için süperpiksel veya komşuluk temelli ağların öne çıktığı görülmektedir. Ayrıca, sınır bölgelerini iyileştirmek amacıyla CRF veya MRF gibi graf tabanlı modellerle bütünleştirilen mimariler ile etiket kıtlığını azaltmaya yönelik üretici ya da yarı denetimli GAN tabanlı yapılar da yaygın biçimde kullanılmaktadır. Bu yaklaşımlara ek olarak, global bağlamı modelleyen Transformer tabanlı tasarımlar ile PolSAR'ın kompleks ve polarimetrik doğasına özgü çok yollu CNN türevleri ve sığdan derine özellik füzyonu gibi stratejiler literatürde yaygın biçimde kullanılmaktadır.

Uzamsal tutarlılığı artırmak üzere süperpiksel temsillerin CNN öğrenmesiyle birleştirildiği SPCNN benzeri yaklaşımlar, gürültü nedeniyle piksel düzeyinde

oluşan karar sapmalarını bastırmayı amaçlamaktadır [45]. Bu tür yöntemler sınıf bölgelerinde daha düzgün haritalar üretebilse de, süperpiksel boyutu ve ayarları ile sahnedeki heterojenlik düzeyi, sonuçları anlamlı ölçüde değiştirebilmektedir. Sınır bölgelerinde daha kararlı etiketleme elde etmek amacıyla kapsül ağlarından elde edilen temsillerin CRF ile uzamsal açıdan iyileştirildiği H-CapsNet+CRF tabanlı mimariler de önerilmiştir [46]. Bununla birlikte, CRF tabanlı iyileştirme aşaması ek hesaplama yükü getirebilmekte ve parametre/ayar seçimine karşı hassasiyet oluşturabilmektedir.

Etiketli örnek sayısının düşük olduğu senaryolarda, üretici modellerin temsil öğrenme gücünden yararlanan N-cluster GAN gibi tasarımlar, kümeleme temelli ve yarı denetimli bir öğrenme düzeniyle sınıflar arasındaki ayrışmayı artırmayı amaçlamaktadır [47]. Ancak GAN tabanlı yaklaşımlarda eğitim kararlılığı ve ilave strateji gereksinimleri uygulamada çeşitli güçlükler doğurabilmektedir.

Global bağlamı yakalamak için Transformer tabanlı tasarımlar PolSAR sınıflandırmada yaygınlaşmıştır. Özellikle MCPT yaklaşımı, konvolüsyonel yerel özellik çıkarımı ile paralel Transformer kollarını birleştirerek hem yerel hem de global ölçekli bağlamsal ilişkileri temsil etmeyi hedefler [48]. Bu tür yaklaşımlar, yüksek doğruluk değerlerine ulaşabilse de, çoğu zaman daha yüksek hesaplama yükü ve daha fazla veri ihtiyacı beraberinde getirmektedir. Çok ölçekli bağlamın ardışıl biçimde modellenmesi amacıyla LSTM türevleri de önerilmiştir. AMSE-LSTM çizgisindeki yaklaşımlar mekansal bağlamı çok ölçekli biçimde kodlayıp sınıflandırma başarımını artırmayı hedeflemiştir [49]. Buna karşılık mimari karmaşıklık ve eğitim maliyeti CNN tabanlı yaklaşımlara oranla artış gösterebilmektedir.

PolSAR verisinin polarimetrik ipuçlarını daha etkin değerlendirebilmek amacıyla, çok kollu CNN mimarileri geliştirilmiştir. PolMPCNN gibi tasarımlar farklı dallarda tamamlayıcı polarimetrik özellikleri çıkarıp birleştirerek sınıflandırma başarımını artırmayı amaçlamıştır [50]. Güncel karşılaştırmalarda öne çıkan bir diğer eğilim ise farklı derinlik seviyelerinde öğrenilen özelliklerin birlikte kullanılmasına dayanan füzyon yaklaşımlarıdır. SDF2Net, sığ katmanlardan elde edilen yerel ayrıntı ağırlıklı temsiller ile derin katmanların sağladığı daha güçlü semantik temsilleri çok dallı bir yapı altında bütünleştirerek, özellikle karmaşık sahnelerde sınıflar arasındaki ayrımı artıran daha seçici bir özellik uzayı oluşturmayı amaçlamaktadır [51]. Bununla birlikte, çok dallı yapı ve özellik füzyonu stratejileri; mimariyi daha karmaşık hale getirebilmekte ve hesaplama yükünü artırabilmektedir.

Fiziksel saçılım temelli öznitelikleri derin temsillerle birleştiren füzyon ağları, yorumlanabilirliği korurken genelleme yeteneğini güçlendirmeyi hedeflemektedir. Ancak çoklu akışlı füzyon tasarımı ek karmaşıklık getirdiğinden, modül/kanal seçimi ve ilgili ayarlar sonuçlara hassas olabilmektedir [52].

Dalgacık dönüşümü ile CNN'yi birleştiren yaklaşımlar, çok ölçekli bileşenleri vurgulayarak benek gürültü etkisini azaltmayı ve sınıflar arası ayrımı güçlendirmeyi amaçlamaktadır. Bununla birlikte dalgacık türü ölçeklerle ağın kapasitesi gibi tercihler, başarımı anlamlı ölçüde değiştirebilmektedir [53].

SDBCS gibi öz damıtma tabanlı yöntemler, benzerlik temelli etiket düzeltme ve daha sağlam temsil öğrenimiyle benek gürültüsü altında sınıflandırma performansını artırmayı hedeflemektedir. Düzeltme eşiği ve benzerlik ölçütünün seçimi doğru yapılmadığında, yanlış eşleşmeler nedeniyle hatalı düzeltim olasılığı artabileceğinden bu parametrelerin titizlikle kalibre edilmesi gerekmektedir [54].

MCFCN türü karşıt öğrenme tabanlı FCN yaklaşımları, uygun karşıt çiftler üzerinden daha ayrıştırıcı öznitelikler öğrenerek doğruluk ve sınıflandırma haritası homojenliğini iyileştirmeyi amaçlamaktadır. Buna karşın çift oluşturma kurgusu ile pencere/örtüşme gibi tasarım seçimleri çıktıyı etkilediğinden, yöntem bu ayarlara duyarlı olabilmektedir [55].

Öte yandan EPF, MRF ve komşuluk duyarlı mekanizmalarla desteklenen yaklaşımlar, gürültü ve sınır karışımı sorunlarını minimize etmeyi amaçlamaktadır [56, 57]. Bu yaklaşımlara örnek olarak, çift kanallı konvolüsyonel ağ ile kenar koruyucu MRF'nin birlikte kullanıldığı mimari Şekil 1.11'de gösterilmektedir [56].

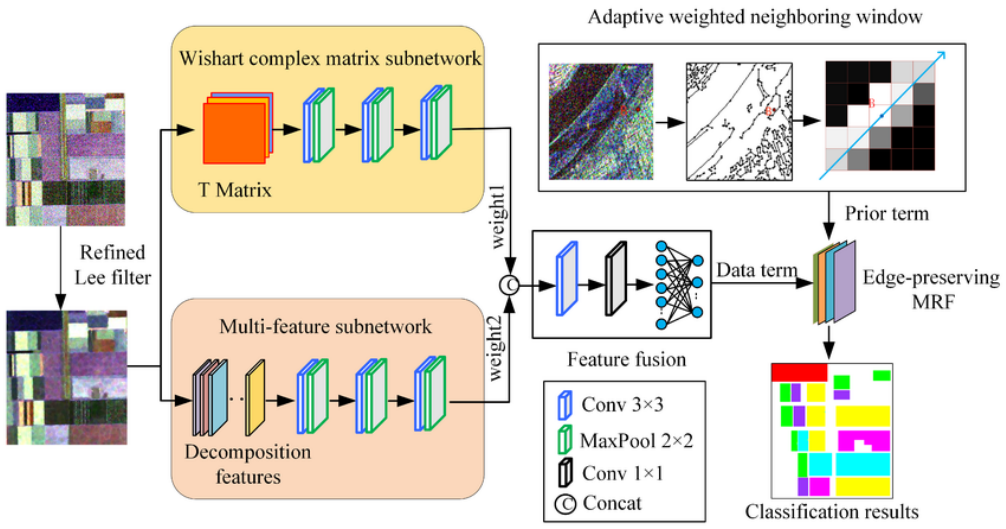

Şekil 1.11 Çift kanallı konvolüsyonel ağ ve kenar koruyucu Markov Rastgele Alan temelli PolSAR sınıflandırma mimarisi

PolSAR verileri için önerilen compact CNN mimarilerinde, küçük boyutlu yamalar üzerinden öğrenme yapılarak parametre sayısı düşük tutulmaktadır. Ancak buna rağmen AIRSAR ve RADARSAT-2 veri setlerinde çok düşük etiket oranlarında dahi yüksek genel doğruluklara erişildiği gösterilmektedir [58]. Daha da karmaşık yapılarda, karmaşık değerli çok ölçekli dikkat vizyon transformatörleri (CV-MsAtViT) ile karmaşık 3B konvolüsyon, dikkat blokları ve Transformer bileşenleri birleştirilerek Flevoland ve San Francisco veri kümelerinde yüksek doğruluk ve Kappa değerlerine ulaşılmaktadır [59].

Kompleks-değerli artık dikkat (residual attention) ile güçlendirilmiş U-Net tabanlı yaklaşımlar, PolSAR verisinde genlik–faz bilgisini birlikte değerlendirerek daha ayırt edici temsiller öğrenmeyi ve sınıflandırma başarımını yükseltmeyi hedeflemektedir. Bununla birlikte kompleks-değerli işlemler ve dikkat modülleri, mimari/hiperparametre seçimlerine duyarlılığı artırarak eğitim kararlılığı ve hesaplama maliyeti açısından ek yük doğurabilmektedir [60].

EPF ile derin ağların birleştirildiği yaklaşımlarda, çok ölçekli derin özellik öğrenme ağları BF ile birlikte kullanılarak SAR veri kümelerinde geleneksel yaklaşımlara göre daha anlamlı sonuçlar ortaya konduğu görülmektedir [61]. Çift kanallı CNN + kenar koruyucu MRF (DC-CNN + EP-MRF) yaklaşımında, bir kanalda polarimetrik, diğerinde doku özellikleri işlenmektedir. Çıktı aşamasında kenar duyarlı MRF ile aşırı yumuşatma kontrol edilerek Flevoland ve San Francisco Bay verilerinde rekabetçi sonuçlar üretildiği gösterilmektedir [62]. Komşuluk duyarlı CNN mimarilerinde ise yama içindeki pikseller uzamsal ve özellik uzayı mesafelerine göre ağırlıklandırılarak sabit komşuluk varsayımı esnetilmekte ve genel doğrulukta anlamlı artışlar olduğu belirtilmektedir [63].

Graf tabanlı derin öğrenme çalışmalarında, MWGCN gibi yarı-denetimli GCN yaklaşımları sınırlı etiketli PolSAR senaryolarında çok ölçekli graf yayılımı ile uzamsal tutarlılığı güçlendirip etiket kıtlığının olumsuz etkisini azaltmayı amaçlamaktadır. Ancak graf kurma stratejisi ile ölçek/komşuluk tasarımı kritik olduğundan, yöntem performansı bu tasarım tercihlerine bağlı olarak belirgin biçimde değişebilmektedir [64]. Ayrıca çok ölçekli ağırlıklı graf konvolüsyon ağları ile yarı denetimli PolSAR sınıflandırmasında yüksek doğruluklar elde edildiği de gösterilmektedir [65].

Transfer-aware Graph U-Net çizgisindeki yaklaşımlarda çapraz-seviye etkileşimler ve graf tabanlı füzyon üzerinden çok ölçekli bağlamı birleştirerek özellikle sınır bölgelerinde daha kararlı etiketleme üretmeyi hedeflemektedir. Öte yandan dinamik graf yapıları ve çok ölçekli modüller, hesaplama yükünü artırırken veri kümesine

göre daha fazla ayar gereksinimi doğurabilmektedir [66].

Genel olarak, derin öğrenme tabanlı yaklaşımlar benek gürültüsüne rağmen yüksek doğruluk sağlayabilmektedir. Fakat çoğu zaman yüksek hesaplama maliyeti, GPU gereksinimi ve yoğun etiketli veri ihtiyacı gibi kısıtlamalarla karşı karşıyadır. Bu nedenle literatürde, EPF, MRF, segmentasyon ve klasik makine öğrenmesi yöntemlerini derin ağlarla birleştiren hibrit yaklaşımların giderek daha fazla önem kazandığı görülmektedir [58, 59, 61, 62, 65, 66].

1.3 Motivasyon

Literatür incelendiğinde, SAR ve PolSAR görüntü sınıflandırmasına yönelik çalışmaların önemli bir kısmının ya gelişmiş saçılma filtreleri tasarlamaya ya da giderek karmaşıklaşan derin öğrenme mimarileri önermeye odaklandığı görülmektedir. Kenar koruyucu filtreler BF, FGS, DT, GF, Fast GF, NLM/ANLM, BM3D gibi yöntemlerin, benek gürültüsünü azaltırken önemli yapısal detayları ve sınıf sınırlarını koruyabildiği gösterilmiştir[4, 6, 14–16]. Öte yandan, SVM, RF, KNN gibi geleneksel makine öğrenmesi yöntemleri ile CNN, Transformer, GCN ve hibrit derin ağlar, çeşitli SAR veri kümelerinde yüksek doğruluklar elde edildiği gösterilmiştir. [38, 39, 42–44]. Ancak bu çalışmaların önemli bir bölümünde filtreler çoğunlukla görsel kalite veya birkaç istatistiksel ölçüt üzerinden değerlendirilmektedir. Buna ek olarak ileri düzey filtreleme teknikleri sadece büyük veri ve yüksek hesaplama gücü gerektiren derin ağ mimarileri ile birlikte ele alınıp incelenmektedir. Bu çerçevede literatürde öne çıkan bazı sınırlılıklar şu şekilde özetlenebilir:

- Bir çok EPF çalışmasında, filtrenin nihai sınıflandırma performansı üzerindeki etkisi sistematik ve bütüncül bir bakış açışı olarak ele alınmamaktadır. Filtreler çoğunlukla görsel izlenim veya sınırlı sayıda metrikle karşılaştırılmaktadır. Bunun yanı sıra aynı deneysel ortamda genel doğruluk, Kappa ve sınıf bazlı ölçütlere olan etkisi tam olarak incelenmemektedir.
- EPF ile öğrenme tabanlı yaklaşımları birleştiren çalışmaların önemli bir bölümü, hiperspektral (HSI) veya optik veriler üzerinde yoğunlaşmaktadır. Çok kanallı SAR verileri için, birden fazla karşılaştırmalı veri kümesi ve açıkça tanımlanmış arazi örtüsü sınıfları ile yürütülmüş sistematik EPF değerlendirmeleri nispeten sınırlı olarak ele alınmaktadır.
- Derin öğrenme tabanlı yöntemler her ne kadar üst düzey doğruluk sağlasa da,

çoğunlukla geniş etiketli eğitim kümelerine, GPU altyapısına ve uzun eğitim sürelerine ihtiyaç duymaktadır. Bu durum düşük etiketli, kaynak kısıtlı ya da işlemsel senaryolarla her zaman uyum sağlama noktasında belli bir kararlılığa sahip olamamaktadır.

- Mevcut pek çok SAR sınıflandırma çalışması, benek gürültüsünün bastırılması ve klasik makine öğrenmesi bileşenlerini bir araya getirse bile genellikle tek bir filtre, tek bir veri kümesi veya tek bir sınıflandırıcı üzerinden ilerlemektedir. Bu ise filtre–sınıflandırıcı seçimine yönelik genel ve anlamlı çıkarımlar yapmayı zorlaştırmaktadır.

Bu tabloya bağlı olarak, daha sistematik ve görece daha hafif bir yaklaşıma ihtiyaç duyulmaktadır. Bu yaklaşımın; kenar koruyucu filtrelerin SAR görüntü sınıflandırmasındaki rolünü açıkça ortaya koyabilecek nitelikte olması gerekir. Aynı zamanda boyut indirgeme kullanarak daha kompakt, ayırt edici bir özellik uzayı oluşturması ve az etiketli veri ile düşük hesaplama maliyetiyle eğitilebilen geleneksel makine öğrenmesi modellerine dayanması beklenmektedir. Bu tez çalışmasının temel motivasyonları aşağıdaki gibi özetlenebilir:

- Farklı kenar koruyucu filtrelerin SAR görüntü sınıflandırma performansı üzerindeki etkisini, 4 farklı SAR veri kümesi kullanarak, kontrollü ve karşılaştırılabilir bir çerçevede incelemek.
- EPF tabanlı ön-işleme adımında farklı parametreleme veya filtre türleriyle üretilen, benek gürültüsü bastırılmış ve kenarları korunmuş çoklu görüntü temsilleri PCA ile ortak bir özellik uzayına taşınarak en baskın ve ayırt edici bileşenlerin otomatik seçilmesi (özellik çıkarımı) ve kompakt bir öznitelik gösterimi elde edilmesi amaçlanmaktadır. Böylece farklı yumuşatma düzeylerinden gelen bilginin yoğunlaştırılıp daha düşük boyutlu fakat daha temsil gücü yüksek özelliklerle arazi örtüsü sınıfları arasındaki ayrılabilirliği artırmak.
- Geleneksel makine öğrenmesi sınıflandırıcılarının (SVM, RF, KNN) filtreleme öncesi ve sonrası performanslarını bilhassa sınırlı eğitim verisi koşullarında, genel doğruluk ve sınıf bazlı ölçütler açısından sistematik olarak karşılaştırmak.
- SAR görüntü sınıflandırması için, doğruluk, kararlılık ve hesaplama maliyeti ölçütleri açısından en dengeli EPF+PCA+sınıflandırıcı kombinasyonlarını belirlemeye yönelik öneriler geliştirmek.

Bu motivasyonlar doğrultusunda tez, yalnızca görsel değerlendirmeler ve temel nicel performans ölçütleri üzerinden yapılan filtre karşılaştırmalarına odaklanan çalışmalar ile hesaplama açısından ağır derin öğrenme tabanlı yaklaşımlar arasında bir boşluğu doldurmayı amaçlamaktadır. Aynı zamanda, kenar koruyucu filtreleme ile elde edilen temsilin ortak ve kompakt bir özellik uzayına taşınmasını izleyen sınıflandırma sürecinin SAR görüntü sınıflandırmasında daha düşük karmaşıklıkla rekabetçi sonuçlar sağlayabildiğini göstermeyi hedeflemektedir.

1.4 Tezin Ana Hatları

Bu tez beş bölümden oluşmaktadır. Birinci bölümde, SAR görüntü sınıflandırma problemi ve benek gürültüsü kısaca tanıtılmakta, temel kavramlar ve literatür özeti verilmekte, ardından tez çalışmasının motivasyonu sunulmaktadır. İkinci bölümde, kullanılan veri kümeleri, deneysel kurulum ve eğitim/test bölmeleri tanıtılmaktadır. Üçüncü bölümde, önerilen yöntemin ayrıntıları verilmekte olup çok kanallı SAR verisine uygulanan kenar koruyucu filtreler, PCA tabanlı boyut indirgeme ve SVM/RF/KNN gibi geleneksel makine öğrenmesi sınıflandırıcılarından oluşan EPF+PCA+sınıflandırıcı tabanlı yöntemin çerçevesi açıklanmaktadır. Dördüncü bölümde, deneysel çalışmalar kapsamında öncelikle performans değerlendirme kriterleri ile K-katlı çapraz doğrulama deney protokolü tanıtılmakta ve EPF hiperparametreleri açıklanmaktadır. Devamında, filtresiz ve EPF sonrası klasik makine öğrenmesi yöntemlerinin sonuçları karşılaştırılmaktadır. PCA sonrası EPF+SVM tabanlı yöntemin çıktıları, tekrarlı ve 100-katlı stratified çapraz doğrulama deneyleri ile sınıflandırma haritalarının görsel analizi üzerinden bulgular tablolar ve şekiller eşliğinde tartışılmakta ve literatür ile karşılaştırmalı değerlendirme sunulmaktadır. Beşinci bölümde ise elde edilen bulgular özetlenmekte, tez çalışmasının katkıları ve gelecekte yapılabilecek çalışmalar kısaca değerlendirilmektedir.

2
VERİ KÜMELERİ

Bu bölümde, tez kapsamında kullanılan SAR veri kümelerine ilişkin temel bilgiler sunulmaktadır. Öncelikle çalışmada kullanılan karşılaştırmalı veri kümeleri tanıtılmaktadır. Ayrıca, deney sürecinde izlenen verinin eğitim ve test kümelerine ayrılması ve deneysel kurulum detayları açıklanmaktadır.

2.1 Veri Kümelerinin Tanıtımı

Bu tezde gerçekleştirilen deneylerde, literatürde yaygın olarak kullanılan tam-kutuplu karşılaştırmalı SAR veri kümelerinden yararlanılmıştır. Burada tam-kutuplu ifadesi; HH, HV, VH ve VV polarizasyon kanallarının tamamının ölçülerek daha zengin saçılım bilgisinin elde edilmesini ifade etmektedir. Bu kapsamda, iki farklı sensör tarafından elde edilen ve L-bant ile C-bant aralığını temsil eden dört veri kümesi kullanılmıştır: AIRSAR sensörü ile toplanan L-bant sahneleri (SFBay_L, Flevo_L) ile RADARSAT-2 sensörü ile toplanan C-bant sahneleri (SFBay_C, Flevo_C).

AIRSAR (Airborne Synthetic Aperture Radar), NASA/JPL tarafından geliştirilen ve hava platformu (uçak) üzerinde çalışan bir SAR sistemidir. Araştırma amaçlı tasarlanan bu sistem, tam-kutuplu ölçüm yeteneği sayesinde HH, HV, VH ve VV kanallarından oluşan saçılım bilgisini doğrudan elde edebilmektedir. AIRSAR'ın öne çıkan özelliklerinden biri, çok frekanslı çalışmaya olanak tanımasıdır. Literatürde yaygın kullanılan uygulamalarında P-, L- ve C-bantta tam-kutuplu veri toplanabildiği belirtilmektedir. Bu yapı, farklı dalga boylarının yüzey ve hacim saçılımına duyarlılığını birlikte inceleme imkanı sunar. Bu yönüyle AIRSAR veri kümeleri, karşılaştırmalı SAR çalışmalarında öne çıkmaktadır [67].

RADARSAT-2, Kanada merkezli bir uydu görevi kapsamında işletilen ve C-bantta görüntüleme yapan SAR sensörüdür. Sistem, uygun çalışma kiplerinde tam-kutuplu veri sağlayarak HH, HV, VH ve VV kanallarının birlikte ölçülmesine imkan tanımaktadır. Uydu platformu, geniş alan kapsaması ve tekrarlı gözlem

avantajlarıyla büyük ölçekli izleme uygulamalarına elverişli bir veri kaynağı sunmaktadır. Bununla birlikte C-bant frekansının sağladığı yüzey pürüzlülüğü, nem koşulları ve bitki örtüsü gibi etmenlere duyarlı geri saçılım tepkileri üretebilmektedir. Bu nedenlerle RADARSAT-2, karşılaştırmalı SAR sınıflandırma ve haritalama çalışmalarında sık kullanılan standart veri kaynaklarından biri olarak değerlendirilmektedir [68].

Değerlendirmelerde kullanılan veri kümeleri aşağıda özetlenmiştir:

- San Francisco Bay L-band (SFBay_L),
- San Francisco Bay C-band (SFBay_C),
- Flevoland L-band (Flevo_L),
- Flevoland C-band (Flevo_C).

Bu sahneler, Ahıshalı ve ark. tarafından ayrıntılı biçimde incelenmiş ve SAR sınıflandırma problemlerinde performans karşılaştırmaları için sıklıkla başvurulan veri kümeleri olarak kullanılmıştır [58]. Benzer biçimde otomatik kodlayıcılar, MRF/seyrek gösterim ve sığ-derin hibrit yaklaşımlar gibi yöntemler de aynı yer gerçeği (GT) verisi üzerinde değerlendirilmiştir [69–71]. Bu çalışmada, tüm sahneler için eğim menzili (slant-range) geometrisi esas alınmıştır. Bu temsil, piksellerin sensör ile hedef arasındaki doğrudan eğik mesafeye göre düzenlendiği ve yer projeksiyonu dönüşümü uygulanmadığı anlamına gelmektedir [58].

Bu tez kapsamında kullanılan veri kümelerinde sensörün logaritmik/dB dönüştürme ve kanal bazlı ölçekleme sonrasında ürettiği tam-kutuplu veriden çok-kanallı temsiller oluşturulmuş olup etiketli pikseller etrafında sabit boyutlu yamalar çıkarılmıştır. Yamalar, EPF (BF, DT, FGS) ile farklı parametre seviyelerinde yumuşatıldıktan sonra PCA ile düşük boyutlu bir öznitelik uzayına indirgenmiş ve son aşamada SVM sınıflandırıcısı ile piksel tabanlı sınıflandırma yapılmıştır.

Eğitim/test ayrımı, güncel SAR çalışmalarında sıkça kullanılan “az sayıda etiketli piksel” senaryosuna uyacak şekilde seçilmiştir. Ahıshalı ve ark. tarafından paylaşılan GT tanımları ve eğitim kurgusu ile uyumlu olacak şekilde, SFBay_C ve Flevo_C için sınıf başına 500 eğitim örneği seçilmiş ve yaklaşık 1:100 eğitim–test oranı kullanılmıştır. SFBay_L ve Flevo_L için ise toplam GT’nin yaklaşık %1–%2’si aralığında değişen sayıda eğitim örneği kullanılmıştır [58].

Tablo 2.1 Çalışmada kullanılan karşılaştırmalı SAR sahneleri için sistem, bant, edinim tarihi ve geliş açısı bilgileri

Bölge	Sistem–Bant	Kısaltma	Tarih	Geliş açıları
San Francisco Bay	AIRSAR–L	SFBay_L	1988	10–60°
San Francisco Bay	RADARSAT-2–C	SFBay_C	Apr 2008	30°
Flevoland	AIRSAR–L	Flevo_L	Aug 1989	40–50°
Flevoland	RADARSAT-2–C	Flevo_C	Apr 2008	30°

Tablo 2.2 Çalışmada kullanılan SAR veri kümeleri ve temel istatistikler

Veri Kümesi	Bölge	Sensör/Bant	Pol.	Boyut (Y×X)	Eğitim	Test	Toplam
SFBay_L	San Francisco	AIRSAR/L	Quad	900×1024	1 462	121 997	123 459
SFBay_C	San Francisco	RADARSAT-2/C	Quad	1426×1876	2 500	250 000	252 500
Flevo_L	Flevoland	AIRSAR/L	Quad	750×1024	4 211	205 768	209 979
Flevo_C	Flevoland	RADARSAT-2/C	Quad	1639×2393	2 000	200 000	202 000

2.1.1 SFBay_L Veri Kümesi

SFBay_L veri kümesi, Kaliforniya'daki San Francisco Körfezi üzerinde NASA/JPL tarafından geliştirilen AIRSAR sistemi ile L-band frekansında edinilmiş tam-kutuplu bir SAR sahnesidir [58]. Yaklaşık 900×1024 boyutundaki bu sahne, kentsel alanları doğal sınıflarla bir arada barındıran heterojen bir kıyı-kent ortamı sunmaktadır. Literatürde kesin yer gerçeği bilgisi bulunmadığından, yer gerçeği seti Pauli RGB görüntüsü ve yardımcı hava fotoğrafları üzerinden görsel yorumlamayla oluşturulmuş ve önceki çalışmalarla uyumlu GT kullanımı benimsenmiştir [58, 72, 73]. Sahnenin görsel olarak anlaşılabilmesi için L-band verisinden elde edilen Pauli RGB gösterimi ve yer gerçeği Şekil 2.1'de sunulmuştur [58].

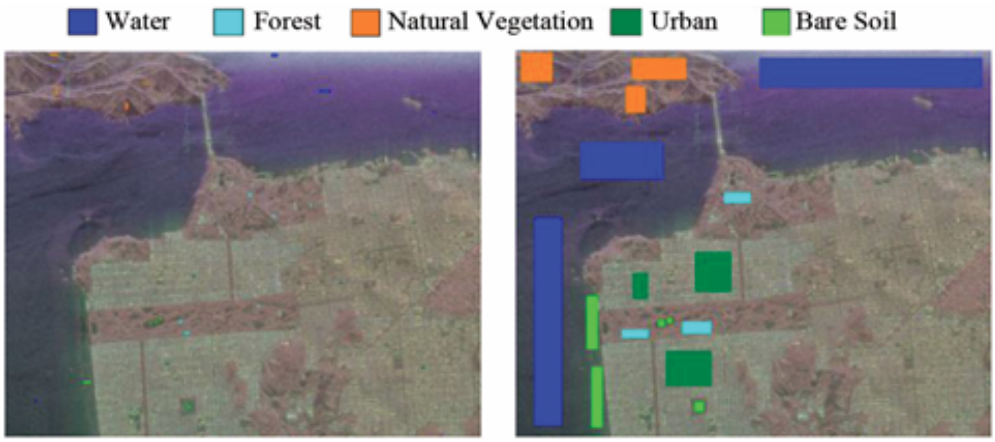

Şekil 2.1 SFBay_L veri kümesi için Pauli RGB gösterimi (solda) ve sınıf etiketleriyle birlikte karşılık gelen GT kümesi (sağda) gösterilmiştir

SFBay_L veri kümesi, beş sınıftan oluşmaktadır: Su, Kentsel alan, Orman, Çıplak

toprak ve Doğal vejetasyon [58].

Toplam 123 459 etiketli pikselden 1 462 adedi eğitim, 121 997 adedi test için kullanılmıştır. Sınıf bazında eğitim ve test piksel sayıları Tablo 2.3'te verilmektedir.

Tablo 2.3 SFBay_L veri kümesi için sınıf bazında eğitim ve test piksel sayıları

No	Sınıf Adı	Eğitim	Test	Toplam
1	Water	450	78 648	79 098
2	Urban	266	17 982	18 248
3	Forest	253	4 535	4 788
4	Bare Soil	125	7 173	7 298
5	Natural Vegetation	368	13 659	14 027
	Toplam	**1 462**	**121 997**	**123 459**

2.1.2 SFBay_C Veri Kümesi

SFBay_C veri kümesi, San Francisco Körfezi bölgesinin RADARSAT-2 uydusundan Fine Quad modunda elde edilen C-band tam-kutuplu SAR görüntüsüdür. Yaklaşık 1426×1876 boyutundaki aynı alt bölge ve sınıf tanımları, önceki çalışmalarla uyumlu şekilde kullanılmaktadır [58, 71, 73]. Sahneye ait Pauli RGB gösterimi ve yer gerçeği Şekil 2.2'de sunulmuştur [58].

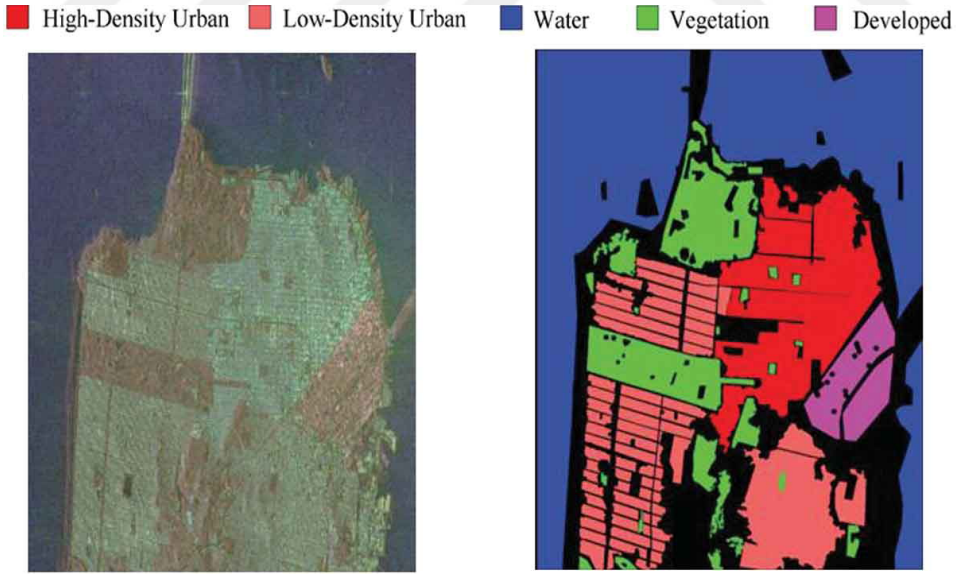

Şekil 2.2 SFBay_C veri kümesi için Pauli RGB gösterimi (solda) ve sınıf etiketleriyle birlikte karşılık gelen GT kümesi (sağda) gösterilmiştir

SFBay_C veri kümesi beş sınıftan oluşmaktadır: Su, Gelişmiş kentsel alanlar, Yüksek yoğunluklu kentsel alan, Düşük yoğunluklu kentsel alan ve Vejetasyon.

Ahıshalı ve ark. çalışmasıyla tutarlı biçimde, sınıf başına 500 eğitim örneği ve

50 000 test örneği seçilerek 1:100 oranı izlenmiştir [58]. Sınıf bazında eğitim ve test piksel sayıları Tablo 2.4'te verilmiştir.

Tablo 2.4 SFBay_C veri kümesi için sınıf bazında eğitim ve test piksel sayıları

No	Sınıf Adı	Eğitim	Test	Toplam
1	Water	500	50 000	50 500
2	Developed	500	50 000	50 500
3	High-Density Urban	500	50 000	50 500
4	Low-Density Urban	500	50 000	50 500
5	Vegetation	500	50 000	50 500
	Toplam	**2 500**	**250 000**	**252 500**

2.1.3 Flevo_L Veri Kümesi

Flevo_L veri kümesi, Hollanda'daki Flevoland tarım bölgesine ait AIRSAR L-band tam-kutuplu SAR sahnesidir ve SAR literatüründe geleneksel bir tarım karşılaştırmalı veri kümesi olarak değerlendirilmektedir [58, 70]. Yaklaşık 750×1024 boyutundaki sahne, 15 sınıflı ayrıntılı ürün/ağırlıklı arazi örtüsü şeması içermektedir. Yer gerçeği ve sınıf tanımları yaygın biçimde kullanılan referansla uyumludur [58]. Flevo_L sahnesine ait Pauli RGB görüntüsü ve yer gerçeği Şekil 2.3'te sunulmuştur [58].

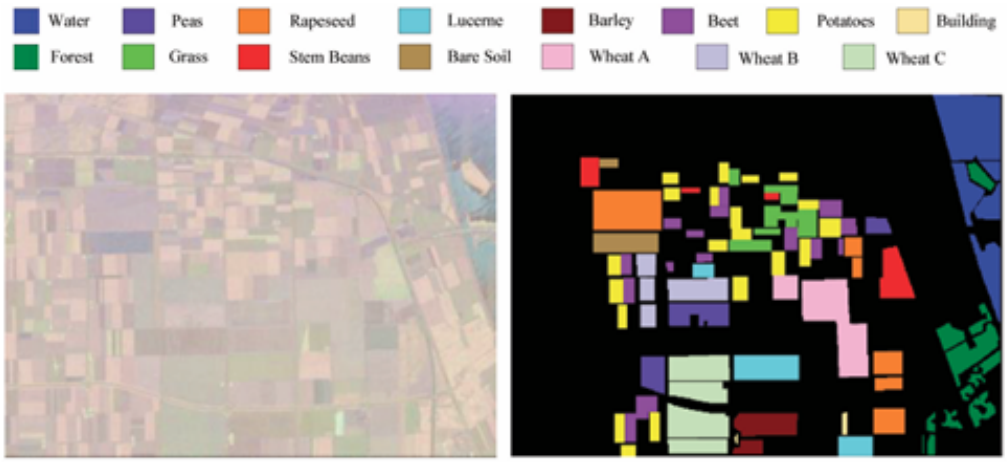

Şekil 2.3 Flevo_L veri kümesi için Pauli RGB gösterimi (solda) ve sınıf etiketleriyle birlikte karşılık gelen GT kümesi (sağda) gösterilmiştir

Flevo_L veri kümesi, 15 sınıftan oluşmaktadır: Su, Orman, Yonca, Çayır, Kolza, Pancar, Patates, Bezelye, Sırık Fasulye, Çıplak Toprak, Buğday 1,Buğday 2, Buğday 3, Arpa ve Yapılar.

Toplam 208 234 etiketli pikselden 4 211 adedi (yaklaşık %2) eğitim, 204 023 adedi test için kullanılmıştır. Sınıf bazında eğitim ve test piksel sayıları Tablo 2.5'te verilmiştir.

Tablo 2.5 Flevo_L veri kümesi için sınıf bazında eğitim ve test piksel sayıları

No	Sınıf Adı	Eğitim	Test	Toplam
1	Water	585	28 672	29 257
2	Forest	317	15 544	15 861
3	Lucerne	224	10 977	11 201
4	Grass	208	10 201	10 409
5	Rapeseed	437	21 422	21 859
6	Beet	297	14 559	14 856
7	Potatoes	427	20 924	21 351
8	Peas	208	10 189	10 397
9	Stem Beans	169	8 303	8 472
10	Bare Soil	126	6 191	6 317
11	Wheat 1	353	17 292	17 645
12	Wheat 2	213	10 419	10 632
13	Wheat 3	440	21 585	22 025
14	Barley	147	7 224	7 371
15	Buildings	60	521	581
	Toplam	**4 211**	**204 023**	**208 234**

2.1.4 Flevo_C Veri Kümesi

Flevo_C veri kümesi, Flevoland bölgesinin RADARSAT-2 C-band tam-kutuplu görüntüsüdür. Yaklaşık 1639×2393 boyutundaki aynı alt bölge ve GT, önceki çalışmalarla uyumlu biçimde kullanılmakta ve dört geniş arazi örtüsü sınıfı tanımlanmaktadır [58, 71, 73, 74]: Su, Kentsel, Orman ve Tarım alanları. Flevo_C sahnesine ait Pauli RGB görüntüsü ve yer gerçeği Şekil 2.4'te verilmiştir [58].

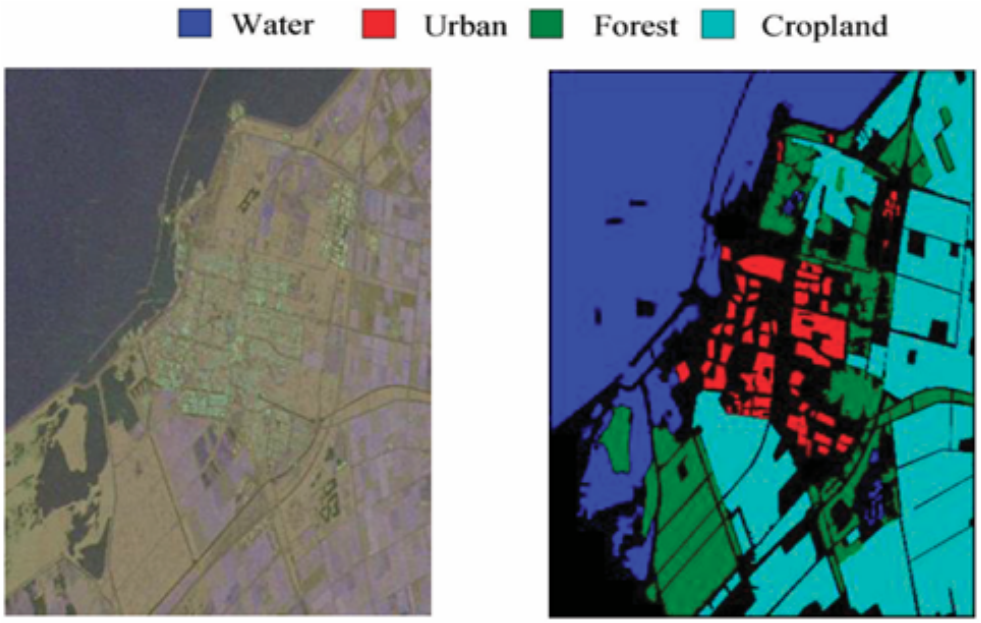

Şekil 2.4 Flevo_C veri kümesi için Pauli RGB gösterimi (solda) ve sınıf etiketleriyle birlikte karşılık gelen GT kümesi (sağda) gösterilmiştir

Ahıshalı ve ark. ile tutarlı olarak sınıf başına 500 eğitim ve 50 000 test örneği seçilerek 1:100 oranı izlenmiştir [58]. Sınıf bazında eğitim ve test piksel sayıları Tablo 2.6'da verilmiştir.

Tablo 2.6 Flevo_C veri kümesi için sınıf bazında eğitim ve test piksel sayıları

No	Sınıf Adı	Eğitim	Test	Toplam
1	Water	500	50 000	50 500
2	Urban	500	50 000	50 500
3	Forest	500	50 000	50 500
4	Cropland	500	50 000	50 500
	Toplam	**2 000**	**200 000**	**202 000**

3
YÖNTEM

SAR görüntülerinde sınıflandırma başarımını sınırlayan temel sorunlardan biri, gözlenen geri saçılım değerlerinin piksel düzeyinde yüksek değişkenlik göstermesi ve bu durumun sınıf içi varyansı artırarak sınıf sınırlarını mekansal olarak belirsizleştirmesidir. Beneklenme gürültüsü, aynı sınıfa ait geri saçılım değerlerinin daha geniş bir aralıkta dağılmasına ve dolayısıyla sınıf içi varyansın büyümesine yol açarak sınıflar arasındaki ayrılabilirliği zorlaştırabilmektedir. Heterojen alanlarda bu dalgalanmalar, gerçek yüzey ve yapı farklılıkları ile yerel doku bileşenleriyle birlikte gözlenebilir. Ayrıca, sahne geometrisine bağlı etkiler de devreye girerek bakış açısı ve geliş açısı ile ilişkili gölgeleme ve kısalma olguları üzerinden, sınıflandırıcının karar sınırlarını olumsuz yönde etkileyebilir.

Bununla birlikte, sınıflandırma güçlükleri yalnızca benek gürültüsüne dayalı değildir. Bir nesnenin yüzey özelliklerinin her noktada aynı olmaması; malzeme türü, pürüzlülük düzeyi, nem koşulları ve bitki örtüsü yoğunluğu gibi mikro-fiziksel farklılıklardan kaynaklanarak sınıflar arası örtüşmeyi artırabilir. Buna ek olarak, sensör ve işlem hattından kaynaklanan kanal dengesi sorunları, kalibrasyon sapmaları, termal gürültünün yanı sıra, aynı sahneye ait çoklu görüntü veya kanalların uzamsal olarak tam hizalanamamasından doğan ko-kayıt hataları da sınıflar arası ayrımı zayıflatabilmektedir. Yer gerçeği etiketlerindeki belirsizlik de bu durumu derinleştirerek sınıfların daha fazla karışmasına yol açabilmektedir [4]. Bu nedenle, ön işleme adımlarının amacı yalnızca gürültü bastırmak değildir. Aynı zamanda sınıf ayrımını taşıyan kenar, çizgi, sınır bölgesi ve karakteristik doku gibi mekansal yapıları mümkün olduğunca koruyarak daha kararlı bir temsil elde etmeyi hedefler.Bu bağlamda kenar koruyucu filtreleme, rastlantısal dalgalanmaları azaltırken sınıflandırma için kritik olan mekansal düzeni korumayı hedefleyen bir ön işleme yaklaşımıdır. Amaç, gürültü bastırma ile ayrım gücü taşıyan yapısal ipuçlarının korunumu arasında dengeli bir temsil oluşturarak sınıf sınırlarının bulanıklaşmasını azaltmak ve daha tutarlı özellikler üretmektir.

Bu tezde geliştirilen yöntemin kuramsal gerekçesi, Kang ve çalışma arkadaşlarının

hiperspektral görüntüler için önerdiği PCA tabanlı kenar koruyucu öznitelik çıkarımı (PCA-EPFs) yaklaşımında ortaya koyduğu temel bulgu ve çıkarımlardan hareketle oluşturulmuştur [75]. İlgili çalışmada, tek bir parametre ayarıyla elde edilen EPF'lerin farklı ölçeklerdeki karmaşık mekansal yapıları her zaman yeterince temsil edemeyebildiği ve filtreleme derecesinin sınıflandırma performansını belirgin biçimde etkilediği vurgulanmaktadır. Bu sınırlılıklarla başa çıkmak için EPF'ler farklı parametre ayarlarıyla ardışık olarak üretilir ve elde edilen çıktılar bir araya getirilerek öznitelik yığını oluşturulur. Bu yığılmış öznitelikler PCA ile daha kompakt ve ayrıştırıcı bir alt uzayda temsil edilir ve son aşamada bir sınıflandırıcı kullanılarak etiketleme gerçekleştirilir [75]. Bu yaklaşımın özünde yer alan fikir, çok ölçekli ve tamamlayıcı mekansal ipuçlarının tek bir özellik kümesinde birleştirilmesi ve boyut indirgeme ile gereksiz ve tekrarlı bileşenlerin azaltılmasıdır.

Bu tezde söz konusu çok parametreli EPF + PCA tabanlı yöntemi ile öznitelik sadeleştirme ilkesi, SAR görüntü sınıflandırma problemine uyarlanmış ve deneysel kurulum dört kanallı bir girdi temsili üzerinden kurgulanmıştır. Dört kanallı yapının amacı, hedef sınıflar arasında ayrıştırıcılığı artırabilecek tamamlayıcı geri saçılım ve polarimetrik bilgiyi birlikte kullanarak gürültü ve örnekleme etkilerinin yol açtığı kararsızlığı daha kararlı bir temsil düzeyine taşımaktır. Mekansal bağlamı etkin biçimde modele taşıyabilmek amacıyla her bir örnek $W \times W$ boyutunda yama (patch) yapısı ile oluşturulmuştur. Böylece EPF sonrası daha homojen sınıf içi dokuların ve sınıf sınırlarına ait yerel örüntülerin geleneksel sınıflandırıcılar tarafından daha tutarlı biçimde öğrenilmesi hedeflenmiştir. Bu tasarım, ön işleme ve öznitelik düzenleme adımlarının doğrudan sınıflandırma doğruluğuna ve kararlılığına yansımasını nicel olarak incelemeye imkan veren karşılaştırmalı bir deney düzeni içinde sağlamaktadır. Bu çerçevede önerilen yöntemin işlem adımları; çoklu-parametreli EPF, PCA tabanlı indirgeme ve sınıflandırıcı ile sınıflandırma aşamalarının sıralı yapısı üzerinden Şekil 3.1'de gösterilmiştir.

Önerilen yöntemin bileşenleri ile bu bileşenlerin parametreleştirilmiş işlem adımları, izleyen bölümde adım adım açıklanmaktadır.

3.1 Algoritma Detayları

Bu tezde önerilen yöntem, dört kanallı SAR temsili üzerinde çoklu-parametreli kenar koruyucu filtreleme, PCA tabanlı kompakt özellik çıkarımı ve SVM sınıflandırmasından oluşan hafif ve sistematik bir çerçeve sunmaktadır. Temel amaç, koherent görüntüleme yapısından kaynaklanan benek gürültüsü etkisini bastırırken sınıf sınırlarını ve ince yapısal detayları korumaktır. Buna ek olarak,

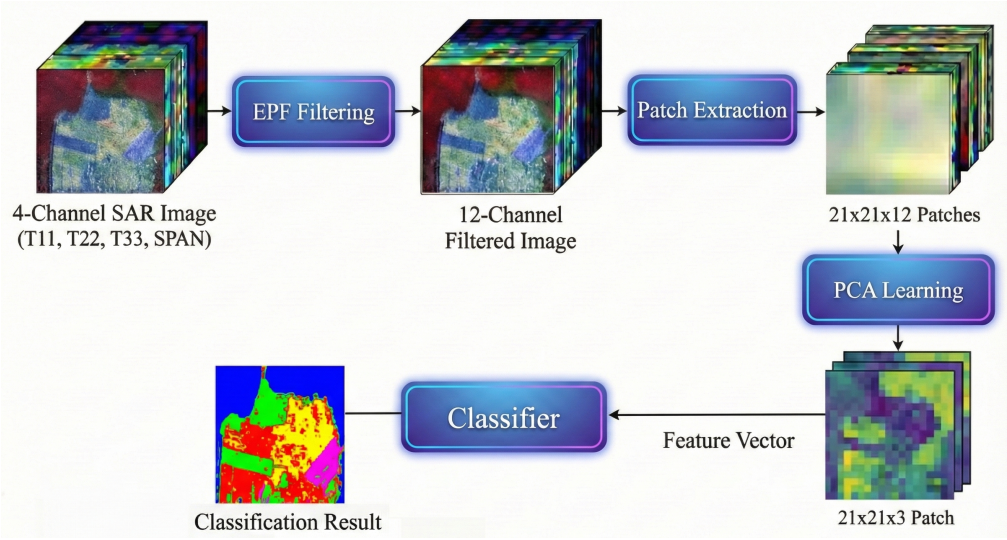

Şekil 3.1 Önerilen yöntemin akışı

sınırlı eğitim verisi koşullarında yüksek ayrım gücüne sahip daha düşük boyutlu bir özellik uzayı elde edilmesi hedeflenmektedir.

Bu bölümde önerilen yöntem, SAR görüntü sınıflandırma problemine yönelik olarak kurgulanmış, ardışık adımlardan oluşan ve bütüncül biçimde entegre edilmiş bir işlem zinciri sunmaktadır. Yöntem, girdi verisinin fiziksel saçılım karakteristiklerini doğrudan yansıtan çok kanallı SAR temsili üzerinden çalışmaktadır. Bu kapsamda sırasıyla kenar koruyucu filtreleme ile mekansal kararlılık artırılmakta, boyut indirgeme ile daha kompakt ve ayrıştırıcı bir özellik uzayı elde edilmektedir. Son aşamada ise geleneksel bir sınıflandırıcı ile nihai karar üretilmektedir.

Önerilen çerçevenin temel motivasyonu yalnızca benek gürültüsü gürültüsünün bastırılması değildir. Bunun yanı sıra, farklı arazi örtüsü sınıflarını ayırt eden kenar, sınır ve karakteristik mekansal yapıların mümkün olduğunca korunması ve sınıf içi varyansın azaltılması hedeflenmektedir. Bu doğrultuda, tek bir filtre parametresine bağlı kalmak yerine, farklı yumuşatma seviyelerini temsil eden çoklu-parametreli bir kenar koruyucu filtreleme stratejisi benimsenmiştir. Böylece, benek gürültüsü bastırma ve kenar korunumu arasındaki denge, tekil bir ayara bağımlı olmaktan çıkarılarak daha esnek ve kararlı bir yapıya kavuşturulmaktadır.

Girdi görüntüsü, çok kanallı bir SAR gösterimi olarak ele alınır ve

$$I = \{I^{(c)}\}_{c=1}^{C} \tag{3.1}$$

şeklinde tanımlanır. Bu tezde $C = 4$ olup kanallar T_{11}, T_{22}, T_{33} ve $SPAN$ bileşenlerinden oluşmaktadır. Bu çok kanallı temsilin nasıl görselleştirilebileceğine

örnek olarak, Şekil 3.2'de Flevoland SAR sahnesinden üç farklı kanal görünümünü gösterilmektedir; sırasıyla T_{11} kanalı ile T_{12} saçılım teriminin reel (Re$\{T_{12}\}$) ve imajiner (Im$\{T_{12}\}$) bileşenleri verilmiştir.

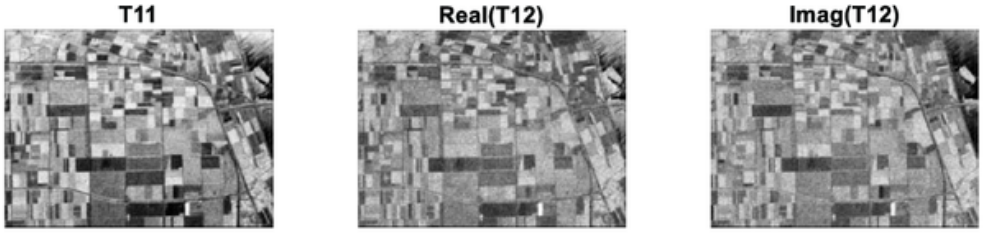

Şekil 3.2 Flevoland SAR sahnesinden örnek kanal görünümleri: T_{11}, Re$\{T_{12}\}$ ve Im$\{T_{12}\}$

Seçilen kenar koruyucu filtre türü f ve bir parametre kümesi ailesi $\Theta = \{\theta_j\}_{j=1}^{M}$ verildiğinde, aynı görüntü farklı yumuşatma düzeylerini yakalamak üzere çoklu-parametreli biçimde filtrelenir:

$$I^{(j)} \leftarrow EPF_f(I, \theta_j), \quad \theta_j \in \Theta. \tag{3.2}$$

Her bir θ_j için elde edilen çıktıların kanal bazında birleştirilmesiyle çoklu ölçekli/çoklu düzeyli bir temsil oluşturulur:

$$\tilde{I} \leftarrow \left[I^{(1)}, I^{(2)}, \ldots, I^{(M)} \right], \tag{3.3}$$

burada $\tilde{I}$ toplamda $C \times M$ kanallı bir yığıt (stack) temsilidir. Bu yaklaşım, benek gürültüsü bastırma ile kenar korunumu dengesinin farklı seviyelerini aynı anda taşımaktadır. Böylece daha zengin ve daha kararlı bir öznitelik temsiline ulaşmayı amaçlar. Bu durum, farklı yumuşatma düzeylerine ait örnek bir sahne üzerinde Şekil 3.3'te görsel olarak gösterilmektedir.

Bu çoklu-parametreli filtreleme yaklaşımı sayesinde, aynı sahneye ait farklı mekansal düzgünlük seviyeleri eş zamanlı olarak temsil edilmektedir. Düşük yumuşatma seviyeleri ince kenar ve detay bilgilerini korurken, yüksek yumuşatma seviyeleri homojen bölgelerde benek gürültüsü kaynaklı rastlantısal dalgalanmaları hedefler. Bu bağlamda daha etkin biçimde bastırmaktadır. Elde edilen bu tamamlayıcı temsillerin kanal bazında birleştirilmesi, tek bir filtre çıktısına kıyasla daha zengin ve daha kararlı bir özellik yığını oluşturulmasına olanak sağlamaktadır.

Yer gerçeği (GT) ile işaretli konumlar merkez alınarak, $\tilde{I}$ üzerinden

$$\mathcal{P} = \{P_i\}_{i=1}^{n}, \qquad P_i \in \mathbb{R}^{W \times W \times (CM)} \tag{3.4}$$

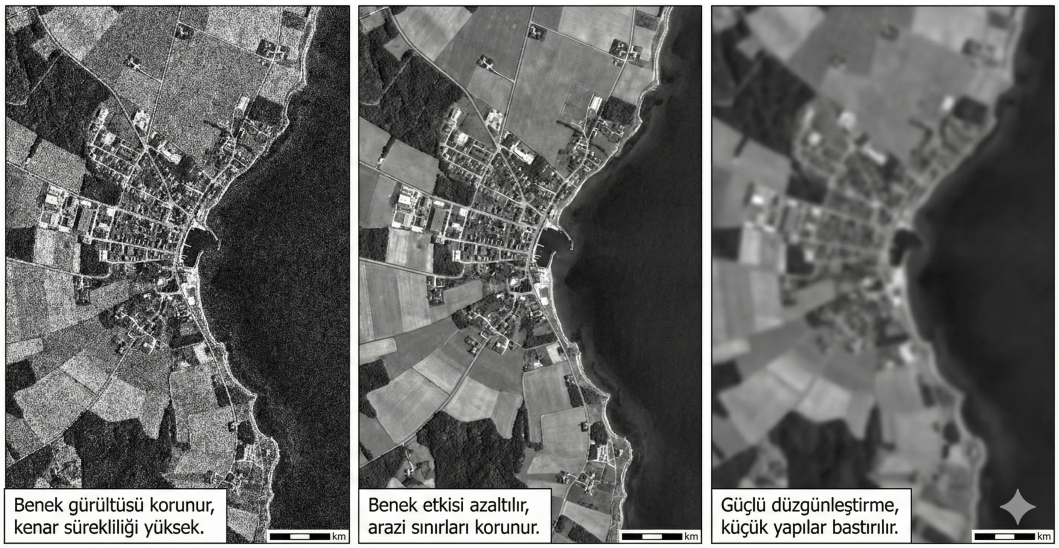

Şekil 3.3 BF ile üç farklı yumuşatma düzeyi: düşük yumuşatma (solda), orta yumuşatma (ortada), yüksek yumuşatma (sağda).

biçiminde yamalar (patch) çıkarılır. Burada W yama boyutunu, n ise kullanılan etiketli örnek sayısını ifade etmektedir. Her bir yama içindeki piksel örnekleri vektörleştirilerek, PCA öğrenimi için bir eğitim matrisi oluşturulur:

$$X_N \in \mathbb{R}^{m_N \times (CM)}, \tag{3.5}$$

burada m_N, eğitim yamalarından toplanan toplam piksel örneği sayısıdır.

Yama tabanlı temsil, her bir pikselin yalnızca kendi geri saçılım özelliklerini değil, aynı zamanda çevresindeki yerel mekansal bağlamı da içerecek şekilde modellenmesini sağlar. Bu yaklaşım, özellikle sınıf sınırları ve heterojen bölgelerde sınıflandırma kararlarının daha kararlı hale gelmesine katkıda bulunmaktadır. Ancak çoklu-parametreli filtreleme sonucunda elde edilen yüksek boyutlu kanal yığını, doğrudan kullanıldığında hesaplama maliyetini artırmakta ve aşırı boyutluluk problemini gündeme getirmektedir. Bu nedenle, PCA yalnızca eğitim verisi üzerinden öğrenilerek, farklı filtreleme seviyelerinden gelen bilginin ortak ve daha düşük boyutlu bir özellik uzayında yoğunlaştırılması sağlanmaktadır. PCA dönüşümü, gürültüye daha az duyarlı ve sınıflar arası ayrımı daha iyi temsil eden baskın bileşenleri ön plana çıkarmaktadır.

PCA, yalnızca eğitim verisi üzerinden öğrenilerek kanal uzayı daha kompakt bir bileşen uzayına indirgenir:

$$\mathbf{W} \leftarrow PCA(X_N, k), \qquad \mathbf{W} \in \mathbb{R}^{(CM)\times k}, \tag{3.6}$$

ve aynı dönüşüm tüm yamalara uygulanır:

$$P_i^{(k)} \leftarrow \Phi(P_i; \mathbf{W}), \qquad P_i^{(k)} \in \mathbb{R}^{W \times W \times k}. \tag{3.7}$$

Sonrasında her bir indirgenmiş yama düzleştirilerek nihai öznitelik vektörü elde edilir:

$$z_i \leftarrow \mathrm{vec}\Big(P_i^{(k)}\Big) \in \mathbb{R}^{kW^2}. \tag{3.8}$$

Son aşamada, elde edilen $\{z_i\}$ öznitelikleri ile SVM (RBF) sınıflandırıcısı eğitilir ve test örnekleri için sınıf tahminleri üretilir:

$$\hat{y}_i \leftarrow \mathrm{SVM}_{\mathrm{RBF}}(z_i; C, \gamma). \tag{3.9}$$

Son aşamada kullanılan RBF çekirdekli SVM sınıflandırıcısı, elde edilen kompakt öznitelik uzayı üzerinde sınıflar arasındaki doğrusal olmayan ayrımları etkin biçimde modelleyebilmektedir. SVM'nin sınırlı sayıda etiketli örnekle dahi kararlı performans sunabilmesi, önerilen yöntemin özellikle az eğitim verisi senaryolarında uygulanabilirliğini artırmaktadır. Özetle, önerilen çoklu-parametreli EPF + PCA + SVM tabanlı sınıflandırma çerçevesi; benek gürültüsü bastırma, kenar korunumu ve boyut indirgeme adımlarını bütünleşik bir yapı içinde ele almaktadır. Bu sayede, farklı SAR veri kümelerinde tutarlı ve yüksek genel doğruluk değerleri elde etmeyi amaçlayan hafif ve sistematik bir sınıflandırma yaklaşımı sunmaktadır.

Önerilen çoklu-parametreli EPF + PCA + SVM çerçevesinin adımları, Algoritma I'de özetlenmiştir.

Algoritma I. Önerilen Çoklu-Parametre EPF + PCA + SVM Çerçevesi

---

Girdi: Çok kanallı görüntü $I = \{I^{(c)}\}_{c=1}^{C}$, yer gerçeği GT, eğitim oranı r, filtre türü f, parametre kümesi $\Theta = \{\theta_j\}_{j=1}^{M}$, yama boyutu W, PCA hedef boyutu k, SVM (RBF) hiperparametreleri (C, γ).

Çıktı: Sınıf tahminleri $\hat{y}$ ve genel doğruluk OA.

İş akışı:

- Veri bölme: GT üzerinden sınıf dengeli biçimde eğitim kümesi $\mathcal{T}$ ve test kümesi $\mathcal{S}$ seçilir.
- Çoklu-parametre EPF:

$$I^{(j)} \leftarrow EPF_f(I, \theta_j), \quad \theta_j \in \Theta, \qquad \tilde{I} \leftarrow [I^{(1)}, I^{(2)}, \ldots, I^{(M)}].$$

- Yama çıkarımı:

$$P_i \in \mathbb{R}^{W \times W \times (CM)} \text{ olacak şekilde } \tilde{I} \text{ üzerinden } \mathcal{P}_N \text{ ve } \mathcal{P}_{\mathrm{te}} \text{ üretilir.}$$

- PCA öğrenimi (yalnızca eğitim verisi):

$$X_N \in \mathbb{R}^{N \times (CM)} \text{ oluşturulur,} \qquad \mathbf{W} \leftarrow PCA(X_N, k).$$

- PCA uygulama ve öznitelik çıkarımı:

$$P_i^{(k)} \leftarrow \Phi(P_i; \mathbf{W}), \qquad z_i \leftarrow \mathrm{vec}\Big(P_i^{(k)}\Big) \in \mathbb{R}^{kW^2}.$$

- SVM (RBF) eğitimi ve çıkarım:

$$\hat{y}_i \leftarrow \mathrm{SVM}_{\mathrm{RBF}}(z_i; C, \gamma), \qquad OA \leftarrow \mathrm{Accuracy}(\hat{y}, y).$$

3.2 Girdi Kanalları

Bu tezde kullanılan dört kanallı girdi temsili, tam polarimetrik SAR (PolSAR) verisinden türetilen ve fiziksel olarak yorumlanabilir ikinci mertebe özniteliklerden türetilmiştir. Bu seçim, sınıflandırma için gerekli bilgiyi kompakt biçimde taşıyan ve uygulama amacına yönelik olarak kurgulanmış bir girdi temsili sağlamaktadır. Özellikle tez kapsamında yürütülen deneylerde kullanılan dört kanallı girdi yapısı, doğrudan Ahishali ve ark. tarafından önerilen ve kanal sayısı ve kanal kombinasyonları açısından sistematik biçimde incelenen deneysel kurulumdan alınmıştır. İlgili çalışmada, koherens matrisinin diyagonal elemanları olan T_{11}, T_{22} ve T_{33} bileşenlerine toplam saçılma gücünü temsil eden *SPAN* kanalının dördüncü kanal olarak eklenmesiyle oluşturulan 4-kanallı yapı açık biçimde tanımlanmış ve üçten altıya uzanan farklı kanal sayılarıyla karşılaştırmalı olarak test edilmiştir [58].

PolSAR sistemlerinde bir hedefin geri saçılım davranışı, yatay (H) ve dikey (V) doğrusal polarizasyonlarda gönderim ve alım yapıldığı kabul edildiğinde, saçılma davranışı karmaşık değerli 2×2 boyutlu bir saçılma matrisi ile modellenir. Alıcı ve verici elektrik alanları sırasıyla $\mathbf{E}_r$ ve $\mathbf{E}_t$ olmak üzere, hedefe ait saçılma davranışı

$$\mathbf{E}_r = \mathbf{S}\mathbf{E}_t, \quad \mathbf{S} = \begin{bmatrix} S_{hh} & S_{hv} \\ S_{vh} & S_{vv} \end{bmatrix} \tag{3.10}$$

şeklinde yazılabilir. Monostatik SAR sistemlerinde karşılıklılık (reciprocity) varsayımı geçerli kabul edildiğinde $S_{hv} = S_{vh}$ eşitliği sağlanır. Böylece bir hedefin saçılma davranışı, üç genlik bileşeni ($|S_{hh}|, |S_{vv}|, |S_{hv}|$) ve iki bağıl faz olmak üzere toplam beş temel parametre üzerinden pratik olarak tanımlanabilir [76]. Bununla birlikte benek gürültüsü gürültüsünün rastlantısal doğası nedeniyle SAR verileri, çoğunlukla çok-bakışlı olarak elde edilir. Böylece hedefe ilişkin fiziksel bilgi, ikinci mertebe istatistikler kullanılarak daha sağlam bir temsil oluşturabilir. Bu amaçla, Pauli tabanlı saçılma vektörü kullanılarak çok-bakışlı koherens matrisi $\mathbf{T}$ oluşturulur. Saçılma vektörü, kanal bileşenlerinin standart bir sırayla ardışık olarak yazıldığı leksikografik gösterimle tanımlanır. Bu gösterimden hareketle çok-bakışlı kovaryans matrisi $\mathbf{C}$ elde edilir. Pauli tabanlı saçılma vektörü

$$\mathbf{k} = \frac{1}{\sqrt{2}} \begin{bmatrix} S_{hh} + S_{vv} \\ S_{hh} - S_{vv} \\ 2S_{hv} \end{bmatrix} \tag{3.11}$$

olarak yazıldığında, n bakış için çok-bakışlı koherens matrisi

$$\mathbf{T} = \frac{1}{n}\sum_{i=1}^{n} \mathbf{k}_i \mathbf{k}_i^{*T} \tag{3.12}$$

şeklinde elde edilir [76]. Benzer şekilde leksikografik saçılma vektörü ile tanımlanan $\mathbf{C}$ matrisi de hedefin polarimetrik içeriğini taşıyan 3×3 Hermit yapıda ve pozitif tanımlı bir gösterim sunar. Literatürde $\mathbf{T}$ ile $\mathbf{C}$ matrislerinin polarimetrik tanımlayıcılık açısından eşdeğer kabul edildiği ve aralarında doğrusal dönüşümün mümkün olduğu ifade edilir [76].

SAR görüntü işlemede yaygın kullanılan bir diğer hedef betimleyicisi, toplam saçılma gücünü temsil eden SPAN büyüklüğüdür. Saçılma matrisinin Frobenius normuna dayanan SPAN,

$$\mathrm{Span}(\mathbf{S}) = \mathrm{Tr}(\mathbf{S}\mathbf{S}^{*T}) = |S_{hh}|^2 + |S_{hv}|^2 + |S_{vh}|^2 + |S_{vv}|^2 \tag{3.13}$$

olarak ifade edilir [76]. Bu tezde kullanılan dört kanallı girdi, $\mathbf{T}$ matrisinin diyagonal bileşenleri (T_{11}, T_{22}, T_{33}) ile SPAN kanalının bir araya getirilmesiyle oluşturulmuştur. Böylece hedefin geri saçılım gücü, farklı polarimetrik bileşenler üzerinden ayrık olarak taşınan üç tamamlayıcı enerji bileşeniyle temsil edilir. SPAN üzerinden bu enerjinin bütünleşik toplam etkisi aynı giriş düzleminde ek bir fiziksel özet olarak sunulmuştur. Bu tasarım, sınıflar arası ayrıştırıcılığı artırmayı hedefleyen kompakt bir temsil yaklaşımıdır. Dolayısıyla dört kanallı yapı, yüksek boyutlu el yapımı öznitelik vektörlerine başvurmadan temel polarimetrik enerji dağılımını ve toplam saçılma şiddetini birlikte taşıyan, temsil gücü ile hesaplama maliyeti arasındaki dengeyi gözeten makul bir ara seçenek olarak görülmektedir.

SAR sınıflandırmada hedeflerin daha iyi ayrıştırılabilmesi için izlenen bir diğer yaklaşım, hedef saçılma davranışını farklı ayrıştırma çerçeveleri altında analiz ederek yorumlamaktır. Koherent hedef ayrışımları, saçılma katsayılarını bağımsız bileşenlerin toplamı olarak modellemeyi amaçlamaktadır. Pauli, Krogager ve Cameron ayrışımları bu gruba örnek olarak gösterilebilir [77, 78]. İnkoherent ayrışımlar ise çok-bakışlı ikinci mertebe betimleyiciler ($\mathbf{C}$ ve $\mathbf{T}$) üzerinden dağıtık saçıcıları ele alır. Huynen ayrışımı ile Cloude–Pottier (H/α/A) ve Freeman–Durden ayrışımları bu yaklaşımın geleneksel örnekleri arasında yer almaktadır [79–81]. Bu tezde kullanılan dört kanallı giriş tasarımı, farklı ayrışım (decomposition) yaklaşımlarının dayandığı ortak fiziksel temel olan ikinci mertebe polarimetrik betimleyicilerle tutarlı bir yapıdadır. Bu sayede, farklı arazi örtüsü sınıflarına ait saçılma mekanizmalarının enerji dağılımı daha kararlı bir temsil üzerinden

yakalanabilmektedir.

Mekansal bağlam bilgisinin sınıflandırmaya etkin biçimde aktarılması amacıyla, dört kanallı veri üzerinden $W \times W$ boyutunda yama (patch) temsili kullanılmıştır. Bu ölçek, hem sınıf içi dokusal örüntüleri hem de sınıf sınırlarına ait yerel geçişleri aynı anda yakalayabilecek yeterli komşuluk bilgisini sağlamayı hedeflemektedir. Ayrıca SAR kanallarının geniş dinamik aralığı ve benek gürültüsü kaynaklı dağılım sapmaları göz önünde bulundurularak, her bir kanal için logaritmik/dB dönüşümü ve ardından kanal bazlı sağlam ölçekleme adımları uygulanmıştır [58]. Bu normalizasyon yaklaşımı, kanallar arasındaki ölçek farklılıklarını azaltarak yama tabanlı gösterimin daha tutarlı bir istatistik yapıya oturmasına yardımcı olur ve sınıflandırıcının karar sınırlarını daha istikrarlı biçimde öğrenmesini destekler.

3.3 Kenar Koruyucu Filtreler

Kenar koruyucu filtreler, görüntüdeki gürültü ve önemsiz küçük ölçekli bileşenleri bastırırken nesne sınırlarını, dokusal sürekliliği ve yapısal ayrıntıları mümkün olduğunca korumayı hedefleyen temel görüntü işleme yaklaşımlarıdır. Özellikle benek gürültüsünün belirgin olduğu SAR verilerinde, EPF tabanlı ön işleme homojen bölgelerdeki rastlantısal dalgalanmaları bastırarak sınıf içi tutarlılığı artırabilir ve sınıf sınırlarının gereğinden fazla yumuşamasını engelleyebilir.Bu tez kapsamında kenar korunumu ile gürültü bastırma arasındaki dengeyi farklı düzeylerde temsil edebilmek amacıyla BF, FGS ve DT yöntemleri tercih edilmiştir.

3.3.1 Bilateral Filter

Bilateral filtreleme, klasik Gauss yumuşatmadan farklı olarak yalnızca piksellerin uzamsal yakınlığını değil, aynı zamanda yoğunluk ve geri saçılım benzerliğini de dikkate alır. Bu nedenle, doğrusal olmayan bir kenar koruyucu yumuşatma yaklaşımı olarak tanımlanmaktadır [82]. Bu yöntemde bir pikselin filtrelenmiş değeri, komşu piksellerin katkılarının iki bileşenden oluşan bir ağırlıklandırma mekanizmasıyla belirlenmesiyle hesaplanır. Uzamsal ağırlık, merkeze yakın piksellere daha yüksek katkı vererek yerel komşuluğu vurgular. Aralık ağırlığı ise yoğunluk ve geri saçılım farkı büyüdükçe katkıyı hızla azaltır ve kenarın karşı tarafındaki örneklerin etkisini bastırır. Bu sayede, doğrusal yumuşatma filtrelerinde sık görülen "kenar üzerinden ortalama" alma eğilimi zayıflatılarak sınır bölgelerinin gereğinden fazla yumuşaması engellenir.

Bilateral filtrelemenin uzamsal ve aralık ağırlıklarını birlikte kullanarak kenarı koruma prensibi, Şekil 3.4 ile görsel olarak gösterilmektedir. Bu prensibi

açıklamak amacıyla örnek bir kenar yapısı üzerinden yapılan incelemede, Şekil 3.4(a)'da benek gürültüsü benzeri dalgalanmalar içeren keskin bir kenar yapısı görülmektedir. Ağırlıklandırma mekanizmasının davranışı Şekil 3.4(b)'de gösterilmektedir. Ayrıca uzamsal yakınlık ile yoğunluk farkının birlikte dikkate alındığı görülmektedir. Sonuç olarak Şekil 3.4(c)'de homojen bölgelerdeki dalgalanmaların azaltıldığı, buna karşılık geçiş bölgelerinde kenar yapısının büyük ölçüde korunarak filtrelenmiş bir çıktı üretildiği görülmektedir [82].

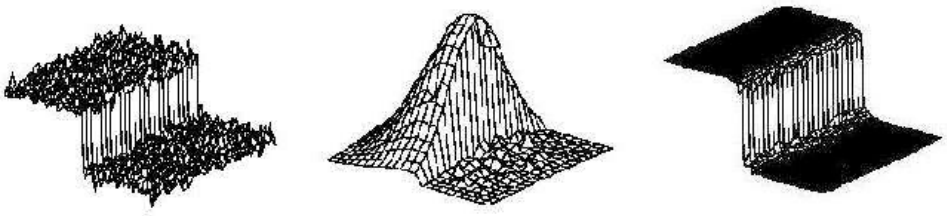

(a) noisy edge (b) bilateral filter (c) filtered output

Şekil 3.4 Bilateral filtreleme örneği

Bilateral filtre, normalize edilmiş ağırlıklar üzerinden aşağıdaki biçimde ifade edilebilir:

$$\hat{I}(p) = \frac{1}{W_p} \sum_{q \in \Omega(p)} \exp\Big(- \frac{\|p-q\|^2}{2\sigma_s^2} \Big) \exp\Big(- \frac{|I(p)-I(q)|^2}{2\sigma_r^2} \Big) I(q), \qquad (3.14)$$

burada $I(\cdot)$ giriş görüntüsünü, $\hat{I}(\cdot)$ filtrelenmiş çıktıyı, $\Omega(p)$ piksel p'nin komşuluk penceresini, σ_s uzamsal ölçeği ve σ_r aralık ölçeğini temsil etmektedir. Normalizasyon terimi W_p, ağırlıkların toplamını ifade ederek çıktının parlaklık ve ölçek düzeyi açısından tutarlı olmasını sağlar:

$$W_p = \sum_{q \in \Omega(p)} \exp\Big(- \frac{\|p-q\|^2}{2\sigma_s^2} \Big) \exp\Big(- \frac{|I(p)-I(q)|^2}{2\sigma_r^2} \Big). \qquad (3.15)$$

Denklem 3.14–3.15'den görüldüğü üzere, uzamsal terim komşuluk içinde yerel katkıyı düzenlerken, aralık terimi yoğunluk/geri saçılım farkı arttıkça ağırlıkları hızla düşürerek kenarların karşı tarafındaki örneklerin ortalamaya dahil edilmesini sınırlar. Bu yapı, gürültü bastırma ile kenar korunumu arasında bir denge kurulmasını sağlar. Bununla birlikte, BF'nin başarımı uzamsal ölçek (ör. σ_s veya pencere boyutu) ile aralık ölçeği (ör. σ_r) parametrelerinin seçimine duyarlıdır. Çok küçük σ_r değerlerinde filtreleme zayıflar ve gürültü benzeri dalgalanmalar yeterince azaltılamayabilir. Çok büyük σ_r değerlerinde ise kenar ayrımı zayıflar ve farklı bölgeler arasında aşırı karışma oluşabilir. Benzer biçimde, uzamsal ölçeğin

büyütülmesi daha güçlü yumuşatma sağlasa da ince yapısal ayrıntıların kaybolma olasılığını artırabilir. Dolayısıyla bilateral filtreleme, gürültü azaltma ile kenar korunumu arasında bir denge sunar. Ancak bu dengenin, veri karakteristiğine uygun parametre seçimiyle sağlanması kritik öneme sahiptir.

3.3.2 Fast Global Smoother

Fast Global Smoother (FGS), kenar duyarlı yumuşatmayı küresel bir optimizasyon problemi çerçevesinde tanımlar. Ardından bu problemi, hesaplama maliyetini düşürecek biçimde etkin bir şekilde çözmeyi amaçlar [26]. FGS'nin temel motivasyonu, ağırlıklı en küçük kareler (Weighted Least Squares, WLS) tabanlı küresel düzgünlük yaklaşımının sunduğu kararlı yumuşatma ve kenar duyarlılığı avantajını sürdürmektir. Buna karşılık, geleneksel WLS tabanlı yöntemlerde ortaya çıkan büyük ölçekli doğrusal sistem çözüm maliyetini pratikte belirgin biçimde düşürmeyi hedefler.

FGS'de yumuşatma, giriş görüntüsü f ile hedef çıktı u arasındaki uyumu ölçen bir veri terimi üzerine kuruludur. Buna ek olarak, komşu pikseller arasındaki değişimleri kenarları gözeterek sınırlayan bir düzgünlük terimiyle birlikte, toplam enerji ifadesinin minimize edilmesi esas alınır.

$$E(\mathbf{u}) = \sum_{i}(u_i - f_i)^2 + \lambda \sum_{(i,j)\in\mathcal{N}} w_{ij}\,(u_i - u_j)^2, \tag{3.16}$$

Burada $\mathcal{N}$ komşuluk ilişkilerini, λ düzgünlük ağırlığını ve w_{ij} ise kenar duyarlı ağırlıkları ifade eder. Ağırlıkların giriş görüntüsündeki gradyan büyüklüğüne göre belirlenmesi, güçlü geçişlerin görüldüğü bölgelerde (olası sınırlar) düzgünlük cezasını azaltır. Böylece yumuşatmanın sınır üzerinden taşması sınırlandırılırken, homojen bölgelerde daha tutarlı bir düzgünleşme elde edilmesi hedeflenir [26].

FGS'yi geleneksel WLS yaklaşımlarından ayıran temel unsur, (3.16) denklemi ile tanımlanan küresel problemin doğrudan çözülmemesidir. Bunun yerine problem, satır ve sütun doğrultularında ayrıştırılmış ardışık tek boyutlu (1B) taramalar şeklinde ele alınarak verimli biçimde çözülür. Bu ayrıştırma sayesinde çözüm, ileri ve geri yönde uygulanan özyinelemeli güncellemelerle elde edilir. Böylece küresel yumuşatma karakteri korunurken hesaplama maliyeti belirgin ölçüde azaltılır [26].

FGS'nin görsel etkisi, giriş/çıktı karşılaştırması üzerinden Şekil 3.5'te gösterilmektedir. [83]. Bu şekilde (a) alt görselinde giriş görüntüsü ve seçili bölgelerin yakınlaştırmaları sunulurken, (b) alt görselinde FGS sonrasında özellikle geniş ve nispeten homojen alanlarda (örneğin gökyüzü ve düz yüzeyler)

yüksek frekanslı dalgalanmaların belirgin biçimde azaltıldığı görülmektedir. Yakınlaştırılmış bölgeler, bu düzgünleşmenin ayrıntı içeren alanlarda kısmi bir yumuşamaya yol açabildiğini göstermektedir. Buna karşın, belirgin yapı sınırları ve şekil hatları tamamen silinmeden görece korunabilmektedir. Söz konusu denge, FGS'nin yumuşatma kararlarını yerel bir çekirdek ortalaması yerine küresel bir enerji minimizasyonu üzerinden vermesinin doğal bir sonucudur [26]. Bu yönüyle FGS, kenar-duyarlı küresel yumuşatmayı makul bir hesaplama maliyetiyle sunabilen bir filtreleme seçeneği olarak literatürde yaygın biçimde tercih edilmektedir [26].



(a) (b)

Şekil 3.5 FGS uygulamasının görsel etkisi: (a) giriş görüntüsü ve (b) FGS çıktısı (yakınlaştırılmış bölgelerle birlikte)

3.3.3 Domain Transform

Domain Transform (DT), kenar duyarlı yumuşatma işlemini iki boyutlu (2B) uzayda yoğun komşuluk hesaplarına başvurmak yerine, sinyali dönüştürülmüş bir domain üzerinde yeniden parametreleyerek işlemi daha verimli biçimde gerçekleştirmeyi hedefleyen bir yaklaşımdır [84]. Bu yaklaşımın çıkış noktası, görüntüde yoğunluk/geri saçılımın hızlı değiştiği bölgelerin kenarlar ve geçişler olarak öne çıkmasıdır. Bu bölgeler, dönüştürülmüş domain içinde komşu örnekler arasındaki etkin mesafeyi artırır. Böylece yumuşatma bu alanlarda doğal olarak zayıflar. Buna karşılık homojen alanlarda etkin mesafe küçük kaldığından, yumuşatma daha güçlü uygulanabilir.

Domain Transform yaklaşımının kenar duyarlı yumuşatma etkisi, iki farklı sahne üzerinden yapılan karşılaştırma ile Şekil 3.6'da gösterilmektedir. Şeklin sol sütununda, üst ve alt satırda iki ayrı giriş görüntüsü yer almaktadır. Orta

sütunda aynı görüntüler üzerinde kenar duyarsız bir filtreleme uygulandığında ortaya çıkan sonuçlar gösterilmiştir. Bu durumda homojen bölgelerde bir miktar düzgünleştirme sağlansa da, nesne sınırları ve keskin geçişler boyunca "ortalama alma" etkisi artmaktadır. Oklarla işaretlenen bölgelerde görüldüğü gibi sınırlar karşı tarafa taşarak bulanıklaşabilmektedir. Sağ sütunda ise kenar duyarlı bir filtreleme yaklaşımının çıktıları verilmiştir. Kenar bölgelerinde yumuşatma etkisinin doğal biçimde sınırlandırılması sayesinde, homojen alanlarda düzgünleştirme korunurken keskin geçişler boyunca sınır bütünlüğünün daha iyi muhafaza edildiği görülmektedir. Bu karşılaştırma, DT yönteminin nasıl işlediğini göstermektedir. Yoğunluk değişiminin belirgin olduğu bölgelerde etkin mesafe artırılarak kenar boyunca bilgi taşınımı sınırlandırılarak homojen alanlarda ise daha istikrarlı bir yumuşatma sağlanır [84].

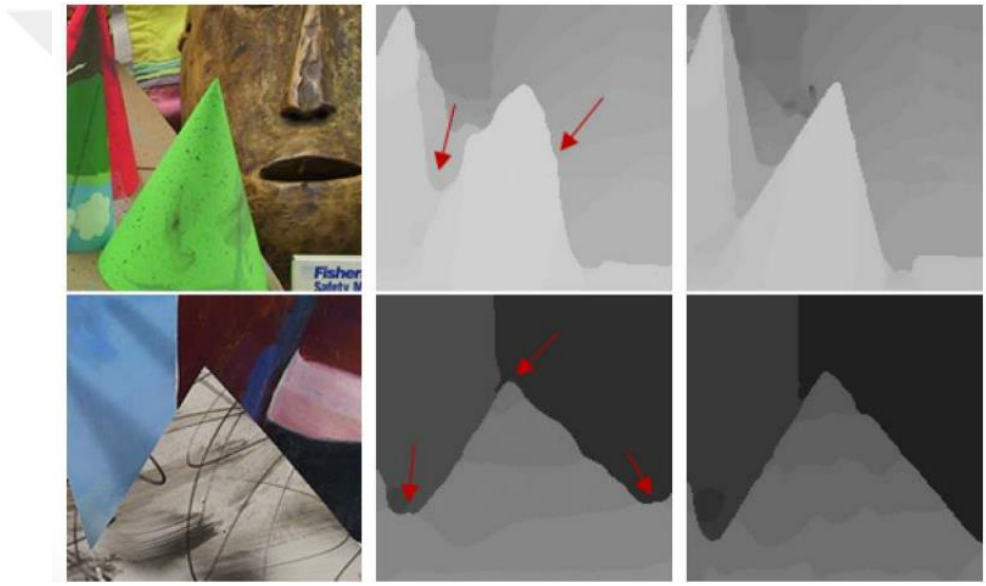

Şekil 3.6 DT ile kenar duyarlı yumuşatmanın kavramsal karşılaştırması

DT, filtre çekirdeğini sadece uzamsal yakınlıkla sınırlamak yerine, yoğunluk/gradyan bilgisini etkin mesafe tanımına dolaylı biçimde entegre eder. Böylece kenar korunumu ile yumuşatma arasındaki dengeyi daha kararlı şekilde sağlamayı hedefler. Bu yaklaşım, DT'nin yaygın olarak kullanılan tek boyutlu (1B) modellemede örnek konumu için tanımlanan birikimli bir dönüşüm fonksiyonu üzerinden açık biçimde ifade edilebilir. Kenar büyüklüğü arttıkça dönüşümün eğimi büyür ve örnekler arası mesafe açılır:

$$c_t(u) \;=\; \int_0^u \left(1 + \frac{\sigma_s}{\sigma_r}\left|\frac{dI(x)}{dx}\right|\right) dx, \tag{3.17}$$

Burada σ_s uzamsal ölçeği, σ_r ise aralık (range) ölçeğini kontrol eder. Bu dönüşümden sonra filtreleme, dönüştürülmüş domain üzerindeki komşu örnekler

arasında tanımlanan mesafeye bağlı olarak kademeli bir yumuşatma şeklinde uygulanabilir. Örneğin ardışık bir geçişte geri besleme katsayısı, dönüştürülmüş domain mesafesi $d_i = c_t(x_i) - c_t(x_{i-1})$ ile azalarak kenar hattı boyunca yayılımı kontrol altında tutar:

$$y_i \;=\; (1 - a_i)\, x_i + a_i\, y_{i-1}, \qquad a_i = \exp\!\left(-\frac{\sqrt{2}}{\sigma_H}\, d_i\right), \tag{3.18}$$

Hedef yumuşatma ölçeğini belirleyen parametre σ_H'dır. Bu yapı sayesinde, d_i kenar bölgelerinde büyüdükçe a_i küçülür ve yumuşatma zinciri kenar boyunca zayıflar. Homojen bölgelerde ise daha tutarlı bir düzgünleşme elde edilir [84]. Ayrıca DT, 2B filtrelemeyi satır ve sütun yönlerinde ardışık uygulanan 1B geçişler biçiminde ele alarak işlem yükünü azaltmayı hedefler. Bu yaklaşım sayesinde yöntem, pratikte hızlı ve kenar koruyucu bir filtreleme alternatifi olarak literatürde yaygın biçimde tercih edilmektedir [84].

3.4 Temel Bileşenler Analizi

Temel Bileşenler Analizi, istatistik ve makine öğrenmesi literatüründe en temel ve en sık kullanılan doğrusal boyut indirgeme yöntemleri arasında yer alır. Yöntemin ilk temelleri, Karl Pearson'ın çok boyutlu veriyi en iyi temsil eden düşük boyutlu alt uzayın geometrik olarak belirlenmesi fikrine dayanmaktadır. Bu fikir daha sonra Harold Hotelling tarafından "temel bileşenler" kavramı ile istatistiksel bir çerçeve içinde ele alınmaktadır [85, 86]. Modern yorumlarda PCA, özgün öznitelikleri korelasyonsuz hale getiren doğrusal birleşimler üzerinden yeni ve ortogonal bir koordinat sistemi tanımlayan bir dönüşüm olarak görülür. Bu yeni eksenler, verideki toplam varyansı ardışık biçimde en yüksek düzeyde açıklayacak şekilde sıralanır [87–89].

PCA'nın algoritmik şeması Şekil 3.7 üzerinde adım adım gösterilmektedir [90]. Şeklin ilk aşaması, özgün uzayda birbirleriyle ilişkili (korelasyonlu) yüksek boyutlu veri dağılımını temsil eder. İkinci adımda, her öznitelikten ortalama değerin çıkarılmasıyla veri merkezleme işlemi yapılır.Böylece temel bileşen yönleri, veri bulutunun baskın yayılım yönlerini daha isabetli biçimde temsil eder. Değişkenlerin ölçekleri ya da gürültü seviyeleri arasında belirgin farklar bulunduğunda, birim varyansa göre ölçekleme yapan standartlaştırmanın uygulanması tavsiye edilmektedir [87, 89].

Üçüncü adımda, merkezlenmiş (gerekirse standartlaştırılmış) veri kullanılarak kovaryans matrisi elde edilir. Dördüncü adımda, söz konusu matrisin özdeğer ve

özvektör ayrışımı gerçekleştirilir. Özvektörler yeni eksen yönlerini, özdeğerler ise her eksenin açıkladığı varyans miktarını gösterir. Jolliffe ve Cadima'nın vurguladığı üzere, özdeğerlerin büyükten küçüğe sıralanması bileşenlerin bilgiyi temsil etme kapasitesine dayanan doğal bir seçim ölçütü sağlar [88]. Beşinci adımda, en büyük özdeğerlere sahip $m < d$ adet özvektör seçilerek boyut indirgeme için gerekli alt uzayın temeli oluşturulur. Altıncı adımda veri, bu özvektörler üzerine izdüşürülür ve yüksek boyutlu temsildeki tekrarlı bilgi bileşenleri büyük ölçüde elimine edilir. Son adımda, yeni uzayda elde edilen düşük boyutlu temsilde bileşenler arasındaki bağımlılık büyük ölçüde ortadan kalkar ve veri daha derli toplu, kompakt bir yapıya kavuşur.

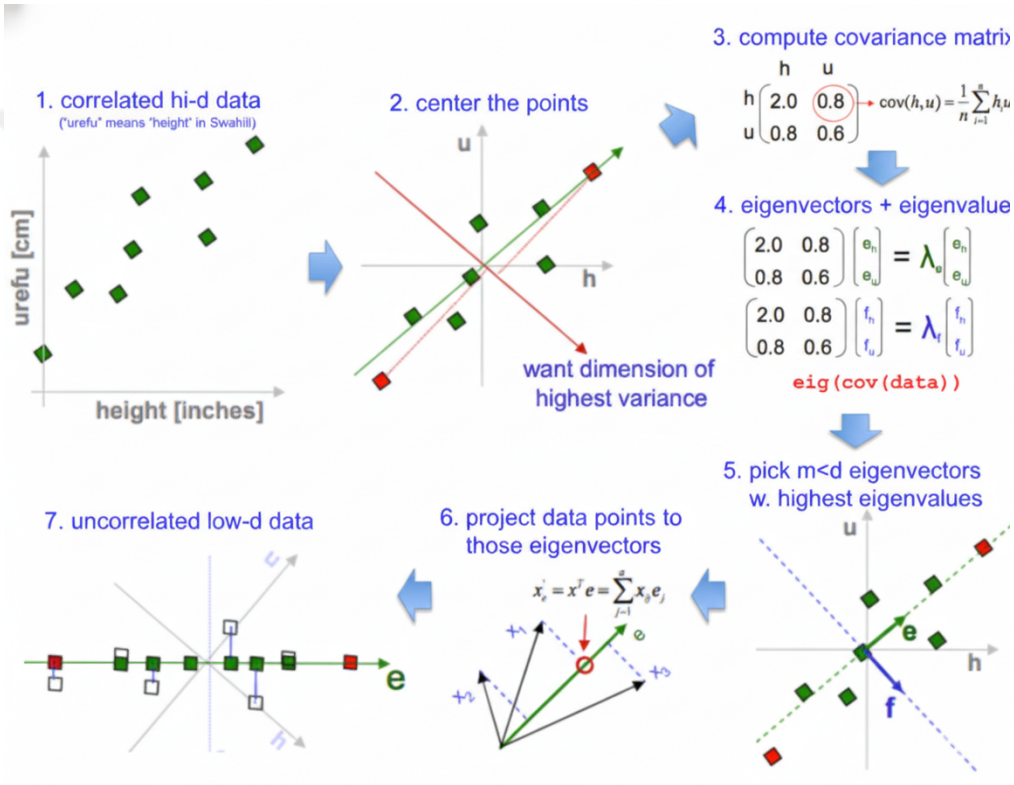

Şekil 3.7 Temel Bileşenler Analizi algoritmasının adım adım gösterimi

Uzaktan algılama çalışmalarında boyut indirgeme, boyut artışından kaynaklanan güçlükleri hafifletmek ve sonraki sınıflandırma aşamalarında kararlılık ile hesaplama verimliliğini artırmak açısından kritik bir ön işleme adımıdır. Güncel literatür derlemeleri, PCA'nın basit ve uygulaması kolay yapısı sayesinde korelasyonlu spektral ve öznitelik tabanlı bilgiyi daha az sayıda bileşende toplayarak hala güçlü bir temel yaklaşım olmayı sürdürdüğünü vurgulamaktadır [91]. Bu tez kapsamında PCA, kenar koruyucu filtreleme adımının ardından, sınıflandırma öncesinde öznitelik temsillerini daha kompakt hale getiren bir boyut indirgeme aşaması olarak kullanılmıştır. Bu seçim, aynı sınıfa ait örneklerde

gözlenen farklılıkları ve ölçüm ile geri saçılım koşullarına bağlı dalgalanmaları, daha yönetilebilir bir öznitelik uzayında temsil etmeyi hedeflemiştir. Ayrıca PCA, gereksiz boyutları budayarak hem sınıflar arası ayrımı destekleyen hem de sınırlı eğitim örneği koşullarında genelleme gücünü artırmayı amaçlayan bütünleşik bir stratejinin parçası olarak değerlendirilmiştir.

3.5 Sınıflandırıcılar

Bu tez kapsamında, kenar koruyucu filtreleme yoluyla ölçüm sürecinden kaynaklanan dalgalanmalar dengelenirken sınıf sınırlarının korunmasına odaklanılmıştır. Elde edilen çok kanallı temsillerin sınıflandırma başarısı, üç farklı klasik makine öğrenmesi yöntemi kullanılarak analiz edilmiştir. KNN, RF ve SVM yöntemlerinin birlikte ele alınması, EPF tabanlı ön işleme farklı karar mekanizmaları altında elde edilen kazanımların karşılaştırmalı olarak izlenmesine olanak tanımaktadır. Uzaktan algılama literatüründe, SVM ve RF'nin yaygın kullanılan ve güçlü sınıflandırıcılar arasında yer aldığı belirtilmektedir [92–94]. Ancak performanslarının veri türüne ve hiperparametre ayarlarına belirgin ölçüde bağlı olduğu da vurgulanmaktadır [92–94].

Son yıllarda yapılan karşılaştırmalı çalışmalar da, farklı uygulama senaryolarında RF ve SVM'nin çoğunlukla yüksek doğruluk üretebildiğini, KNN'nin ise daha basit bir yaklaşım olmakla birlikte, temsildeki gürültüye ve sınıflar arası örtüşmeye karşı daha hassas bir referans davranışı ortaya koyduğunu göstermektedir. [92–94].

SAR verilerinde sınıflandırmayı güçleştiren başlıca etken, sensör edinim koşulları ile geri saçılımın yerel heterojenliğinden türeyen rastlantısal dalgalanmaların sınıf içi yayılımı artırarak sınıflar arasındaki ayrımı belirsizleştirmesidir. Bu nedenle EPF ile elde edilen kenar duyarlı ve daha tutarlı geri saçılım temsillerinin, özellikle mesafe ve marjin temelli sınıflandırıcılarda karar sınırlarının daha istikrarlı hale gelmesine yardımcı olacağı öngörülmektedir [82, 84]. Nitekim güncel SAR odaklı değerlendirmeler, standart KNN ve SVM türü yaklaşımların SAR verisindeki rastlantısal dalgalanmaların kendine özgü dağılım yapısını doğrudan dikkate almadıkları durumlarda performans kaybı yaşayabildiğini belirtmektedir. Ayrıca bu tür etkileri azaltmaya veya onlarla daha uyumlu bir temsil üretmeye yönelik öznitelik tasarımı ve ön işleme stratejilerinin kritik rolüne dikkat çekmektedir [95]. Bu tezde EPF'nin çoklu parametre seviyelerinde uygulanması, yumuşatma gücü ile sınır koruma arasındaki dengenin farklı ölçeklerde eş zamanlı temsil edilmesini sağlamaktadır. Böylece seçilen üç sınıflandırıcının aynı veri üzerinde karşılaştırılabilir ve birbirini tamamlayan bir değerlendirme

ortamı sunmasına imkan vermektedir.Bu değerlendirme mantığı korunarak, önce tezde deneysel karşılaştırmalarda temel alınan KNN, RF ve SVM yöntemleri özetlenmektedir. Ardından sonuçların daha geniş bir geleneksel yöntem ailesi içinde konumlandırılabilmesi ve yöntemsel çeşitliliğin gösterilebilmesi amacıyla çalışmada kullanılan diğer sınıflandırıcılar da kısaca tanıtılmaktadır:

- K-En Yakın Komşu (K-Nearest Neighbors, KNN), parametrik olmayan ve örnekler arası benzerliği bir mesafe ölçütü üzerinden değerlendiren örnek tabanlı bir sınıflandırma yöntemidir. Temel prensip, sınıflandırılacak yeni bir örneğin öznitelik uzayında en yakın k komşusunun etiketlerine bakılarak sınıfının çoğunluk oylaması ile belirlenmesidir [96]. Bu yaklaşımda karar mekanizması komşuluk ilişkilerine dayanır ve k parametresi komşuluk penceresinin genişliğini belirleyerek kararın hangi ölçekte verileceğini tanımlar. Uzaktan algılama ve SAR sınıflandırma çalışmalarında KNN, yalın yapısı ve doğrudan mesafe tabanlı karar mekanizması nedeniyle karşılaştırma amaçlı sıklıkla kullanılan bir yaklaşım olarak yer almaktadır [95].

- Rastgele Orman (Random Forest, RF), çok sayıda karar ağacının bir araya getirilmesiyle oluşturulan ağaç tabanlı bir topluluk öğrenme yöntemidir [97]. Yöntem, eğitim veri kümesinden rassal örnekleme ile oluşturulan alt veri kümeleri üzerinde birden fazla karar ağacının eğitilmesine ve her bölme adımında rastgele seçilmiş öznitelik alt uzaylarının kullanılmasına dayanır; böylece ağaçlar arası çeşitlilik artırılır ve nihai karar, ağaç çıktılarının çoğunluk oylaması ile belirlenir. Uzaktan algılama literatüründe RF, doğrusal olmayan karar sınırlarını ifade edebilmesi ve yüksek boyutlu öznitelik uzaylarında etkin kullanılabilmesi nedeniyle yaygın biçimde tercih edilmektedir [92–94].

- Destek Vektör Makineleri (Support Vector Machines, SVM), sınıfları ayıran karar yüzeyini belirlemek üzere sınıflar arasındaki marjini maksimize edecek bir hiperdüzlemin öğrenilmesine dayanan marjin temelli bir sınıflandırma yöntemidir [98]. Karar yüzeyinin konumu, marjin sınırlarına en yakın örnekler olan destek vektörleri tarafından belirlenir ve sınıfların doğrusal bir hiperdüzlem ile ayrılamadığı durumlarda çekirdek fonksiyonları kullanılarak veriler daha yüksek boyutlu bir uzaya eşlenir. Uzaktan algılama literatüründe SVM, yüksek boyutlu öznitelik uzaylarında ve sınırlı eğitim örneği içeren senaryolarda yaygın biçimde kullanılan bir yöntem olarak yer almaktadır [92–94, 99].

- Karesel Ayırt Edici Analiz (Quadratic Discriminant Analysis, QDA), her sınıf için ayrı bir ortalama vektörü ve ayrı bir kovaryans matrisi varsayımıyla

sınıfların olasılıksal dağılımını modelleyen istatistiksel bir sınıflandırma yöntemidir. Sınıfların çok değişkenli normal dağılıma uyduğu kabulü altında Bayes karar kuralını uygular ve bu nedenle karar fonksiyonları genel olarak ikinci dereceden bir biçim alır. Kovaryans matrislerinin sınıfa özgü tanımlanması, modelin sınıf-şartlı saçılım yapısını ayrı ayrı ifade etmesine olanak tanır [100].

- Doğrusal Ayırt Edici Analiz (Linear Discriminant Analysis, LDA), sınıf dağılımlarını Gauss varsayımı altında ele alan parametrik bir yöntemdir. LDA, sınıfların ortak bir kovaryans matrisini paylaştığını kabul eder ve bu varsayım altında doğrusal karar sınırları üretir. Yöntem, sınıflar arası ayrımı artıran doğrusal ayırıcı fonksiyonlar üzerinden sınıflandırma gerçekleştirir [100].

- Lojistik Regresyon (Logistic Regression), doğrusal bir karar fonksiyonu üzerinden sınıf olasılıklarını modelleyen denetimli bir sınıflandırma yöntemidir. İkili sınıflandırmada lojistik bağlantı fonksiyonu, çok sınıflı durumda ise softmax genellemesi kullanılarak artalan olasılıklar elde edilir. Parametreler, maksimum olabilirlik ilkesine dayalı sayısal optimizasyon ile öğrenilir [101].

- Naif Bayes (Naive Bayes), sınıf koşulunda öznitelikler arasında koşulsal bağımsızlık varsayımı yaparak sınıf-şartlı olasılıkları çarpanlara ayıran olasılıksal bir sınıflandırma yöntemidir. Sınıf olasılıkları Bayes teoremi ile hesaplanır ve karar, en yüksek artalan olasılığa sahip sınıfın seçilmesiyle verilir [101].

- Karar Ağaçları (Decision Trees), veri uzayını ardışık bölme kurallarıyla parçalayan ve her bölgede sınıf kararını yaprak düğümler üzerinden veren, kural tabanlı ve yorumlanabilir sınıflandırma modelleridir. Bölme kararları saflık ölçütlerini iyileştirecek biçimde seçilir ve doğrusal olmayan karar bölgeleri hiyerarşik olarak ifade edilebilir [102].

- Uyarlamalı Artırma (Adaptive Boosting, AdaBoost), zayıf öğrenicileri ardışık biçimde birleştirerek güçlü bir topluluk sınıflandırıcısı oluşturan boosting tabanlı bir yöntemdir. Eğitim sürecinde örnek ağırlıkları güncellenir ve sonraki öğreniciler bu ağırlıklandırılmış örnekler üzerinde eğitilir [103].

- Gradyan Artırma (Gradient Boosting), bir kayıp fonksiyonunu en aza indirmek amacıyla ardışık biçimde eğitilen zayıf öğrenicilerin toplamı şeklinde bir model kuran topluluk öğrenme yaklaşımıdır. Her yeni öğrenici, önceki modelin artık hatasına karşılık gelecek biçimde modele eklenir [104].

- Aşırı Gradyan Artırma (Extreme Gradient Boosting, XGBoost), gradyan artırma yaklaşımını ağaç tabanlı zayıf öğrenicilerle uygulayan ve amaç fonksiyonuna düzenlileştirme terimleri ekleyen bir boosting algoritmasıdır. İkinci mertebe türev bilgisi kullanılarak daha etkin bir optimizasyon sağlanır [105].

- Aşırı Rastgele Ağaçlar (Extremely Randomized Trees, Extra Trees), karar ağaçlarını yüksek düzeyde rastgeleleştirilmiş bölme seçimleriyle birleştiren bir topluluk yöntemidir. Nihai karar, ağaç çıktılarının oy çokluğu veya ortalama gibi birleştirme kurallarıyla üretilir [106].

- Hafif Gradyan Artırma Makinesi (Light Gradient Boosting Machine, LightGBM), histogram tabanlı bölme stratejileri ile gradyan artırma öğrenmesini ölçeklenebilir biçimde gerçekleştiren bir yöntemdir. Yaprak odaklı büyütme yaklaşımı sayesinde verimlilik odaklı bir yapı sunar [107].

- Kategorik Artırma (Categorical Boosting, CatBoost), boosting tabanlı ağaç topluluklarında öğrenme yanlılığını azaltmaya yönelik tasarım tercihleri içeren bir yöntemdir. Sıralı öğrenme yaklaşımı ve simetrik ağaç yapıları ile boosting çerçevesi uygulanır [108].

4
DENEYSEL ÇALIŞMALAR

Bu bölümde, önerilen EPF+PCA+SVM tabanlı yöntem çerçevesinin farklı SAR veri kümeleri üzerindeki başarımı deneysel olarak incelenmektedir. Uygulanan değerlendirme düzeni, kenar koruyucu filtrelerin (FGS, BF, DT) ve boyut indirgeme adımının sınıflandırma doğruluğuna etkisini açık biçimde ortaya koyacak şekilde yapılandırılmıştır. Ayrıca, farklı değerlendirme senaryolarının hesaplama maliyeti üzerindeki yansımaları da aynı çerçevede incelenmiştir.

Bu doğrultuda, deneysel değerlendirme sekiz aşama altında sistematik biçimde gerçekleştirilmiştir: İlk aşamada, herhangi bir EPF ya da PCA uygulanmadan geleneksel makine öğrenmesi yöntemleri ile karşılaştırılmış. Böylece sonraki ön işleme adımlarının katkısını yorumlayabilmek için referans bir performans düzeyi oluşturulmuştur. İkinci aşamada, farklı doğruluk seviyeleri sergileyen (SVM, RF ve KNN) yöntemler, (FGS, BF ve DT) filtreleriyle oluşturulan senaryolar üzerinde değerlendirilmiştir. Bu aşamada, benek gürültüsüne bağlı rastgele dalgalanmaların bastırılması ve sınıf sınırlarının korunmasının doğruluk ölçütlerine nasıl yansıdığı incelenmiştir. Üçüncü aşamada, ikinci aşamada ele alınan senaryolar için sınıflandırma haritaları oluşturularak nicel bulguların görüntü üzerindeki mekansal karşılıkları görsel olarak ortaya konmuştur. Bu görseller üzerinden, ikinci aşamada doğruluk ölçütleriyle değerlendirilen gürültü bastırımı ve sınıf sınırı korunumu eğilimleri nitel olarak tartışılmıştır. Ayrıca homojen bölgelerdeki tutarlılık ve tekrarlayan hatalı sınıflandırma örüntüleri değerlendirilmiştir. Dördüncü aşamada, çok kanallı gösterim PCA uygulanarak daha düşük boyutlu bir öznitelik temsiline dönüştürülmüştür. EPF sonrasında elde edilen SVM çıktıları incelenerek boyut indirgeme adımının sınıflandırma başarımına etkisi ile filtreler arasındaki ayrışmanın PCA sonrasında nasıl biçimlendiği değerlendirilmiştir. Beşinci aşamada, PCA sonrasında SVM ile birden fazla tekrarlı denemeler yapılarak başarımdaki değişkenlik incelenmiş ve farklı rastgele örneklemeler altında elde edilen sonuçların tutarlılığı değerlendirilmiştir. Altıncı aşamada, veri her yinelemede sınıf dağılımı benzer kalacak şekilde bölünerek 100 katlı çapraz

doğrulama uygulanmış ve daha yoğun bir değerlendirme düzeni oluşturulmuştur. Böylece sonuçların istatistiksel güvenilirliği güçlendirilerek yöntem davranışı daha temsil edici ölçütler üzerinden analiz edilmiştir. Yedinci aşamada, filtresiz senaryo, yalnızca EPF uygulanan senaryo ve EPF+PCA uygulanan senaryo birlikte değerlendirilmiştir. Böylece önerilen yaklaşımın her bir bileşeninin sınıflandırma başarımına katkısı toplu biçimde ortaya konmuştur.Sekizinci aşamada ise, elde edilen bulgular seçili çalışmalarla karşılaştırılmış ve benzer veri kümeleri ile değerlendirme düzenleri dikkate alınarak yöntemin literatürdeki yeri tartışılmıştır.

4.1 Performans Değerlendirme Kriterleri

Bu tezde önerilen EPF+PCA+SVM tabanlı yöntem çerçevesinin başarımı, farklı SAR veri kümeleri üzerinde nicel doğruluk ölçütleri ve hesaplama maliyeti açısından değerlendirilmiştir. Performans analizi, sınıflandırma çıktılarının hem genel başarımını hem de sınıf dağılımındaki dengesizlikten daha az etkilenen ve bu nedenle daha temsil edici ölçütleri kapsayacak şekilde tasarlanmıştır. Bu doğrultuda, makro ortalama temelli ölçütlere özel olarak yer verilmiştir. Makro ortalama yaklaşımı, her sınıf için elde edilen değerleri eşit ağırlıkla birleştirerek SAR görüntülerinde sık karşılaşılan sınıf dengesizliği koşullarında az örnekli ancak kritik sınıfların baskın sınıflar tarafından gölgelenme etkisini sınırlar. Böylece önerilen yöntemin sınıf bazlı ayırt ediciliği daha adil ve yorumlanabilir biçimde analiz edilebilir. Bu değerlendirmeyi nicel olarak temellendirmek üzere, ölçütlerin hesaplanmasında Tablo 4.1'de verilen genel K sınıflı karmaşıklık matrisi esas alınmıştır. Burada n_{ij}, gerçek sınıfı c_j olan örneklerin c_i olarak tahmin edilme sayısını göstermektedir. Köşegen elemanlar n_{ii} doğru sınıflandırılan örnekleri ifade eder. Satır ve sütun toplamları sırasıyla $n_{i\cdot} = \sum_{j=1}^{K} n_{ij}$ ve $n_{\cdot i} = \sum_{j=1}^{K} n_{ji}$ biçiminde tanımlanırken, toplam örnek sayısı $N = \sum_{i=1}^{K}\sum_{j=1}^{K} n_{ij}$ olarak elde edilir.

Tablo 4.1 K sınıflı bir problem için genel karmaşıklık matrisi gösterimi

	Gerçek sınıf				
Tahmin	c_1	c_2	$\cdots$	c_K	**Satır toplamı**
c_1	n_{11}	n_{12}	$\cdots$	n_{1K}	$n_{1\cdot}$
c_2	n_{21}	n_{22}	$\cdots$	n_{2K}	$n_{2\cdot}$
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$
c_K	n_{K1}	n_{K2}	$\cdots$	n_{KK}	$n_{K\cdot}$
Sütun toplamı	$n_{\cdot 1}$	$n_{\cdot 2}$	$\cdots$	$n_{\cdot K}$	N

Çok sınıflı bir problemde, sınıf bazlı ölçütlerin elde edilebilmesi için her bir sınıf,

diğer tüm sınıflar tek bir grup altında toplanacak şekilde ikili bir karşılaştırma düzeni kurulmuştur. Buna göre, i'inci sınıf için doğru pozitif (TP_i), yanlış pozitif (FP_i), yanlış negatif (FN_i) ve doğru negatif (TN_i) değerleri, Tablo 4.1'deki karmaşıklık matrisi üzerinden aşağıdaki biçimde tanımlanır:

$$TP_i = n_{ii}, \tag{4.1}$$

$$FP_i = n_{i\cdot} - n_{ii}, \tag{4.2}$$

$$FN_i = n_{\cdot i} - n_{ii}, \tag{4.3}$$

$$TN_i = N - \big(TP_i + FP_i + FN_i\big). \tag{4.4}$$

4.1.1 Genel Doğruluk

Genel doğruluk (Overall Accuracy), test kümesinde doğru sınıflandırılan örneklerin toplam test örneği sayısına oranı üzerinden sınıflandırıcının genel performansını nicel olarak ifade eden temel bir ölçüttür. Ayrıca, sınıflandırıcının tüm veri kümesi üzerindeki genel performansını tek bir değerle özetlediği için uzaktan algılama alanında yapılan sınıflandırma çalışmalarında standart performans göstergeleri arasında yer almaktadır. Bu ölçüt aşağıdaki gibi tanımlanır:

$$\text{Genel Doğruluk} = \frac{N_{\text{doğru}}}{N}, \tag{4.5}$$

K sınıflı bir problemde, doğru sınıflandırılan örnek sayısı karmaşıklık matrisinin köşegen elemanları kullanılarak aşağıdaki biçimde de ifade edilebilir:

$$N_{\text{doğru}} = \sum_{i=1}^{K} n_{ii}, \tag{4.6}$$

dolayısıyla genel doğruluk eşdeğer olarak şu şekilde yazılabilir:

$$\text{Genel Doğruluk} = \frac{1}{N} \sum_{i=1}^{K} n_{ii}. \tag{4.7}$$

burada K sınıf sayısını, N toplam test örneği sayısını ve n_{ii} karmaşıklık matrisinin köşegen elemanlarını, yani i'inci sınıf için doğru sınıflandırılan örnek sayısını göstermektedir.

4.1.2 Makro Ortalama Kesinlik

Kesinlik (precision), bir sınıfa ait olduğu tahmin edilen örneklerin ne kadarının gerçekten o sınıfa ait olduğunu ifade eder. Diğer bir deyişle, modelin ilgili sınıf

için ürettiği pozitif tahminlerin hangi oranının doğru olduğunu gösterir. Bu ölçüt, özellikle yanlış pozitif (FP) hatalarının etkisini değerlendirmek açısından önemlidir. Makro ortalama kesinlik, her sınıf için hesaplanan kesinlik değerlerini eşit ağırlıkla ortalayarak sınıf örnek sayılarından kaynaklanan baskınlık etkisini azaltır ve daha dengeli bir performans yorumu sağlar. Bu ölçüt aşağıdaki gibi tanımlanır:

$$\text{Kesinlik}_i = \frac{TP_i}{TP_i + FP_i}, \tag{4.8}$$

$$\text{Macro-Kesinlik} = \frac{1}{K}\sum_{i=1}^{K} \text{Kesinlik}_i = \frac{1}{K}\sum_{i=1}^{K} \frac{TP_i}{TP_i + FP_i}. \tag{4.9}$$

4.1.3 Makro Ortalama Duyarlılık

Duyarlılık (recall), belirli bir sınıfa ait gerçek örneklerin model tarafından ne ölçüde doğru tespit edilebildiğini gösterir. Bu ölçüt, özellikle kaçırılan örnekleri temsil eden yanlış negatif (FN) hatalarının sınıflandırma performansına etkisini daha görünür kılar. Makro Ortalama Duyarlılık, sınıf bazlı duyarlılık değerlerinin eşit ağırlıklı ortalaması olup, bazı sınıfların örnek sayısının düşük kaldığı senaryolarda, modelin her sınıfı ne ölçüde kapsayabildiğini daha adil biçimde incelemeye olanak sağlar. Bu ölçüt aşağıdaki gibi tanımlanır:

$$\text{Duyarlilik}_i = \frac{TP_i}{TP_i + FN_i}, \tag{4.10}$$

$$\text{Macro-Duyarlilik} = \frac{1}{K}\sum_{i=1}^{K} \text{Duyarlilik}_i = \frac{1}{K}\sum_{i=1}^{K} \frac{TP_i}{TP_i + FN_i}. \tag{4.11}$$

4.1.4 Makro Ortalama F1-Skoru

F1-skoru, kesinlik (precision) ve duyarlılık (recall) değerlerini harmonik ortalama üzerinden bir araya getirerek tek bir performans göstergesi elde eder. Böylece modelin hem doğru pozitif tahmin üretme başarısını hem de gerçek örnekleri yakalama düzeyini birlikte dikkate alan dengeli bir yaklaşım sunar. Makro Ortalama F1, her sınıf için hesaplanan F1 değerlerini eşit ağırlıkla ortalayarak sınıflar arası dengesizliğe karşı daha dayanıklı ve sınıf bazlı tutarlılığı daha iyi temsil edici biçimde özetleyen bir ölçüt sunar. Bu ölçüt aşağıdaki gibi tanımlanır:

$$\text{F1}_i = \frac{2\,\text{Kesinlik}_i\,\text{Duyarlilik}_i}{\text{Kesinlik}_i + \text{Duyarlilik}_i}, \tag{4.12}$$

$$\text{Macro-F1} = \frac{1}{K} \sum_{i=1}^{K} \text{F1}_i. \tag{4.13}$$

4.1.5 Cohen's Kappa Katsayısı

Cohen's Kappa, gözlenen sınıflandırma başarımını rastlantısal olarak oluşabilecek uyum düzeyini hesaba katarak değerlendirir. Özellikle sınıf dağılımının dengesiz olduğu veri kümelerinde OA, genel bir özet sunsa da bazı sınıflardaki hataları yeterince görünür kılmayabilir. Bu nedenle Kappa, toplam doğruluk değerine ek bir bakış sağlayarak modelin sınıflar arası uyum düzeyini daha anlamlı biçimde yorumlanmasına olanak tanır. Kappa katsayısı aşağıdaki gibi tanımlanır:

$$\kappa = \frac{p_o - p_e}{1 - p_e}, \tag{4.14}$$

burada p_o gözlenen uyumu (genel doğruluğu), p_e ise rastlantısal uyum olasılığını ifade eder. K sınıflı bir karmaşıklık matrisi için p_o ve p_e aşağıdaki şekilde yazılabilir:

$$p_o = \frac{1}{N} \sum_{i=1}^{K} n_{ii}, \tag{4.15}$$

$$p_e = \sum_{i=1}^{K} \left(\frac{n_{i\cdot}}{N} \right) \left(\frac{n_{\cdot i}}{N} \right), \tag{4.16}$$

burada $n_{i\cdot}$ i'inci satır toplamını (gerçek sınıfı i olan örnek sayısı), $n_{\cdot i}$ ise i'inci sütun toplamını (tahmini sınıfı i olan örnek sayısı) göstermektedir.

4.1.6 Hesaplama Süreleri

Önerilen yöntemin pratik uygulanabilirliğini değerlendirmek amacıyla, temsili deneylerde hesaplama süreleri ayrıca sunulmuştur. Bu kapsamda:

- **PCA süresi (s):** Boyut azaltımı adımındaki süresi,
- **Eğitim süresi (s):** Sınıflandırıcının eğitim süresi,
- **Test süresi (s):** Tüm görüntü üzerinde tahmin (prediction) üretim süresi.

hesaplanarak yöntemler arası karşılaştırmada kullanılmıştır.

Bu ölçütler birlikte ele alındığında, önerilen yaklaşımın performansı doğruluk ölçütlerini tamamlayacak biçimde değerlendirilir. Buna ek olarak, hesaplama verimliliği ve sınıflar arası tutarlılık açısından da yönteme daha bütüncül bir bakış sağlanmaktadır.

4.2 K-katlı Çapraz Doğrulama Deney Protokolü

Bu tezde, sınıflandırma sonuçlarının rastgele seçilen eğitim ve test ayrımının aşırı bağımlı kalmasını azaltmak ve yöntemlerin genellenebilirliğini daha güvenilir biçimde incelemek amacıyla, uygun deney senaryolarında K-katlı çapraz doğrulama (K-Fold) yaklaşımından yararlanılmıştır. K-Fold doğrulama, etiketli örnek havuzunun K adet yaklaşık eşit alt kümeye (fold) ayrılması ve her yinelemede bir fold'un test, kalan $K - 1$ fold'un eğitim amacıyla kullanılması prensibine dayanır. Bu kapsamda her örnek, çapraz doğrulama süreci boyunca yalnızca bir yinelemede test kümesine düşer. Diğer yinelemelerde ise eğitim aşamasında kullanılarak, performans ölçütleri tüm katların sonuçları birleştirilerek daha temsil edici şekilde hesaplanır.

Bu doğrultuda, tez kapsamında yürütülen veri hazırlama ve sınıflandırma süreci içinde K-katlı çapraz doğrulamanın (K-Fold) hangi aşamalarda kullanıldığı ve sürece nasıl dahil edildiği ana hatlarıyla açıklanmaktadır. K-Fold uygulanan deneyde, veri kümesine ait etiketli örnekler tek bir havuzda birleştirilmiş ve yinelenen örnekler ayıklanmıştır. Bölme işlemi, her yinelemede sınıf dağılımlarının korunmasına dikkat edilerek eğitim ve test alt kümelerinin oluşturulması şeklinde yürütülmüştür. Fold sayısı, en az örneğe sahip sınıfın örnek sayısının izin verdiği uygulanabilirlik sınırları dikkate alınarak seçilmiştir. Gerekli durumlarda bu kısıtı sağlayacak şekilde yeniden düzenlenmiştir.

Her yinelemede, eğitim ve test alt kümeleri için sabit boyutlu yamalar çıkarılarak öznitelikler oluşturulmuştur. Boyut indirgeme ve benzeri veri dönüşümleri yalnızca eğitim verisi üzerinde öğrenilmiş, elde edilen dönüşüm test verisine aynen uygulanmıştır. Ardından sınıflandırıcı eğitim verisiyle eğitilmiş ve test verisi üzerinde tahminler üretilmiştir. Fold bazında üretilen tahminler üzerinden genel doğruluk, makro-Precision, makro-Recall, makro-F1 ve Cohen's Kappa değerleri hesaplanmıştır. Ayrıca bu ölçütlerin ortalama ve standart sapma istatistikleri verilerek yöntemin farklı bölünmeler altında sergilediği performans daha güvenilir biçimde incelenmiştir

4.3 Kenar Koruyucu Filtre Hiperparametreleri

Bu tezde, görüntüdeki gürültüye bağlı rastgele dalgalanmaların azaltılması ve arazi örtüsü sınıfları arasındaki sınırların olabildiğince korunması hedefiyle üç farklı kenar koruyucu filtre (FGS, BF, DT) kullanılmıştır. Her bir filtrenin düzleştirme gücü ile kenar koruma davranışı, seçilen hiperparametreler tarafından doğrudan belirlenmektedir. Bu nedenle deneyler, düşük–orta–yüksek olmak üzere üç seviyeli

bir parametreleme altında gerçekleştirilmiştir. İlgili hiperparametre düzeyleri Tablo 4.2'de özetlenmektedir.

FGS filtresinde, küresel düzgünleştirme düzeyini belirleyen λ parametresi ile kenar duyarlılığını yönlendiren renk ve yoğunluk ölçeği σ_c birlikte ayarlanmıştır. Buna ek olarak, iterasyon sayısı (iter) artırıldıkça filtrenin etkinliği güçlenmektedir. Ancak aşırı düzleştirme riski ve hesaplama maliyeti de artabilmektedir. Bu nedenle FGS için düşük–orta–yüksek seviyeler, hem λ ve σ_c değerlerini hem de *iter* sayısını birlikte kademeli biçimde artıracak şekilde seçilmiştir.

DT filtresinde, uzamsal yayılımın kapsamını belirleyen σ_s ile renk ve yoğunluk benzerliğine bağlı ağırlıklandırmayı yöneten σ_c parametreleri temel rol oynamaktadır. Bu iki parametrenin daha yüksek değerler alması, filtrenin daha geniş komşuluklarda daha baskın bir yumuşatma davranışı sergilemesine yol açmaktadır. Buna ek olarak, iterasyon sayısı (numIters) arttıkça, filtrenin toplam düzleştirme etkisi daha belirgin hale gelmektedir. Bu çalışmada DT için üç seviyeli parametreleme, ilgili değerlerin aşamalı olarak artırılmasıyla düşük seviyeden yüksek seviyeye doğru daha belirgin bir benek gürültüsü bastırımı elde edilecek biçimde kurgulanmıştır.

BF filtresinde, yerel komşuluk alanının ölçeğini tanımlayan d parametresi ile uzamsal düzgünleştirme düzeyini belirleyen σ_s ve yoğunluk benzerliğine dayalı kenar duyarlılığını yöneten σ_r parametreler birlikte kullanılmıştır. Uzamsal komşuluk etkisi, σ_s değeri büyüdükçe artar ve daha geniş bir çevredeki piksellerin katkısı güçlenir. Yoğunluğu farklı piksellerin de ortalamaya katılması ise σ_r arttığında kolaylaşır. Bu durum benek gürültüsünün bastırılmasına yardımcı olabilir. Ancak kenarların bulanıklaşma olasılığını da yükseltebilir. Bu nedenle BF seviyeleri, kenar korunumu ile gürültü bastırımı arasındaki dengeyi gözlemlemek üzere σ_s ve σ_r değerlerinin düşük–orta–yüksek basamaklı biçimde ayarlandığı bir çerçevede ele alınmıştır.

Sonuç olarak, Tablo 4.2'de sunulan üç seviyeli EPF hiperparametreleri üzerinden filtre davranışları düzenli bir karşılaştırma çerçevesinde incelenmiştir. Böylece zayıf düzleştirme ile güçlü kenar koruma eğilimi ile güçlü düzleştirme ve buna bağlı olası detay kaybı eğilimi arasındaki fark sistematik bir biçimde karşılaştırılabilmiştir. Bu karşılaştırma, Bu karşılaştırma, filtre ayarlarının PCA öncesi öznitelik temsiline ve sınıflandırma başarımına yansımasını hem doğruluk ölçütleri hem de hesaplama süreleri üzerinden incelemeye olanak sağlamıştır.

Tablo 4.2 EPF yöntemleri için üç seviyeli (düşük–orta–yüksek) hiperparametreler

Filtre Türü	Parametre 1 ve Değeri	Parametre 2 ve Değeri	Parametre 3 ve Değeri
FGS	Düşük: $\lambda = 100.0$	Düşük: $\sigma_c = 3.0$	Düşük: iter=2
	Orta: $\lambda = 500.0$	Orta: $\sigma_c = 5.0$	Orta: iter=4
	Yüksek: $\lambda = 1000.0$	Yüksek: $\sigma_c = 8.0$	Yüksek: iter=4
DT	Düşük: $\sigma_s = 5.0$	Düşük: $\sigma_c = 20.0$	Düşük: numIters=2
	Orta: $\sigma_s = 10.0$	Orta: $\sigma_c = 30.0$	Orta: numIters=3
	Yüksek: $\sigma_s = 20.0$	Yüksek: $\sigma_c = 40.0$	Yüksek: numIters=3
BF	Düşük: $d = 15$	Düşük: $\sigma_s = 1.5$	Düşük: $\sigma_r = 0.25$
	Orta: $d = 15$	Orta: $\sigma_s = 3.0$	Orta: $\sigma_r = 0.50$
	Yüksek: $d = 15$	Yüksek: $\sigma_s = 4.5$	Yüksek: $\sigma_r = 0.75$

4.4 Deneysel Sonuçlar

Bu bölümde, tez kapsamında gerçekleştirilen tüm deneysel çalışmaların sonuçları sunulmakta ve analiz edilmektedir. Farklı veri kümeleri ve değerlendirme senaryoları altında elde edilen bulgular, yöntemlerin nasıl davrandığı ve performanslarının hangi yönde değiştiği, karşılaştırma esaslı bir değerlendirme kapsamında ele alınmaktadır.

4.4.1 Filtresiz Klasik Makine Öğrenmesi Yöntemlerinin Karşılaştırılması

Bu alt bölümde, herhangi bir kenar koruyucu filtreleme veya boyut indirgeme uygulanmadan, geleneksel makine öğrenmesi yöntemleri dört farklı SAR veri kümesi üzerinde karşılaştırılmıştır. Deneyler, SAR sınıflandırmada sık karşılaşılan sınırlı etiketli veri koşullarında yöntemlerin doğrudan ayırt ediciliğini aynı değerlendirme düzeni altında gözlemlemeye yöneliktir. Ayrıca, ilerleyen bölümlerde incelenecek EPF ve PCA adımlarının sağlayacağı katkıyı yorumlayabilmek için bir referans performans seviyesi oluşturmayı amaçlamaktadır.

Bu kapsamda elde edilen genel doğruluk sonuçları Tablo 4.3'de verilmiştir. Sonuçlar incelendiğinde, doğrusal ilişki varsayımı ya da sınırlı olasılıksal modellemeler temellerine dayanan QDA, Naive Bayes ve AdaBoost gibi yöntemler özellikle karmaşık sahne yapısına sahip veri kümelerinde nispeten daha düşük doğruluk sonuçları vermiştir. Buna karşılık, ağaç tabanlı yöntemler (Random Forest, Extra Trees, Gradient Boosting, XGBoost, LightGBM ve CatBoost) tüm veri kümelerinde daha istikrarlı ve yüksek genel doğruluk değerleri elde ederek doğrusal olmayan karar sınırlarını modelleme açısından daha güçlü bir eğilim sergilemiştir.

Filtresiz senaryoda en yüksek ve en tutarlı sınıflandırma başarımı, çekirdek tabanlı bir yaklaşım olan RBF çekirdekli SVM ile elde edilmiştir. SVM, tüm veri kümelerinde yüksek genel doğruluk değerleri sunmuş ve ortalama doğruluk bakımından diğer yöntemlerin önüne geçmiştir. Bu bulgu, SAR verilerinin yüksek boyutlu ve doğrusal olmayan yapısının RBF çekirdekli SVM ile etkili biçimde temsil edilebildiğini göstermektedir. Genel olarak bu filtresiz sonuçlar, yöntemler arasında belirgin performans farkları bulunduğunu ortaya koymaktadır. Ayrıca bu sonuçlar, ilerleyen bölümlerde ele alınacak EPF ve PCA destekli senaryolarda elde edilen iyileşmeleri daha açık biçimde değerlendirebilmek için güvenilir bir başlangıç noktası sunmaktadır.

Tablo 4.3 Filtreleme öncesinde geleneksel makine öğrenmesi yöntemlerinin dört farklı veri kümesi üzerindeki OA sonuçları

Model	SFBay_C (OA)	SFBay_L (OA)	Flevo_C (OA)	Flevo_L (OA)	Ortalama (OA)
QDA	0.2387	0.4152	0.2933	0.3536	0.325
AdaBoost	0.5682	0.8524	0.8826	0.4238	0.682
Naive Bayes	0.8895	0.8719	0.7936	0.4492	0.751
Decision Tree	0.7474	0.9109	0.8165	0.7864	0.815
KNN	0.8562	0.9244	0.7644	0.9322	0.869
LDA	0.8681	0.9162	0.9195	0.8001	0.876
Logistic Regression	0.9476	0.9815	0.9698	0.8825	0.945
Random Forest	0.9157	0.9604	0.9684	0.9366	0.945
Gradient Boosting	0.9233	0.9520	0.9718	0.9333	0.945
XGBoost	0.9248	0.9513	0.9722	0.9375	0.946
Extra Trees	0.9204	0.9672	0.9738	**0.9476**	0.952
LightGBM	0.9311	0.9491	0.9803	0.9474	0.952
CatBoost	0.9420	0.9484	0.9800	0.9438	0.954
SVM (RBF)	**0.9607**	**0.9838**	**0.9809**	0.9366	**0.966**

4.4.2 Kenar Koruyucu Filtre Sonrası Klasik Makine Öğrenmesi Yöntemlerinin Karşılaştırılması

Bu alt bölümde, BF, FGS ve DT kenar koruyucu filtreleri ile ön işleme uygulandıktan sonra, geleneksel makine öğrenmesi tabanlı sınıflandırıcıların dört farklı SAR veri kümesindeki performaansı karşılaştırmalı olarak incelenmiştir. Deneyler, filtrelemenin gürültüye bağlı rastgele dalgalanmaları azaltırken sınıf sınırlarını koruma eğiliminin, doğrudan sınıflandırma başarımına nasıl yansıdığını incelemek amacıyla yürütülmüştür. Böylece, filtresiz senaryoda gözlenen başlangıç düzeyi ile EPF sonrası elde edilen sonuçlar arasındaki fark, veri kümesi bazında nicel olarak görünür hale getirilmiştir. Bu aşamada, filtresiz karşılaştırmada farklı doğruluk seviyeleri sergileyen ve çalışma boyunca temsili bir kapsama sağlayan üç yöntem (KNN, RF ve SVM) seçilmiştir. Bu tercih, hem düşük/orta/yüksek başarım

aralığını tek bir çerçevede izlemeye hem de EPF etkisini sınıflandırıcı türüne göre karşılaştırmalı biçimde değerlendirmeye olanak tanımaktadır. Bu kapsamda elde edilen genel doğruluk sonuçları Tablo 4.4'te sunulmuştur.

Sonuçlar incelendiğinde, filtreleme sonrasında tüm sınıflandırıcılarda genel doğruluk değerlerinin genel olarak yükseldiği görülmektedir. Özellikle benek gürültüsünün etkin biçimde bastırılması ve sınıf sınırlarının korunması, sonuçlara doğrudan yansımıştır. Bu sayede hem KNN hem de RF yöntemlerinin filtresiz senaryoya kıyasla daha kararlı ve daha yüksek doğruluklar elde ettiği dikkat çekmektedir. Bu eğilim, homojen bölgelerdeki kararlılığın artması ve sınıf geçiş bölgelerinde sınırların daha belirgin hale gelmesiyle uyumludur.

Filtre türleri karşılaştırıldığında, FGS ve BF filtrelerinin çoğu veri kümesinde DT'ye kıyasla daha yüksek genel doğruluklar ürettiği görülmektedir. En yüksek ve en tutarlı sonuçların ise özellikle SVM (RBF) ile birlikte elde edildiği gözlenmektedir. Bu bulgular, EPF tabanlı ön işlemenin ayırt edici özniteliklerin daha kararlı biçimde temsil edilmesine katkı sağladığını göstermektedir. Bu etkinin, çekirdek tabanlı sınıflandırıcılarla birleştiğinde daha belirgin hale geldiği görülmektedir.

Tablo 4.4 BF/FGS/DT sonrası ML yöntemlerinin dört veri kümesindeki OA sonuçları ve filtresiz duruma göre ortalama artış (ΔOA)

Filtre	Model	SFBay_C (OA)	SFBay_L (OA)	Flevo_C (OA)	Flevo_L (OA)	Ortalama (OA)	Δ Ortalama (OA)
DT	KNN	0.8720	0.9251	0.7789	0.9665	0.886	+0.017
DT	RF	0.9308	0.9671	0.9755	0.9538	0.957	+0.012
DT	SVM	0.9664	0.9884	0.9840	0.9721	0.978	+0.012
BF	KNN	0.9499	0.9528	0.9790	0.9628	0.961	**+0.092**
BF	RF	0.9625	0.9630	0.9836	0.9629	0.968	+0.023
BF	SVM	**0.9752**	0.9918	0.9857	0.9672	0.980	+0.014
FGS	KNN	0.8895	0.8978	0.8030	0.9667	0.889	+0.020
FGS	RF	0.9429	0.9648	0.9806	0.9730	0.965	+0.020
FGS	SVM	0.9705	**0.9958**	**0.9878**	**0.9812**	**0.984**	+0.018

4.4.3 Sınıflandırma Haritalarının Görsel Analizi

Bu alt bölümde, San Francisco RADARSAT-2 SAR veri kümesi için üretilen sınıflandırma haritaları görsel açıdan değerlendirilmiştir. Filtresiz durum ile BF, DT ve FGS tabanlı ön işleme senaryoları farklı sınıflandırma yapılandırmalarıyla karşılaştırılarak, kenar koruyucu filtrelerin mekansal tutarlılık, sınıf içi homojenlik ve sınıf sınırlarının korunmasına etkisi nitel olarak incelenmiştir. Böylece önceki alt bölümlerde sunulan nicel doğruluk ölçütlerinin görüntü uzayı üzerindeki karşılıkları ortaya konmuştur.

Filtresiz KNN ile BF sonrası KNN sonuçları arasındaki farklar Şekil 4.1

'de gösterilmektedir. Filtresiz senaryoda, özellikle benek gürültüsü kaynaklı rastgelelikler nedeniyle sınıf bölgelerinin parçalı ve düzensiz bir yapı sergilediği gözlenmektedir. BF uygulaması sonrasında ise sınıf içi homojenliğin belirgin biçimde arttığı, küçük ölçekli gürültülerin bastırıldığı ve mekansal sürekliliğin güçlendiği dikkat çekmektedir. Bu iyileşme, sınıf sınırlarının büyük ölçüde korunması pahasına aşırı bir bulanıklaşma oluşturmadan sağlanmış olup, BF filtresinin dengeli bir düzleştirme etkisi sunduğunu göstermektedir.

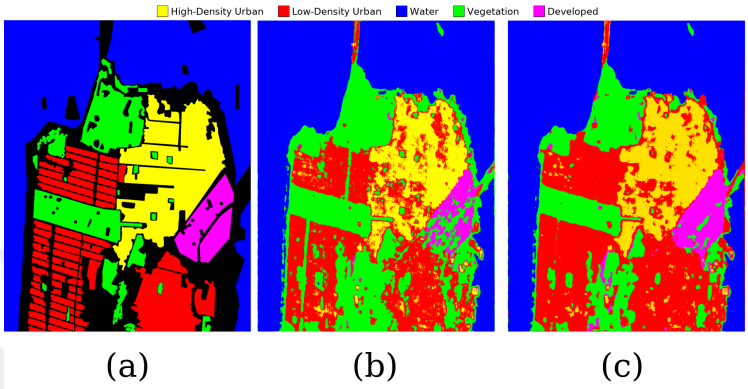

Şekil 4.1 (a) GT, (b) KNN ve (c) BF+KNN ile elde edilen sınıflandırma sonuçlarının karşılaştırılması.

Filtresiz SVM ile BF sonrası SVM sonuçları arasındaki farklar Şekil 4.2'de gösterilmektedir. Filtresiz SVM haritasında sınıf sınırları genel olarak ayırt edilebilir düzeyde olsa da, özellikle benek gürültüsünün etkili olduğu alanlarda sınıf içi dalgalanmaların sürdüğü gözlenmektedir. BF uygulaması sonrasında elde edilen sınıflandırma haritasında ise sınıf sınırlarının daha net biçimde korunduğu, homojen bölgelerde daha temiz ve kararlı mekansal örüntülerin oluştuğu dikkat çekmektedir. Bu iyileşme, aşırı düzleştirmeye yol açmadan sağlanmış olup, BF filtresinin SVM tarafından kullanılan öznitelik temsillerini daha ayırt edici ve mekansal olarak tutarlı hale getirdiğini göstermektedir.

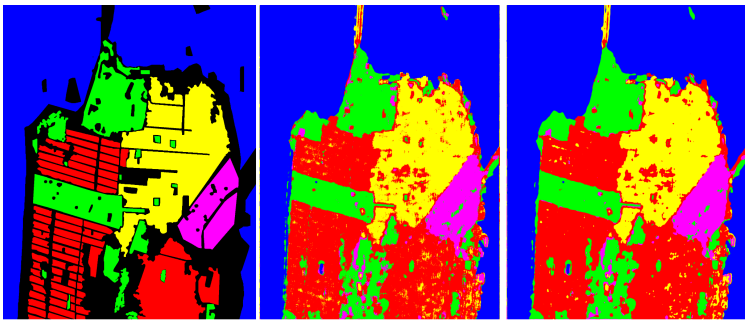

(a) (b) (c)

Şekil 4.2 (a) GT, (b) SVM ve (c) BF+ SVM sınıflandırma sonuçlarının karşılaştırılması.

DT sonrası KNN ile filtresiz KNN sonuçları arasındaki farklar Şekil 4.3'de gösterilmektedir. DT sonrası KNN haritasında, sınıf geçiş bölgelerinin büyük ölçüde korunmasına karşın bazı homojen alanlarda sınıf içi gürültünün kısmen devam ettiği görülmektedir. Bu durum, DT filtresinin kenar duyarlılığını ön planda tutarken, güçlü bir düzleştirme etkisini her bölgede eşit ölçüde sağlayamadığını göstermektedir.

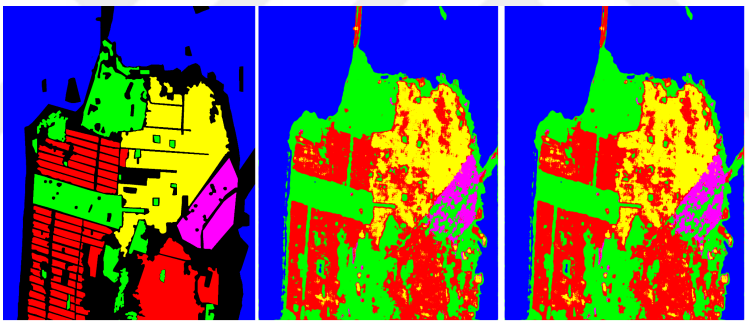

(a) (b) (c)

Şekil 4.3 (a) GT, (b) KNN ve (c) DT + KNN sınıflandırma sonuçlarının karşılaştırılması.

FGS sonrası RF ile filtresiz RF sonuçları arasındaki farklar Şekil 4.4'te gösterilmektedir. FGS uygulaması sonrasında mekansal tutarlılığın belirgin biçimde arttığı dikkat çekmektedir. Bu bağlamda, mekansal açıdan en belirgin iyileşmelerin FGS+RF birleşimiyle elde edildiği görülmektedir. FGS sonrası elde edilen haritada, geniş homojen bölgelerin oldukça temiz biçimde temsil edildiği ve sınıf sınırlarının keskinliğini koruduğu dikkat çekmektedir. Bu yaklaşım, hem benek gürültü etkisinin bastırılması hem de detay kaybının sınırlandırılması açısından dengeli bir sonuç sunmaktadır.

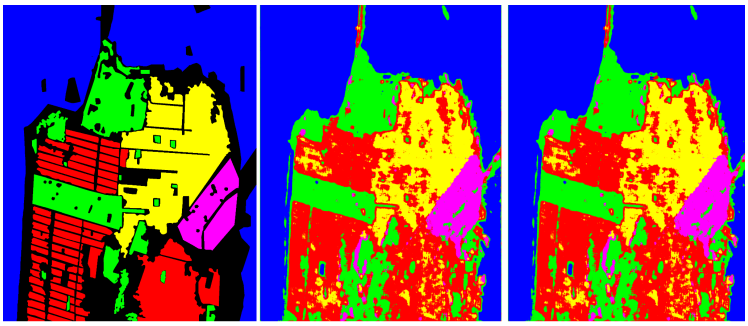

(a) (b) (c)

Şekil 4.4 (a) GT , (b) RF ve (c) FGS+ RF sınıflandırma sonuçlarının karşılaştırılması.

Genel olarak, Şekil 4.1–Şekil 4.4 üzerinden yapılan görsel inceleme, nicel doğruluk ölçütleriyle tutarlı bir eğilim ortaya koymaktadır. Buna göre, kenar koruyucu filtreler SAR görüntülerinde benek gürültüsünü bastırırken sınıf sınırlarının belirginliğini büyük ölçüde korumaktadır. Sonuç olarak, EPF uygulanmasıyla birlikte sınıflandırma haritalarında sınıf içi homojenlik ve mekansal süreklilik belirgin biçimde artmıştır. Bu bulgu, benek gürültü etkisinin azaltılmasına karşın sınıf sınırlarının okunabilirliğinin büyük ölçüde korunduğunu ve EPF'nin daha kararlı bir mekansal temsil sağladığını göstermektedir.

4.4.4 PCA Sonrası Kenar Koruyucu Filtreler ile SVM Sonuçlarının Değerlendirilmesi

Bu alt bölümde, tez kapsamında önerilen EPF+PCA+SVM tabanlı sınıflandırma yaklaşımında, PCA adımının ardından elde edilen SVM sınıflandırıcının sonuçları incelenmiştir. Amaç, kenar koruyucu filtrelerle zenginleştirilen çok kanallı öznitelik temsiline uygulanan boyut indirgeme işleminin sınıflandırma başarımına katkısını nicel olarak ortaya koymaktır. Ayrıca, farklı EPF türleri arasındaki ayrışmanın PCA sonrasında nasıl değiştiği, nicel olarak incelenmektedir. Literatürde bazı çalışmalarda kanal seçimi ve yama boyutu, veri kümesine veya senaryoya göre değişken tutulabilmektedir. Ancak bu tezde, karşılaştırılabilirliği korumak ve etki analizini yalınlaştırmak amacıyla kanal seti ile yama boyutu önerilen yönteme ait ilgili deneylerde sabit tutulmuştur.

SAR verisi, dört kanallı bir temsil (T11, T22, T33 ve SPAN) olarak ele alınmıştır. Aynı görüntü, seçilen kenar koruyucu filtre (FGS, DT ve BF) için üç farklı hiperparametre seviyesi altında işlenerek 12 kanallı bir gösterime dönüştürülmüştür. Ardından, Yer Gerçeği (GT) konumları merkez alınarak her bir etiketli piksel için $21 \times 21 \times 12$ boyutunda yamalar çıkarılmıştır. Boyut indirgeme adımı, yalnızca eğitim verisi üzerinden olacak şekilde, tüm yamalardaki piksellerin kanal vektörleri

bir araya getirilerek öğrenilmiş ve kanal boyutu $12 \rightarrow 3$ olacak biçimde PCA uygulanmıştır. Böylece her yama, $21 \times 21 \times 3$ biçiminde daha kompakt ve ayırt edici bir temsile dönüştürülmüştür. Son aşamada bu yamalar vektörleştirilerek $21 \times 21 \times 3 = 1323$ boyutlu öznitelik vektörleri elde edilmiş ve RBF çekirdekli SVM ile eğitim ve test işlemleri gerçekleştirilmiştir. Ayrıca RBF çekirdeği için hiperparametreler (C ve γ) tüm deneylerde sabit tutularak karşılaştırılabilirlik korunmuştur. Bu deneylerin temel amacı, EPF sonrası zenginleştirilen temsilin PCA ile daha seçici hale getirilmesinin sınıflandırma başarımına etkisini ortaya koymaktır. Ayrıca, farklı EPF türleri arasındaki performans ayrışmasının PCA sonrasında nasıl şekillendiği nicel olarak incelenmektedir.

Bu kapsamda elde edilen genel doğruluk sonuçları Tablo 4.5'te sunulmuştur. Tabloda görüldüğü üzere, PCA sonrasında tüm filtre türleri için yüksek ve birbirine oldukça yakın genel doğruluk değerleri elde edilmiştir. Bu bulgu, PCA'nın kanal boyutundaki fazlalığı baskılayarak daha kompakt ve ayırt edici bir temsil oluşturduğunu göstermektedir. Dolayısıyla SVM'in karar sınırlarını daha kararlı biçimde öğrenebildiği anlaşılmaktadır. Özellikle BF ve FGS tabanlı yaklaşımlar tüm veri kümelerinde istikrarlı biçimde yüksek doğruluk üretmiştir.Genel doğruluk açısından en yüksek değer FGS+PCA+SVM yaklaşımı ile elde edilmiştir. Bu kombinasyon hem veri kümeleri arasında dengeli hem de genel olarak en tutarlı sonuçları sunmuştur.

Genel olarak bulgular, EPF ile zenginleştirilen çok kanallı temsile uygulanan PCA tabanlı sıkıştırmanın; az etiketli veri koşullarında dahi ayırt edici ve daha kararlı bir öznitelik uzayı oluşturduğunu göstermektedir. Bu temsil üzerine kurulan RBF çekirdekli SVM sınıflandırması ise, yüksek doğruluğu destekleyerek yaklaşımın bütüncül ve güvenilir bir çerçeve sunduğunu ortaya koymaktadır.Ayrıca önerilen yaklaşımın, farklı EPF türleri arasında gözlenen genel doğruluk düzeyindeki ayrışmayı belirgin biçimde azaltarak yöntemler arası performans farklarını daha dar ve sınırlı bir aralığa topladığı görülmektedir.

Tablo 4.5 PCA sonrası kenar koruyucu filtreler ile SVM modelinin dört veri kümesi üzerindeki genel doğruluk (OA) sonuçları

Filtre	Model	SFBay_C (OA)	SFBay_L (OA)	Flevo_C (OA)	Flevo_L (OA)	Ortalama (OA)
DT	SVM	0.9709	0.9898	0.9883	**0.9797**	0.982
BF	SVM	0.9739	0.9905	0.9891	0.9785	0.983
FGS	**SVM**	**0.9767**	**0.9924**	**0.9908**	0.9766	**0.984**

4.4.5 PCA Sonrası SVM için Tekrarlı Deneylerin Değerlendirilmesi

Bu alt bölümde, tez kapsamında önerilen EPF+PCA+SVM tabanlı sınıflandırma yaklaşımının güvenilirliğini desteklemek amacıyla tekrarlı deneyler ele alınmıştır. Bu değerlendirme, elde edilen başarımın yalnızca tek bir eğitim/test ayrımına bağlı tesadüfi bir sonuç olmadığını göstermeyi amaçlamaktadır. Ayrıca, farklı örnek seçimleri altında da benzer doğruluk düzeyinin korunduğunu ortaya koymayı hedeflemektedir. Dolayısıyla, elde edilen performansların rastgele eğitim/test bölünmelerine karşı kararlılığını ve güvenilirliğini ortaya koymayı amaçlamaktadır. Bu doğrultuda 10 tekrarlı bir deney düzeni uygulanmış olup her tekrarda etiketli örnek havuzundan %1 oranında örnek eğitim kümesi olarak seçilmiştir. Kalan %99 örnek ise test kümesini oluşturacak biçimde yeniden ayrılmıştır.

Deneyler, 4 farklı SAR veri kümesi üzerinde yürütülmüştür. Bu kapsamda, T11, T22, T33 ve SPAN kanallarına üç seviyeli FGS, DT ve BF uygulanmıştır. Elde edilen çıktılar birleştirilerek 12 kanallı bir temsil oluşturulmuştur. Sınıflandırma öncesinde bu temsil PCA ile 3 bileşene indirgenmiş olup her etiketli piksel konumu etrafından çıkarılan sabit 21×21 yamalar üzerinden öznitelikler elde edilmiştir. PCA, her yinelemede yalnızca eğitim verisi kullanılarak öğrenilmiş ve aynı dönüşüm test verisine uygulanmıştır. Ardından öznitelikler StandardScaler ile ölçeklendirilmiş ve RBF çekirdekli SVM (C=4.0, γ=scale) ile modelleme yapılmıştır. Her tekrarda SVM modeli sıfırdan eğitilmiş, test kümesi üzerinde tahmin üretilmiş ve genel doğruluk, makro Precision/Recall/F1 ile Cohen's Kappa ölçütleri hesaplanmıştır. Elde edilen sonuçlar Tablo 4.6'da ortalama $\pm$ standart sapma biçiminde özetlenmiştir. Tablodaki düşük standart sapma değerleri; eğitim/test örnekleri değişse dahi başarımın büyük ölçüde korunduğunu ve önerilen EPF+PCA+SVM tabanlı sınıflandırma yaklaşımının rastgeleliğe karşı duyarlılığının sınırlı kaldığını göstermektedir. PCA, her yinelemede yalnızca eğitim verisi üzerinde öğrenilmiş ve elde edilen aynı dönüşüm test verisine uygulanmıştır.Bu bulgular, PCA sonrasında uygulanan SVM tabanlı sınıflandırmanın yüksek doğruluğu tutarlı biçimde koruduğunu ve deneyler arasında düşük varyans gösterdiğini ortaya koymaktadır. Buna bağlı olarak, elde edilen başarımın istatistiksel açıdan güvenilir ve tekrarlanabilir olduğu anlaşılmaktadır. Ek olarak, her tekrarda PCA dönüşümü ile SVM eğitim ve test süreleri kaydedilerek yöntemin hesaplama yükü de nicel olarak izlenmiştir.

Sonuç olarak, eğitim verisinin yalnızca %1 gibi oldukça sınırlı bir oranla oluşturulduğu bu senaryoda dahi tekrarlı deneylerde gözlenen kararlı sonuçlar, tez kapsamında önerilen EPF+PCA+SVM tabanlı sınıflandırma yaklaşımının tutarlı bir performans sergilediğini göstermektedir. Bu bulgu, söz konusu yöntemin az etiketli

veri koşullarında güvenilir ve tekrarlanabilir bir sınıflandırma çerçevesi sunduğuna işaret etmektedir.

Tablo 4.6 PCA sonrası SVM için 10 tekrarlı deneylerde genel doğruluk (OA) ortalama $\pm$ standart sapma sonuçları

Filtre	Model	SFBay_C (OA)	SFBay_L (OA)	Flevo_C (OA)	Flevo_L (OA)	Ortalama (OA)
DT	SVM	0.9707 ± 0.0007	0.9996 ± 0.0002	0.9907 ± 0.0005	$\mathbf{0.9685 \pm 0.0017}$	0.9824
BF	SVM	0.9758 ± 0.0006	0.9998 ± 0.0001	0.9908 ± 0.0007	0.9660 ± 0.0021	0.9831
FGS	SVM	$\mathbf{0.9767 \pm 0.0009}$	$\mathbf{0.9999 \pm 0.0000}$	$\mathbf{0.9928 \pm 0.0006}$	0.9663 ± 0.0022	**0.9839**

4.4.6 100-Katlı Stratified Çapraz Doğrulama Sonuçlarının Değerlendirilmesi

Bu alt bölümde, önerilen EPF+PCA+SVM tabanlı sınıflandırma yaklaşımının SFBay_C veri kümesi üzerindeki genellenebilirliğini daha güvenilir biçimde incelemek amacıyla $K = 100$ olacak şekilde 100-katlı K-Fold çapraz doğrulama uygulanmıştır. Bu değerlendirme, önceki alt bölümde kullanılan 10 tekrarlı $\%1$ eğitim ve $\%99$ test rastgele bölme düzeninden farklı olarak, etiketli örnek havuzunu sabit biçimde 100 parçaya ayırmaktadır. Ayrıca her yinelemede farklı bir parçayı test ederek performansı tüm örnekler üzerinde sistematik biçimde ölçmektedir. Deney kapsamında EPF ile zenginleştirilmiş öznitelik temsili oluşturulmuş olup PCA ile boyut indirgeme uygulanmıştır. Elde edilen temsiller üzerinden SVM sınıflandırması yapılmıştır. Bu değerlendirmenin amacı, yöntemin farklı bölünmeler altında ne ölçüde tutarlı sonuçlar verdiğini nicel olarak ortaya koymaktır. Ayrıca, hesaplama süreleri açısından sergilediği davranış da nicel biçimde incelemektir.

Bu deneyde SVM sınıflandırıcısının seçilmesinin temel nedeni, önceki karşılaştırmalarda (filtresiz ve EPF sonrası) en yüksek ve en tutarlı doğruluk değerlerini üreten sınıflandırıcı olarak öne çıkmasıdır. Benzer şekilde FGS filtresi, önceki karşılaştırmalarda elde edilen doğruluk ölçütleri üzerinden, homojen bölgelerdeki kararlılığı artırırken sınıf sınırlarının korunumu açısından en belirgin iyileşmeleri sağlayan EPF yaklaşımı olarak öne çıkmıştır. Bu nedenle 100-katlı değerlendirme, tez kapsamında önerilen yaklaşımın temsil gücü en yüksek yapılandırması üzerinde, daha yoğun ve istatistiksel açıdan daha güvenilir bir ölçüm elde etmeye odaklanmıştır.

Bu doğrultuda SFBay_C veri kümesi üzerinde, kenar koruyucu FGS filtresi üç farklı parametre seviyesiyle (düşük–orta–yüksek) uygulanarak 4 temel kanal (T11, T22, T33, SPAN) üzerinden toplam 12 kanallı bir temsil elde edilmiştir. Ardından bu temsil, hesaplama maliyetini ve boyutluluğu azaltmak amacıyla PCA ile 12 boyuttan 3 boyuta indirgenmiştir. Sınıflandırma aşamasında, her etiketli piksel

konumu merkez alınarak $21 \times 21 \times 3$ boyutunda yamalar çıkarılmış, bu yamalar vektörleştirilerek RBF çekirdekli SVM sınıflandırıcısına girdi olarak verilmiştir. Çapraz doğrulamada, train ve test etiketleri bir araya getirilerek tek bir etiketli örnek havuzu oluşturulmuş ve bu havuz 100 parçaya ayrılmıştır. StratifiedKFold ile her yinelemede sınıf oranları korunacak şekilde yaklaşık %1'lik kısım eğitim ve kalan %99'luk kısım test olarak kullanılmıştır. Her bölümleme (fold) için accuracy, macro-Precision, macro-Recall, macro-F1 ve Cohen's Kappa metrikleri ile birlikte PCA süresi, eğitim süresi ve test süresi hesaplanmıştır. Bu kapsamda 100 bölümleme (fold) sonucunda elde edilen ortalama ve standart sapma değerleri Tablo 4.7'de sunulmuştur.

Genel olarak bu deney, tez kapsamında önerilen EPF+PCA+SVM tabanlı sınıflandırma yaklaşımının tek bir bölünmeye bağlı kalmadan farklı alt bölünmeler altında da yüksek ve tutarlı performans sergilediğini göstermektedir. Ayrıca, standart sapma değerlerinin düşük seyretmesi, önerilen yaklaşımın farklı bölünmeler altında kararlı sonuçlar ürettiğini ve bu nedenle istatistiksel açıdan güvenilir ve genellenebilir bir sınıflandırma çerçevesi sunduğunu ortaya koymaktadır.

Tablo 4.7 SFBay_C veri kümesi için 100-katlı Stratified çapraz doğrulama sonuçları (Ortalama $\pm$ Std)

Metrik	**Ortalama $\pm$ Std**
Accuracy	0.9765 ± 0.0007
Precision (macro)	0.9771 ± 0.0007
Recall (macro)	0.9767 ± 0.0007
F1-score (macro)	0.9768 ± 0.0007
Cohen's Kappa	0.9706 ± 0.0008
PCA süresi (s)	2.0487 ± 0.2345
Eğitim süresi (s)	0.2795 ± 0.0159
Test süresi (s)	100.0203 ± 6.1700

4.4.7 Genel Karşılaştırma: Filtresiz, EPF+SVM ve EPF+PCA+SVM

Bu alt bölümde, tez kapsamında kurgulanan deneylerin temel çıktıları bir araya getirilerek filtresiz, EPF+SVM tabanlı sınıflandırma ve EPF+PCA+SVM tabanlı sınıflandırma olmak üzere üç ana yaklaşımın genel bir karşılaştırması sunulmuştur. Karşılaştırma, dört farklı SAR veri kümesi üzerinde elde edilen genel doğruluk (OA) değerleri üzerinden yapılmıştır. Böylece kenar koruyucu filtrelerin ve PCA tabanlı boyut indirgeme adımının sınıflandırma performansına etkisi bütüncül bir biçimde incelenmiştir. Bu etkinin yalnızca doğruluk artışıyla sınırlı kalmayıp kararlılık ve genellenebilirlik açısından da sağladığı katkı ortaya konmuştur. Bu

bağlamda yapılan özetleme, tez kapsamında önerilen EPF+PCA+SVM tabanlı sınıflandırma yaklaşımının önceki basamaklara göre hangi yönde ayrıştığını ortaya koymayı amaçlamaktadır. Ayrıca, az etiketli veri koşullarında daha güvenilir bir performans düzeyine hangi bileşenlerle ulaşıldığını netleştirmeyi hedeflemektedir.

Karşılaştırmanın adil ve doğrudan yapılabilmesi için tüm yaklaşımlarda aynı temel SAR kanalları (T11, T22, T33, SPAN) kullanılmıştır. Filtresiz ve EPF sonrası geleneksel makine öğrenmesi deneylerinde, literatürde yaygın yaklaşımlarla uyumlu biçimde olacak şekilde her veri kümesine uygun patch boyutları seçilmiştir. Buna karşılık, bu tezde önerilen yöntem kapsamında karşılaştırılabilirliği korumak amacıyla yama boyutu sabit tutulmuş ve tüm veri kümelerinde 21×21 olarak kullanılmıştır. Böylece gözlenen iyileşmelerin, yama optimizasyonundan bağımsız biçimde, doğrudan EPF ile temsil zenginleştirme ve PCA ile seçici boyut indirgeme adımlarından kaynaklandığı daha açık bir şekilde yorumlanabilmiştir. Bu tercih, özellikle az etiketli senaryolarda parametre arama alanını büyütmeden, yöntemin pratikte daha uygulanabilir bir çerçeve sunmasını da desteklemektedir.

Bu kapsamda, filtresiz senaryoda yüksek başarı üreten en iyi üç geleneksel sınıflandırıcı (Extra Trees, CatBoost ve SVM) referans olarak ele alınmıştır. Ardından, kenar koruyucu filtrelerin doğrudan etkisini göstermek üzere EPF sonrası SVM sonuçları, son olarak da tez kapsamında önerilen EPF+PCA+SVM tabanlı sınıflandırma yaklaşımı kapsamında elde edilen sonuçlar değerlendirilmiştir.

Güçlü sınıflandırıcılar, filtresiz senaryoda dahi, Tablo 4.8'de de görüldüğü üzere, yüksek doğruluk değerlerine ulaşabilmektedir. Ancak performansın, veri kümesi ve sahne yapısına bağlı olarak daha değişken bir karakter sergilediği dikkat çekmektedir. Bu durum, gürültüye bağlı dalgalanmaların ve sınıf geçiş bölgelerindeki belirsizliğin, özellikle heterojen sahnelerde karar sınırlarını daha kırılgan hale getirmesiyle ilişkilendirilebilir. Bu kırılganlık, az etiketli veri koşullarında daha görünür hale gelmektedir. Sınırlı eğitim örneğiyle öğrenilen sınıf temsillerinin gürültü ve yerel tutarsızlıklara daha açık kalmasına yol açabilmektedir.

EPF+SVM tabanlı sınıflandırma yaklaşımında, tüm veri kümelerinde genel doğruluk değerlerinin yükselmesi; kenar koruyucu filtrelerin gürültüye bağlı dalgalanmaları bastırırken sınıf sınırlarını koruyan daha kararlı bir temsil ürettiğini göstermektedir. Az etiketli senaryolarda öne çıkan bu katkı, daha temiz bir temsil sayesinde sınırlı örnekle öğrenilen karar sınırlarının daha az bozulmasına işaret etmektedir. Ayrıca farklı sahnelerde benzer yüksek başarım düzeylerine yaklaşılması, genellenebilirliğin arttığını göstermektedir. Filtre türleri arasında FGS ve BF sonuçlarının, çoğu veri kümesinde DT'ye göre daha güçlü bir iyileştirme

sağlaması dikkat çekmektedir. Bu durum, filtrelerin düzleştirme ile kenar koruma dengesini farklı biçimde kurmasına bağlı olarak daha elverişli bir özellik uzayı üretmesiyle açıklanabilir. Tez kapsamında önerilen EPF+PCA+SVM tabanlı sınıflandırma yaklaşımı ise, bu iyileştirmeyi bir adım ileri taşıyarak az etiketli veri koşullarında kritik olan temsil seçiciliğini artırmaktadır. PCA'nın eklenmesi, EPF ile zenginleştirilen 12 kanallı temsildeki fazlalığı azaltıp daha ayırt edici bileşenleri öne çıkarmıştır. Böylece doğruluk değerleri yüksek seviyede yakınsamıştır. Bu noktada kritik katkı, PCA'nın yalnızca doğruluğu artırması değil, aynı zamanda filtreler arası farkları daraltarak yöntemi daha kararlı hale getirmesidir. Bu özellik, az etiketli senaryolarda aşırı uyum (overfitting) riskini sınırlayan bir etki sunmaktadır. Bu sayede SVM'nin daha genellenebilir karar sınırları öğrenmesine katkı sağlayan bir avantaj olarak değerlendirilebilir. Buna ek olarak, en yüksek ve en dengeli sonuçların çoğunlukla FGS tabanlı yaklaşımlarda elde edilmesi, FGS'nin sınıf sınırları ve homojen bölgelerde tutarlılık açısından daha elverişli bir öznitelik tabanı sağladığını düşündürmektedir.

Genel olarak bu özet karşılaştırma, filtresiz güçlü sınıflandırıcıların yüksek genel doğruluklara ulaşabilse bile, tezde önerilen EPF+PCA+SVM tabanlı sınıflandırma yaklaşımının sabit kanal seti ve sabit yama boyutu altında dahi az etiketli veri koşullarında performansı daha istikrarlı ve genellenebilir hale getirdiğini göstermektedir. Dolayısıyla elde edilen katkı, yalnızca tekil veri kümelerinde en yüksek doğruluğa ulaşmaktan öte, sınırlı etiket bilgisini daha verimli kullanan bir yaklaşım sunmaktır. Farklı sahneler altında benzer yüksek performans seviyelerini sürdürebilen ve bileşenleri açıkça analiz edilebilir bir sınıflandırma çerçevesi ortaya koymaktadır.

Tablo 4.8 Dört SAR veri setinde filtresiz en iyi üç ML, EPF+SVM ve EPF+PCA+SVM yöntemlerinin OA karşılaştırması

Kategori	**Filtre**	**Model**	**SFBay_C**	**SFBay_L**	**Flevo_C**	**Flevo_L**
Filtresiz en iyi 3 ML	–	Extra Trees	0.9204	0.9672	0.9738	**0.9476**
	–	CatBoost	0.9420	0.9484	0.9800	0.9438
	–	SVM	**0.9607**	**0.9838**	**0.9809**	0.9366
EPF+SVM	DT	SVM	0.9664	0.9884	0.9840	0.9721
	BF	SVM	**0.9752**	0.9918	0.9857	0.9672
	FGS	SVM	0.9705	**0.9958**	**0.9878**	**0.9812**
EPF+PCA+ SVM	DT	SVM	0.9709	0.9898	0.9883	**0.9797**
	BF	SVM	0.9739	0.9905	0.9891	0.9785
	FGS	SVM	**0.9767**	**0.9924**	**0.9908**	0.9766

4.4.8 Literatür ile Karşılaştırmalı Değerlendirme

Bu alt bölümde, tez kapsamında önerilen EPF+PCA+SVM tabanlı sınıflandırma yaklaşımından elde edilen deneysel sonuçlar, literatürde yer alan seçili çalışmalarla karşılaştırmalı olarak değerlendirilmiştir. Karşılaştırma, aynı veya benzer SAR veri kümeleri üzerinde bildirilen genel doğruluk (OA) değerleri ve kullanılan eğitim oranları esas alınarak gerçekleştirilmiştir. Bu değerlendirmenin temel amacı, önerilen yöntemin yalnızca doğruluk düzeyini değil, özellikle az etiketli veri koşullarında temsil gücü ve veri verimliliği açısından ne sunduğunu ortaya koymaktır. Ayrıca yöntemin pratik uygulanabilirlik bakımından literatürdeki güncel yaklaşımlar karşısındaki konumunu netleştirmektir.

Karşılaştırma sürecinde, SFBay_C, SFBay_L, Flevo_C ve Flevo_L dört farklı SAR veri kümeleri üzerinde yapılan çalışmaların sonuçları dikkate alınmıştır.Ayrıca farklı ağ mimarileri, eğitim oranları ve yöntemsel karmaşıklıklar arasındaki farkların daha sağlıklı yorumlanabilmesi hedeflenmiştir. Bu bağlamda, literatürde yer alan birçok derin öğrenme ve hibrit yaklaşımın yüksek doğruluk değerleri ürettiği görülmektedir. Ancak bu başarıların çoğunlukla daha yüksek eğitim oranları, karmaşık ağ yapıları ve uzun eğitim süreleri gerektirdiği gözlemlenmektedir. Özellikle kapsül ağlar, GAN tabanlı yapılar ve dikkat mekanizmaları içeren modeller, temsil gücü avantajı sağlasa da, pratik kullanımda yüksek hesaplama maliyeti ve etiket gereksinimi gibi sınırlılıklar barındırmaktadır. Buna karşılık, bu tezde önerilen EPF+PCA+SVM tabanlı sınıflandırma yaklaşımı, derin ağlara dayanmayan ve geleneksel makine öğrenmesi temelli bir sınıflandırma düzeni ortaya koymaktadır. Bu sayede uzun eğitim sürelerine ve karmaşık model optimizasyonlarına ihtiyaç duymadan rekabetçi doğruluk seviyelerine ulaşmaktadır. Önerilen yöntemde, dört temel SAR kanalından (T11, T22, T33, SPAN) başlayan temsil, kenar koruyucu filtreler ile zenginleştirilmiştir. Böylece PCA ile daha seçici ve kompakt bir öznitelik uzayına indirgenmiş ve son aşamada RBF çekirdekli SVM ile sınıflandırılmıştır. Bu çerçevede önerilen yöntem, sınırlı etiket bilgisinin daha verimli kullanılmasına olanak tanıyan yalın ve sistematik bir çerçeve sunmaktadır.

Literatürde bazı çalışmalarda yama (patch) boyutunun veri kümesine veya yönteme göre ayarlanabildiği görülmektedir.Buna karşın, bu tezde önerilen yaklaşımda patch boyutu tüm deneylerde sabit tutulmuştur. Tüm veri kümeleri için sabit yama kullanılması, elde edilen katkının ek bir yama optimizasyonuna bağlı olmadan, doğrudan EPF ile temsil zenginleştirme ve PCA ile boyut indirgeme adımlarından kaynaklandığını açık biçimde göstermektedir. Bu tercih, özellikle az etiketli senaryolarda yöntem tasarımının daha kontrollü ve genellenebilir olmasını desteklemektedir.

Literatür ile karşılaştırmalı değerlendirmelerin sonuçları Tablo 4.9'da sunulmuştur. Tablodaki bulgulara bakıldığında, önerilen EPF+PCA+SVM tabanlı sınıflandırma yaklaşımının yalnızca %1 eğitim verisi kullanmasına rağmen tüm veri kümelerinde literatürdeki birçok güçlü derin öğrenme yöntemine kıyasla rekabetçi, bazı durumlarda ise üstün genel doğruluk değerleri elde ettiği görülmektedir. Özellikle Özellikle FGS tabanlı yaklaşımın, düşük eğitim oranına rağmen yüksek doğruluk üreterek başarılı bir denge kurduğu görülmektedir. Bu bulgu, sınırlı etiketli SAR sınıflandırma problemlerinde geleneksel makine öğrenmesi temelli yöntemlerin halen güçlü ve uygulanabilir bir alternatif sunduğunu ortaya koymaktadır.

Genel olarak bu karşılaştırmalı değerlendirme, önerilen yöntemin yalnızca doğruluk düzeyiyle sınırlı kalmadığını göstermektedir. Aynı zamanda veri verimliliği, hesaplama maliyeti ve yöntemsel yalınlık açısından literatürdeki birçok yaklaşıma kıyasla belirgin avantajlar sunduğu görülmektedir.

Tablo 4.9 Seçili çalışmalar ile EPF+PCA+SVM yönteminin SFBay_C/L ve Flevo_C/L veri kümelerinde OA ve eğitim oranı karşılaştırması

Yöntem / Yıl	Eğitim oranı	SFBay_C	SFBay_L	Flevo_C	Flevo_L
SDBCS [54]	SFBay_C: %1 Flevo_L: %1	0.9200	–	–	0.9187
U-Net [60]	SFBay_C: %2 SFBay_L: %2 Flevo_L: %9	0.9285	0.9627	–	0.9476
LI-PS-SF [52]	SFBay_C: %0.003 Flevo_L: %0.02	0.9518	–	–	0.9601
CCNN [58]	SFBay_C: %1 SFBay_L: %1.5 Flevo_C: %1 Flevo_L: %2	0.9532	0.9939	0.9631	0.8368
SDF2Net [51]	SFBay_L: %1 Flevo_L: %1	–	0.9713	–	0.9601
WT [53]	SFBay_L: %5 Flevo_L: %10	–	0.9691	–	0.9925
MCFCN [55]	SFBay_C: %5	0.9852	–	–	–
MWGCN [64]	SFBay_C: %1.5 SFBay_L: %1.5 Flevo_L: %4	0.9849	0.9876	–	0.9816
CV-MSA+ViT [59]	SFBay_L: %1 Flevo_L: %1	–	0.9812	–	0.9835
CLIGUNet [66]	SFBay_C: %1.5 SFBay_L: %1.5 Flevo_L: %4	0.9914	0.9902	–	0.9951
Önerilen Yöntem	SFBay_C: %1 SFBay_L: %1.5 Flevo_C: %1 Flevo_L: %2	0.9767	0.9924	0.9908	0.9766

5
SONUÇ

Bu tez çalışmasında, SAR görüntülerinde benek gürültüsü ile birlikte yansıma ve saçılma karakteristiğinin dalga boyu ve görüntüleme geometrisine bağlı değişimi ile sınırlı etiketli veri koşullarının sınıflandırmayı zorlaştırdığı dikkate alınmıştır. Bu bağlamda, kenar koruyucu filtreler temelli sistematik bir ön işleme ve sınıflandırma çerçevesi geliştirilmiş ve değerlendirilmiştir. Bu çerçevede BF, DT ve FGS filtreleri; SVM, RF ve KNN sınıflandırıcılarıyla birlikte SFBay_C, SFBay_L, Flevo_C ve Flevo_L veri kümeleri üzerinde karşılaştırmalı olarak incelenmiştir. Elde edilen bulgular, EPF kullanımının filtreleme öncesine kıyasla yerel yapıları daha kararlı hale getirdiğini ve sınıf içi dalgalanmaları azalttığını göstermiştir. Ayrıca EPF, sınır seçiciliğini korurken sınıflandırma haritalarında mekansal tutarlılığı artırmıştır. Özellikle SVM tabanlı yaklaşımlarda EPF sonrasında genel doğrulukta belirgin artışlar gözlenmiştir. BF, DT ve FGS filtrelerinin farklı sahne karakteristiklerinde birbirini tamamlayan avantajlar sunduğu ortaya konmuştur. Bu sonuçlar, filtre–sınıflandırıcı seçimine yönelik pratik bir değerlendirme zemini sağlayarak EPF'lerin SAR sınıflandırma yöntemlerinde etkin bir ön işleme adımı olduğunu göstermektedir.

Tezin ikinci ana katkısı, EPF ile iyileştirilmiş çok kanallı SAR verisinin PCA ile daha kompakt bir uzaya indirgenmesi ve yama tabanlı temsiller üzerinden SVM ile sınıflandırılmasıdır. Önerilen EPF+PCA+SVM tabanlı yöntem dört veri kümesinde yaklaşık %97–%99 aralığında genel doğruluk değerlerine ulaşmıştır. FGS ve BF özellikle SFBay_L ve Flevo_C sahnelerinde %99'a yaklaşan performans sergilemiştir. Bu kazanımların önemli bir yönü, yöntemin az etiketli veri koşullarında daha kararlı bir temsil üreterek sınıf ayrımını güçlendirmesi ve eğitim/test bölünmelerine duyarlılığı azaltmaya yardımcı olmasıdır. Dolayısıyla önerilen yaklaşım, sınırlı etiketli ve hesaplama kaynaklarının kısıtlı olabileceği gerçekçi senaryolarda dahi yüksek doğruluk, kararlılık ve uygulanabilirlik sunan düşük karmaşıklıklı bir çözüm sağlamaktadır.

Buna karşın EPF parametrelerinin sahne bağımlılığı, farklı sensör ve geometri

koşullarında genellenebilirliğin daha geniş ölçekte sınanması ve etiketli örnek sayısındaki sınırlılık, çalışmanın doğal kısıtları arasındadır. Gelecek çalışmalarda EPF parametrelerinin uyarlamalı ya da öğrenilebilir biçimde seçilmesi, EPF+PCA yaklaşımının yarı denetimli veya öz denetimli yapılara taşınması ve EPF'nin CNN ya da Transformer tabanlı mimarilerle hibrit kullanımı önemli araştırma yönleri olarak öne çıkmaktadır.

Sonuç olarak bu tez, kenar koruyucu filtrelerin SAR verilerinde benek gürültüsünü bastırma ve sınıf ayrışmasını eş zamanlı iyileştirebilen güçlü araçlar olduğunu ortaya koymaktadır. Elde edilen sonuçlar, EPF'nin PCA ve geleneksel makine öğrenmesi yöntemleriyle birlikte kullanıldığında, az etiketli veri koşullarında da rekabetçi ve güvenilir bir sınıflandırma çerçevesi sunduğunu göstermektedir.

KAYNAKÇA

[1] F. T. Ulaby, R. K. Moore A. K. Fung, *Microwave Remote Sensing: Active and Passive*. Norwood, MA, USA: Artech House, 1986, Vols. I–III.

[2] M. C. Dobson, F. Ulaby L. E. Pierce, "Land-cover classification and estimation of terrain attributes using synthetic aperture radar," *Remote Sensing of Environment*, c. 51, no. 1, ss. 199–214, Ocak 1995.

[3] C. A. Wiley, "Synthetic Aperture Radars," *IEEE Transactions on Aerospace and Electronic Systems*, c. AES-21, ss. 440–443, 1985.

[4] A. Moreira, P. Prats-Iraola, M. Younis, G. Krieger, I. Hajnsek K. P. Papathanassiou, "A Tutorial on Synthetic Aperture Radar," *IEEE Geoscience and Remote Sensing Magazine*, c. 1, no. 1, ss. 6–43, 2013.

[5] S. R. Cloude, *Polarisation: Applications in Remote Sensing*. Oxford University Press, 2010.

[6] C. Oliver S. Quegan, *Understanding synthetic aperture radar images*. SciTech Publishing, 2004.

[7] J. C. Curlander R. N. McDonough, *Synthetic aperture radar: systems and signal processing*. Wiley., 1991.

[8] R. Touzi, "A review of speckle filtering in the context of estimation theory," *IEEE Transactions on Geoscience and Remote Sensing*, c. 40, no. 11, ss. 2392–2404, 2003.

[9] J.-S. Lee, "Speckle analysis and smoothing of synthetic aperture radar images," *Computer Graphics and Image Processing*, c. 17, no. 1, ss. 24–32, 1981.

[10] J. W. Goodman, *Speckle phenomena in optics: theory and applications*. Roberts ve Company Publishers, 2007.

[11] J. S. Lee, M. R. Grunes G. De Grandi, "Polarimetric SAR speckle filtering and its implication for classification," *IEEE Transactions on Geoscience and Remote Sensing*, c. 37, no. 5, ss. 2363–2373, Eyl. 1999.

[12] F. T. Ulaby, F. Kouyate, B. Brisco T. L. Williams, "Textural infornation in SAR images," *IEEE Transactions on Geoscience and Remote Sensing*, no. 2, ss. 235–245, 2007.

[13] L. Van Der Maaten, E. O. Postma, H. J. Van Den Herik ve diğ., "Dimensionality reduction: A comparative review," tek. rap. 66-71, 2009, s. 13.

[14] J.-S. Lee, L. Jurkevich, P. Dewaele, P. Wambacq A. Oosterlinck, "Speckle filtering of synthetic aperture radar images: A review," *Remote sensing reviews*, c. 8, no. 4, ss. 313–340, 1994.

[15] A. Shizutoshi, “A Brief Survey of Recent Edge-Preserving Smoothing Algorithms on Digital Images,” 2021.

[16] F. Zhu, Z. Liang, X. Jia, L. Zhang Y. Yu, “A benchmark for edge-preserving image smoothing,” *IEEE Transactions on Image Processing*, c. 28, no. 7, ss. 3556–3570, 2019.

[17] F. Melgani L. Bruzzone, “Classification of hyperspectral remote sensing images with support vector machines,” *IEEE Transactions on geoscience and remote sensing*, c. 42, no. 8, ss. 1778–1790, 2004.

[18] R. Farhadiani, S. Homayouni A. Safari, “Impact of Polarimetric SAR Speckle Reduction on Classification of Agriculture Lands,” *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, c. 42, ss. 379–385, 2019.

[19] A. Masurkar, R. Daruwala A. Mohite, “Performance analysis of SAR filtering techniques using SVM and Wishart Classifier,” *Remote Sensing Applications: Society and Environment*, c. 34, s. 101 189, 2024.

[20] F. Guo, C. Sun, N. Sun, X. Ma W. Liu, “Integrated quantitative evaluation method of SAR filters,” *Remote Sensing*, c. 15, no. 5, s. 1409, 2023.

[21] J.-S. Lee, M. R. Grunes R. Kwok, “Classification of multi-look polarimetric SAR imagery based on complex Wishart distribution,” *International Journal of Remote Sensing*, c. 15, no. 11, ss. 2299–2311, 1994.

[22] W. Zhang, F. Liu L. Jiao, “SAR image despeckling via bilateral filtering,” *Electronics letters*, c. 45, no. 15, ss. 781–783, 2009.

[23] K. He, J. Sun X. Tang, “Guided image filtering,” *IEEE transactions on pattern analysis and machine intelligence*, c. 35, no. 6, ss. 1397–1409, 2012.

[24] E. S. Gastal M. M. Oliveira, “Domain transform for edge-aware image and video processing,” içinde *ACM SIGGRAPH 2011 papers*, 2011, ss. 1–12.

[25] K. He J. Sun, “Fast guided filter,” *arXiv preprint arXiv:1505.00996*, 2015.

[26] D. Min, S. Choi, J. Lu, B. Ham, K. Sohn M. N. Do, “Fast global image smoothing based on weighted least squares,” *IEEE Transactions on Image Processing*, c. 23, no. 12, ss. 5638–5653, 2014.

[27] S. Reich, A. Abramov, J. Papon, F. Wörgötter B. Dellen, *A novel real-time edge-preserving smoothing filter*, 2013.

[28] X. Kang, S. Li J. A. Benediktsson, “Spectral–spatial hyperspectral image classification with edge-preserving filtering,” *IEEE transactions on geoscience and remote sensing*, c. 52, no. 5, ss. 2666–2677, 2013.

[29] S. Zhong, C.-l. Chang Y. Zhang, “Iterative edge preserving filtering approach to hyperspectral image classification,” *IEEE Geoscience and Remote Sensing Letters*, c. 16, no. 1, ss. 90–94, 2018.

[30] X. Kang, P. Duan S. Li, “Hyperspectral image visualization with edge-preserving filtering and principal component analysis,” *Information Fusion*, c. 57, ss. 130–143, 2020.

[31] J. Jiang, J. Ma, C. Chen, Z. Wang, Z. Cai L. Wang, "SuperPCA: A superpixelwise PCA approach for unsupervised feature extraction of hyperspectral imagery," *IEEE Transactions on Geoscience and Remote Sensing*, c. 56, no. 8, ss. 4581–4593, 2018.

[32] A. Alonso-González, C. López-Martınez, P. Salembier X. Deng, "Bilateral distance based filtering for polarimetric SAR data," *Remote Sensing*, c. 5, no. 11, ss. 5620–5641, 2013.

[33] M. Mousavi, J. Amini, Y. Maghsoudi S. Arab, "PolSAR speckle filtering techniques and their effects on classification," *Proceedings of the Imaging and Geospatial Technology Forum, IGTF*, 2015.

[34] A. D. B. Garcia, J. J. Celeste, I. Cheng, V. H. R. Prudente I. D. Sanches, "Evaluation of multiple SAR speckling filter techniques performance in irrigated rice areas," *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, c. 48, ss. 169–176, 2024.

[35] W. Wang ve diğ., "A fast, edge-preserving, distance-regularized model with bilateral filtering for oil spill segmentation of SAR images," *Journal of Oceanology and Limnology*, c. 39, no. 4, ss. 1198–1210, 2021.

[36] D. Song ve diğ., "An efficient marine oil spillage identification scheme based on an improved active contour model using fully polarimetric SAR imagery," *IEEE Access*, c. 6, ss. 67 959–67 981, 2018.

[37] J. Y. Liu, Z. N. Zhang H. M. Yang, "A variational level set remote sensing SAR image segmentation approach for oil spill detecting based on fuzzy cluster," *Applied mechanics and materials*, c. 719, ss. 1049–1055, 2015.

[38] A. Lapini ve diğ., "Application of deep learning to optical and SAR images for the classification of agricultural areas in Italy," *IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium*, IEEE, 2020, ss. 4163–4166.

[39] R. Garg, A. Kumar, N. Bansal, M. Prateek S. Kumar, "Semantic segmentation of PolSAR image data using advanced deep learning model," *Scientific reports*, c. 11, no. 1, s. 15 365, 2021.

[40] J. Li, J. M. Bioucas-Dias A. Plaza, "Classification of Hyperspectral Images by SVM Using a Composite Kernel by Employing Spectral, Spatial and Hierarchical Structure Information," *IEEE Transactions on Geoscience and Remote Sensing*, c. 51, no. 4, ss. 1992–2004, 2013.

[41] A. R. Aghajani Fesharaki M. Emadi, "Classification of SAR images in urban areas with the combination of FCM and SVM," *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, c. 5, no. 8, 2016.

[42] N. Wang, W. Jin, H. Bi, C. Xu J. Gao, "A survey on deep learning for few-shot PolSAR image classification," *Remote Sensing*, c. 16, no. 24, s. 4632, 2024.

[43] A. A. Aleissaee ve diğ., "Transformers in Remote Sensing: A Survey," *arXiv*, 2023, arXiv:2209.01206.

[44] Y. Wang, Z. Guo, H. Bi, D. Hong C. Xu, "Dual-Branch PolSAR Image Classification Based on GraphMAE and Local Feature Extraction," *Proceedings of IGARSS 2024*, arXiv:2408.04294, 2024.

[45] A. Zhang ve diğ., "Superpixel-Based Convolutional Neural Network for Polarimetric SAR Image Classification," *Remote Sensing*, 2019.

[46] Y. Cheng ve diğ., "Hierarchical Capsule Network with Conditional Random Field for Polarimetric SAR Image Classification," *IEEE Geoscience and Remote Sensing Letters*, 2021.

[47] C. Yang ve diğ., "N-Cluster loss and hard sample generative deep metric learning for PolSAR image classification," *IEEE Transactions on Geoscience and Remote Sensing*, c. 60, ss. 1–16, 2021.

[48] Y. Wang ve diğ., "MCPT: Mixed Convolutional Parallel Transformer for Polarimetric SAR Image Classification," *Remote Sensing*, 2023.

[49] H. Wang ve diğ., "Attention-Based Multiscale Sequential Network for Polarimetric SAR Image Classification," *IEEE Geoscience and Remote Sensing Letters*, 2022.

[50] C. Cui ve diğ., "Polarimetric Multi-Path Convolutional Neural Network for Polarimetric SAR Image Classification," *IEEE Transactions on Geoscience and Remote Sensing*, 2022.

[51] M. Q. Alkhatib ve diğ., "SDF2Net: Shallow to Deep Feature Fusion Network for Polarimetric SAR Image Classification," *arXiv:2402.17672*, 2024.

[52] W. Hua, Q. Hou, X. Jin, L. Liu, N. Sun Z. Meng, "A Feature Fusion Network for PolSAR Image Classification Based on Physical Features and Deep Features," *IEEE Geoscience and Remote Sensing Letters*, c. 21, s. 4 012 705, 2024.

[53] A. Jamali, M. Mahdianpari, F. Mohammadimanesh, A. Bhattacharya S. Homayouni, "PolSAR Image Classification Based on Deep Convolutional Neural Networks Using Wavelet Transformation," *IEEE Geoscience and Remote Sensing Letters*, c. 19, s. 4 510 105, 2022.

[54] N. Wang, H. Bi, F. Li, C. Xu J. Gao, "Self-Distillation-Based Polarimetric Image Classification with Noisy and Sparse Labels," *Remote Sensing*, c. 15, s. 5751, 2023.

[55] W. Hua, Y. Wang, S. Yang X. Jin, "PolSAR Image Classification Based on Multi-Modal Contrastive Fully Convolutional Network," *Remote Sensing*, c. 16, s. 296, 2024.

[56] J. Shi, M. Nie, S. Ji, C. Shi, H. Liu H. Jin, "Polarimetric SAR Image Classification Based on Double-Channel Convolution Network and Edge-preserving Markov Random Field," 2023.

[57] X. Yang, X. Yang, C. Zhang J. Wang, "SAR Image Classification Using Markov Random Fields with Deep Learning," *Remote Sensing*, c. 15, no. 3, s. 617, 2023.

[58] M. Ahishali, S. Kiranyaz, T. Ince M. Gabbouj, "Classification of Polarimetric SAR Images Using Compact Convolutional Neural Networks," *GIScience & Remote Sensing*, c. 58, no. 1, ss. 28–47, 2021.

[59] M. Q. Alkhatib, "PolSAR image classification using complex-valued multiscale attention vision transformer (CV-MsAtViT)," *International Journal of Applied Earth Observation and Geoinformation*, c. 137, s. 104 412, 2025.

[60] S. Ren F. Zhou, "Polsar image classification with complex-valued residual attention enhanced U-Net," *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*, IEEE, 2021, ss. 3045–3048.

[61] J. Geng, W. Jiang X. Deng, "Multi-scale deep feature learning network with bilateral filtering for SAR image classification," *ISPRS Journal of Photogrammetry and Remote Sensing*, c. 167, ss. 201–213, 2020.

[62] X. Liu ve diğ., "Polarimetric SAR image classification based on double-channel convolution network and edge-preserving Markov random field," *IEEE Transactions on Geoscience and Remote Sensing*, c. 60, ss. 1–13, 2022.

[63] A. Zhang ve diğ., "SAR image classification using adaptive neighborhood-based convolutional neural network," *European Journal of Remote Sensing*, c. 52, no. 1, ss. 178–193, 2019.

[64] S. Ren F. Zhou, "Semi-Supervised Classification for PolSAR Data with Multi-Scale Evolving Weighted Graph Convolutional Network," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, c. 14, ss. 2911–2927, 2021.

[65] S. Ren F. Zhou, "Semi-supervised classification of PolSAR data with multi-scale weighted graph convolutional network," *IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium*, IEEE, 2020, ss. 1715–1718.

[66] S. Ren, F. Zhou L. Bruzzone, "Transfer-aware graph U-Net with cross-level interactions for PolSAR image semantic segmentation," *Remote Sensing*, c. 16, no. 8, s. 1428, 2024.

[67] Y. Lou, Y. Kim J. Van Zyl, "The NASA/JPL airborne synthetic aperture radar system," *Summaries of the Sixth Annual Airborne Science Workshop*, California: Jet Propulsion Laboratory (JPL), c. 2, 1996, ss. 4–8.

[68] European Space Agency (ESA), "RADARSAT-2 Product Description," European Space Agency, Product Description, 2011. erişim adresi: `https://earth.esa.int/eogateway/documents/20142/0/Radarsat-2-Product-description.pdf` (erişim tarihi 22/12/2025).

[69] W. Chen, S. Gou, X. Wang, X. Li L. Jiao, "Classification of PolSAR Images Using Multilayer Autoencoders and a Self-Paced Learning Approach," *Remote Sensing*, c. 10, no. 1, 2018.

[70] J. Feng, Z. Cao Y. Pi, "Polarimetric contextual classification of PolSAR images using sparse representation and superpixels," *Remote Sensing*, c. 6, no. 8, ss. 7158–7181, 2014.

[71] Z. Fang, G. Zhang, Q. Dai, B. Xue P. Wang, “Hybrid attention-based encoder–decoder fully convolutional network for PolSAR image classification,” *Remote Sensing*, c. 15, no. 2, s. 526, 2023.

[72] S. Kiranyaz, T. Ince, S. Uhlmann M. Gabbouj, “Collective network of binary classifier framework for polarimetric SAR image classification: An evolutionary approach,” *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, c. 42, no. 4, ss. 1169–1186, 2012.

[73] S. Uhlmann S. Kiranyaz, “Integrating color features in polarimetric SAR image classification,” *IEEE Transactions on Geoscience and Remote Sensing*, c. 52, no. 4, ss. 2197–2216, 2013.

[74] W. Yang, X. Zhang, L. Chen H. Sun, “Semantic segmentation of polarimetric SAR imagery using conditional random fields,” *2010 IEEE International Geoscience and Remote Sensing Symposium*, IEEE, 2010, ss. 1593–1596.

[75] X. Kang, X. Xiang, S. Li J. A. Benediktsson, “PCA-based edge-preserving features for hyperspectral image classification,” *IEEE Transactions on Geoscience and Remote Sensing*, c. 55, no. 12, ss. 7140–7151, 2017.

[76] J.-S. Lee E. Pottier, *Polarimetric radar imaging: from basics to applications*. CRC press, 2017.

[77] E. Krogager, “New decomposition of the radar target scattering matrix,” *Electronics letters*, c. 26, no. 18, ss. 1525–1527, 1990.

[78] Y. Yamaguchi, J. Nakamura, K. Aoyama H. Yamada, “Coherent Decomposition of Fully Polarimetric Radar Data,” *IGARSS 2008 - 2008 IEEE International Geoscience and Remote Sensing Symposium*, c. 4, 2008, ss. IV - 161-IV –164.

[79] E. Pottier, “Dr. JR Huynen’s main contributions in the development of polarimetric radar techniques and how the’Radar Targets Phenomenological Concept’becomes a theory,” *Radar polarimetry*, SPIE, c. 1748, 1993, ss. 72–85.

[80] S. R. Cloude E. Pottier, “An entropy based classification scheme for land applications of polarimetric SAR,” *IEEE transactions on geoscience and remote sensing*, c. 35, no. 1, ss. 68–78, 2002.

[81] A. Freeman S. L. Durden, “A three-component scattering model for polarimetric SAR data,” *IEEE transactions on geoscience and remote sensing*, c. 36, no. 3, ss. 963–973, 2002.

[82] C. Tomasi R. Manduchi, “Bilateral Filtering for Gray and Color Images,” *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, 1998, ss. 839–846.

[83] J. Long, K. Zhang, Y. Liu, S. Chen Q. Luo, “Edge-preserving image smoothing via sparse gradient enhancement,” *Pattern Analysis and Applications*, c. 28, no. 4, s. 160, 2025.

[84] E. S. L. Gastal M. M. Oliveira, “Domain Transform for Edge-Aware Image and Video Processing,” *ACM Transactions on Graphics*, c. 30, no. 4, 69:1–69:12, 2011.

[85] K. Pearson, "LIII. On lines and planes of closest fit to systems of points in space," *The London, Edinburgh, and Dublin philosophical magazine and journal of science*, c. 2, no. 11, ss. 559–572, 1901.

[86] H. Hotelling, "Analysis of a complex of statistical variables into principal components.," *Journal of educational psychology*, c. 24, no. 6, s. 417, 1933.

[87] H. Abdi L. J. Williams, "Principal component analysis," *Wiley interdisciplinary reviews: computational statistics*, c. 2, no. 4, ss. 433–459, 2010.

[88] I. T. Jolliffe J. Cadima, "Principal component analysis: a review and recent developments," *Philosophical transactions of the royal society A: Mathematical, Physical and Engineering Sciences*, c. 374, no. 2065, s. 20 150 202, 2016.

[89] F. L. Gewers ve diğ., "Principal component analysis: A natural approach to data exploration," *ACM Computing Surveys (CSUR)*, c. 54, no. 4, ss. 1–34, 2021.

[90] R. R. Arvind. "Principal component analysis." Devopedia, 12-Jan-2019. Accessed: 06-Dec-2025. (Ocak 2019), erişim adresi: `https : / / devopedia . org / principal – component – analysis` (erişim tarihi 06/12/2025).

[91] R. Vaddi, B. P. Kumar, P. Manoharan, L. Agilandeeswari V. Sangeetha, "Strategies for dimensionality reduction in hyperspectral remote sensing: A comprehensive overview," *The Egyptian Journal of Remote Sensing and Space Sciences*, c. 27, no. 1, ss. 82–92, 2024.

[92] M. Sheykhmousa, M. Mahdianpari, H. Ghanbari, F. Mohammadimanesh, P. Ghamisi S. Homayouni, "Support vector machine versus random forest for remote sensing image classification: A meta-analysis and systematic review," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, c. 13, ss. 6308–6325, 2020.

[93] T. Adugna, W. Xu J. Fan, "Comparison of random forest and support vector machine classifiers for regional land cover mapping using coarse resolution FY-3C images," *Remote Sensing*, c. 14, no. 3, s. 574, 2022.

[94] Y.-C. Tan, L. Duarte A. C. Teodoro, "Comparative study of random forest and support vector machine for land cover classification and post-wildfire change detection," *Land*, c. 13, no. 11, s. 1878, 2024.

[95] J. A. Ferreira, A. K. Rodrigues, R. Ospina L. Gomez, "Machine learning classification based on k-Nearest Neighbors for PolSAR data," *Anais da Academia Brasileira de Ciências*, c. 96, e20230064, 2024.

[96] T. Cover P. Hart, "Nearest neighbor pattern classification," *IEEE transactions on information theory*, c. 13, no. 1, ss. 21–27, 1967.

[97] L. Breiman, "Random forests," *Machine learning*, c. 45, no. 1, ss. 5–32, 2001.

[98] C. Cortes V. Vapnik, "Support-vector networks," *Machine learning*, c. 20, no. 3, ss. 273–297, 1995.

[99] M. Pal P. M. Mather, "Support vector machines for classification in remote sensing," *International journal of remote sensing*, c. 26, no. 5, ss. 1007–1011, 2005.

[100] Z. John Lu, *The elements of statistical learning: data mining, inference, and prediction*, 2010.

[101] C. M. Bishop N. M. Nasrabadi, *Pattern recognition and machine learning*. Springer, 2006, c. 4.

[102] L. Breiman, J. Friedman, R. A. Olshen C. J. Stone, *Classification and regression trees*. Chapman ve Hall/CRC, 2017.

[103] Y. Freund R. E. Schapire, "A decision-theoretic generalization of on-line learning and an application to boosting," *Journal of computer and system sciences*, c. 55, no. 1, ss. 119–139, 1997.

[104] J. H. Friedman, "Greedy function approximation: a gradient boosting machine," *Annals of statistics*, ss. 1189–1232, 2001.

[105] T. Chen, "XGBoost: A Scalable Tree Boosting System," *Cornell University*, 2016.

[106] P. Geurts, D. Ernst L. Wehenkel, "Extremely randomized trees," *Machine learning*, c. 63, no. 1, ss. 3–42, 2006.

[107] G. Ke ve diğ., "Lightgbm: A highly efficient gradient boosting decision tree," *Advances in neural information processing systems*, c. 30, 2017.

[108] L. Prokhorenkova, G. Gusev, A. Vorobev, A. V. Dorogush A. Gulin, "CatBoost: unbiased boosting with categorical features," *Advances in neural information processing systems*, c. 31, 2018.

TEZDEN ÜRETİLMİŞ YAYINLAR

Konferans Bildirisi

1. B. Akkuş, A. Elbir, & A. C. Karaca, “SAR image classification using edge-preserving filters,” in 2025 9th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT), 2025.