

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

SAR İMGELERİNİN ANLAMBİLİMSEL
SINIFLANDIRILMASI

İLTER TÜRKMENLİ
YÜKSEK LİSANS TEZİ
ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

GEBZE
2018

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

SAR İMGELERİNİN ANLAMBİLİMSEL
SINIFLANDIRILMASI

İLTER TÜRKMENLİ
YÜKSEK LİSANS TEZİ
ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DANIŞMANI
DOÇ. DR. KORAY KAYABOL

GEBZE
2018

T.R.
GEBZE TECHNICAL UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

**SEMANTIC CLASSIFICATION OF SAR
IMAGES**

İLTER TÜRKMENLİ
A THESIS SUBMITTED FOR THE DEGREE OF
MASTER OF SCIENCE
DEPARTMENT OF ELECTRONIC ENGINEERING

THESIS SUPERVISOR
ASSOC. PROF. DR. KORAY KAYABOL

GEBZE
2018

GTÜ Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 27/06/2018 tarih ve 2018/33 sayılı kararıyla oluşturulan jüri tarafından 19/07/2018 tarihinde tez savunma sınavı yapılan İlter TÜRKMENLİ 'nin tez çalışması Elektronik Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI) : Doç. Dr. Koray KAYABOL



ÜYE

: Doç. Dr. Erchan APTOULA



ÜYE

: Dr. Öğr. Üyesi Alp ERTÜRK



ONAY

Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun

...../...../..... tarih ve/..... sayılı kararı.

ÖZET

Çok geniş bir kullanım alanına sahip sentetik açıklık radar(SAR) sistemlerindeki iyileştirmelerle birlikte yüksek çözünürlükte SAR imgeleri elde edilmeye başlanmış ve bunun sonucunda çok fazla bilgi içeren bu imgelerin piksel tabanlı sınıflandırılması yerine anlambilimsel sınıflandırılma ihtiyacı artmıştır. Bu tezde farklı öznitelik çıkarma ve sınıflandırma yöntemleri kullanılarak SAR imgelerinin anlambilimsel sınıflandırılmasında en etkin algoritmalar belirlenmeye çalışılmıştır. Piksel tabanlı sınıflandırma yaparken çözünürlükle birlikte artan işlem yükünün üstesinden gelmek için yama tabanlı anlambilimsel sınıflandırma algoritmaları tercih edilmiştir. Farklı türde öznitelik çıkarma yöntemleri ile elde edilen öznitelikleri sınıflandırmada, bireysel sınıflandırıcıların yanında topluluk öğrenmesine dayalı sınıflandırıcılar da kullanılarak anlambilimsel sınıflandırmada etkinlikleri incelenmiştir. Yaklaşık seyreltik çok terimli bağlanım (YSÇLB) yöntemi, SAR imgelerinin sınıflandırılmasında ilk defa kullanılmış ve diğer sınıflandırma yöntemlerine yakın sonuçlar elde edilmiştir.

Anahtar Kelimeler: Yapay açıklık radar (SAR), yama tabanlı anlambilimsel sınıflandırma, öznitelik çıkarma, topluluk öğrenme tabanlı sınıflandırıcı, YSÇLB.

SUMMARY

The improvements in synthetic aperture radar (SAR) systems having a very wide range of applications lead to obtain high resolution SAR images and consequently to increase the need for semantic classification instead of pixel-based classification of these images containing a lot of information. In this thesis, different feature extraction and classification methods are used to determine the most efficient algorithms for semantic classification of SAR images. Patch-based semantic classification algorithms are preferred to overcome processing load increasing with resolution while making pixel based classification. By using classifiers based on ensemble learning besides individual classifier for classification of features obtained using different feature extraction methods, the effectiveness of these classifiers are examined. Approximate sparse multinomial logistic regression (ASMLR) method is proposed for SAR images classification for the first time and approximate results to other classification methods is obtained.

Key words: SAR image, patch-based semantic classification, feature extraction, ensemble learning based classifier, ASMLR.

TEŞEKKÜR

Yüksek lisans eğitimimde ve bu çalışmanın oluşmasında hiçbir desteğini esirgemeyen danışman hocam Doç. Dr. Koray KAYABOL'a

Bilgi ve tecrübesini esirgemeyerek, çalışmalarına destek olan Doç. Dr. Erchan APTOULA'ya

Başta tezimde emeği geçen Selim ŞAHİN ve Sertaç ARISOY olmak üzere, güzel bir çalışma ve dayanışma ortamı oluşturdıkları için tüm iş arkadaşlarıma,

Tüm destek ve anlayışlarıyla her zaman yanımda olan aileme en içten teşekkürlerimi sunarım.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	v
SUMMARY	vi
İÇİNDEKİLER	viii
SİMGELER VE KISALTMALAR DİZİNİ	x
ŞEKİLLER DİZİNİ	xiii
TABLolar DİZİNİ	xv
1. GİRİŞ	1
1.1. Tezin Amacı, Katkısı ve İçeriği	1
2. SAR İMGELERİNE GENEL BAKIŞ	3
3. YÖNTEMLER	6
3.1. Öznitelik Çıkarma Yöntemleri	6
3.1.1. Gri Seviye Eş-Oluşum Matrisi	6
3.1.2. Gabor Dalgacık Dönüşümü	8
3.1.3. Yerel İkili Örüntü	10
3.1.4. Yönlü Gradyanlar Histogramı	11
3.2. Sınıflandırma Yöntemleri	13
3.2.1. Destek Vektör Makinaları	13
3.2.2. Topluluk Öğrenme Yöntemleri	15
3.2.2.1. Torbalama	16
3.2.2.2. Hızlandırma	18
3.2.2.3. Rastgele Orman	20
3.2.3. Softmax	24
3.2.4. Yaklaşık Seyretilik Çok Terimli Lojistik Bağlanım	25
4. DENEYSEL ÇALIŞMALAR	27
4.1. Veri Seti Oluşturma	27
4.1.1. Görüntü 1 Veri Seti	27
4.1.2. Görüntü 2 Veri Seti	29
4.1.3. Görüntü 3 Veri Seti	30
4.2. Deneysel Sonuçlar	34

5. SONUÇLAR	49
KAYNAKLAR	50
ÖZGEÇMİŞ	55
EKLER	56

SİMGELER VE KISALTMALAR DİZİNİ

<u>Simgeler ve</u> <u>Kısaltmalar</u>	<u>Açıklamalar</u>
SAR	: Sentetik Açıklıklı Radar
GLCM	: Gri Seviye Eş-Oluşum Matris
LBP	: Yerel İkili Örüntü
HOG	: Yönlü Gradyanlar Histogramı
SVM	: Destek Vektör Makinaları
RF	: Rastgele Orman
YSÇLB	: Yaklaşık Seyretilik Çok Terimli Bağlanım
ASMLR	: Approximate Sparse Multinomial Logistic Regression
H	: Yatay
V	: Dikey
HH	: Yatay Yatay
VV	: Dikey Dikey
SM-SAR	: Şerit Haritalama SAR
$P(i, j)$	: Olasılık Değeri
μ_x	: x Yönünde Ortalama
σ_x	: x Yönünde Standart Sapma
μ_y	: y Yönünde Ortalama
σ_y	: y Yönünde Standart Sapma
$LBP_{P,R}(x_c)$	: Yerel İkili Örüntü Etiket değeri
δ_{kj}	: Kronecker delta fonksiyonu
V_k	: Düzgelenmemiş Histogram Değeri
v	: Düzgelenmiş Histogram Değeri/Sensör Hızı
C	: Düzenleme Parametresi
σ	: Çekirdek Genişliği
$P(c x)$	: Sonsal Olasılık
Adaboost	: Adaptif Hızlandırma
ε	: Ağırlıklı Sınıflandırma Hatası
α	: Ağırlık Katsayısı

$y_m(x_n, k)$	: Sınıflandırıcı Güveni
N	: Ağaç Sayısı
m	: Düğüm Değişken Sayısı
CART	: Sınıflandırma ve Bağlanım Ağacı
$E(D)$	: Entropi Değeri
$Gini(T)$	: Gini İndeksi
$Gini_b(T)$	: Bölünmüş Gini İndeksi
$\omega_{1:K}$	: Bağlanım Parametrelerini İçeren Matris
$\ \omega_k\ _1$	: l_1 Normu
s_n	: n. Örneğin Öznitelik Vektörü
λ	: Seyreklik Katsayısı
Θ_a	: Azimut Hüzne Genişliği
r_0	: Sensör ile Hedef Arasındaki En Yakın Yaklaşım Uzaklığı
i	: Referans Piksel
j	: Komşu Piksel
d	: Adım Mesafesi
θ	: Yön Parametresi/Döndürme Açısı
$\tilde{x}$	: θ Açısı Kadar Döndürülmüş Koordinat
$\tilde{y}$	: θ Açısı Kadar Döndürülmüş Koordinat
o_{ij}	: Ortalama
s_{ij}	: Standart Sapma
e_{ij}	: Entropi
P	: Komşu Sayısı
R	: Komşuluk Mesafesi
x_c	: Merkez Pikseli
x_p	: Komşu Pikseli
$u(y)$	: Birim Basamak Fonksiyonu
$I(x, y)$	: İmge
$f_x(x, y)$	: x Yönündeki Gradyan değeri
$f_y(x, y)$	: y Yönündeki Gradyan değeri
$m_x(x, y)$	: Gradyan Büyüklüğü
$\theta_x(x, y)$	: Gradyan Yönü

$E[\hat{f}(x)]$	: $\hat{f}(x)$ Fonksiyonunun Beklenen Değeri
$K(x_i, x_j)$	: Çekirdek Fonksiyonu
σ_e^2	: Azaltılamaz Hata
M	: İterasyon Sayısı
t_n	: n. Elemanın Etiket
$y_1(x)$	: Birinci Sınıflandırıcı
J_m	: Ağırlıklandırılmış Hata Fonksiyonu
OOB	: Out of Bag
$P_t(c v)$	: t. Ağacın Sonsal Olasılığı
z_n	: Etiket Vektörü
$g_k(\omega_k^{(t)})$	: Alt Gradyan Vektörü
AdaboostM2	: Çok Sınıflı Adaptif Hızlandırma
Torbalama (A)	: Ağaç Tabanlı Torbalama
Torbalama (LDA)	: Lineer Diskriminant Analiz Tabanlı Torbalama

ŞEKİLLER DİZİNİ

<u>Sekil No:</u>	<u>Sayfa</u>
2.1: SAR sisteminin görüntüleme geometrisi.	3
2.2: SAR imgelerinin oluşturulmasındaki sinyal işleme adımları.	5
3.1: $d=1$ ve $\theta=(0^\circ, 45^\circ, 90^\circ, 135^\circ)$ olduğundaki komşu pikseler.	7
3.2: a) Görüntü, b) $d=1$ ve $\theta=0^\circ$ olması durumundaki GLCM.	8
3.3: a) Gri seviye yama görüntüsü, b) Yamanın 4 farklı yönlü.	9
3.4: 1 komşuluklu 8-bitlik LBP etiket değerinin belirlenme işlemi	10
3.5: a) LBP(8,1), b) LBP(4,2), c) LBP(8,2).	11
3.6: Yerel histogram oluşturulma işlemi.	12
3.7: İki sınıflı doğrusal olarak ayrılabilen veri setinde sınıflar arasındaki optimum hiper düzlem ve destek vektörleri.	14
3.8: Çekirdek dönüşümleri ile optimum hiper düzlemin belirlenmesi.	14
3.9: Yanlılık ve varyansla ilgili bir gösterim.	15
3.10: Optimum model karmaşıklığı.	16
3.11: Torbalama yöntemi ile sınıflandırma işlemi.	18
3.12: Hızlandırma yöntemi ile sınıflandırma.	19
3.13: Adaboost algoritması.	19
3.14: CART yöntemiyle oluşturulmuş karar ağacı.	21
3.15: Rastgele orman yöntemi ile sınıflandırma.	23
3.16: 3 Farklı ağaçlara ait sonsal olasılık.	24
3.17: Seyrek bağlanım parametresi belirlenirken kullanılan algoritma.	26
4.1: Marsilya SAR imgesi.	28
4.2: a) Görüntü 1, b) Yer doğruluk haritası.	28
4.3: Görüntü 1'in içerdiği sınıfların SAR ve optik görüntüleri.	29
4.4: a) Görüntü 2, b) Yer doğruluk haritası.	29
4.5: Görüntü 2'nin içerdiği sınıfların SAR ve optik görüntüleri.	30
4.6: Shanghai SAR İmgesi.	30
4.7: Görüntü 3.	31
4.8: 3 Sınıf dikkate alınarak elde edilmiş Görüntü 3'e ait yer doğruluk haritası.	31
4.9: 3 Sınıflı Görüntü 3'ün içerdiği sınıflara ait SAR ve optik görüntüler.	32
4.10: 4 sınıflı Görüntü 3'e ait yer doğruluk haritası.	33

4.11:	4 Sınıflı Görüntü 3'ün içerdği sınıflara ait SAR ve optik görüntüler.	33
4.12:	Anlambilimsel sınıflandırma algoritma akış şeması.	34
4.13:	Karışıklık matrisi.	35
4.14:	Görüntü 1'de GLCM öznitelikleriyle elde edilen sınıflandırma haritaları.	36
4.15:	Görüntü 1'de Gabor öznitelikleriyle elde edilen sınıflandırma haritaları.	37
4.16:	Görüntü 1'de LBP öznitelikleriyle elde edilen sınıflandırma haritaları.	37
4.17:	Görüntü 1'de HOG öznitelikleriyle elde edilen sınıflandırma haritaları.	38
4.18:	Görüntü 2'de GLCM öznitelikleriyle elde edilen sınıflandırma haritaları.	39
4.19:	Görüntü 2'de Gabor öznitelikleriyle elde edilen sınıflandırma haritaları.	40
4.20:	Görüntü 2'de LBP öznitelikleriyle elde edilen sınıflandırma haritaları.	40
4.21:	Görüntü 2'de HOG öznitelikleriyle elde edilen sınıflandırma haritaları.	41
4.22:	3 Sınıflı Görüntü 3'de GLCM öznitelikleri kullanılarak elde edilen sınıflandırma haritaları.	42
4.23:	3 Sınıflı Görüntü 3'de Gabor öznitelikleri kullanılarak elde edilen sınıflandırma haritaları.	43
4.24:	3 Sınıflı Görüntü 3'de LBP öznitelikleri kullanılarak elde edilen sınıflandırma haritaları.	43
4.25:	3 Sınıflı Görüntü 3'de HOG öznitelikleri kullanılarak elde edilen sınıflandırma haritaları.	44
4.26:	4 Sınıflı Görüntü 3'de GLCM öznitelikleri kullanılarak elde edilen sınıflandırma haritaları.	45
4.27:	4 Sınıflı Görüntü 3'de Gabor öznitelikleri kullanılarak elde edilen sınıflandırma haritaları.	46
4.28:	4 Sınıflı Görüntü 3'de LBP öznitelikleri kullanılarak elde edilen sınıflandırma haritaları.	46
4.29:	4 Sınıflı Görüntü 3'de HOG öznitelikleri kullanılarak elde edilen sınıflandırma haritaları.	47

TABLÖLAR DİZİNİ

<u>Tablo No:</u>	<u>Sayfa</u>
3.1: GLCM'yi temsil etmede kullanılan öznitelikler ve formülleri.	7
4.1: Görüntü 1'in içerdigi sınıfların etiketleri, adları ve yama sayıları.	28
4.2: Görüntü 2'nin içerdigi sınıfların etiket değeri, adı ve yama sayıları.	30
4.3: 3 Sınıflı Görüntü 3'e ait sınıfların etiket değeri, adı ve yama sayıları.	32
4.4: 4 Sınıflı Görüntü 3'ün içerdigi sınıfların etiket değerleri ve yama sayıları.	33
4.5: Görüntü 1'e ait sınıflandırma sonuçları.	36
4.6: Görüntü 2'ye ait sınıflandırma sonuçları.	39
4.7: 3 Sınıflı Görüntü 3'den elde edilen sınıflandırma sonuçları.	42
4.8: 4 Sınıflı Görüntü 3'den elde edilen sınıflandırma sonuçları.	44

1. GİRİŞ

Sentetik açıklıklı radar (Synthetic aperture radar-SAR), pasif uzaktan algılama sistemlerin aksine kendi ışınımını kendisi üreten aktif bir uzaktan algılama sistemidir. Bu özelliği sayesinde güneş aydınlatmasındaki değişimlerden ve bulutlu havalardan etkilenmeyerek, her türlü hava koşulunda görüntü elde edebilirler. Bu sistemler uygun frekansta çalıştırıldığında başta askeri uygulamalar olmak üzere, tarımdan doğal afet sonrası hasar tespitine kadar birçok sayısız uygulama alanına sahiptirler. SAR imgelerinde içerik analizi yapılırken, bu imgelerin bölütlenerek etiketlenmesi işlemi, bu imgelerin anlambilimsel(Semantic) sınıflandırması olarak ifade edilmektedir [1]. SAR sistemlerinde yapılan iyileştirmelerle birlikte yüksek çözünürlükte görüntüler elde edilmeye başlanmış ve bunun sonucunda çok fazla veriye sahip bu imgelerin anlambilimsel sınıflandırma ihtiyacı da artmıştır.

Literatürde piksel tabanlı veya yama tabanlı yöntemler kullanılarak SAR imgelerinin içerikleri sınıflandırılmaktadır [2] - [6]. Piksel veya bir yamanın hangi sınıfa ait olduğu belirlenirken ilk olarak bunlara ait öznitelikler çıkarılır ve sonrasında bu öznitelikler kullanılarak sınıflandırma işlemi gerçekleştirilir. SAR görüntüleri içerdikleri yoğun benek gürültülerinden dolayı, yeğlilik, genlik ve faz gibi temel öznitelikler, yüksek performanslı bir sınıflandırma sonucu elde etmede yetersiz kalır [7]. Bunun için SAR imgelerinde sınıflandırma başarımını artırmak için öznitelik çıkarma yöntemleri kullanılmaktadır[8] - [11]. Elde edilen öznitelikleri sınıflandırmak için literatürde farklı sınıflandırıcılar önerilmektedir [12] - [15].

Bu çalışmada SAR imgeleri yamalara ayrılarak, bu yamalara ait etiketler belirlenmiştir. Bu işlemler yapılırken farklı öznitelik çıkarma ve sınıflandırma yöntemleri kullanılarak başarımları karşılaştırılmıştır.

1.1. Tezin Amacı, Katkısı ve İçeriği

Bu çalışmada, yüksek çözünürlüklü SAR imgelerinin anlambilimsel sınıflandırılması yapılırken farklı öznitelik ve sınıflandırma yöntemleri kullanılarak, en etkili yöntemlerin belirlenmesi hedeflenmiştir. Önerilen yöntemleri uygulayabileceğimiz kullanıma sunulmuş yüksek çözünürlüklü bir SAR veri seti

bulunmadığından [16], çalışma kapsamında ilk olarak yüksek çözünürlüklü SAR imgelerinden oluşan veri setleri hazırlanmıştır [17].

Piksel tabanlı sınıflandırmada çözünürlükle birlikte artan işlem yükünün üstesinden gelmek için bu çalışmada yama tabanlı anlambilimsel sınıflandırma tercih edilmiştir. SAR imgelerinden öznitelik çıkarmada en çok kullanılan gri seviye eş-oluşum matrisi (Gray level co-occurrence matrix-GLCM) [18], Gabor dalgacık dönüşümü [19], yerel ikili örüntü (Local binary pattern-LBP) [20] ve yönlü gradyanlar histogramı (Histogram of oriented gradients-HOG) [21] yöntemleri kullanılarak yamalara ait öznitelikler çıkarılmıştır. Bu öznitelikleri sınıflandırmak için literatürde yer alan destek vektör makinaları (Support vector machines-SVM) [22], topluluk öğrenicileri (Torbalama, hızlandırma ve rastgele orman (Random forest-RF) [23], [24] ve softmax [25] yöntemlerinin yanı sıra yaklaşık seyreltik çok terimli lojistik bağlanım (YSÇLB) [26] yöntemi önerilerek SAR imgelerinin sınıflandırılmasında literatüre dahil edilmiştir.


SAR imgelerinden öznitelik çıkarmada kullanılan yöntemler için literatüre bakıldığında, bina hasar imza analizinde GLCM [8], hızlı haritalama yapmak için veri analizinde Gabor [9], örüntü sınıflandırmada LBP [10] ve hedef tespitinde HOG [27] öznitelik çıkarma yöntemlerinin kullanılabildiği görülmektedir.

Tezin ikinci bölümünde SAR imgelerine genel bakış başlığı altında bu imgelerle ilgili genel bilgiler verilerek, elde edilme süreçleri anlatılmaktadır. Üçüncü bölümde öznitelik çıkarmada ve sınıflandırma kullanılan yöntemler anlatılmaktadır. Dördüncü bölümde ise veri setlerinin oluşturularak, önerilen yöntemlerin denendiği deneysel çalışmalar ve elde edilen sonuçlar verilmiştir. Beşinci bölüm olan son bölümde ise sonuç ve gelecekte yapılacak çalışmalar anlatılmıştır.

2. SAR İMGELERİNE GENEL BAKIŞ

1950 yılından bu yana hava ve uzay platformlarından görüntü elde etmede kullanılan SAR sistemleri, uçuş yüksekliğinden bağımsız olarak yüksek çözünürlükte görüntü üretmesiyle yer yüzü görüntülemeye etkin bir role sahip hale gelmiştir [28]. SAR sistemleri; arazi haritalarının belirlenmesinden, insan yapımı yapıların araştırılmasına, okyanus hareketlerinin gözlenmesinden, sel, yangın ve kentsel büyüme gibi çevre izlemesine, tarım ve ormancılıkta ürünlerin gelişmesinin incelenmesinden, savaş alanlarının gerçek zamanlı takip edilerek izlenmesi ve hareketli hedef takibine kadar çok geniş bir kullanım alanına sahiptir [29].


Geleneksel radarlarla uçuş yönünde yükseklikten bağımsız olarak yüksek çözünürlükte görüntü elde edebilmek için pratikte mümkün olmayacak uzunluktaki antenlere ihtiyaç duyulur. SAR sistemlerinde bu durumun üstesinden gelebilmek için radar platformunun hareketlerini dijital sinyal işleme teknikleriyle kullanarak pratikte mümkün olmayan yapay açıklık elde edilir. Buradaki yapay açıklık, anten uzunluğunun sinyalleri toplayacağı alanı kısmen belirlediği için, antenin uzunluğu olarak ifade edilebilir [30]. SAR sisteminde küçük uzunlukta antenler kullanılarak hedefe sıralı bir şekilde darbe sinyalleri gönderilir ve sonrasında yansıyan sinyaller toplanır. Toplanan sinyaller evreyumlu bir şekilde bir araya getirilerek istenilen yapay açıklık elde edilmiş olunur. SAR sisteminin görüntüleme geometrisi Şekil 2.1’de verilmiştir [31].



Şekil 2.1: SAR sisteminin görüntüleme geometrisi.

Buradaki azimut, sensörün v hızıyla hareket ettiği yön veya çapraz menzil olarak ifade edilmektedir. Sensörün hedefi gördüğü aralık orak genişliği (swath width) veya menzil olarak ifade edilmektedir. Hedefin, sensöre baktığı yön eğim aralığı, Θ_a , azimut hüzmeye genişliği, r_0 ise hedef ile sensör arasındaki en yakın yaklaşım uzaklığını ifade etmektedir. Hedefteki noktaların zamandaki değişimi azimut fazı olarak ifade edilir ve bu faz değerleri toplanarak, sinyal işleme esnasında kullanılmasıyla sahnedeki nesne şekilleri çıkarılır [31]. SAR sistemlerini topladığı geri saçılan sinyaller iki boyutlu karmaşık veri matrisi şeklindedir. Karmaşık olmasının sebebi bu sistemlerin evreyuymulu olmasıdır, yani saçılan dalganın hem şiddetini hem de evresindeki uzamsal ve zamansal değişimlerini ölçebilirler bu sayede her pikselde genlik ve faz değerleri oluştururlar. İki boyutlu veri matrisinin birinci boyutu menzil, ikinci boyutu ise azimut ile ilişkilidir. Menzil çözünürlüğü, gönderilen sinyalin bant genişliğiyle doğru orantılıdır yani bant genişliği arttıkça menzil yönündeki çözünürlükte artar. Azimut çözünürlüğü ise anten boyuyla doğru orantılıdır. Anten boyu arttıkça daha dar hüzmelerle daha yüksek çözünürlük elde edilir. Çözünürlük hücre sayısı ise menzil genişliği ile azimut hücre sayısının çarpımı şeklinde hesaplanır.

SAR sistemleri ile elde edilen ham veri matrisleri kullanıcılar için doğrudan bir sahne sunmaz. Bu nedenle Şekil 2.2’de verilen sinyal işleme adımları kullanılarak SAR imgesi kullanılabilir bir hale getirilir [31]. İlk olarak ham veri, referans menzil fonksiyonuyla evrimiyle kısa darbelere sıkıştırılır. Bu sayede radar ile zemin arasındaki mesafe belirlenir. Daha sonra sıkıştırılmış bu veri geometri ve uzaklığa göre değişimle alakalı referans azimut fonksiyonu ile evrimiyle kullanılabilir SAR imgesi elde edilir. Görüntülenen bölgede çok fazla bağımsız saçılım bölgesi olması durumunda, alıcı antenle bu saçılımların eşzamanlı olarak toplanılması, yapıcı ve bozucu girişimlere yol açar ve bu da SAR görüntülerinde tuz-biber şeklinde benek gürültüsü içermesine neden olabilir. Bu durumun üstesinden gelmek için çoklu bakış yöntemleri kullanılabilir. Bu yöntem, görüntü spektral bant genişliğinin örtüşmeyen birkaç bölgeye bölünerek, birbirinden istatistiksel olarak bağımsız farklı bakış sahne imgeleri oluşturulmasını ve bu imgelerin birleştirilmesi olarak ifade edilebilir. Ancak bu yöntem sinyal çözünürlüğünde azalmaya ve veri istatistiklerinin değişmesine neden olabilir.



Şekil 2.2: SAR imgelerinin oluşturulmasındaki sinyal işleme adımları.

SAR sistemlerinde gönderilen elektromanyetik sinyaller polarize edilmiş şekilde yollanarak, sahnelerin kapsamlı fiziksel özellikleri çıkarılır. Yaygın olarak yatay (Horizontal-H) ve dikey (vertical-V) şeklinde iki temel polarizasyon kanalı kullanılır. Geleneksel radarlarda tek polarizasyonlu elektromanyetik sinyal yaymak ve almak için tek anten kullanırken, SAR sistemlerinde ise her biri dikgen olarak polarize olmuş, iki farklı sinyalden birini yayabilen ve alabilen iki antene sahiptir. Bu sayede, antenden gönderilen ve alınan dalga türüne göre, yatay gönderilip yatay alındığında HH, dikey gönderilip dikey alındığında VV, yatay gönderilip dikey alındığında HV ya da dikey gönderilip yatay alındığında VH dalga polarizasyonu üretebilmektedir.

SAR sistemleri genelde üç farklı mod da çalışırlar. Bunlar, şerit harita (string-map-SM), gözetleme(Scan) ve noktasal aydınlatma(spotlight) SAR olarak ifade edilir. En temel mod olan SM-SAR modunda belirli bir bölge şerit şeklinde taranır. Gözetleme SAR'ı ise SM-SAR'dan daha kısa sürede daha fazla alanı tarar fakat çözünürlüğü SM-SAR'dan daha düşüktür. Noktasal aydınlatmalı SAR ise küçük bölgelerde yüksek çözünürlük üretmede kullanılır.

3. YÖNTEMLER

Yüksek çözünürlükteki SAR imgelerinde yama tabanlı anlambilimsel sınıflandırma yaparken ilk olarak imgeler 400×400 'lük yamalara ayrılarak bu yamaları temsil eden öznitelikler çıkarılmış ve denetimli sınıflandırıcılar ile bu öznitelikler sınıflandırılarak yamalar etiketlenmiştir. Bu çalışmada farklı öznitelik çıkarma ve sınıflandırma yöntemleri kullanılarak en etkili yöntemler belirlenmeye çalışılmıştır. Bölüm 3.1'de kullanılan öznitelik çıkarma yöntemleri, bölüm 3.2'de ise kullanılan denetimli sınıflandırma yöntemleri detaylı olarak anlatılmıştır.

3.1. Öznitelik Çıkarma Yöntemleri


3.1.1. Gri Seviye Eş-Oluşum Matrisi

GLCM, istatistiksel bir yaklaşımla öznitelik çıkarma yöntemidir. İlk defa 1973 yılında Robert Haralick tarafından önerildiği için bu yöntem ile elde edilen öznitelikler Haralick öznitelikleri olarak da adlandırılır [18]. GLCM, belirlenen bir pencere içerisindeki iki komşu piksel arasındaki ilişkiyi tanımlar. Normalize edilmiş GLCM'deki $P(i, j)$ olasılık değerleri (3.1)'de verilen eşitlikteki gibi hesaplanır.

$$P(i, j) = \frac{P(i, j, d, \theta)}{\sum_i \sum_j P(i, j, d, \theta)} \quad (3.1)$$

Bu formülde yer alan i , referans piksel değerine, j ise komşu piksel değerine karşılık gelir. d , adım mesafesi olarak adlandırılır ve genelde 1 veya 2 değerini alabilir. Son parametre olan θ ise yön parametresi olarak adlandırılır ve 0° , 45° , 90° , 135° değerlerini alabilir. Adım mesafesi 1 olduğunda, dört fark yöndeki komşu pikseller Şekil 3.1'de gösterilmiştir [32].


Bu yöntemde, Şekil 3.2'de gösterildiği gibi gri seviye eş oluşum matrisini oluşturduktan sonra bu matrisin normalize edilmiş halini temsil eden öznitelikler hesaplanır [33]. Bu çalışmada normalize edilmiş GLCM'yi temsil etmede kullanılan öznitelikler ve bunları elde etmede kullanılan denklemler Tablo 3.1'de verilmiştir. Her yama için 4 farklı yönde 12'şer öznitelik çıkarılarak toplamda 48 adet öznitelik elde edilmiştir.



Şekil 3.1: $d=1$ ve $\theta=(0^\circ, 45^\circ, 90^\circ, 135^\circ)$ olduğundaki komşu pikseller.

Tablo 3.1: GLCM'yi temsil etmede kullanılan öznelilikler ve formülleri.

Öznitelik	Formülü	Notlar
Ortalama	$f = \frac{1}{MN} \sum_i^M \sum_j^N P(i, j)$	$ i - j = n$
Varyans	$f = \frac{1}{MN} \sum_i^M \sum_j^N (P(i, j) - \mu)^2$	$\mu_x = \sum_i \sum_j iP(i, j)$ $\mu_y = \sum_i \sum_j jP(i, j)$
Entropi	$f = - \sum_i \sum_j p(i, j) \log(P(i, j))$	$\sigma_x = \sqrt{\sum_i (i - \mu_x)^2 \sum_j P(i, j)}$ $\sigma_y = \sqrt{\sum_j (j - \mu_y)^2 \sum_i P(i, j)}$
Kontrast	$f = \sum_{n=0}^{N-1} n^2 \left\{ \sum_i \sum_j P(i, j) \right\}$	
Enerji	$f = \sum_i \sum_j P(i, j)^2$	
İlinti	$f = \sum_i \sum_j \frac{ijP(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y}$	
Homojenlik	$f = \sum_i \sum_j \frac{P(i, j)}{1 + (i - j)^2}$	
Özilinti	$f = \sum_i \sum_j ijP(i, j)$	
Farklılık	$f = \sum_i \sum_j i - j P(i, j)$	
Kümeleme Gölgesi	$f = \sum_i \sum_j (i + j - \mu_x - \mu_y)^3 P(i, j)$	
Kümeleme Önemi	$f = \sum_i \sum_j (i + j - \mu_x - \mu_y)^4 P(i, j)$	
Maximum Olasılık	$f = \text{MAX}_{i,j} P(i, j)$	



Şekil 3.2: a) Görüntü, b) d=1 ve $\theta=0^\circ$ olması durumundaki GLCM

3.1.2. Gabor Dalgacık Dönüşümü

İlk defa tek boyutlu gürültülü sinyal tespitinde Denis Gabor tarafından önerilen bu yöntem [34], sonrasında geliştirilerek son halini almıştır [19]. Özellikle doku bazı görüntü analizinde yaygın olarak kullanılan bir öznelilik çıkarım yöntemidir. Gabor dalgacıkları gerek yönelim gerekse de uzaysal lokalizasyon için çok iyi filtreler oluşturur. Eşitlik (3.2)'de verilen iki boyutlu Gabor filtresi, karmaşık üstel fonksiyon ile eliptik Gauss fonksiyonunun çarpımından oluşur. Üstel fonksiyon, dönme dayanımını elde etmede, Gauss fonksiyonu ise ölçek dayanımını elde etmede kullanılır.

$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left[-\frac{1}{2}\left(\frac{\tilde{x}}{\sigma_x^2} + \frac{\tilde{y}}{\sigma_y^2}\right)\right] \exp[j2\pi f\tilde{x}] \quad (3.2)$$

$$\tilde{x} = x\cos\theta + y\sin\theta \quad (3.3)$$

$$\tilde{y} = -x\sin\theta + y\cos\theta \quad (3.4)$$


Buradaki θ döndürme açısı, f ise Gabor süzgecinin frekansıdır. Buradaki, σ_x ve σ_y , x ve y yönlerindeki standart sapmaları, $\tilde{x}$ ve $\tilde{y}$ ise x ve y kordinatlarının θ açısı kadar döndürülmesiyle oluşan koordinatlardır. Bir yama ile 4 farklı yönde ve 5 farklı ölçekteki Gabor süzgeçleriyle konvolüsyon işleminden geçirilmesiyle elde edilen görüntülerin genlikleri Şekil 3.3'de verilmiştir. Elde edilen bu görüntülerin

$M \times N$ boyutlu $I(i, j)$ matrisi olarak ifade edecek olursak, aşağıda verilen eşitlikler kullanılarak ortalaması (3.5), standart sapması (3.6) ve entropisi (37) alınarak, her bir yama için toplamda 60 tane öznitelik elde edilmiştir.


$$o_{ij} = \frac{1}{MN} \sum_i^M \sum_j^N I_{ij} \quad (3.5)$$

$$s_{ij} = \frac{1}{MN} \sum_i^M \sum_j^N (I_{ij} - o_{ij}) \quad (3.6)$$

$$e_{ij} = - \sum_i^M \sum_j^N I(i, j) \log(I(i, j)) \quad (3.7)$$



a)



b)

Şekil 3.3: a) Gri seviye yama görüntüsü, b) Yamanın 4 farklı yönlü 5 farklı ölçekli Gabor süzgecinden geçmesiyle elde edilmiş genlik görüntüleri.


3.1.3. Yerel İkili Örüntü

Yerel uzamsal yapıyı betimlemede kullanılan, komşuluk ilişkisine dayalı bir öznitelik çıkarma yöntemidir. Parametrik olamayan bu yöntem ilk defa Ojala ve arkadaşları tarafından 1994 yılında önerilmiştir [35]. Bu yöntemde, bir merkez piksel ile R komşuluğundaki piksellerin sıralı ikili karşılaştırılmasıyla ikili (binary) bir sayı üretilerek merkez pikselin değerine atanır. Her pikselin bu şekilde etiketlendiği değerler, (3.8) ve (3.9)'da verilen eşitliklerle belirlenir.

$$LBP_{P,R}(x_c) = \sum_{p=0}^{P-1} u(x_p - x_c) 2^p \quad (3.8)$$

$$u(y) = \begin{cases} 1 & y \geq 0 \\ 0 & y < 0 \end{cases} \quad (3.9)$$


Buradaki P ; komşu sayısı, R komşuluk mesafesi, x_c ; merkez pikseli x_p ; komşu pikseli, $u(y)$ ise komşu piksel ile merkez piksel arasındaki birim basamak fonksiyonunu ifade etmektedir. Eğer komşu piksel, merkez pikselden büyükse 1 küçükse 0 değerini alır. Bu sayede 1 piksel komşulukta 8-bitlik bir LBP etiketi elde edilir ve bu etiket değeri onluk sisteme dönüştürülerek 0 ile 255 arasında değer alan bir LBP imgesi elde etmiş oluruz. 8-bitlik LBP etiket değerinin belirlenme işleminin bir gösterimi Şekil 3.4' de verilmiştir.



Şekil 3.4: 1 komşuluklu 8-bitlik LBP etiket değerinin belirlenme işlemi

Bu yöntemde, tüm bu etiket değerlerini kullanmak yerine yünden bağımsız olarak sadece 0-1 yada 1-0 geçiş sayısı 2 yada daha az olan düzgün örüntü değerleri de kullanılabilir. Bu sayede 8-bitlik bir LBP etiketi kullanıldığında öznitelik sayısı 256'dan 59'a düşürülerek sınıflandırma esnasındaki işlem yükü azaltılmış olunur. LBP yöntemi, Şekil 3.5'de verildiği gibi çeşitli dairesel komşulukları kullanabilmesi sayesinde farklı ölçeklerde analiz yapma imkanına da sahiptir [36].

Bu çalışmada, hücre boyutu yama boyutuyla eş seçilmiş, 8 komşuluklu yönden bağımsız düzgün örüntü değerleri kullanılarak her bir yama için 59 adet öznitelik elde edilmiştir.



Şekil 3.5: a) $LBP_{(8,1)}$, b) $LBP_{(4,2)}$, c) $LBP_{(8,2)}$.

3.1.4. Yönlü Gradyanlar Histogramı

HOG, imge içerisindeki nesnelerin gradyan yön ve büyüklüklerinin belirlenmesine dayanan bir öznitelik çıkarma yöntemidir [21]. Bu yöntemde imge, yerel histogramlar cinsinden ifade edilir. Bu yerel histogramlar belirlenirken, imge ilk olarak bloklara ve bu bloklarda kendi içlerinde hücelere ayrılır. Hücelere ait piksellerin, gradyan yön ve büyüklükleri hesaplanır. Bu gradyan değerlerin belirlenen yöndeki oluşma sayıları ise yerel histogramları oluşturur. Bir blok içerisindeki tüm yerel histogramlar bir araya getirilerek düzgeleme edilir. Bu işlem tüm bloklar için tekrarlanmasıyla elde edilen düzgelenmiş histogramların yan yana dizilmesiyle imgeyi ifade eden öznitelikler elde edilmiş olunur. Bu yöntem, gradyan yön ve büyüklük hesaplama, histogram oluşturma ve blokların düzgelenmesi olmak üzere üç aşamadan oluşur.

Gradyan yön ve büyüklük hesaplaması aşamasında, imgemizi $I(x, y)$ olarak ifade edecek olursak, ilk olarak $[-1 \ 0 \ 1]$ şeklinde bir türev maskesi ve imgenin dikey ve yatay bileşeniyle konvolüsyon işlemi uygulanır. Bunun sonucunda, eşitlik (3.10) ve (3.11)'de verildiği gibi dikey ve yatay gradyan değerleri hesaplanır. Bu gradyan değerlerinin eşitlik (3.12)'de verildiği gibi bileşkesi alınarak gradyan büyüklüğü hesaplanır, eşitlik (3.13)'de verildiği gibi de gradyan yönleri hesaplanır.


$$f_x(x, y) = I(x + 1, y) - I(x - 1, y) \quad (3.10)$$

$$f_y(x, y) = I(x, y + 1) - I(x, y - 1) \quad (3.11)$$

$$m_x(x, y) = \sqrt{f_x(x, y)^2 + f_y(x, y)^2} \quad (3.12)$$

$$\theta_x(x, y) = \arctan \frac{f_y(x, y)}{f_x(x, y)} \quad (3.13)$$

Histogram oluřturma ařamasında, gradyan yönü 0 ile 180 arasında eřit bölgelere ayrılır. Örneęin bölge aralıęı 20° olarak seildięinde 9, 15° olarak seildięinde 12 eř bölgeye ayrılabilir. Bu eř bölgeler açısıl bin olarak da ifade edilebilir. Her hücrenin pikseli, onun açısıl gradyanına katkıda bulunarak yerel histogramlar oluřturulur. Yerel histogramların oluřturulma iřlemi řekil 3.6’da gösterilmiřtir [33].



řekil 3.6: Yerel histogram oluřturulma iřlemi.

Blokların düzgeleme edilmesi ařamasında, bir blok ierisindeki tüm yerel histogramların birleřtirilmesiyle büyük bir histogram elde edilir. Bu histogramın da (3.14)’de verilen eřitlik ile düzgelelenmiř o bloęa ait öznitelikler ıkarılmıř olunur. Bu eřitlikteki V_k , düzgelelenmemiř büyük histogram deęerini, v ise düzgelelenmiř histogram deęerini ifade etmektedir. Bu iřlem tüm bloklar iinde tekrarlanması elde edilen tüm özniteliklerin bir araya getirilmesiyle HOG öznitelikleri elde edilmiř olunur.

$$v = \frac{V_k}{\sqrt{\|V_k\|^2 + 1}} \quad (3.14)$$


Bu çalışmada her bir yama tek bir blok olarak kabul edilerek, [2,2]'lik hücrelere ayrılmış ve her hücrede 16 binlik yerel histogramlarla ifade edilmiştir. Bu sayede her bir yama için 64 adet HOG öznitelikleri elde edilmiştir.

3.2. Sınıflandırma Yöntemleri

3.2.1. Destek Vektör Makinaları

SVM, yapısal risk minimizasyonuna dayalı parametrik olmayan bir denetimli sınıflandırma yöntemidir [22]. Bu yöntemde, dağılım hakkında herhangi bir varsayım yapılmaz, eğitim kümesinden bir karar fonksiyonu elde edilerek test kümesi bu karar fonksiyonuna göre sınıflandırılır. İlk olarak iki sınıflı doğrusal olarak ayrılabilen verilerin sınıflandırılması için önerilen bu yöntem, sonrasında genelleştirilerek çok sınıflı ve doğrusal olarak ayrılamayan verilerin sınıflandırılması için de kullanılır hale gelmiştir. İki sınıflı doğrusal olarak ayrılabilen veri setlerinde, sınıflar arasındaki maksimum mesafeli optimum hiper düzlemi bulmaya çalışır. Bu optimum hiper düzlemi oluşturan sınır elemanları ise destek vektörleri olarak adlandırılır. Şekil 3.7'de iki sınıflı doğrusal olarak ayrılabilen veriler için bir optimum hiper düzlem ve destek vektörleri gösterilmiştir [37].

Doğrusal olarak ayrılamayan veri setlerinde için, sınıflar arasındaki hiper düzlemi maksimuma getirilmeye çalışılırken hatalı sınıflandırılmış eleman sayılarını minimum yapılmaya çalışılır. Bu iki duruma arasından ki denge, C ile gösterilen ve daima pozitif değer alan bir düzenleme parametresi ile sağlanmaya çalışılır. Doğrusal eşitliklerle optimum hiper düzlemin belirlenememesi durumunda çekirdek (kernel) dönüşümleri kullanılarak, Şekil 3.8'de gösterildiği gibi daha yüksek boyutlu bir uzayda sınıfların doğrusal olarak ayrılabilmesi sağlanır [37]. Literatürde çok sayıda çekirdek fonksiyonu tanımlanmaktadır. Bunlar arasında en çok kullanılanları doğrusal çekirdek fonksiyonu eşitlik (3.15)'de, çok terimli çekirdek fonksiyonu eşitlik (3.16)'de ve radyal tabanlı çekirdek fonksiyonu eşitlik (3.17)'de verilmiştir.




Şekil 3.7 : İki sınıflı doğrusal olarak ayrılabilen veri setinde sınıflar arasındaki optimum hiper düzlem ve destek vektörleri.

$$K(x_i, x_j) = x_i \cdot x_j \quad (3.15)$$

$$K(x_i, x_j) = (x_i \cdot x_j + 1)^d \quad (3.16)$$

$$K(x_i, x_j) = \exp\left(-\frac{1}{2\sigma^2} \|x_i - x_j\|^2\right) \quad (3.17)$$

Bu çalışmada çok sınıflı ve doğrusal olarak ayrılamayan veri setlerimiz olduğu için problem çözümündeki etkinliği ve yüksek sınıflandırma başarımına sahip olması nedeniyle radyal tabanlı çekirdek fonksiyonu tercih edilmiştir. Bu yöntem kullanıldığında, kullanıcı tarafından belirlenmesi gereken ve sınıflandırma sonucunu doğrudan etkileyen düzenleme (C) ve çekirdek genişliği(σ) parametrelerinin en optimal şekilde seçilmesi gerekmektedir. Bu nedenle çapraz geçerlilik yöntemi kullanılarak en optimal parametre değerleri seçilmeye çalışılmıştır.



Şekil 3.8: Çekirdek dönüşümleri ile optimum hiper düzlemin belirlenmesi.


3.2.2. Topluluk Öğrenme Yöntemleri

Topluluk öğrenme (Ensemble learning), tek bir sınıflandırıcı yerine birden fazla sınıflandırıcıdan elde edilen tahminlerin ortalaması alınarak veya oylaması yapılarak topluluk adına bir tahminin elde edildiği yöntemlerdir [38]. Bu yöntemde de diğer tüm sınıflandırma yöntemleri gibi eşitlik (3.18) ve (3.19)'de verilen hata minimize edilerek sınıflandırma başarımı arttırılmaya çalışılır.

$$hata(x) = (E[\hat{f}(x)] - f(x))^2 + E[\hat{f}(x) - E[f(x)]]^2 + \sigma_e^2 \quad (3.18)$$


$$hata(x) = yanlılık^2 + varyans + azaltılamaz hata \quad (3.19)$$

Buradaki yanlılık, tahmin edilen değer ile gerçek değer arasındaki farkı ifade eder. Yanlılık artıkcı elde edilen başarımlar düşer. Varyans ise, tahminler arasındaki farkı belirtmede kullanılan bir ifadedir. Yüksek varyanslı bir model olması durumunda modelimiz eğitim elamanlarına aşırı uyacak ve eğitim kümesi dışındaki başka bir gözlem üzerinde kötü performans sergileyecektir [39]. Yanlılık ve varyansı daha iyi açıklayabilmek için Şekil 3.9 verilmiştir [39]. Bu şekildeki kırmızı nokta gerçek değeri, mavi noktalar ise tahminleri ifade etmektedir.



Şekil 3.9: Yanlılık ve varyansla ilgili bir gösterim.

Sınıflandırma modelinde karmaşıklık arttırdıkça düşük yanlılıktan kaynaklı hata azalır. Ancak bu işlem bir yere kadar olur, bir yerden sonra aşırı uyumluluk meydana gelir ve buda varyansı arttırır. En iyi sınıflandırma modeli, bu iki değişken arasındaki dengeyi sağlayabilen optimum karmaşıklığa sahip modeldir. Şekil 3.10'da optimum karmaşıklık gösterilmiştir [39]. Topluluk öğrenme yöntemleri, bu optimum karmaşıklığı belirlenmesinde en etkili yöntemlerdir. En yaygın kullanılan topluluk öğrenme yöntemleri torbalama(bagging), hızlandırma(boosting) ve rasgele orman yöntemidir.



Şekil 3.10: Optimum model karmaşıklığı.

3.2.2.1. Torbalama


Torbalama, ilk defa Breiman tarafından önerilmiş bir topluluk öğrenme yöntemidir [40]. Bu yöntemde, eğitim veri setinden her defasında yerine koyulmak şartıyla örnekler seçilerek alt veri seti kümeleri oluşturulur. Literatürde bu işlem bootstrap tekniği olarak da ifade edilmektedir. Farklı eğitim alt kümelerinin seçilmesindeki amaç bu kümelere eğitilen sınıflandırıcılar ile karar farklılıkları elde ederek, aşırı öğrenme karşı güçlü, varyansı düşük ve sınıflandırma başarısı yüksek bir yöntem elde etmektir. Bu şekilde oluşturulan alt veri seti kümeleri ile sınıflandırıcılar eğitilir ve test aşamasından bu sınıflandırıcılardan elde edilen tahminler oylama usulü bir araya getirilerek topluluğa ait nihai bir karar elde edilmiş olunur. Torbalama yöntemi ile sınıflandırma işlemi Şekil 3.11'de gösterilmektedir.

Verilen şekilde de görüldüğü gibi torbalama yöntemi, paralel öğrenme yöntemidir. İçerdiği tüm sınıflandırıcılar aynı anda üretilir.

Torbalama yöntemi, K en yakın komşuluk, Navia Bayes, yapay sinir ağları, lineer diskriminant analizi (LDA) ve karar ağaçları gibi birçok sınıflandırma modeline uygulanabilmektedir ancak kararsız sınıflandırma modellerinde daha etkili bir yöntem olduğu için yaygın olarak karar ağaçları ile kullanılmaktadır. Bu çalışmada da karar ağaçları ve lineer diskriminant analizi yöntemleri kullanılarak torbalama yöntemiyle sınıflandırma yapılmıştır.

Ağaç tabanlı torbalama yöntemiyle sınıflandırma yapılırken, eğitim veri setindeki tüm örnekler eşit ağırlık verilerek 100 adet alt eğitim küme oluşturulmuş ve bu alt eğitim kümesi sayısı kadar karar ağacı eğitilmiştir. Tüm bu karar ağaçlarına eşit ağırlık verilip, oylama yapılarak nihai sınıflandırma kararı elde edilmiştir.

LDA tabanlı torbalama yöntemiyle sınıflandırma yapılırken, yine eğitim kümesindeki tüm örnekler eşit olasılık verilerek 100 adet alt eğitim kümesi oluşturulmuş ve bu alt eğitim kümeleri kullanılarak 100 adet LDA sınıflandırıcı eğitilmiştir. Bu sınıflandırıcılar eğilirken, her sınıfa ait örnekler çok değişkenli normal dağılıma sahip olduğu varsayılır ve tüm sınıflar için ayrı bir ortalama belirlenirken tüm sınıflar için tek bir kovaryans matrisi belirlenir. Bu ortalaması farklı, kovaryans matrisleri aynı normal dağılımlar kullanılarak, girilen bir test örneğinin hangi sınıfa ait olma olasılığı en yüksek ise o sınıfa ataması yapılır [41]. LDA sınıflandırıcılardan elde edilen tahminlere eşit ağırlık verilip, oylamaya yapılarak nihai sınıf kararı elde edilir.




Şekil 3.11: Torbalama yöntemi ile sınıflandırma işlemi.

3.2.2.2. Hızlandırma

Hızlandırma, Schapire tarafından geliştirilmiş iteratif bir topluluk öğrenme yöntemidir [42]. Bu yöntemin temelinde, düşük performanslı zayıf sınıflandırıcılar bir araya getirilerek yüksek performanslı güçlü sınıflandırıcı serilerinin üretilmesi vardır. Hızlandırma yönteminde genel olarak yanlışlık düşürülmeye çalışılır ancak bu işlemi yaparken gürültüye karşı duyarlı olduğu için eğitim kümesine aşırı uyumlu olma sorunuyla karşılaşılabilir.

Bu yöntemde iteratif olarak bir sınıflandırıcı serisi üretilirken, ilk olarak eğitim kümesindeki tüm elemanlara eşit olasılık verilerek yeni bir eğitim alt kümesi oluşturulur. Bu eğitim kümesi ile sınıflandırıcı eğitilir ve tüm eleman üzerinde test edilir. Yanlış sınıflandırılmış elemanların ağırlıkları artırılıp, doğru sınıflandırılmış elemanların ağırlıkları azaltılarak yeni bir eğitim alt kümesi oluşturulur. Bu sayede yanlış sınıflandırılmış elemanların daha çok olduğu yeni bir eğitim alt kümesiyle sınıflandırıcı eğitilir ve test edilerek yeniden ağırlıklandırılma yapılır. Bu şekilde işlemler tekrarlanarak güçlü bir sınıflandırıcı serisi üretilmiş olunur. Final tahmini kısmında, tüm bu sınıflandırıcılardan elde edilen tahminlerin ağırlıklı oylama yapılarak bir araya getirilmesiyle nihai karar verilir. Şekil 3.12’de hızlandırma yöntemi ile sınıflandırma gösterilmiştir.

Şekil 3.12’ de yer alan ϵ , ağırlıklı sınıflandırıcı hatasını, α , sınıflandırıcı ağırlığını ve $P(c|x)$ ise sonsal olasılığını ifade etmektedir. Literatürde çok sayıda kullanılan hızlandırma algoritması mevcuttur ancak bunlar içerisinde en yaygın olarak kullanılan Adaboost (Adaptive boosting) algoritmasıdır. İki sınıflı problemler için kullanılan Adaboost algoritması Şekil 3.13’de verilmiştir [43].



Şekil 3.12: Hızlandırma yöntemi ile sınıflandırma.

Algoritma	AdaBoost
1:	Başlangıç eleman ağırlıkları $\{w_n\}$, $1/N$ olarak ata
2:	for $m=1:M$
3:	J_m ağırlıklandırılmış hata fonksiyonunu minimize edecek şekilde $y_m(x)$ sınıflandırıcısı oluşturulur
4:	$J_m = \sum_{n=1}^N w_n^{(m)} I[y_m(x_n) \neq t_n]$
5:	$\epsilon_m = \sum_{n=1}^N w_n^{(m)} I[y_m(x_n) \neq t_n] / \sum_{n=1}^N w_n^{(m)}$
6:	$\alpha_m = \frac{1}{2} \log \left(\frac{1-\epsilon_m}{\epsilon_m} \right)$
7:	Elemanların ağırlıklarını yenile $w_n^{(m+1)} = w_n^{(m)} \exp \{ \alpha_m I[y_m(x_n) \neq t_n] \}$
8:	end for
9:	Final modelini kullanarak kesin kararı belirle: $Y_m(x) = \text{sign}(\sum_{m=1}^M \alpha_m y_m(x))$

Şekil 3.13: Adaboost algoritması.

Buradaki M , iterasyon sayısını, t_n ise n 'inci elemanın gerçek etiketini ifade eder. İlk sınıflandırıcı $y_1(x)$, eşit ağırlık katsayıları verilerek eğitilir. Sonraki hızlandırma turlarında, doğru sınıflandırılmış veri noktalarında ağırlık azaltılırken, yanlış sınıflandırılmış veri noktalarında ağırlık katsayısı artırılır. ϵ , her sınıflandırıcının ağırlıklı hatasını gösterir. Bundan dolayı, ağırlık katsayısı α daha doğru sınıflandırıcılara daha fazla ağırlık verir. Çok sınıflı Adaboost algoritması, AdaboostM2 olarak da bilinir ve ağırlıklı sınıflandırıcı hatası ϵ 'un hesaplanması dışında diğer işlemleri iki sınıflı Adaboost'la benzerlik gösterir. AdaboostM2 için sınıflandırma hata oranı olarak eşitlik 3.20'de verilen ağırlıklı pseudo kayıpları

kullanılır. Bu eşitlikteki $y_m(x_n, k)$, x_n 'in k olarak etiketlendiğindeki sınıflandırıcı güvenini ifade eder ve 0 ile 1 arasından değerler alır. İkinci toplam simgesi ise x_n 'in gerçek sınıfı dışındaki tüm durumları ifade eder.

$$\varepsilon_m = \frac{1}{2} \sum_{n=1}^N \sum_{k \neq t_n} w_{n,k}^{(m)} (1 - y_m(x_n, t_n) + y_m(x_n, k)) \quad (3.20)$$

Bu çalışmada çok sınıflı problemlerle ilgilenildiği için ağaç temelli AdaboostM2 algoritması tercih edilmiştir. İterasyon sayısı yani ağaç sayısı 100 seçilerek sınıflandırma işlemi yapılmıştır.


3.2.2.3. Rastgele Orman

Amit ve Geman tarafından yapılan bir çalışmada, yazılan karakterleri tanıırken her düğümdeki en iyi ayrımın rasgele seçim üzerinden yapılmasından etkilenen Leo Breiman, kendi geliştirdiği torbalama tekniği ile Ho tarafından geliştirilen rastgele alt uzay seçim yöntemini birleştirerek, yine bir topluluk öğrenme yöntemi olan rastgele orman yöntemini geliştirmiştir [44] [45]. Bu yöntemde, birden fazla ağaç rastgele olarak üretilerek bir araya getirildiği için rastgele orman olarak adlandırılmaktadır. RF, hesap yükü olarak daha basit olduğu için hızlı ve gürültüye karşı daha az duyarlı olduğu için yüksek doğruluk elde edebilen bir yöntemdir. Bu yöntemde, torbalama yöntemine ek olarak rastgelelik özelliği eklendiği için birbirlerinden daha bağımsız ağaçlar üretilmektedir. Bu sayede aşırı öğrenmeye karşı daha güçlü hale gelmiş olur. Bu yöntemde kullanıcı tarafından belirlenen ağaç sayısı(N) ve düğüm değişken sayısı (m) parametrelerinin sonuca etkilerinin çok büyük olmamasından dolayı kullanımı oldukça kolay bir yöntemdir.

RF yönteminde ilk olarak, oluşturulacak ağaç sayısı kadar bootstrap tekniği ile alt eğitim kümeleri oluşturulur. Her bir alt eğitim kümesinin 2/3'ü inbag, 1/3'ü ise out of bag (OOB) verisi olarak ayrılır. Daha sonra inbag verilerinin içerisindeki tüm değişkenleri kullanmak yerine kullanıcı tarafından belirlenen m sayısı kadar rastgele değişken seçilerek ağaçlar oluşturulur.

Ağaçlar oluşturulurken CART(Classification and Regression Tree) algoritması kullanılır. Bu algoritma ile oluşturulmuş bir ağaç örneği Şekil 3.14'de verilmiştir. Oluşturulan ağaç, kök düğümü, ara düğüm, yaparak (terminal) düğüm ve bu

düğümler arasındaki dallardan oluşmaktadır. Ağaç, farklı sınıflara ait bütün değişkenlerin yer aldığı kök düğümlerle başlar. Ara düğümler karar düğümleridir ve her biri farklı bir değişkeni ifade eder. Yaprak düğüm, terminal yani son düğüm olarak da bilinir. Düğümün içirdiği tüm değişkenler tek bir sınıfa aitse yada dallanma yapılacak başka bir öznelik yoksa bu düğüm, yaprak düğüm adlandırılır ve bir etiket değeri atanır.



Şekil 3.14: CART yöntemiyle oluşturulmuş karar ağacı.

CART algoritmasıyla kök düğümde, değişkenler arasında en iyi dallanma yapılacak olan belirlenmeye çalışılırken bilgi kazancına bakılır. Hangi değişkenin en yüksek bilgi kazancı sağlayacağı (3.21)'de verilen eşitlikle belirlenir ve dallanma o değişken üzerinden yapılır.

$$\text{Bilgi Kazancı}(D, X) = E(D) - \sum_{i=1}^n p(D_i) E(D_i) \quad (3.21)$$

Buradaki X , bölünecek olan değişken, D_i , bölünecek özneliğin alt kümeleri, $E(D)$, X değişkenine göre bölünme olmadan önceki entropi, $E(D_i)$, X değişkenine göre bölünme olduktan sonraki i . alt kümenin entropisi ve $p(D_i)$ ise X değişkeni üzerinden bölünme olduğunda i . alt kümenin olma olasılığıdır.

Dallanma yapılacak olan değişken belirlendikten sonra değişkenin hangi değeri ile dallanma yapılacağı Gini indeksi ile belirlenir. D veri seti, n tane sınıf içeriyorsa, T değerine ait Gini değeri eşitlik (3.22)'de verildiği gibi bulunur. Burada ki p_j , j 'inci sınıfın D veri setinde olma olasılığıdır.

$$Gini(T) = 1 - \sum_{j=1}^n (p_j)^2 \quad (3.22)$$

N büyüklüğündeki D veri seti, N_1 ve N_2 büyüklüğündeki D_1 ve D_2 alt veri setlerine bölünecek olursa, bölünmüş Gini indeksi eşitlik (3.23) verildiği gibi hesaplanır. Belirlenen Gini indeks değerleri içerisindeki en küçük $Gini_b$ değerine sahip değişken değeri, dallara ayrılma (cut-off) değeri olarak seçilir.

$$Gini_b(T) = \frac{N_1}{N} Gini(D1) + \frac{N_2}{N} Gini(D2) \quad (3.23)$$


Yaparak düğümler elde edilene kadar ağaç dallanarak büyüme devam eder. Ağaç oluşturma işlemi tamamlandıktan sonra OOB verileri kullanılarak, geliştirilen ağaca ait OOB hata değeri bulunur. Tüm bu işlemler tekrarlanarak ormandaki ağaçlar geliştirilir ve bu ağaçlara ait OOB hata değerleri belirlenir. Her ağaca OOB hata oranıyla ters oranlı olacak şekilde bir ağırlık verilir yani OOB hata oranı düşük olana yüksek ağırlık verilirken, OOB hata oranı yüksek olana düşük ağırlık verilir. Test kümesinden bir elaman için sınıflandırma yapıldığında, tüm karar ağaçlarından elde edilen tahminler ağırlıklarıyla birlikte oylamaya dahil edilerek nihai karar verilmiş olunur. RF yöntemi ile nasıl sınıflandırma yapıldığı Şekil 3.15’de gösterilmiştir.

RF yöntemiyle tüm sınıf dağılımları için bir çıkış olasılık değeri üretilmektedir. Bu değerler belirlenirken, eşitlik (3.24)’de verildiği gibi her ağaç tarafından belirlenen $P_t(c|v)$ sonsal olasılıkların ortalaması alınarak belirlenir. Buradaki T , ağaç sayısıdır. 3 Farklı ağaca ait sonsal olasılıklar Şekil 3.16’da gösterilmiştir [46].


$$P(c|v) = \frac{1}{T} \sum_{t=1}^T P_t(c|v) \quad (3.24)$$

RF yöntemiyle sınıf dağılımların yanında, kullanıcıya 3 parametre daha üretilir. Bunlardan ilki, genelleştirilmiş hatadır. Her bir karar ağacı için elde edilen OOB hatalarının ortalaması alınarak sınıflandırıcının genel doğrulunu ifade eden genelleştirilmiş hata değeri belirlenebilir. İkinci parametre, değişken önemi (variable importance). Gini indeksiyle hesaplanan bu parametrede, bir değişken belirlenerek yeri değiştirilir. Yeri değiştirilmeden önceki ve değiştirildikten sonraki Gini indeksiindeki farka göre değişkene bir önem değeri atanır. Bu parametre

sayesinde önem derecesi düşük değişkenler çıkarılarak boyut indirgeme yapılabilir. Son parametre ise yakınlık analizidir (Proximity analysis). Bu parametre ile eğitim kümesini oluşturan elemanlar arasında yakınlık ifade edilir. Bu parametre sayesinde kümeleme yapılabilir ve bunun yanı sıra aykırı gürültü değerleri belirlenebilir.



Şekil 3.15: Rastgele orman yöntemi ile sınıflandırma.



Şekil 3.16: 3 Farklı ağaçlara ait sonsal olasılık.

Bu çalışmada, RF yöntemi kullanılırken işlem yükünü çok fazla arttırmamak için ağaç sayısı 100 olarak seçilmiştir. Düğüm değişken sayısı olan m değeri azalırken korelasyon ve sınıflandırma gücü azalır, m değeri artarken korelasyon ve sınıflandırma gücü artar. Amacımız ağaçları arasında düşük korelasyon olan, sınıflandırma gücü yüksek bir orman geliştirmek olduğu için, bir örneğe ait öznelilik sayının kareköküne en yakın tam sayı değeri, düğüm değişken sayısı olarak seçilmiştir.

3.2.3. Softmax

Literatürde çok sınıflı lojistik bağlanım (Multinomial logistic regression) olarak da bilinen bu yöntem, lojistik bağlanım (Logistic regression) yönteminin çok sınıflı problemler için genelleştirilmiş halidir [47]. K adet sınıf içeren softmax sınıflandırıcının sonsal olasılığı eşitlik (3.25)'de ifade edildiği gibi bulunmaktadır.

$$P(\mathbf{z}_n | \mathbf{s}_n, \boldsymbol{\omega}_{1:K}) = \prod_{k=1}^K \left(\frac{e^{\boldsymbol{\omega}_k^T \mathbf{s}_n}}{\sum_{j=1}^K e^{\boldsymbol{\omega}_j^T \mathbf{s}_n}} \right)^{z_{n,k}} \quad (3.25)$$

Bu eşitlikte yer alan $\mathbf{z}_n = [z_{n,1}, z_{n,2}, \dots, z_{n,K}]^T$, sınıf etiket vektörünü ifade eder ve sadece etiket değerine karşılık gelen değer 1, diğer değerler ise 0 değerini alır. Örneğin etiket numarası 2 olan bir örneğin etiket vektörü $[0, 1, 0, \dots, 0]^T$ şeklinde ifade edilir. $\mathbf{s}_n$, n ' inci örneğin öznelilik vektörünü ifade eder. $\boldsymbol{\omega}_{1:K}$ ise, eşitlik

(3.26)'da verildiği gibi tüm sınıflara ait bağlanım parametrelerini içeren bir matrisi ifade eder.

$$\omega_{1:K} = \begin{bmatrix} | & | & | & | \\ \omega_1 & \omega_2 & \dots & \omega_K \\ | & | & | & | \end{bmatrix} \quad (3.26)$$

Softmax sınıflandırıcı da kullanıcı tarafından belirlenen bir parametre yoktur. Test verilerinin sonsal olasılığı belirlenirken, bilinmesi gereken tüm sınıflara ait bağlanım parametresinin bileşenleri eğitim kümesindeki veriler kullanılarak, eşitlik (3.27)'de verilen log-posterior değerini maksimize eden $\omega_{1:K}$ seçilir. Bu bağlanım bileşenleri analitik olarak bulmak mümkün olmadığı için iteratif bir yöntem olan Newton metodu kullanılarak tüm sınıflara ait bağlanım bileşenleri belirlenir.

$$J(\omega) = - \sum_{n=1}^N \left[\sum_{k=1}^K z_{n,k} \omega_k^T s_n - \log \sum_{j=1}^K \exp(\omega_j^T s_n) \right] \quad (3.27)$$

Tüm sınıflara ait bağlanım bileşenleri belirlendikten sonra, girilen örneğe ait öznitelik vektörü hangi sınıf için maksimum sonsal olasılığa sahipse, o sınıfa atanarak etiketlemesi yapılır.

3.2.4. Yaklaşık Seyrelik Çok Terimli Lojistik Bağlanım

YSCLB yöntemi, çok terimli lojistik bağlanım yani softmax yöntemine seyreklik kısıtı eklenmiş halidir [26]. Bu yöntemde bağlanım parametresinin seyrek olmasını sağlamak için eşitlik (3.28)' de verilen Laplace önseli kullanılır.

$$p(\omega_{1:K}|\lambda) = \prod_{k=1}^K \frac{\lambda}{2} e^{-\lambda \|\omega_k\|_1} \quad (3.28)$$

Bu eşitlikte yer alan $\|\omega_k\|_1 = \sum_{l=1}^L |\omega_{k,l}|$, l_1 normunu ifade eder. λ ise seyreklik katsayısını ifade eder. Bağlanımı parametresini seyreltirken kullanılan algoritma Şekil 3.17'de verilmiştir [26].

Algoritma	Yaklaşık Seyrelik Çok Terimli Lojistik Bağlanım
------------------	--

Maksimum iterasyon sayısı $T_{\max}$ ve
Seyreklik katsayısı λ değerini belirle
Tüm k değerleri için $\omega_k^{(0)} = 1/1000$ ve $e_k = 1/1000$
Tüm (k, j) değerleri için $B_{kj} = -\frac{1}{2}(\delta_{kj} - 1/K)S^T S$
While $t \leq T_{\max}$ **do**
 for $k = 1:K$ **do**
 $\pi_{n,k} = \frac{e^{(\omega_k^{(t)})^T s_n}}{\sum_{j=1}^K e^{(\omega_j^{(t)})^T s_n}}$
 $g_k(\omega_k^{(t)}) = \sum_{n=1}^N (z_{n,k} - \pi_{n,k})s_n + \lambda \text{sign}(\omega_k^{(t)})$
 end for
 for $k=1:K$ **do**
 $\Lambda(\omega_k^{(t)}) = \text{diag}\{| \omega_{k,1}^{(t)} |^{-1}, | \omega_{k,2}^{(t)} |^{-1}, \dots, | \omega_{k,L}^{(t)} |^{-1}\}$
 $e_k = -[B_{kk} - \lambda \Lambda(\omega_k^{(t)})]^{-1} [g_k(\omega_k^{(t)}) + \sum_{j \neq k} B_{kj} e_j]$
 $\omega_k^{(t+1)} = \omega_k^{(t)} + e_k$
 end for
end while

Şekil 3.17: Seyrek bağlanım parametresi belirlenirken kullanılan algoritma.

Buradaki $S = [s_1, s_2, s_3, \dots, s_N]^T$, δ_{kj} ise Kronecker delta fonksiyonudur. Burada türevi alınamayan fonksiyonlarla başa çıkabilmek için alt gradyan vektörü olan $g_k(\omega_k^{(t)})$ kullanılmıştır. Bu algoritmayla seyreltilmiş $\hat{\omega}_{1:K}$ belirlendikten sonra test aşamasında girilen s_n öznitelik vektörünün sınıfı eşitlik (3.29)' da verildiği gibi belirlenir. Buradaki q_k , k . sınıfa ait yoğunluğu belirtir.

$$z_n \leftarrow \max_{z_n} \prod_{k=1}^K \left(\frac{e^{(\hat{\omega}_k^{(t)})^T s_n}}{\sum_{j=1}^K e^{(\hat{\omega}_j^{(t)})^T s_n}} q_k \right)^{z_{n,k}} \quad (3.29)$$

Bu çalışmada YSÇLB yöntemi kullanılırken seyreklik katsayısı 0.1 ve maksimum iterasyon sayısı 100 seçilerek sınıflandırma işlemi yapılmıştır.

4. DENEYSEL ÇALIŞMALAR

Bu tezde yapılan tüm çalışmalar MATLAB ortamında Intel(R) Core i7-3610QM, 2.60 Ghz CPU ve 6 GB Ram özelliklerine sahip bilgisayarda yapılmıştır. Yapılan deneysel çalışmalar iki aşamadan oluşmaktadır. Bu aşamalardan ilkinde, önerilen yöntemleri üzerinde deneyerek başarımlarını ölçmek için oluşturduğumuz yüksek çözünürlüklü SAR veri setleri anlatılmaktadır. İkinci aşama olan deneysel sonuçlar kısmında ise oluşturulan veri setleri üzerinde önerilen yöntemler denenerek elde edilen sınıflandırma başarımları karşılaştırılmıştır.


4.1. Veri Seti Oluşturma

Kullanıma sunulmuş ve yer doğruluk haritasını içeren yüksek çözünürlüklü bir SAR veri seti olmadığı için TerraSAR-X uydusu tarafından elde edilmiş ve erişime açılmış SAR imgeleri içerisinde yüksek çözünürlüklü olanları seçilerek, bu imgelerin yama tabanlı yer doğruluk haritaları çıkarılmıştır [48]. Bu işlemler yapılırken literatürde yer alan [3], [49]'daki gibi benzer çalışmalar referans alınmıştır.


4.1.1. Görüntü 1 Veri Seti

Veri seti oluşturmak için TerraSAR-X uydusu tarafından elde edilerek kullanıma sunulmuş SAR imgeleri arasından, 2014 yılında HH polarizasyonlu, noktasal aydınlatma modunda elde edilmiş, 0,25 m çözünürlüğe sahip Marsilya SAR imgesi seçilmiştir. Marsilya SAR imgesi Şekil 4.1'de verilmiştir.

Bu imgenin boyutları çok büyük olduğu için 8000×10000 boyutlarında bir kesit alınarak Görüntü 1 adı verilmiştir. Görüntü 1 imgesi, 400×400 boyutlarında yamalara ayrılarak, toplamda 500 adet yama elde edilmiştir. Tüm bu yamalara, sınıflarına göre bir etiket değeri verilerek yer doğruluk haritası çıkarılmıştır. Görüntü 1 ve ona ait yer doğruluk haritası Şekil 4.2'de verilmiştir. Görüntü 1'in içerdiği sınıfların SAR ve optik görüntüleri Şekil 4.3'de verilmiştir. Görüntü 1'in içerdiği sınıfların isimleri ve yama sayıları Tablo 4.1'de verilmiştir.




Şekil 4.1: Marsilya SAR imgesi.



Şekil 4.2: a) Görüntü 1, b) Yer doğruluk haritası.

Tablo 4.1: Görüntü 1'in içerdği sınıfların etiketleri, adları ve yama sayıları.


Etiket Değeri	Sınıf Adı	Yama Sayısı
1	Deniz	207
2	Dalga kıran	19
3	Liman	40
4	Yüksek yoğunlukta yerleşim alanı	84
5	Orta yoğunlukta yerleşim alanı	118
6	Marina	32



Şekil 4.3: Görüntü 1'in içerdği sınıfların SAR ve optik görüntüleri.

4.1.2. Görüntü 2 Veri Seti

Şekil 4.1'de verilen Marsilya SAR imgesinden 8000×10000 boyutlarında başka bir kesit alınarak Görüntü 2 adı verilmiştir. Aynı şekilde bu imge de 400×400 boyutlarında yamalara ayrılarak, toplamda 500 adet yama elde edilmiştir. Tüm bu yamalar, sınıflarına göre etiketlenerek yer doğruluk haritası çıkarılmıştır. Görüntü 2 ve yer doğruluk haritası Şekil 4.4'de verilmiştir. Görüntü 2'in içerdği sınıfların SAR ve optik görüntüleri Şekil 4.5'de verilmiştir. Görüntü 2'in içerdği sınıfların isimleri ve yama sayıları Tablo 4.1'de verilmiştir



Şekil 4.4: a) Görüntü 2, b) Yer doğruluk haritası.




Şekil 4.5: Görüntü 2'nin içerdiği sınıfların SAR ve optik görüntüleri.

Tablo 4.2: Görüntü 2'nin içerdiği sınıfların etiket değeri, adı ve yama sayıları.

Etiket Değeri	Sınıf Adı	Yama Sayısı
1	Düşük yoğunlukta yerleşim alanı	73
2	Orta yoğunlukta yerleşim alanı	391
3	Demiryolu	36


4.1.3. Görüntü 3 Veri Seti

Görüntü 3 veri setini oluşturmak için TerraSAR-X uydusu tarafından 2013 yılında HH polarizasyonlu, noktasal aydınlatma modunda elde edilmiş, 0,25 m çözünürlüğe sahip Shanghai SAR imgesi seçilmiştir. Shanghai SAR imgesi Şekil 4.6'da verilmiştir.




Şekil 4.6: Shanghai SAR İmgesi.

Shanghai SAR imgesinin boyutları çok büyük olduğu için 18000×12000 boyutlarında bir kesit alınarak buna Görüntü 3 adı verilmiştir. Görüntü 3 imgesi, 400×400 boyutlarında yamalara ayrılarak, toplamda 1350 adet yama elde edilmiştir. Tüm bu yamalara, sınıflarına göre bir etiket değeri verilerek yer doğruluk haritası çıkarılmıştır. Görüntü 3 Şekil 4.7’de verilmiştir. Görüntü 3 içerisindeki sınıflardan 3 tanesi dikkate alınarak elde edilen yer doğruluk haritası Şekil 4.8’de verilmiştir.




Şekil 4.7: Görüntü 3.



Şekil 4.8: 3 Sınıf dikkate alınarak elde edilmiş Görüntü 3’e ait yer doğruluk haritası.

3 Sınıflı Görüntü 3’ün içerdiği sınıflara ait SAR ve optik görüntüler Şekil 4.9’da bu sınıflara ait etiket değerleri ve yama sayıları ise Tablo 4.3’de verilmiştir.




Şekil 4.9: 3 Sınıflı Görüntü 3'ün içerdiği sınıflara ait SAR ve optik görüntüler.


Tablo 4.3: 3 Sınıflı Görüntü 3'e ait sınıfların etiket değeri, adı ve yama sayıları.

Etiket Değeri	Sınıf Adı	Yama Sayısı
0	Etiketlenmemiş Alan	631
1	Konteynır Alanı	249
2	Orta Yoğunlukta Yerleşim alanı	262
3	Ağaçlık Alan	208

Görüntü 3 içerisinde 4 tane sınıf dikkate alınarak elde edilmiş yer doğruluk haritası Şekil 4.10' da verilmiştir. Bu dört sınıflı Görüntü 3'ün içerdiği sınıfların SAR ve optik görüntüleri Şekil 4.11'de verilmiştir. Bu sınıflara karşılık gelen etiket değerleri ve yama sayıları Tablo 4.4'de verilmiştir.



Şekil 4.10: 4 sınıflı Görüntü 3'e ait yer doğruluk haritası.




Şekil 4.11: 4 Sınıflı Görüntü 3'ün içerdiği sınıflara ait SAR ve optik görüntüler.

Tablo 4.4: 4 Sınıflı Görüntü 3'ün içerdiği sınıfların etiket değerleri ve yama sayıları.

Etiket Değeri	Sınıf Adı	Yama Sayısı
0	Etiketlenmemiş Alan	368
1	Konteynır Alanı	249
2	Orta Yoğunlukta Yerleşim alanı	262
3	Ağaçlık Alan	208
4	Endüstriyel Bina	263

4.2. Deneysel Sonuçlar

Bu çalışma kapsamında yapılan SAR imgelerinde anlambilimsel sınıflandırma işleminde ilk olarak imgeler çözünürlüğüne ve piksel genişliğine bağlı olarak yamalara ayrılır. Bu yamaları temsil etmek için önerilen öznetelik çıkarma yöntemleri kullanılarak, tüm yamaların öznetelikleri ile ifade edildiği bir veri kümesi oluşturulur. Bu veri kümesi, içerdiği sınıfların yama sayılarına bağlı olarak eğitim ve test kümelerine ayrılır. Eğitim kümesindeki örnekler ve bunlara ait sınıf etiketleri kullanılarak önerilen denetimli sınıflandırıcılar eğitilir. Eğitilmiş sınıflandırıcılar ile test kümesindeki örnekler sınıflandırılarak, başarımlarıyla birlikte sınıflandırma haritaları üretilir. Anlambilimsel sınıflandırılma algoritma akış şeması Şekil 4.12’de gösterilmiştir.



Şekil 4.12: Anlambilimsel sınıflandırma algoritma akış şeması.

Test kümesi üzerinde sınıflandırma başarımlarını elde ederken, sınıflandırma sonuçlarına göre Şekil 4.13’de verilen gibi bir karışıklık matrisi (Confusion matrix) oluşturulur. Bu matriste, mavi renkle gösterilen köşegenlerinde yer alan doğru sınıflandırılış örnek sayıları toplanarak, test kümesindeki toplam örnek sayısına bölünmesiyle genel doğruluk (Overall accuracy) oranı elde edilir.

Karışıklık Matrisi		Tahmin Edilen			
		Sınıf 1	Sınıf 2	...	Sınıf N
Gerçek	Sınıf 1				
	Sınıf 2				
	⋮				
	Sınıf N				

Şekil 4.13: Karışıklık matrisi.


Görüntü 1’in anlambilimsel sınıflandırılmasında GLCM (48 öznitelik), Gabor (60 öznitelik), LBP (59 öznitelik) ve HOG (64 öznitelik) yöntemleri kullanılarak her yamaya ait öznitelikler çıkarılmıştır. Elde edilen öznitelik kümesindeki sınıflara ait yama sayılarına bakılarak, yama sayısı 100’den büyük olan sınıflardan rastgele 50 örnek, yama sayısı 100’den küçük olan sınıflardan sahip olduğu toplam yama sayısının yarısı kadar rastgele örnek alınarak eğitim kümesi oluşturulmuştur. Geri kalan örneklerle de test kümesi oluşturulmuştur. Eğitim kümesindeki örnekler kullanılarak, SVM, ağaç tabanlı torbalama (Torbalama (A)), liner discriminant analizi tabanlı torbalama(Torbalama(LDA)), AdaboosM2, RF, softmax ve YSÇLB sınıflandırıcıları eğitilerek test kümesi içerisindeki örnekler sınıflandırılmıştır. Rastgele örnekler seçilerek eğitim ve test kümesi oluşturma işlemi yirmi kez tekrarlanarak, elde edilen sınıflandırma sonuçların ortalamaları alınarak Tablo 4.5’ de verilen sonuçlar elde edilmiştir. GLCM öznitelikleri kullanılarak elde edilen sınıflandırma haritaları Şekil 4.14’ de verilmiştir. Gabor öznitelikleri kullanılarak elde edilen sınıflandırma haritaları Şekil 4.15’ de verilmiştir. LBP öznitelikleri kullanılarak elde edilen sınıflandırma haritaları Şekil 4.16’ da verilmiştir. HOG öznitelikleri kullanılarak elde edilen sınıflandırma haritaları Şekil 4.17’ de verilmiştir.

Görüntü 1’den elde edilen tüm sonuçlar kıyaslandığında GLCM ve Gabor özniteliklerinde torbalama(LDA), LBP özniteliklerinde softmax, HOG


özniteliklerinde RF yöntemin en yüksek başarıma sahip olduğu görülmektedir. Topluluk öğrenmesine dayalı sınıflandırıcıların bireysel sınıflandırıcılara kıyasla daha iyi sınıflandırma başarımına sahipken sadece LBP yönteminde bireysel bir sınıflandırıcı olan softmax ile en iyi başarımın elde edilmiştir. Elde edilen en yüksek sınıflandırma başarımın yamalara ait Gabor özniteliklerinin torbalama(LDA) yöntemi ile sınıflandırılmasıyla elde edildiği görülmektedir.

Tablo 4.5: Görüntü 1'e ait sınıflandırma sonuçları.


Öznitelik Çıkarma Yöntemi	Sınıflandırma Yöntemi						
	SVM	Torbalama (A)	Torbalama (LDA)	AdaboostM2	RF	Softmax	YSÇLB
GLCM	75.50	79.72	83.35	73.85	80.01	82.20	82.86
Gabor	83.18	83.95	84.68	76.26	83.48	81.72	83.80
LBP	78.46	81.99	78.32	72.81	82.10	82.26	80.17
HOG	71.66	74.47	74.18	70.46	74.61	69.13	73.41




Şekil 4.14: Görüntü 1'de GLCM öznitelikleriyle elde edilen sınıflandırma haritaları.



Şekil 4.15: Görüntü 1’de Gabor öz nitelikleriyle elde edilen sınıflandırma haritaları.



Şekil 4.16: Görüntü 1’de LBP öz nitelikleriyle elde edilen sınıflandırma haritaları.



Şekil 4.17: Görüntü 1’de HOG öznitelikleriyle elde edilen sınıflandırma haritaları.


Görüntü 2’nin anlambilimsel sınıflandırılmasında, Görüntü 1’in sınıflandırılmasında kullanılan öznitelik çıkarma ve denetimli sınıflandırma yöntemleri kullanılmıştır. Bu görüntüden elde edilen öznitelik kümesinde sınıflara ait yamalara sayılarına bakılarak, yama sayısı 260’ dan büyük olan sınıflardan 130 tane rastgele örnek, yama sayısı 260’ dan küçük olan sınıflardan içerdikleri örnek sayısının yarısı kadar rastgele örnek alınarak eğitim kümesi oluşturulmuştur. Geri kalan örneklerle de test kümesi oluşturulmuştur. Bu rastgele örnek seçme işlemi yirmi kez tekrarlanarak elde edilen sınıflandırma sonuçlarının ortalaması Tablo 4.6’ de verilmiştir. Görüntü 2’nin anlambilimsel sınıflandırılmasında, GLCM öznitelikleri kullanılarak elde edilen sınıflandırma haritaları Şekil 4.18’de, Gabor öznitelikleri kullanılarak elde edilen sınıflandırma haritaları Şekil 4.19’da, LBP öznitelikleri kullanılarak elde edilen sınıflandırma haritaları Şekil 4.20’de, HOG öznitelikleri kullanılarak elde edilen sınıflandırma haritaları Şekil 4.21’de verilmiştir.

Görüntü 2’ den elde edilen sınıflandırma başarımlarına bakıldığında, GLCM ve LBP özniteliklerinde en yüksek başarımlar YSÇLB yöntemi ile alınırken, Gabor ve HOG özniteliklerinde ise en yüksek başarımların RF yöntemiyle alındığı görülmektedir. Bu görüntüde yer alan sınıfların birbirlerine benzer özellikler taşımlarından dolayı bu sınıfların doğrusal olarak ayrılabilmesini zorlaştırmıştır. Bundan dolayı sınıflandırma


yöntemlerinin başarımlarına bakıldığında LDA tabanlı torbalama yönteminin diğer yöntemlerin gerisinde kalmasına neden olduğu düşünülmektedir. En yüksek sonucun YSÇLB yöntemiyle elde edilmesine rağmen topluluk öğrenme yöntemleriyle de yakın sonuçlar elde edilebildiği görülmektedir.

Tablo 4.6: Görüntü 2'ye ait sınıflandırma sonuçları.


Öznitelik Çıkarma Yöntemi	Sınıflandırma Yöntemi						
	SVM	Torbalama (A)	Torbalama (LDA)	AdaboostM2	RF	Softmax	YSÇLB
GLCM	77.64	84.85	85.52	82.78	84.89	85.44	86.48
Gabor	82.18	86.12	82.61	84.57	86.45	78.30	84.21
LBP	82.08	86.53	82.40	85.06	86.83	85.75	87.78
HOG	79.66	83.32	74.25	82.57	83.56	73.19	77.92




Şekil 4.18:Görüntü 2'de GLCM öznitelikleriyle elde edilen sınıflandırma haritaları.



Şekil 4.19: Görüntü 2'de Gabor öz nitelikleriyle elde edilen sınıflandırma haritaları.



Şekil 4.20: Görüntü 2'de LBP öz nitelikleriyle elde edilen sınıflandırma haritaları.



Şekil 4.21: Görüntü 2'de HOG öznitelikleri ile elde edilen sınıflandırma haritaları.


3 Sınıflı Görüntü 3'de de benzer şekilde öznitelik çıkarma ve sınıflandırma yöntemleri kullanılmıştır. Elde edilen öznitelik kümesinde sınıflara ait yamalar sayılarına bakılarak, yama sayısı 260' dan büyük olan sınıflardan 130 tane rastgele örnek, yama sayısı 260' dan küçük olan sınıflardan içerdikleri örnek sayısının yarısı kadar rastgele örnek alınarak eğitim kümesi oluşturulmuştur. Geri kalan örneklerle de test kümesi oluşturulmuştur. Bu rastgele örnek seçme işlemi yirmi kez tekrarlanarak elde edilen sınıflandırma sonuçlarının ortalaması Tablo 4.7' de verilmiştir. GLCM, Gabor, LBP ve HOG öznitelikleri kullanılarak elde edilen sınıflandırma haritaları sırasıyla Şekil 22, Şekil 23, Şekil 24 ve Şekil 25' de verilmiştir.

3 Sınıflı Görüntü 3'den elde edilen sonuçlara bakıldığında, GLCM ve Gabor öznitelikleri kullanıldığında en iyi sonucun torbalama(LDA) ile alındığı görülmektedir. Bu sınıflandırıcıya en yakın sonucun ise YSÇLB ile elde edildiği görülmektedir. LBP ve HOG özniteliklerinde ise SVM ile en yüksek sınıflandırılma başarımının elde edildiği görülmektedir. En yüksek sınıflandırma başarımının ise


öznitelik çıkarmada GLCM, sınıflandırmada ise torbalama(LDA) yöntemi kullanıldığında elde edildiği görülmektedir.

Tablo 4.7: 3 Sınıflı Görüntü 3'den elde edilen sınıflandırma sonuçları


Öznitelik Çıkarma Yöntemi	Sınıflandırma Yöntemi						
	SVM	Torbalama (A)	Torbalama (LDA)	AdaboostM2	RF	Softmax	YSÇLB
GLCM	79.21	77.17	87.65	65.95	76.99	71.67	86.81
Gabor	81.68	80.68	82.41	71.31	80.33	79.54	81.80
LBP	83.86	83.51	81.52	77.86	83.58	83.22	82.91
HOG	66.90	64.05	59.70	59.13	64.47	63.13	61.65




Şekil 4.22: 3 Sınıflı Görüntü 3'de GLCM öznitelikleri kullanılarak elde edilen sınıflandırma haritaları.



Şekil 4.23: 3 Sınıflı Görüntü 3'de Gabor öz nitelikleri kullanılarak elde edilen sınıflandırma haritaları.



Şekil 4.24: 3 Sınıflı Görüntü 3'de LBP öz nitelikleri kullanılarak elde edilen sınıflandırma haritaları.



Şekil 4.25:3 Sınıflı Görüntü 3'de HOG öznitelikleri kullanılarak elde edilen sınıflandırma haritaları.


3 Sınıflı Görüntü 3 verisine uygulanan işlemlerin aynısı 4 sınıflı Görüntü 3 verisine de uygulanarak elde edilen sınıflandırma sonuçları Tablo 4.8'de verilmiştir. GLCM, Gabor, LBP ve HOG yöntemleriyle elde edilen sınıflandırma haritaları sırasıyla Şekil 4.26, Şekil 4.27, Şekil 4.28 ve Şekil 4.29' da verilmiştir.

Tablo 4.8: 4 Sınıflı Görüntü 3'den elde edilen sınıflandırma sonuçları.


Öznitelik Çıkarma Yöntemi	Sınıflandırma Yöntemi						
	SVM	Torbalama (A)	Torbalama (LDA)	AdaboostM2	RF	Softmax	YSÇLB
GLCM	66.60	65.59	73.72	56.51	65.70	59.77	73.35
Gabor	68.04	68.60	70.85	57.44	68.22	68.80	70.06
LBP	68.99	72.13	68.41	62.93	71.96	70.56	70.20
HOG	53.55	53.56	49.95	43.92	53.09	52.14	50.64

4 sınıflı Görüntü 3 veri setinde de GLCM ve Gabor öznitelikleri kullanıldığında en yüksek sonucun torbalama(LDA) ile elde edildiği ve yine bu sınıflandırıcıya en yakın başarımın YSÇLB ile elde edildiği görülmektedir. LBP ve


HOG özniteliklerinde ise en iyi sonucun Torbalama(A) ile elde edildiği görülmektedir. En yüksek sınıflandırılma başarımının ise yamalarak ait GLCM özniteliklerinin, torbalama(LDA) yöntemiyle sınıflandırıldığında elde edildiği görülmektedir.




Şekil 4.26: 4 Sınıflı Görüntü 3'de GLCM öznitelikleri kullanılarak elde edilen sınıflandırma haritaları.



Şekil 4.27: 4 Sınıflı Görüntü 3'de Gabor öznitelikleri kullanılarak elde edilen sınıflandırma haritaları.



Şekil 4.28: 4 Sınıflı Görüntü 3'de LBP öznitelikleri kullanılarak elde edilen sınıflandırma haritaları.



Şekil 4.29: 4 Sınıflı Görüntü 3'de HOG öznitelikleri kullanılarak elde edilen sınıflandırma haritaları.

Tüm veri setlerinden elde edilen sınıflandırma başarımlarına göre öznitelik çıkarma yöntemlerinin etkinliğini kıyasladığımızda, GLCM, Gabor ve LBP öznitelik çıkarma yöntemleriyle en yüksek sonuçların elde edilebildiği görülmüştür. Farklı veri setlerinde farklı yöntemlerin iyi sonuç verebilmesinin nedeni olarak, bu görüntülerin içerdiği gürültü miktarı, sınıflar ve bu sınıfların ayrılabilirlik zorluklarının farklı olması gösterilebilir. Bu yöntemlerin yanı sıra HOG yöntemi ile tüm veri setlerinde en düşük sonuçların alındığı görülmektedir. Bunun sebebi olarak yamalardan elde edilen gradyan büyüklüklerinin, sınıfların birbirinden ayrılmasında etkin bir ayırt edici özellik olmadığı söylenebilir.

Sınıflandırma yöntemlerini kıyasladığımızda elde edilen özniteliklerin lineer bir şekilde ayrılıp ayrılamadığı durumlara göre sınıflandırıcı başarımlarının farklılık gösterdiği görülmektedir. GLCM ve Gabor yöntemleriyle elde edilen özniteliklerde genelde torbalama(LDA) yöntemleri ile en yüksek sonuçların alındığı görülmektedir. YSCLB yöntemiyle de torbalama(LDA)'a yakın sonuçlar elde edilebildiği, hatta LBP ve HOG özniteliklerinde torbalama(LDA)'dan daha iyi sonuçlar elde edildiği görülmektedir. LBP ve HOG öznitelikleri kullanıldığı torbalama(A), RF ve SVM ile yüksek başarımlar elde edildiği görülmektedir.

Gürültüye karşı çok hassas olan AdaboostM2 yöntemiyle tüm öznelilik çıkarma yöntemleriyle de en düşük sonuçların elde edildiği görülmektedir. Bu yönteme kıyasla softmax sınıflandırma yöntemiyle daha yüksek başarımlar elde edildiği görülmektedir.

5. SONUÇLAR

Bu yüksek lisans tezinde, yüksek çözünürlüklü SAR imgelerinin yama tabanlı anlambilimsel sınıflandırılması üzerine çalışmalar yapılmıştır. Farklı öznetelik çıkarma ve sınıflandırma yöntemleri kullanılarak sınıflandırma başarımları üzerindeki etkinlikleri karşılaştırılmıştır. Literatürde doku betimleyici olarak kullanılan GLCM, Gabor ve LBP öznetelik çıkarma yöntemleriyle, HOG öznetelik çıkarma yöntemine kıyasla daha iyi sonuçlar elde edildiği görülmüştür. Bu öznetelik çıkarma yöntemlerinin, veri setinin içerdiği sınıfların ayrılabilirliğine ve gürültü miktarına bağlı olarak sınıflandırma başarımlarındaki etkinliklerinin değiştiği görülmüştür. Bu nedenle veri setine uygun öznetelik çıkarma yöntemi seçildiğinde sınıflandırma başarımının artırılabilceği görülmüştür. Yamaları ifade eden özneteliklerin sınıflandırılmasında, bireysel sınıflandırıcıların yanında topluluk öğrenmesine dayalı sınıflandırıcılar da kullanılarak başarımları incelenmiştir. Topluluk öğrenmesine dayalı sınıflandırıcıların bireysel sınıflandırıcılara göre daha etkin olduğu görülmüştür. SAR imgelerin anlambilimsel sınıflandırılmasında ilk kez kullanılan ve bireysel bir sınıflandırıcı olan YSÇLB yöntemi ile en yüksek sonuçların elde edildiği torbalama(LDA)'ya yakın sonuçlar elde edildiği görülmüştür. Elde edilen sınıflandırma sonuçlarından öznetelik çıkarmada kullanılan yöntemle bağlı olarak, sınıflandırıcıların etkinliklerinin değişiklik gösterebildiği kanısına varılmıştır. Veri setine uygun öznetelik çıkarma ve sınıflandırma yöntemi seçilerek daha yüksek başarılı sınıflandırmalar gerçekleştirilebileceği gösterilmiştir.

Bu çalışmada elde edilen sonuçlardan yola çıkılarak, gelecekte YSÇLB tabanlı torbalama yöntemi geliştirilmesi planlanmaktadır. Bu geliştirilecek sınıflandırma yöntemi ile daha iyi sınıflandırma başarımları elde edilebileceği öngörülmektedir. Ayrıca yamalara tek bir etiket vermek yerine çoklu etiketler verilerek anlambilimsel sınıflandırma yapılması planlanmaktadır.

KAYNAKLAR

- [1] Yang W., Dai D., Triggs B., Xia G. S., (2009), “Semantic Labeling of SAR Images with Hierarchical Markov Aspect Models”, HAL Research Report ID: hal-00433600 ,The Centre for Direct Scientific Communication,France.
- [2] Dumitru C. O., Datcu M., (2013), “Information Content of Very High Resolution SAR Images: Study of Feature Extraction and Imaging Parameters”, IEEE Transection on Geoscience Remote Sensing, 51(8), 4591-4610.
- [3] Dumitru C. O., Datcu M., (2013), “Diversity of Settlement Categories in Very High Resolution SAR Images”, Joint Urban Remote Sensing Event 2013, 87-90, Sao Paulo,Brazil, 21-23 April.
- [4] Feng H., Hou B., Gong M., (2011), “SAR Image Despeckling Based on Local Homogeneous-Region Segmentation by Using Pixel-Relativity Measurement”, IEEE Transactions on Geoscience and Remote Sensing, 49(7), 2724-2737.
- [5] Popescu A., Gavat I., Datcu M., (2008), “Complex SAR Image Characterization Using Space Variant Spectral Analysis”, 2008 IEEE Radar Conference,1-4, Roma,Italy,26-30 May.
- [6] Sakarya U., Demirpolat C., (2017), “Genel ve Yerel Bilgiler Tabanlı Doğrusal Ayraç Analizi Kullanılarak Bitki Sınıflandırmada SAR Görüntüsü Zaman Serisi Analizi”, 2017 25th Signal Processing and Communications Applications Conference (SIU) , 1-4, Antalya, Turkey,15-18 Mayıs.
- [7] Geng J., Fan J., Wang H. , X. Ma, Li B., Chen F., (2015), “High-Resolution SAR Image Classification via Deep Convolutional Autoencoders”, Geoscience and Remote Sensing Letters, 12(11), 2351-2355.
- [8] Wu F., Gong L., Wang C., Zang H., Zang B., Xie L., (2016), “Signature Analysis of Building Damage With TerraSAR-X New Staring SpotLight Mode Data”, IEEE Geosience Remote Sensing Letters, 13(11),1696-1700.
- [9] Dumitru C. O., Chui S., Faur D., Datcu M., (2015), “Data Analytics for Rapid Mapping: Case Study of a Flooding Event in Germany and the Tsunami in Japan Using Very High Resolution SAR Images”, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 8(1),114-129.
- [10] Bhadran B., Nair J. J., (2015), “Classification of Patterns on High Resolution SAR Images”, 2015 International Conference on Computing and Network Communications, 784-792, Trivandrum, India, 16-19 December.

- [11] Ye Y., Shan J., Bruzzone L., Shen L., (2017), "Robust Registration of Multimodal Remote Sensing Images Based on Structural Similarity", *IEEE Transactions on Geoscience and Remote Sensing*, 55(5), 2941-2958.
- [12] Waske B., Benediktsson J. A.,(2007), "Fusion of Support Vector Machines for Classification of Multisensor Data", *IEEE Transactions on Geoscience and Remote Sensing*, 45(12), 3858-3866.
- [13] Liu Y., Wu L., (2016), "Geological Disaster Recognition on Optical Remote Sensing Images Using Deep Learning", *Procedia Computer Science*, 91, 566-575.
- [14] Li J., Bioucas-Dias J. M., Plaza A., (2011), "Hyperspectral Image Segmentation Using a New Bayesian Approach with Active Learning", *IEEE Transactions on Geoscience and Remote Sensing*, 49(10), 3947-3960.
- [15] Belgiu M., Dragut L., (2016), "Random Forest in Remote Sensing: A Review of Applications and Future Directions", *ISPRS Journal of Photogrammetry and Remote Sensing*, 114,24-31.
- [16] Dumitru C. O., Schwarz G., Datcu M., (2018), "SAR Image Land Cover Datasets for Classification Benchmarking of Temporal Changes", *IEEE Journal of Selected Topics in Applied Earth Observations and Remote*, 11(5), 1571 - 1592.
- [17] Türkmenli İ., Kayabol K., Aptoula E., (2018), "Comparison of Semantic Classification Algorithms on SAR Images", 2018 26th Signal Processing and Communications Applications Conference, 1-4, İzmir, Turkey, 2-5 May.
- [18] Haralick R. M., Shanmugam K., Dinstein I., (1973), "Textural Features for Image Classification", *IEEE Transactions on Systems, Man, and Cybernetics*, 3(6), 610-621.
- [19] Jain A. K., Farrokhnia F., (1990), "Unsupervised Texture Segmentation Using Gabor Filters", 1990 IEEE International Conference on Systems, Man, and Cybernetics Conference Proceedings, 14-19, Los Angeles, USA, 4-7 November.
- [20] Ojala T., Pietikainen M., Harwood D., (1996), "A Comparative Study of Texture Measures with Classification Based on Featured Distribution", *Pattern Recognition*, 29(1), 51-59.
- [21] Dalal N., Triggs B., (2005), "Histograms of Oriented Gradients for Human Detection", 2005 IEEE Computer Society Conference on Computer Vision, 886-893, San Diego, USA, 20 June.
- [22] Cortes C., Vapnik V., (1995) "Support-Vector Network", *Machine Learning*, 20(3), 273-297.

- [23] Waske B., Braun M., (2009), "Classifier Ensembles For Land Cover Mapping Using Multitemporal SAR Imagery", *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(5),450-457.
- [24] Samat A., Du P., Baig M. H. A., Chakravarty S., Cheng L., (2014), "Ensemble Learning with Multiple Classifiers and Polarimetric Features for Polarized SAR Images Classification", *Photogrammetric Engineering and Remote Sensing*, 80(3), 239-251.
- [25] Krishnapuram B., Carin L., Figueiredo M. A. T., (2005), "Sparse Multinomial Logistic Regression: Fast Algorithms and Generalization Bounds", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27(6), 957-968.
- [26] Kayabol K., (2016), "Spectral-Spatial Classification of Hyperspectral Images Using Approximate Sparse Multinomial Logistic Regression", *WSEAS Transactions on Mathematics*, 16, 57-61.
- [27] Song S., Xu B. ve Yang J., (2016), "SAR Target Recognition via Supervised Discriminative Dictionary Learning and Sparse Representation of the SAR-HOG Feature", *Remote Sensing*, 8(8), 683.
- [28] Irak H., (2009), "SAR Sistem ve Teknolojileri", *EMO Elektrik Mühendisliği*, 47(437), 86-90.
- [29] Yiğit E., (2013), "Yer Üstü Platformlara Monte Edilebilecek Sentetik Açıklıklı Radar Sistemi Oluşturulması ve Gerçek Karasal Radar Görüntülerinin Elde Edilmesi", Yüksek Lisans Tezi, Mersin Üniversitesi.
- [30] Demirci Ş., (2005), "Yapay Açıklıklı Radar (SAR) Görüntülerinde İstenmeyen Yankıların Giderilmesi", Yüksek Lisans Tezi, Mersin Üniversitesi.
- [31] Arısoy S., (2015), "Uzaktan Algılanan Görüntülerin Süperpiksel Tabanlı Sınıflandırılması", Yüksek Lisans Tezi, Gebze Teknik Üniversitesi.
- [32] Purwadı N., (2016), "A Contribution Towards Content-Based Image Retrieval Issue: Comparison Between GLCM,2DPCA and SURF in CBIR For Screening Mammography Analysis", Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi.
- [33] Acar E., Özerdem M. S., (2016), "Tarımsal İmge Dokularından HOG Algoritması ile Öznetelik Çıkarımı ve Öznetelik Tabanlı Toprak Neminin Tahmini", *Bilgisayar Bilimleri Dergisi*, 1(1), 1-7.
- [34] Gabor D., (1946), "Theory of communication. Part 2: The Analysis of Hearing", in *Electrical Engineers - Part III: Radio and Communication Engineering*, *Journal of the Institution of*, 93(26), 442-445.

- [35] Ojala T., Pietikäinen M., Harwood D., (1994), “Performance Evaluation of Texture Measures with Classification Based on Kullback Discrimination of Distributions”, Proceedings of the 12th IAPR International Conference on Pattern Recognition, 1, 582-585, Jerusalem, Israel, 9-13 October.
- [36] Döngel T., (2016), “Büyük İmge Veri Tabanlarında Erişim İçin Yarı Eğitimli Görsel Temsiller”, Yüksek Lisans Tezi, Eskişehir Osmangazi Üniversitesi.
- [37] Çölkesen İ., Kavzoğlu T., (2010), “Farklı Boyutta Eğitim Örnekleri İçin Destek Vektör Makinalarının Sınıflandırma Performansının Analizi”, III. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu, 161-170, Gebze, KOCAELİ, 11-13 Ekim.
- [38] Dietterich T., (2000), “An Experimental Comparison of Three Methods for Constructing Ensembles of Decision Trees: Bagging, Boosting, and Randomization”, Machine Learning, 40(2), 139-158.
- [39] Web 1, (2018), <https://www.analyticsvidhya.com/blog/2015/08/introduction-ensemble-learning/>, (Erişim Tarihi: 23/05/2018).
- [40] L. Breiman, (1996), “Bagging predictors”, Machine Learning, 24(2), 123-140.
- [41] Fisher R. A., (1936), “The Use of Multiple Measurements in Taxonomic Problems”, Annals of Eugenics, 7(2), 179–188.
- [42] Schapire R. E., (1990), “The strength of weak learnability”, Machine Learning, 5(2), 197–227.
- [43] Web2, (2018), http://www.pinsdaddy.com/random-forest-method_1qjiNsoa7J81QDhmgsbtYM60uDvnISayzOYBMS2VySI/, (Erişim Tarihi: 25/05/2018).
- [44] Breiman L., (2001), “Random forest”, Machine Learning, 45(1), 5-32.
- [45] Amit Y., Geman D., (1997), “Shape Quantization and Recognition with Randomized Trees”, Neural Computation, 9(7), 1545–1588.
- [46] Criminisi A., Shotton J., Konukoglu E., (2012), “Decision Forests: A Unified Framework for Classification, Regression, Density Estimation, Manifold Learning and Semi-Supervised Learning”, Foundations and Trends® in Computer Graphics and Vision, 7(2-3), 81-227.
- [47] Böhning D., (1992), “Multinomial Logistic Regression Algorithm”, Annals of the Institute of Statistical Mathematics, 44(1), 197-200.
- [48] Web 3, (2018), <https://www.intelligence-airbusds.com/en/6818-radar-dataset-sample-imagery>, (Erişim Tarihi: 04/06/2018).

- [49] Dumitru C. O., Datcu M., (2013), “ How many categories are in very high resolution SAR images?”, 2013 IEEE International Geoscience and Remote Sensing Symposium, 4257-4260, Melbourne-Australia, 21-26 July.

ÖZGEÇMİŞ

İlter Türkmenli 1992 yılında Adana'nın Kozan ilçesinde doğdu. İlk ve orta öğrenimini Kozan'da tamamlayıp, lisans eğitimini Mersin Üniversitesi Elektrik-Elektronik Mühendisliğinde aldı. 2016 yılında Adana Bilim ve Teknoloji Üniversitesi'nde Havacılık ve Uzay Mühendisliği bölümünde araştırma görevlisi olarak göreve başladı. Aynı yıl içerisinde lisansüstü eğitimini alması için Gebze Teknik Üniversitesi Elektronik Mühendisliği bölümüne görevlendirildi. 2018 yılında Gebze Teknik Üniversitesi Elektronik Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimini tamamladı. Halen Gebze Teknik Üniversitesi Elektronik Mühendisliği bölümünde araştırma görevlisi olarak uzaktan algılama, örüntü tanıma ve görüntü işleme alanında çalışmaktadır.

EKLER

Ek A: Tez Çalışması Kapsamında Yapılan Yayınlar

Türkmenli İ., Kayabol K., Aptoula E, (2018) “SAR Görüntülerinde Anlambilimsel Sınıflandırma Algoritmalarının Karşılaştırılması”, 26. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı, 1-4, İzmir, Türkiye, 2-5 Mayıs.