

**T.C.  
GEBZE TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**SAR İMGELERİNİN ÖZNETELİK TABANLI  
SINIFLANDIRILMASI**

**AYŞE TOMBAK  
YÜKSEK LİSANS TEZİ  
ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**GEBZE  
2019**

**T.C.  
GEBZE TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**SAR İMGELERİNİN ÖZNİTELİK TABANLI  
SINIFLANDIRILMASI**

**AYŞE TOMBAK**

**YÜKSEK LİSANS TEZİ**

**ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**DANIŞMANI**

**DOÇ. DR. KORAY KAYABOL**

**GEBZE**

**2019**

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

**FEATURE – BASED CLASSIFICATION  
OF SAR IMAGES**

**AYŞE TOMBAK**

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

**THESIS SUPERVISOR  
ASSOC. PROF. DR. KORAY KAYABOL**

**GEBZE  
2019**

GTÜ Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 03/07/2019 tarih ve 2019/30 sayılı kararıyla oluşturulan jüri tarafından 10/10/2019 tarihinde tez savunma sınavı yapılan Ayşe TOMBAK 'ın 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

: DOÇ. DR. IŞIN YAZGAN ERER

**ONAY**

Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun  
...../...../..... tarih ve ...../..... sayılı kararı.

## ÖZET

Uzaktan algılamada sentetik açıklık radar (SAR) imgelerinin sınıflandırılması yeryüzü bölgelerinin doğru yorumlanması açısından önemlidir. Öznitelikler kullanılarak yapılan sınıflandırma işlemi, piksel genlikleri kullanılarak yapılan sınıflandırmaya göre daha iyi sonuçlar vermektedir. Bu çalışmada, uydudan elde edilmiş SAR imgelerden yeryüzü bölgeleri farklı öznitelik yöntemleri kullanılarak piksel tabanlı olarak sınıflandırılmıştır. Öznitelik çıkarma yöntemi olarak yönlü gradyanların histogramı, yerel ikili örüntü, Gabor süzgeci, gri seviyeli eş-oluşum matrisi ve öznitelik profil yöntemleri kullanılmıştır. Sınıflandırma işlemi ise Bayesçi Gaussların karışım modeli kullanılarak yapılmıştır. Gerçek SAR uydu imgeleri ile yapılan testlerde, öznitelik profil yöntemi ile çıkarılan öznitelikler piksel tabanlı sınıflandırmada diğer öznitelik çıkarma yöntemlerine göre daha iyi sonuçlar vermiştir.

**Anahtar Kelimeler : Yönlü Gradyanların Histogramı (HOG), Yerel İkili Örüntü (LBP), Gabor Süzgeci (GF), Öznitelik Profilleri (FPs), Gri Seviyeli Eş-Oluşum Matrisi (GLCM), Bayesçi Gauss Karışım Modeli (BGMM).**

## SUMMARY

The classification of synthetic aperture radar (SAR) images is an important task in the correct interpretation of the land-covers. Classification using features gives better results than classification using pixel amplitudes. In this study, the pixel-based classification is performed by extracting features from SAR images acquired by satellites. Histogram of oriented gradients, local binary patterns, Gabor filters, feature profiles and gray level co-occurrence matrix methods are used for feature extraction. Bayesian Gaussian mixture model was used as classifier. The tests carried on real SAR images show that the features extracted by feature profiles method give the better results than the features extracted by the other methods.

**Keywords : Histogram of Oriented Gradient (HOG), Local Binary Pattern (LBP), Gabor Filter (GF), Feature Profiles (FPs), Gray Level Co-Occurrence Matrix (GLCM), Bayes Gaussian Mixture Models (BGMM).**

# TEŞEKKÜR

Başta, yüksek lisans eğitimimde ve akademik hayatımda desteğini ve yardımlarını hiçbir zaman esirgemeyip bilgisi ile bu çalışmanın oluşmasının yolunu açan danışmanım Doç. Dr. Koray KAYABOL'a,

Çalışma boyunca bilgi ve tecrübelerini benimle paylaşan, yardımlarını hiçbir zaman esirgemeyen Doç. Dr. Erchan APTOULA'a ve Elektronik Mühendisliği Araştırma Görevlisi Sertaç ARISOY'a

TerraSAR-X Spotlight ve TerraSAR-X StripMAP uydularına ait Rosenheim ve Mississippi görüntülerine, <https://terrasar-x-archive.infoterra.de> adresinden çevrimiçi erişimi sağlayan AIRBUS Defence&Space'e

ve öğrenim hayatım boyunca her zaman yanımda duran ve destekleyen aileme en içten teşekkürlerimi sunarım.

# İÇİNDEKİLER

	<b><u>Sayfa</u></b>
ÖZET	v
SUMMARY	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
SİMGELER ve KISALTMALAR DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
TABLolar DİZİNİ	xi
1. GİRİŞ	1
1.1. Tezin Amacı, Katkısı ve İçeriği	1
2. ÖZİNİTELİK ÇIKARIM YÖNTEMLERİ VE SINIFLANDIRMA	4
2.1. Özİnİtelik Çıkarım Yöntemleri	4
2.1.1. Yönlü Gradyan Histogramı	5
2.1.2. Yerel İkili Örüntü	7
2.1.3. Gabor Süzgeçleri	8
2.1.4. Gri Seviyeli Eş – Oluşum Matrisleri	10
2.1.5. Nitelik Profilleri	14
2.1.6. Özİnİtelik Profilleri	16
2.2. Sınıflandırma	17
2.2.1. Bayesçi Gauss Karışım Modeli	19
3. SAR İMGELİRİNİN ÖZİNİTELİK TABANLI SINIFLANDIRILMASI	22
3.1. SAR İmgelerine Giriş	22
3.2. SAR İmgesi Veri Kümesi	26
3.2.1. Rosenheim İmgesi	27
3.2.2. Mississippi İmgesi	28
4. DENEYSEL ÇALIŞMALAR	30
5. SONUÇLAR	43
KAYNAKLAR	44
ÖZGEÇMİŞ	48
EKLER	49

# SİMGELER ve KISALTMALAR DİZİNİ

<u>Simgeler ve</u>	<u>Açıklamalar</u>
<u>Kısaltmalar</u>	
$\mu$	: Ortalama Vektörü
$\sigma^2$	: Varyans
$\Sigma$	: Kovaryans Matrisi
$\varepsilon$	: Aşınım İşlemi
$\delta$	: Genleşme İşlemi
$\gamma$	: Morfolojik Açma İşlemi
$\phi$	: Morfolojik Kapama İşlemi
GT	: SAR İmgesi Yer Gerçeklik Haritası
HOG	: Yönlendirilmiş Gradyanların Histogramı
LBP	: Yerel İkili Örüntü
GFs	: Gabor Süzgeçleri
MPs	: Biçimbilimsel Profiller
APs	Nitelik Profilleri
FPs	Özellik Profilleri
AFs	Nitelik Süzgeçleri
GLCM	: Gri-Seviyeli Eş - Oluşum Matrisleri
BGMM	Bayesçi Gauss Karışım Modeli
SAR	: Sentetik Açıklıklı Radar
SLAR	: Side-Looking Airborne Radar
CC	: Bağlı Bileşen
MAP	: En Büyük Sonsal

# ŞEKİLLER DİZİNİ

<b><u>Sekil No:</u></b>	<b><u>Sayfa</u></b>
2.1: Yönlü Gradyan Histogramı hücre ve blok yapısı.	5
2.2: Yönlü Gradyan Histogramı.	6
2.3: Yerel İkili Örüntü piksel öznitelik çıkarımı.	7
2.4: Yerel İkili Örüntü piksel komşulukları.	8
2.5: Gauss Süzgeçleri ; a) Gri seviyedeki SAR imgesi b) 5 farklı ölçekli ve 6 farklı yönlü Gauss süzgecinden elde edilen SAR imgesinin genlik görüntüleri.	9
2.6: $\Delta=1$ ve $\theta=(0^0, 45^0, 90^0, 135^0)$ durumundaki komşu pikseller.	11
2.7: $N_g=5$ boyutu için 4 farklı rotasyondaki eş – oluşum matrisleri : $P_H(0^0), P_V(90^0), P_{RD}(45^0), P_{LD}(135^0)$ .	12
2.8: Max- ağaç; a) Yoğunluk 0-2 oranlı gri seviyeli imge, b) bağlantılı bileşenleri etiketlenmiş a)'da ki imge, c) a) imgesinin max- ağaç yapısı.	15
2.9: Veri boyutu; (a) 2 boyutlu veri (b) 3 boyutlu veri .	18
3.1: Spotlight-SAR Yöntemi.	23
3.2 Stripmap-SAR Yöntemi.	23
3.3: SAR sistemi geometrisi.	24
3.4: SAR görüntülerinin oluşturulması sırasındaki sinyal işleme süreci.	25
3.5: Rosenheim şehri imgesi.	27
3.6: Rosenheim şehri imgesinden elde edilen TSX1, TSX2, TSX3 SAR imgeleri ve yer-gerçekliği haritaları.	28
3.7: Mississippi şehri imgesi.	29
3.8: Mississippi şehri imgesinden elde edilen TSX4 SAR görüntüleri ve yer-gerçekliği haritası.	29
4.1: Akış Diagramı.	30
4.2: Karışıklık Matrisi.	32
4.3: TSX1 (eğitim ve test pikselleri) imgesinin sınıflandırma haritaları; a) Yer Gerçeklik, b) Eğitim kümesi $N=20$ , c) Eğitim kümesi $N=1000$ , d) Eğitim kümesi $N=20000$ .	33

- 4.4: TSX2 (eđitim ve test pikselleri) imgesinin sınıflandırma haritaları; 35  
a) Yer Gerçeklik, b) Eđitim kümesi N=20, c) Eđitim kümesi N=1000,  
d) Eđitim kümesi N=20000.
- 4.5: TSX3 (eđitim ve test pikselleri) imgesinin sınıflandırma haritaları; 37  
a) Yer Gerçeklik, b) Eđitim kümesi N=20, c) Eđitim kümesi N=1000,  
d) Eđitim kümesi N=20000.
- 4.6: TSX4 (eđitim ve test pikselleri) imgesinin sınıflandırma haritaları; 39  
a) Yer Gerçeklik, b) Eđitim kümesi N=20, c) Eđitim kümesi N=1000,  
d) Eđitim kümesi N=20000.



# TABLolar DİZİNİ

<b><u>Tablo No:</u></b>	<b><u>Sayfa</u></b>
2.1: GLCM' yi oluřturan öznitelik tanımlamaları ve formülleri.	13
4.1: TSX1 İmgesinin BGMM Sınıflandırma Başarımı.	33
4.2: TSX2 İmgesinin BGMM Sınıflandırma Başarımı.	35
4.3: TSX3 İmgesinin BGMM Sınıflandırma Başarımı.	37
4.4: TSX4 İmgesinin BGMM Sınıflandırma Başarımı.	39
4.5: TSX1 İmgesinin N=20000 FPs + GLCM Sınıflandırma Sonucunun Karışıklık Matrisi.	41
4.6: TSX2 İmgesinin N=20000 FPs + GLCM Sınıflandırma Sonucunun Karışıklık Matrisi.	41
4.7: TSX3 İmgesinin N=20000 FPs + GLCM Sınıflandırma Sonucunun Karışıklık Matrisi.	42
4.8: TSX4 İmgesinin N=20000 FPs + GLCM Sınıflandırma Sonucunun Karışıklık Matrisi.	42

# 1. GİRİŞ

Uzaktan algılama sistemleri, yeryüzü hakkında uzaya gönderilmiş aktif ya da pasif sensörlere sahip uydular ile bilgi alma ve analiz gerçekleştirme sistemleridir. Uydu teknolojilerindeki son yıllarda hızlanan gelişmeler ile beraber uzaktan algılama alanında önemli teknolojik gelişmeler olmuştur. Son yıllarda yüksek çözünürlükte, uzamsal ve spektral bilgi üreten ve bu bilgiyi topluma sunan yüksek çözünürlüklü uyduların gelişmesi uzamsal bilgi üretiminde çok büyük kolaylık sağlamaktadır. Bu uydular tarafından yüksek çözünürlüklü olarak elde edilen sentetik açıklıklı radar (SAR) imgeleri, uydu üzerindeki hareketli platform tarafından gönderilen ve ters saçılan sinyallerin toplanması sonucunda oluşturulmaktadır. SAR görüntüleme sistemleri mikrodalga frekanslarında çalışmaktadır, aydınlatma kaynağını kendi sağladığı için gece ve gündüz, tüm hava koşullarında, yüzeyin geometrik özelliklerini gösteren imgeler sağlamaktadır. Bu nedenle yeryüzü hareketlerinin izlenmesinden hedef tespitine kadar geniş bir alanda kullanılmaktadır. Bu tezde SAR imgesine uygulanan beş farklı öznitelik çıkarma yöntemi ile elde edilen piksel özniteliklerinin, piksel tabanlı sınıflandırılması gerçekleştirilmektedir.

## 1.1. Tezin Amacı, Katkısı ve İçeriği

Sentetik açıklıklı radar (SAR) imgeleri ışık ve hava şartlarında çalışma avantajından dolayı uzaktan algılama sistemlerinde tercih edilmektedir. Yeryüzü şekillerinin yorumlanmasında SAR imgelerinin önemli bir rolü vardır. Yeryüzü sınıflandırılmasında imge öznitelikleri önemlidir. Daha önceki çalışmalarda SAR imgelerinin sınıflandırılmasında piksel yoğunlukları ve genlikleri öznitelik olarak kullanılmıştır [1]. Literatürde yoğunluk ve genlik modelleri kullanılarak farklı teorik ve deneysel olasılık yoğunluk fonksiyonları öne sürülmüştür [2 - 3]. Bu yöntemlerden bazıları, birden fazla hedef noktasının arka plana heterojen olarak dağılarak oluşmuş yerleşim alanları veya ormanlık alanlar gibi heterojen bölgelerde iyi çalışırken bazıları da hedef noktaların arka plana düzgün dağılması ile oluşmuş homojen bölgelerde iyi çalışmaktadır.

İmge sınıflandırmasında ham piksel yoğunluk değerlerini kullanmak yerine imgeden çıkarılan özniteliklerin kullanılması başarıyı artırmaktadır. Bu alanda SAR

imge sınıflandırılmasında birçok öznitelik çıkarma yöntemi kullanılmıştır. Derin öğrenme yöntemlerinin çok fazla eğitim verisine ihtiyaç duymasından dolayı, bu tezde, derin öğrenme yöntemleri yerine klasik öznitelik çıkarım yöntemleri üzerinde durulmuştur. Diğer taraftan klasik ve sığ yöntemler, az sayıda eğitim verisi ile daha iyi bir başarımla sergileyebilir ve daha pratik bir çözüm üretebilirler. Öznitelik çıkarma yöntemleri SAR imgelerinin anlamlandırılmasında daha önceden kullanılmıştır. SAR imgelerindeki deniz buzlu doku analizi için Shokr [4] ve Soh ve Tsatsoulis [5] gri seviyeler eş oluşum matrisini (GLCM: Gray Level Co-Occurrence Matrix) [6] kullanmıştır, diğer taraftan aynı doku analizi için Barber ve ark. [7] Gabor süzgeçlerini (GF: Gabor Filters) kullanmıştır [8]. Ayrıca, Dai ve ark. [9] SAR imge sınıflandırması için benzer öznitelik çıkarım yöntemlerinden yerel ikili örüntüyü (LBP: Local Binary Pattern) [10] önermektedir. Song ve ark. [11] SAR hedef tanımda öznitelik çıkarım yöntemi olarak yönlü gradyanların histogramını (HOG: Histogram of Oriented Gradients) [12] kullanmıştır. Ayrıca öznitelik profillerin (FPs: Feature Profiles) [13][14] optik görüntüler ile önemli başarımlarına rağmen SAR imge uygulamalarındaki üstün genlik ve uzamsal tanımlama kapasiteleri, verimleri ve esnekliklerine karşılık çok fazla çalışma yer almamaktadır. Özellikle, Boldt ve ark. [15] SAR imgelerin bölütlenmesi için niteleyici profiller (APs: Attribute Profiles) kullanımını araştırmıştır. Marpu ve ark. [16] ise APs'yi polarimetrik SAR sınıflandırmasına uygulamıştır. Bu tezde, birçok öznitelik çıkarım yöntemi uygulanarak SAR görüntülerinin piksel düzeyinde sınıflandırılması gerçekleştirilmiştir. Yaygın olarak kullanılan SAR piksel öznitelikleri yer geçeklik haritaları ile karşılaştırılarak sınıflandırma başarımları ölçülmüştür. SAR imgelerinin sınıflandırılmasında ise bir Bayesçi Gauss karışım modeli (BGMM: Bayes Gaussian Mixture Model) kullanılmıştır. BGMM modeli, hiperspektral imge sınıflandırması için [17] 'de önerilmiştir.

Tez şu şekilde düzenlenmiştir. İkinci bölümde öznitelik çıkarım yöntemlerinin ve sınıflandırmanın amacı açıklanmıştır. Tez çalışması kapsamında kullanılan yönlendirilmiş gradyanların histogramı, yerel ikili örüntü, Gabor süzgeci, öznitelik profilleri ve gri seviyeli eş-oluşum matrisleri yöntemlerinin ve sınıflandırma aşamasında kullanılan Bayesçi Gauss Karışım Modeli açıklamaları yer almaktadır. Üçüncü bölümünde SAR imgelerinin elde edilme süreci ve kullanılan SAR imgeleri tanımlanmaktadır. Dördüncü bölümde SAR imgelerinden çıkarılan özniteliklerin Bayesçi Gauss Karışım Modeli ile sınıflandırılması ve sınıflandırma sonuçları

karşılaştırılarak SAR imgelerinin piksel tabanlı sınıflandırılmasında etkili yöntem  
aranmaktadır.



## 2. ÖZNETELİK ÇIKARIM YÖNTEMLERİ VE SINIFLANDIRMA

### 2.1. Öznitelik Çıkarım Yöntemleri

Öznitelik çıkarma işlemi büyük veri yapılarını açıklamak için gereken kaynak miktarını azaltmayı hedefler. Karmaşık veri yapıları analiz edilirken karşılaşılan başlıca problemlerden biri de kullanılan değişken sayısının artmasıdır. Değişken miktarının fazla olması analizler için çoğunlukla büyük bir bellek alanına ve işlemci gücüne gereksinim duyulur, ayrıca bu durum sınıflandırma algoritmalarını eğitim kümesine bağımlı duruma getirerek kestirim performansını düşürür. Öznitelik çıkarma ve bu özneteliklere uygun bir sınıflandırma sistemi tasarımı sonucun başarı oranı ve performansını etkileyen unsurlardır. Öznitelik çıkarma sonucunda elde edilen birden fazla özneteliğin karşılığını tutan veri yapısına öznetelik vektörü (feature vector) denir.

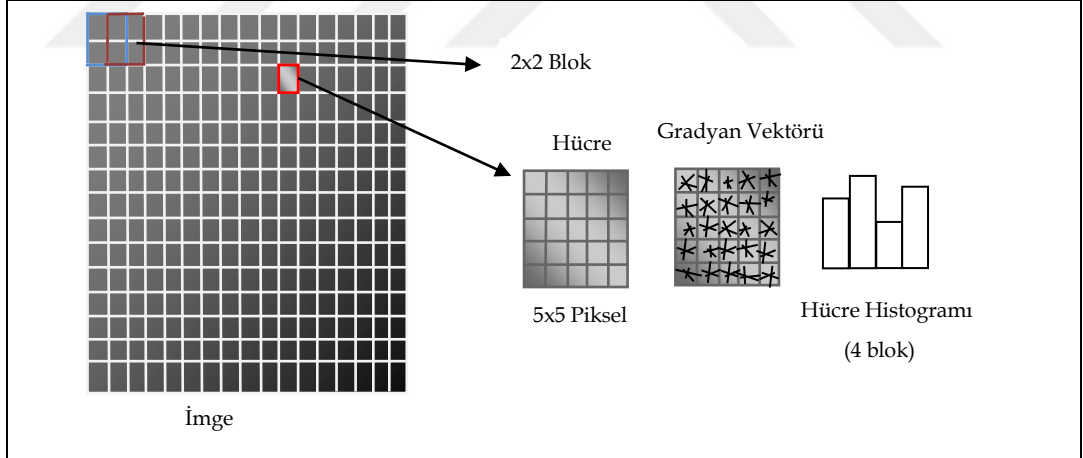
Yukarıdaki açıklamaya göre öznetelik çıkarma işlemi bir boyut azaltma işlemi olarak görülebilir ve buna göre karmaşık olan bir verinin boyutları azaltılarak daha basit bir problem haline indirgenebilir. Fakat yapılan bu çalışmada oluşturulan öznetelik çıkarma işlemleri veri boyutunu indirgemeye değil arttırmaya yönelik kullanılmıştır. Çıkarılan piksel öznetelikleri var olan iki boyutlu veriye eklenerek veri yapısı üç boyutlu duruma getirilmiştir. Eklenen bu yeni boyutla birlikte var olan piksel koordinatlarına ait bilgiye ek olarak piksel komşuluklarına ait bilgiyi içeren bir veri yapısı elde edilmiştir. Bu şekilde eklenen veri yapısı ile sınıflandırma aşamasında verinin sadece piksel konum bilgisi ile değil, piksel komşuluk bilgilerini de içeren üç boyutlu bir veri yapısı kullanılarak başarı oranının artması sağlanmıştır.

Bu çalışmada, SAR imgeleri öznetelik çıkarma işlemi olarak beş farklı yöntem kullanılmıştır. Kullanılan yöntemler; HOG, LBP, GFs, FPs ve GLCM' dir.

### 2.1.1. Yönlü Gradyan Histogramı

Yönlü gradyan histogramı (HOG), temelde imgedeki yerel nesne görünümünün ve keskinliğinin gradyan yoğunluklarının ve kenar yönlerinin dağılımı olarak tanımlanabilir. Yönlü gradyan histogramı kullanımı Dalal ve Triggs tarafından ilk olarak yaya tespiti çalışmasında kullanılmıştır [12]. Yönlü gradyan histogramı, nesne tanıma çalışmalarında öznitelik çıkarımı için yaygın olarak kullanılmakta ve çeşitli şartlar altında da başarılı sonuçlar vermektedir.

Yönlü gradyan histogramı hesaplamasında imge renk ve gama değerleri normalize edilir. Öncelikle imge “hücre” olarak isimlendirilen alt bölgelere bölünür Şekil 2.1’ de görüldüğü üzere hücelere bölünmüş bir imgenin farklı yön ve açılarda gradyanları bulunarak yönelim histogramları hesaplanır. Bu işlem tüm hücrelerde gerçekleştirilerek imge histogramı çıkarılır. Ayrıca HOG’ da hücreler arasında bulunan aydınlanma farklılıklarının önüne geçmek amacıyla hücreler arasındaki komşuluk ilişkileri incelenir.



Şekil 2.1: Yönlü Gradyan Histogramı hücre ve blok yapısı.

$I(x, y)$  imgesinin HOG değerlerini bulmak için ilk olarak imgeye eşitlik (2.1)’ de tanımlanan Sobel maskeleri ile imgenin yatay ve dikey yönlü bileşeniyle evrişim işlemi uygulanarak eşitlik (2.2) ve (2.3)’ deki yatay ve dikey gradyan değerleri oluşur.

$$S_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad S_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \quad (2.1)$$

$$f_x(x, y) = I(x, y) \otimes S_x \quad (2.2)$$

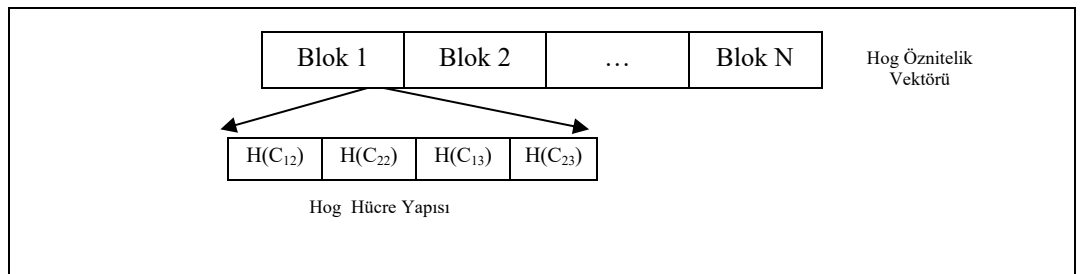
$$f_y(x, y) = I(x, y) \otimes S_y \quad (2.3)$$

Hesaplanan gradyan değerleri eşitlik (2.4)' deki gibi bileşkesi alınarak gradyan büyüklüğü ve eşitlik (2.5)'e göre de gradyan yönü hesaplanır.  $m_x(x, y)$  ve bunların yönelim açıları  $\theta_x(x, y)$

$$m_x(x, y) = \sqrt{f_x(x, y)^2 + f_y(x, y)^2} \quad (2.4)$$

$$\theta_x(x, y) = \arctan\left(\frac{f_y(x, y)}{f_x(x, y)}\right) \quad (2.5)$$

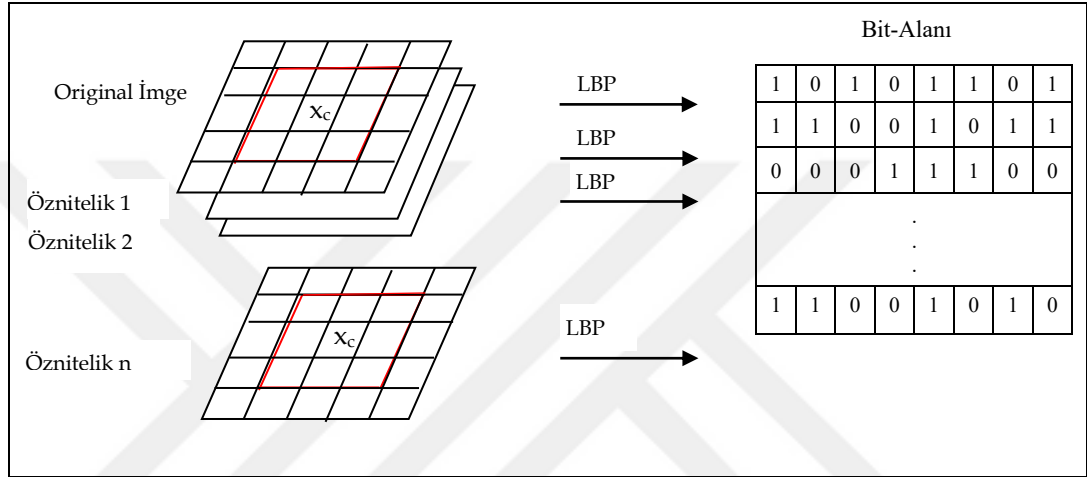
hesaplanarak imgenin HOG öznitelik çıkarımı gerçekleştirilir. Şekil 2.2 görüldüğü gibi birden fazla hücre bir araya getirilerek blok yapısı oluşturulur. Bu nedenle HOG için kayan pencere modelini kullanan bir yöntem olduğu söylenebilir [12]. Pencereler birbiri üzerine binen bloklara ayrılır ve her blok içerisinde hesaplanan gradyan genlikleri ve yönleri, bir yönelim histogramında toplanmasıyla öznitelikler elde edilmiş olur [34]. Hesaplanan bu histogramlar ardışık olarak eklenerek imgenin öznitelik vektörü çıkarılır.



Şekil 2.2: Yönlü Gradyan Histogramı.

## 2.1.2. Yerel İkili Örüntü

Yerel ikili örüntü (LBP), görüntü doku analizinde yerel kontrastların ölçülerek yerel bölgede mikrotektonların araştırılması olarak tanımlanabilir [18]. 1990 yılında Wang ve He tarafından önerilmiştir [19]. Yerel ikili örüntü yapısı her piksel için ikili bir etiket oluşturmaktadır [10]. Bu etiketleme merkez pikselin  $W \times W$  komşuluğundaki piksellerin karşılaştırılması ile elde edilen ikili bir sayıdır.



Şekil 2.3: Yerel İkili Örüntü piksel öznitelik çıkarımı.


Şekil 2.3' te görülen bir imgenin LBP öznitelik çıkarımı görülmektedir. İmgede seçilen merkez pikselin kendisi ve komşu pikselleri arasında  $u(y)$  basamak fonksiyonu ile ikili (binary) sistemde değerler hesaplanarak pikseller etiketlenir. (2.4)' te tanımlanan  $LBP_{p,r}(x_c)$  operatöründe  $p$  komşu sayısını,  $r$  ise örnek sayısını ifade etmekte

$$LBP_{p,r}(x_c) = \sum_{p=0}^{p-1} u(x_p - x_c) 2^p \quad (2.4)$$

burada  $x_c$  merkez piksel değeri,  $x_p$  merkez piksele komşu olan piksel değeridir.

$$u(y) = \begin{cases} 1, & y \geq 0 \\ 0, & \text{diğer durumda} \end{cases} \quad (2.5)$$

$u(y)$  ise LBP operatörü sonucunda çıkan bit değerleridir. Burada merkez piksel ve komşu piksel değer farklarının 0'dan büyük olup olmama durumuna göre ikili değer oluşmaktadır. Bu şekilde her bir pikselin  $W \times W$  pencere içerisinde öznitelik vektörü oluşur. Şekil 2.4'te farklı değerlerde oluşturulan pencere yapıları görülmektedir [35]. Bu şekilde LBP operatörü ile farklı ölçekteki dokuların analizini gerçekleştirmek mümkün olmuştur. Piksellerin ara değerlerinin bulunması (interpolasyon), herhangi bir çap ve sayıdaki komşuluğa imkan sağlamaktadır.



Şekil 2.4: Yerel İkili Örüntü piksel komşulukları  
a)  $LBP_{(8,1)}$ , b)  $LBP_{(8,2)}$ , c)  $LBP_{(16,2)}$ .

LBP modelinde, eşitlik yerine büyüklük durumu ayırıcı etkindir. Bu koşul komşu piksellere atanacak değerler kümesinin yalnızca  $\{0,1\}$  ile sınırlandırılır. Bu nedenle, her biri LBP modeli için yerel komşuluk ikili desenler ile karakterize edilir. Tanım gereği, LBP tanımlayıcısı yerel komşuluk sırasını koruyan piksel yoğunlukları monotonik gri skala dönüşümünden etkilenmez [20].

### 2.1.3. Gabor Süzgeçleri

Gabor süzgeci, frekans ve yön seçebilme özelliğine sahip bant geçiren bir süzgeçtir. Gabor süzgeci bir Gauss fonksiyonu tarafından harmonik fonksiyonların modüle edilmesi ile oluşur. 1940' larda Gabor süzgeci kavramı Dennis Gabor tarafından sunulmuştur. 1980' lerde Daugman tarafından 2D süzgeci olarak genişletilmiştir [21 - 22]. Karmaşık üstel bir işaretin, Gauss fonksiyonu tarafından modüle edilmesi sonucu elde edilebilir. Gabor süzgecinin parametreleri değiştirilerek farklı yönelim ve ölçeklerde süzgeçler oluşturulabilir. İmgenin tamamına ya da bir bölgesine evrişim işlemiyle uygulanır. Farklı ölçekler, yönelimler ve konumlar

kullanarak süzgeçlenmiş farklı imgeler elde edilir. Gabor süzgecinin birim dürtü yanıtı aşağıdaki gibidir.

$$g(x, y; \sigma, \lambda, \theta_k) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left(\frac{x_\theta^2}{2\sigma_x^2} - \frac{y_\theta^2}{2\sigma_y^2}\right) \exp\left(\frac{2\pi x_\theta}{\lambda} i\right) \quad (2.6)$$

$$x_{\theta_k} = x\cos(\theta_k) + y\sin(\theta_k) \quad (2.7)$$

$$y_{\theta_k} = -x\sin(\theta_k) + y\cos(\theta_k) \quad (2.8)$$

Denklem (2.6)' da  $x$  ve  $y$  piksel koordinatları,  $\lambda$  ve  $\theta_k$  sırası ile dalga boyu ve yönelimdir.  $\sigma_x$  ve  $\sigma_y$  ise Gauss süzgecinin  $x$  ve  $y$  koordinatlarındaki standart sapmasıdır.  $[x_{\theta_k}, y_{\theta_k}]$ ,  $x$  ve  $y$  koordinatlarının  $\theta_k$  açısı kadar döndürülmesi ile oluşan koordinatlardır ve denklem (2.7) ve (2.8)' de bu koordinatların eşitliği bulunmaktadır.

$x - y$  düzleminin  $\theta_k$  açısı kadar döndürülmesi Gabor süzgecinin  $\theta_k$  açılı olması ile sonuçlanır.  $\theta_k$  açısı tanımı;

$$\theta_k = \frac{\pi}{n}(k - 1) \quad (2.9)$$

burada  $k=1, 2, \dots, n$  için  $n \in \mathbb{N}$ ,  $n$  yönelimlerin sayısını göstermektedir.

Denklem (2.6)' daki Gauss süzgecinin tek ve çift bileşenleri aşağıdaki gibidir:


$$g_e(x, y; \sigma, \lambda, \theta_k) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left(\frac{x_\theta^2}{2\sigma_x^2} - \frac{y_\theta^2}{2\sigma_y^2}\right) \cos\left(\frac{2\pi x_\theta}{\lambda}\right) \quad (2.10)$$

$$g_o(x, y; \sigma, \lambda, \theta_k) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left(\frac{x_\theta^2}{2\sigma_x^2} - \frac{y_\theta^2}{2\sigma_y^2}\right) \sin\left(\frac{2\pi x_\theta}{\lambda}\right) \quad (2.11)$$

burada  $g_e$  ve  $g_o$  sırasıyla Gabor süzgecini çift-simetriği ve tek-simetriğidir.

Çalışmada kullanılacak tüm SAR imgelerine aynı parametre değerlerinde tanımlanmış süzgeçler uygulanmıştır. Tanımlanan bir Gauss süzgecinin pencere

boyutu 30 x 30' dur ve 5 farklı ölçekli ve 6 farklı yönelimde toplam 30 farklı Gauss süzgeci tanımlanmıştır. Bu şekilde oluşturulan 30 farklı Gauss süzgeci çalışmada kullanılan tüm SAR imgelerine uygulanarak her bir piksel için 30 adet öznelik değeri çıkarılmıştır. Şekil 2.5'te çalışmada Gauss öznelikleri çıkarımı için oluşturulan 30 Gauss süzgecinin gerçek kısımları ve büyüklükleri görülmektedir.



Şekil 2.5: Gauss Süzgeçleri; a) Gri seviyedeki SAR imgesi, b) 5 farklı ölçekli 6 farklı yönlü Gauss süzgecinden elde edilen sar imgesinin genlik görüntüleri.


#### 2.1.4. Gri Seviyeli Eş - Oluşum Matrisleri

Bir imge veya bölge sınıflandırılmasında en basit yaklaşım histogram istatistiksel momentlerini kullanmaktır [24]. Sadece histogram analizi kullanarak analiz gerçekleştirmek, sadece piksel yoğunluk dağılımları hakkında bilgi verir. Piksellerin birbiri ile ilişkisi ve konumları hakkında bilgi vermez. Eş-oluşum matrisleri

gibi istatistiksel yaklaşımların kullanımı imge içerisindeki komşu piksellerin konumları hakkında bilgi sağlayacaktır [33]. Ayrıca bu matrisler piksellerin gri seviyedeki uzaysal dağılımları bilgisini de içerir.  $N \times N$  boyutlarındaki  $I$  imgesinin eş-oluşum matrisi  $P$  aşağıdaki gibi tanımlanır:

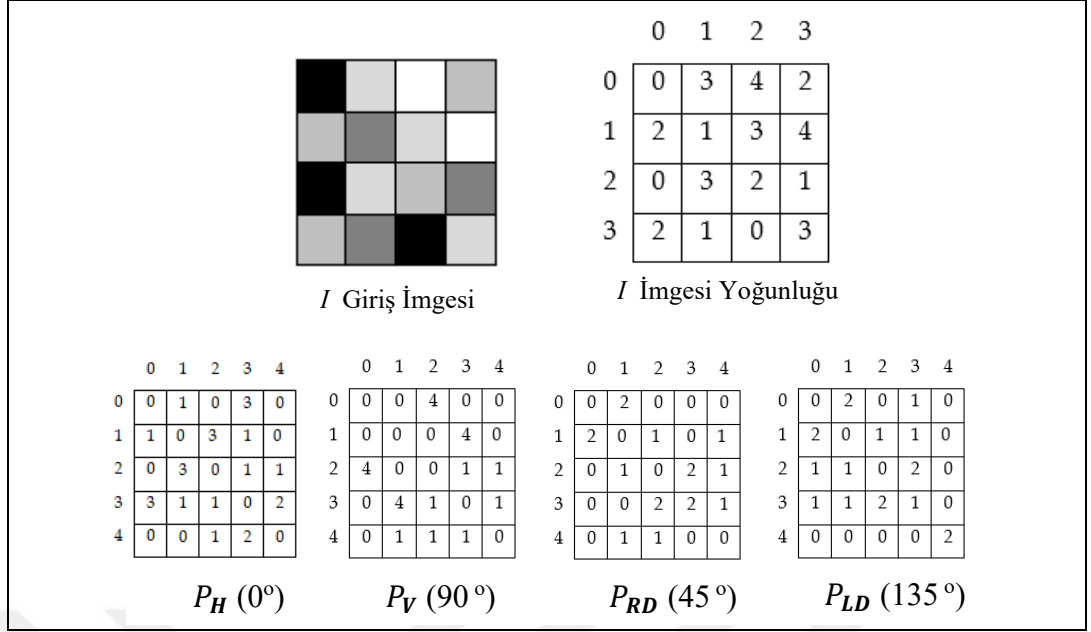
$$P(i, j) = \sum_{x=1}^N \sum_{y=1}^N \begin{cases} 1, & \text{eğer } I(x, y) = i \text{ ve } I(x + \Delta_x, y + \Delta_y) = j \\ 0, & \text{otherwise} \end{cases} \quad (2.12)$$

burada  $(\Delta_x, \Delta_y)$  ofset değerleri ilgilenilen piksel ile komşu pikseli arasındaki mesafedir. Bu açıdan ofset parametrelerinin açığa duyarlı olduğu gözlenir ve aynı imge için farklı rotasyon açıları sonucunda farklı eş-oluşum matrisleri elde edilebilir. Kısaca eş-oluşum matrisinin  $(\Delta_x, \Delta_y)$  parametreleri yerine  $\Delta$  mesafe ve  $\theta$  açı parametreleri kullanılabilir. Aynı  $\Delta$  mesafesi için  $180^\circ$  tam yönelimiyle  $0^\circ$  de yatay  $P [0 \ \Delta]$ ,  $45^\circ$  için sağ köşegen  $P [-\Delta \ \Delta]$ ,  $90^\circ$  için dikey  $P [-\Delta \ 0]$  ve  $135^\circ$  için sol köşegen  $P [-\Delta \ -\Delta]$  eş - oluşum matrisleri oluşur.



Şekil 2.6:  $\Delta=1$  ve  $\theta=(0^\circ, 45^\circ, 90^\circ, 135^\circ)$  durumundaki komşu pikseller.

Aşağıdaki Şekil 2.7’de  $\Delta = 1$  mesafesi için komşu piksellerin 4 yönelimde ( $[0 \ 1]$ ,  $[-1 \ 1]$ ,  $[-1 \ 0]$ ,  $[-1 \ -1]$ ),  $N_g=5 \times 5$  boyutunda bir eş – oluşum matrisinin oluşumu gösterilmektedir. Örneğin giriş imgesi  $I$  ‘ da komşu iki piksel  $(2, 1)$  için  $P_H$  (yatay) rotasyondaki oluşum matris değeri 3’ tür. Bu değer giriş imgesindeki piksel yoğunluk değeri 2 ve 1 olan komşu oluşumlarının sayısıdır ve bu da 3 değeridir. Ayrıca  $I$  incelendiğinde komşu pikseller  $(1, 2)$  içinde aynı rotasyondaki  $P_H$  oluşum matrisindeki değeri 3’ tür. Bu durumda çıkarılan oluşum matrislerin simetrik olduğu söylenebilir. Aynı şekilde diğer rotasyonlar  $P_V$  (dikey),  $P_{RD}$  (sağ diyagonal) ve  $P_{LD}$  (sol diyagonal) içinde oluşum matrisleri hesaplanır.



Şekil 2.7:  $N_g = 5$  boyutu için 4 farklı rotasyondaki eş – oluşum matrisleri :  
 $P_H(0^\circ)$ ,  $P_V(90^\circ)$ ,  $P_{RD}(45^\circ)$ ,  $P_{LD}(135^\circ)$ .

Haralick tarafından tanımlanmış olan eş-oluşum matrisi,  $N \times N$  boyutunda bir matristir ve M. Haralick tarafından imge hakkında bilgi içeren homojenlik, entropi, enerji, kontrast, korelasyon gibi 14 tane doku özelliği tanımlanmıştır [6 - 25].

Tanımlanan Haralick öznitelikleri Tablo 2.1’de yer almaktadır.

Tablo 2.1: GLCM' yi oluşturan öznelik tanımlamaları ve formülleri.

Öznelikler	Formüller	Notlar
Enerji	$f_1 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i,j)^2$	$P_x(i) = \sum_{j=1}^{N_g} P(i,j) \quad , \quad P_y(j) = \sum_{i=1}^{N_g} P(i,j)$
Kontrast	$f_2 = \sum_{n=0}^{N_g-1} n^2 \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i,j)$	$\mu_x = \sum_{i=1}^{N_g} iP_x(i) \quad , \quad \mu_y = \sum_{j=1}^{N_g} jP_y(j)$
Koralesyon	$f_3 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{(i - \mu_x)(j - \mu_y)P(i,j)}{\sigma_x \sigma_y}$	$\sigma_x = \left( \sum_{i=1}^{N_g} P_x(i) (1 - \mu_x)^2 \right)^{1/2}$ $\sigma_y = \left( \sum_{j=1}^{N_g} P_y(j) (1 - \mu_y)^2 \right)^{1/2}$
Varyans	$f_4 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - \mu)^2 P(i,j)$	$P_{x+y}(k) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i,j) \quad ; \quad k = 2,3 \dots, 2N_g$ $P_{x-y}(k) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i,j) \quad ; \quad k = 0, \dots, N_g - 1$
Homojenlik	$f_5 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{1}{1 + (i - j)^2} P(i,j)$	$HXY1 = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P(i,j) \log \{P_x(i)P_y(j)\}$ $HXY2 = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P_x(i)P_y(j) \log \{P_x(i)P_y(j)\}$
Ort. Toplamı	$f_6 = \sum_{k=2}^{2N_g} kP_{x+y}(k)$	$HX = - \sum_{i=1}^{N_g-1} P_x(i) \log \{P_x(i)\}$ $HY = - \sum_{j=1}^{N_g-1} P_y(j) \log \{P_y(j)\}$
Varyansların Toplamı	$f_7 = \sum_{k=2}^{2N_g} (k - f)^2 P_{x+y}(k)$	$Q(i,j) = \sum_{k=1}^{N_g} \frac{P(i,k)P(j,k)}{P_x(i)P_y(j)}$
Entropilerin Toplamı	$f_8 = - \sum_{k=2}^{2N_g} P_{x+y}(k) \log \{P_{x+y}(k)\}$	
Entropi	$f_9 = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P_{x+y}(k) \log \{P_{x+y}(k)\}$	
Varyansların Farkı	$f_{10} = \sum_{k=0}^{N_g-1} [k - \sum_{l=0}^{N_g-1} lP_{x-y}(l)]^2 P_{x-y}(k)$	
Entropi Farkı	$f_{11} = - \sum_{k=0}^{N_g-1} P_{x-y}(k) \log \{P_{x-y}(k)\}$	
	$f_{12} = \frac{f_9 - HXY1}{\max(HX, HY)}$	
	$f_{13} = (1 - \exp[-2(HXY2 - f_9)])^2$	
Max. Corr. Katsayısı	$f_{14} = (\text{second largest eigenvalue of } Q)^{1/2}$	

### 2.1.5. Nitelik Profilleri

Nitelik profilleri (APs), bir dizi nitelik süzgecinin (AF: Attributes filter) art arda uygulanması ile elde edilmiş çok düzeyli imge tanımlama araçlarıdır [23].

Genel morfolojik profil (MPs) yönteminde imge öznitelik bilgilerini çıkarmak için imgenin tamamına aşamalı şekilde artan boyutlu yapısal elemanlar (*se*) ile sırasıyla açılım ( $\gamma$ ) ve kapanım ( $\phi$ ) işlemi uygulanarak piksellerin öznitelik vektörleri oluşur. Yapısal eleman, çizgi, kare, daire, disk vb. yapıda tanımlanabildiği gibi birçok farklı geometrik karakteristikte tercih edilebilir.  $F$  imgesindeki  $n$  pikseli için  $m$  boyutunda yapısal eleman ile yapılan açılım işlemi  $\gamma_m F(n)$  ve kapama işlemi  $\phi_m F(n)$  olsun. Bu işlemler uygulandıktan sonra oluşan MPs vektörü aşağıdaki gibi ifade edilebilir.

$$MP(F(n)) = \{\phi_m(F(n)), \phi_{m-1}(F(n)), \dots, \phi_1(F(n)), F(n), \gamma_1 F(n), \dots, \gamma_{m-1} F(n), \gamma_m(F(n))\} \quad (2.13)$$

Klasik MPs yöntemleri sadece süzgeçlenmiş piksel değerlerine göre çıkarım yaparken APs yönteminde ayrıca süzgeçlerin imgedeki bağlantılı bileşenler (CC: connected component) üzerindeki etkisi de göz önünde bulunmaktadır. Detaylandırarak olursak, belirlenen öznitelik süzgeçleri farklı seviyelerdeki ağaç düğümlerine uygulanarak imgede bulunan nesnelerin boyut, şekil ya da diğer özellikleri çıkarılarak genel APs vektörü oluşturur [14].

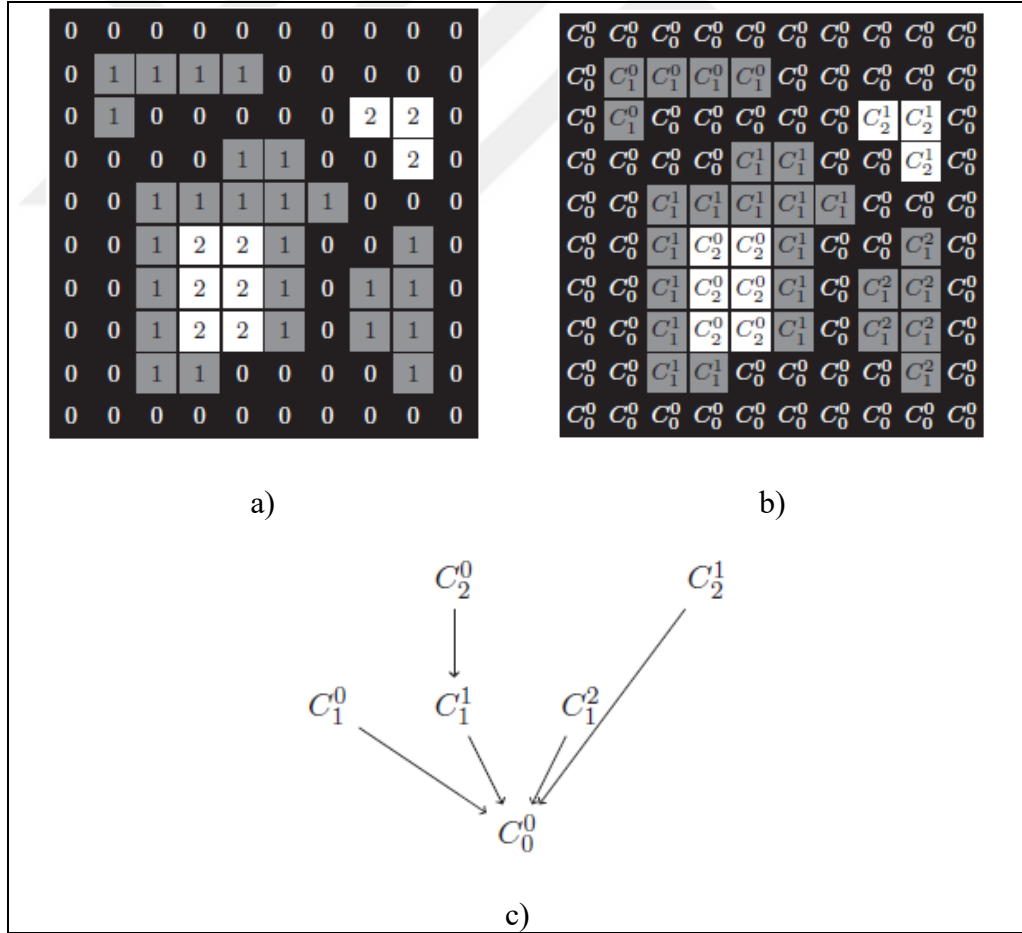
Genel olarak,  $F : \Omega \rightarrow E$  mekânsal alanı  $\Omega \subseteq \mathbb{Z}^2$  'ye bağlı ve  $E \subseteq \mathbb{Z}$  skaler değerler kümesinden değerler alan iki boyutlu gri seviyeli bir imgedir [38]. Her hangi  $\lambda \in \mathbb{Z}$  için alt  $\mathcal{L}(F)$  ve üst  $\mathcal{U}(F)$  eşik (threshold) yapıları aşağıdaki gibi tanımlanabilir:

$$\mathcal{L}(F) = \{x \in \Omega, F(x) < \lambda\} \quad (2.14)$$

$$\mathcal{U}(F) = \{x \in \Omega, F(x) > \lambda\} \quad (2.15)$$

$\mathbb{P}(\Omega)$ ,  $\Omega$ 'nin olası tüm alt kümelerinin grubu olsun.  $X \in \Omega$ 'de verilen  $X'$  in bağlı bileşenleri  $\mathcal{C}(X) \in \mathbb{P}(\Omega)$  olarak belirtilebilir. Tüm ilişki " $\leq$ "ye bağlı ise herhangi  $X, Y \in \mathcal{C}(\phi(F))$  iki bağlı bileşene ayrılır (disjointed) ya da iç içe geçer (nested) [38]. Max-ağaç (max-tree) ve min-ağaç (min-tree) yapıları sırası ile  $\mathcal{L}(F)$  ve  $\mathcal{U}(F)$  ile ilişkilendirilebilir.

Eşitlik (2.13) ve (2.14)'e göre imgeden hesaplanan AFs' ler uygulama açısından verimli değildir. Bunun yerine imgenin max-ağaç gösterimi üzerinden yapılan işlemler daha verimli olacaktır. Max-ağaç yapısı Şekil 2.8'de gösterilmektedir. İmgedeki bileşenler Şekil 2.8'de görülebilmektedir ve bölgeye ait tüm pikseller aynı değere sahiptir [39]. Max-ağaç yapısı, imge bağlı bileşenlerinin her birini bir düğüme eşler ve hiyerarşik ağaç yapısı şeklinde düzenler [39]. Ağaç yapısı kökten büyür ve bu yaprak düğümleri şeklinde dallanarak imgenin en düşük seviyedeki değerleri de temsil edilir [39].



Şekil 2.8: Max- ağaç; a) Yoğunluk 0-2 oranlı gri seviyeli imge  
b) bağlantılı bileşenleri etiketlenmiş a)'daki imge,c) a) imgesinin max- ağaç yapısı.

Ağaç yapısı taşıma algoritmasına (flood-filling algorithm) göre oluşturulmuştur , bu yapı bağlı bileşenlerin tespitine izin verir ve düğümler arasında hiyerarşik bağlantılar oluşturur. Max-ağaç yapısının AFs hesaplanmasında izlenilecek adımlar sırası ile:

- İmgenin max-ağaç yapısının oluşturulması
- Eşik değerine göre imgenin değerlendirilmesi
- İmgenin tekrar oluşturulması

Daha genel olarak öznitelik ve eşik değeri çifti,  $T$  mantıksal bir yüklem olarak kabul edilebilir [37]. Uygulanacak eşik değerleri seti uzunluğu  $L$  olsun ve eşik değerleri kümesi  $\{\kappa_i\}_{1 \leq i \leq L}$  olarak gösterilebilir. Standart APs vektörünün oluşumu belirlenen eşik değerlerine göre sıralı olarak uygulanan AFs'in min-ağaç (öznitelik kapanım ( $\phi$ )) ve max-ağaç (öznitelik açılım ( $\gamma$ )) işlemlerine dayanmaktadır [36].  $F$  imgesindeki her bir  $n$  pikseli için APs vektörü yapısı :

$$AP(F(n)) = \{\phi_{\kappa_L}(F(n)), \dots, \phi_{\kappa_i}(F(n)), \dots, \phi^{\kappa_1}(F(n)), F(n), \gamma_{\kappa_i}(F(n)), \dots, \gamma_{\kappa_L}(F(n))\} \quad (2.16)$$

burada  $\phi_{\kappa_L}(F(n))$  ,  $F(n)$  imgesinin  $\kappa_L$  eşik değerinde öznitelik kalınlaştırma süzgecini ;  $\gamma_{\kappa_L}(F(n))$  ise  $F(n)$  imgesinin  $\kappa_L$  eşik değerinde öznitelik inceltme süzgecini ifade etmektedir.

MPs tanımına göre APs' in kümülatif bir fonksiyon olduğu söylenebilir [36]. Uygulanan AFs göre imgeden farklı bilgiler elde edilebilir. Uygulanacak süzgeç değerlerinin artırılması imgedeki yapı analizlerinin değerlendirilmesinde etkili olurken, piksel değerlerinin homojenliği ölçütü ile yapılan analizler de ise imge dokusu hakkında detaylı bilgi alınmaktadır [36].

### 2.1.6. Öznitelik Profilleri

Özellik profilleri (Feature Profiles - FPs) imge içerisinde bulunan CC ile çevrilen bölge ve nesnelere daha iyi belirlemek için düğümün gri seviyesi yerine düğüm özelliklerinin çıkarıldığı bir yöntemdir [36]. Gerçekte,  $\phi_{\kappa_i}$  özneliği süzgeci

tarafından budanan ağaç (pruned-tree) elde etmek için; düğümlerin gri seviyelerini kullanarak filtrelenmiş görüntüyü yeniden oluşturmak yerine, FP' leri oluşturarak farklı özellikler çıkarılır [36].

$F$  imgesindeki her bir  $n$  pikseli için uygulanan AF  $\phi_{\kappa_i}$  süzgeci ile elde edilen  $n$ 'nin AP vektöründeki gri değeri  $F'(n)$ ' dir [36]. Burada  $F' = \phi_{\kappa_i}(F)$  eşittir ve  $F'$  süzgeçlenmiş imgeden yeniden oluşturulan imgedir [35].  $\Gamma_n(F)$  ifadesi de  $n$  pikselini içeren  $F'$  in CC' si olsun ve  $f$  ise dışarıya çıkarılmak istenen özellik ya da öznelik olsun [36]. Örneğin  $f'$  yi CC' yi içeren ve gerçek bir değer üreten bir fonksiyon gibi düşünülebilir.  $n$ ' nin FP ' si  $f[\Gamma_n(F')]$  olacaktır. Genel olarak min.-ağaç ve max-ağaca dayalı  $f$  özellikli FPs vektörünün oluşumu eşitlik (2.16)'deki gibidir.

$$FP_f(n) = \{f[\Gamma_n(\phi_{\kappa_L}(F))], \dots, f[\Gamma_n(\phi_{\kappa_1}(F))], F(n), f[\Gamma_n(\gamma_{\kappa_1}(F))], \dots, f[\Gamma_n(\phi_{\kappa_L}(F))]\} \quad (2.17)$$

APs yönteminde budanmış bir ağaç yapısından bir profil oluşturulabilir, FPs yönteminde ise birkaç özellik eşzamanlı olarak dışarı çıkarılabilir ve eşitlik (2.17)'deki gibi sonuç FPs' sini oluşturmak için tutulur [14].

$$FP_{f_1+\dots+f_p}(n) = [FP_{f_1}(n), FP_{f_2}(n), \dots, FP_{f_p}(n)] \quad (2.18)$$


## 2.2. Sınıflandırma

Sınıflandırma imgede bulunan homojen piksel gruplarının istenilen yeryüzü özellikleri ve hedeflere ayrılması olarak tanımlanabilir [26]. Bu işlem imgeye uygulanan yorumlama olarak tanımlayabileceğimiz teknikler kullanılarak gerçekleştirilebilir. İmge sınıflandırmada, imgedeki tüm pikseller spektral özelliklerine göre farklı sınıflara ya da temalara atanarak gruplanır. Sınıflandırma sonrası oluşan haritadaki tüm pikseller, sahip olduğu özelliklere göre ayrılmıştır ve oluşan bu yeni imgeye sınıflandırma haritası denir.

Çeşitli tarla alanları, orman bölgeleri, kaya türleri vb. imgede gruplanması istenilen ilgi alanları gruplarına bilgi sınıfları denir. Spektral sınıflar ise benzer yansıtım değerlerine sahip piksellerin bir arada bulunduğu yapılardır. Sınıflandırma işleminin amacı spektral sınıflar ile bilgi sınıflarının eşleştirilmesidir. Bazen birkaç spektral sınıf aynı bilgi sınıfını temsil edebilir bazen de bazı spektral sınıflar herhangi bir bilgi sınıfının özelliğini göstermeyebilir, bu noktada hangi sınıfın hangi bilgi sınıfına ait olduğuna karar verilmesi gerekir. Sınıflandırma işlemi uzaktan algılama çalışmalarında uygulanan temel yapılardan biridir.

Bu çalışmada kullanılan SAR imgeleri bir genlik imgesinden oluşmaktadır ve farklı spektral bilgiye sahip değildir. Bu nedenle sınıflandırma başarımını artırmak için öznitelik çıkarılarak SAR verileri zenginleştirilmektedir. Bu zenginleştirme işleminde verilerde kullanılan fazladan bilgi piksel komşuluklarından gelmektedir. Sınıflandırma işlemi piksel tabanlı yapıldığı için her bir piksele ait bir öznitelik vektörü oluşturulmaktadır. Şekil 2.10' da görüldüğü gibi 2 boyutlu olan SAR imgeleri piksel öznitelik vektörleri bilgisi de eklenerek piksel konum ve özniteliğini içeren 3 boyutlu bir veri seti elde edilmiştir [40].

SAR imgelerinden elde edilen özniteliklerin sınıflandırılmasında Bayeşçi Gauss karışım modeli kullanılacaktır. Modelin ayrıntıları bir sonraki bölümde verilmektedir.



Şekil 2.9: a) 2 boyutlu imge, b) 3 boyutlu veri.

## 2.2.1. Bayesçi Gauss Karışım Modeli

Gauss karışım modeli, verinin birden fazla Gauss dağılımı bileşeninden türetildiğini varsayar. Bu çalışmada, verideki tüm sınıfların Gauss karışım modeli şeklinde oluştuğu varsayılmıştır ve imgedeki her bir piksel için oluşturulan öznitelik vektörünün  $K$  çok değişkenli Gauss dağılımlarının birinden üretildiği kabul edilmiştir.

$k$ . sınıfın çok değişkenli Gauss dağılımı aşağıdaki gibi ifade edilir [17]:

$$p(\mathbf{s}_n | \mathbf{m}_k, \Sigma_k) = \mathcal{N}(\mathbf{s}_n | \mathbf{m}_k, \Sigma_k) \quad (2.19)$$

burada  $\mathbf{s}_n$  ifadesi  $n$ . Pikselin öznitelik vektörüdür,  $\mathbf{m}_k$  ve  $\Sigma_k$  sırası ile  $k$ . Sınıfın ortalama vektörü ve kovaryans matrisidir.  $K$ . Sınıfın parametre seti  $\theta_k = \{\mathbf{m}_k, \Sigma_k\}$  olarak gösterilebilir.

Gaussların  $\mathbf{m}_k$  ve  $\Sigma_k$  parametreleri için normal-ters Wishart önsel dağılımı:

$$p(\mathbf{m}_k, \Sigma_k) = \mathcal{N}\left(\mathbf{m}_k \mid \mathbf{m}_0, \frac{1}{\lambda} \Sigma_k\right) \mathcal{W}^{-1}(\Sigma_k | (\tau + L + 1)\psi, \tau) \quad (2.20)$$

olacak şekilde tanımlanmıştır. Burada  $\mathbf{m}_0$ ,  $\psi$  ve  $\tau$  önsel dağılımın parametreleridir [17].

Gauss dağılımının ortalama vektörlerini ve kovaryans matrislerini bulmak için en büyük sonsal (MAP: maximum-a-posteriori) kestirimi kullanılmıştır. Parametreler için sonsal dağılımlar aşağıdaki gibidir:  $\mathbf{s}_{\mathcal{D}_k}$  kullanılarak, parametreler için sonsal dağılımlar aşağıdaki gibi verilir:

$$p(\mathbf{m}_k | \mathbf{s}_{\mathcal{D}_k}, \Sigma_k) = \frac{p(\mathbf{s}_{\mathcal{D}_k} | \Sigma_k, \Sigma_k) p(\mathbf{m}_k, \Sigma_k)}{\int p(\mathbf{s}_{\mathcal{D}_k} | \mathbf{m}'_k, \Sigma_k) p(\mathbf{m}'_k, \Sigma_k) d\mathbf{m}'_k} \quad (2.21)$$

$$p(\Sigma_k | \mathbf{s}_{\mathcal{D}_k}, \mathbf{m}_k) = \frac{p(\mathbf{s}_{\mathcal{D}_k} | \Sigma_k, \Sigma_k) p(\mathbf{m}_k, \Sigma_k)}{\int p(\mathbf{s}_{\mathcal{D}_k} | \mathbf{m}_k, \Sigma'_k) p(\mathbf{m}_k, \Sigma'_k) d\Sigma'_k} \quad (2.22)$$

Denklem (2.18) ve (2.19) analitik olarak hesaplanırsa aşağıdaki sonsal dağılımlar elde edilir:

$$(\mathbf{m}_k | \mathbf{s}_{\mathcal{D}_k}, \Sigma_k) \sim \mathcal{N} \left( \frac{N_k \bar{\mathbf{s}}_k + \lambda \mathbf{m}_0}{N_k + \lambda}, \frac{1}{N_k + \lambda} \Sigma_k \right) \quad (2.23)$$

$$(\Sigma_k | \mathbf{s}_{\mathcal{D}_k}) \sim \mathcal{W}^{-1}(\mathbf{P}_k, N_k + \tau) \quad (2.24)$$

Burada,  $N_k$ ,  $k$ . Sınıfa ait  $\mathcal{D}_k$  eğitim veri kümesindeki örneklerin sayısıdır ve  $\mathbf{P}_k$  aşağıdaki şekilde tanımlanır.

$$\mathbf{P}_k = (\tau + L + 1)\Psi + N_k \mathbf{S}_k + \frac{N_k \lambda}{(N_k + \lambda)} (\bar{\mathbf{s}}_k - \mathbf{m}_0)(\bar{\mathbf{s}}_k - \mathbf{m}_0)^T \quad (2.25)$$

Burada örnek ortalama vektörü  $\bar{\mathbf{s}}_k$  ve örnek kovaryans matrisi  $\mathbf{S}_k$  (2.23) ve (2.24)' te verilen eşitlikler ile hesaplanır.

$$\bar{\mathbf{s}}_k = \frac{1}{N_k} \sum_{n \in \mathcal{D}_k} \mathbf{s}_n \quad (2.26)$$

$$\mathbf{S}_k = \frac{1}{N_k} \sum_{n \in \mathcal{D}_k} (\mathbf{s}_n - \bar{\mathbf{s}}_k)(\mathbf{s}_n - \bar{\mathbf{s}}_k)^T \quad (2.27)$$

(2.23) ve (2.24)'te sırasıyla normal ve Ters-Wishart sonsal dağılımları görülmektedir. Bu sonsal dağılımlardan parametrelerin MAP kestirimleri aşağıdaki gibi bulunur [17]:

$$\hat{\mathbf{m}}_k = \frac{N_k \bar{\mathbf{s}}_k + \lambda \mathbf{m}_0}{N_k + \lambda} \quad (2.28)$$

$$\hat{\Sigma}_k = \alpha \Psi + (1 - \alpha) \mathbf{S}_k + \frac{N_k \lambda (\bar{\mathbf{s}}_k - \mathbf{m}_0)(\bar{\mathbf{s}}_k - \mathbf{m}_0)^T}{(N_k + \lambda)(N_k + \tau + D + 1)} \quad (2.29)$$

Burada tanımlanan  $\lambda$  ve  $\alpha$  parametreleri kullanıcı tarafından seçilerek tanımlanır ve  $\alpha$  :

$$\alpha = \frac{\tau + L + 1}{N_k + \tau + L + 1}, \quad 0 \leq \alpha \leq 1 \quad (2.30)$$

şeklinde belirlenir.  $\tau$  parametresi de  $\alpha$  terminolojisine göre

$$\tau = \frac{\alpha(N_k + D + 1) - D - 1}{1 - \alpha}, \quad 0 \leq \alpha \leq 1 \quad (2.31)$$

olarak yazılabilir. Başlangıç durumunda kullanıcı tarafından belirlenmesi gereken parametreler  $\mathbf{m}_0$ ,  $\Psi$  ve  $\lambda$  ve  $\alpha$  dir.  $\mathbf{m}_0$  parametresi tüm eğitim verisi kümesi  $\mathcal{D}$ ' nin örnek ortalamasıdır (2.29). Burada  $\mathcal{D}$  tüm sınıflara ait eğitim veri kümeleri  $\mathcal{D}_k$ ' ların birleşimidir.  $\Psi$  ise eğitim verisi kümesi  $\mathcal{D}$ ' nin örnek kovaryans matrisi  $\mathbf{S}$  kullanılarak  $\Psi = 0.75\mathbf{S} + 0.25\text{diag}\{\mathbf{S}\}$  şeklinde hesaplanır.

$$\mathbf{m}_0 = \frac{1}{N} \sum_{n \in \mathcal{D}} (\mathbf{s}_n) \quad (2.32)$$

$$\mathbf{S} = \frac{1}{N} \sum_{n \in \mathcal{D}} (\mathbf{s}_n - \mathbf{m}_0)(\mathbf{s}_n - \mathbf{m}_0)^T \quad (2.33)$$

$\Psi$  parametresini ayarlamak için  $\mathbf{S}$  kullanılmaktadır, çünkü seçilen küçük örnek eğitim kümelerinde  $\mathbf{S}$  negatif tanımlı bir matris olarak bulunabilir.  $\Psi$  eşitliğinde yer alan 0.75 ve 0.25 değerleri yapılan denemeler sonucunda bulunmuştur.

Bu çalışmada, başlangıç parametre değeri olarak [17]' de verilen değerler kullanılmıştır. Bunlar;

$$\alpha \in [0, 1], \lambda = 10^{-3}, \eta = 0.5 \quad (2.34)$$

Piksellerin sınıflandırma işlemlerinde eğitim basamağı [17]' de önerildiği şekilde gerçekleştirilmiştir.


### 3.

## 3. SAR İMGELERİNİN ÖZİNİTELİK TABANLI SINIFLANDIRILMASI

### 3.1. SAR İmgelerine Giriş


Sentetik açıklı radar (Synthetic Aperture Radar – SAR) görüntüleme sistemi SEASAT uydusunun 1978 yılında uzaya gönderilmesiyle başlamıştır. SAR uyduları çeşitli iç dalgalar, akıntı yönleri, yükselmeler, gemi geçişi, buz dağları ve buzul parçaları gibi okyanus hareketlerini gözlemlemede, sel ve yangın alanlarının görüntülenmesinde, tarım alanlarındaki ürün gelişimlerinin gözlenmesinde, insan ya da araç takibinde, şehir bölgeleri görüntülenmesinde, uzaktan algılama ve tanıma sistemleri gibi hem askeri hem de sivil amaçlar olmak üzere birçok farklı alanda yaygın olarak kullanılmaktadır. SAR görüntüleme sistemlerinde kullanılan sensörler 1 m'nin birkaç cm aşağısına kadar küçük yüzey değişimlerine karşı duyarlı ve güneş ışınları, bulut örtüleri gibi hava koşullarından bağımsız olarak yüksek çözünürlüklü iki boyutlu görüntüler sağlamaktadır.

SAR sistemi, yana bakan hava tabanlı radarın (SLAR) gelişmiş bir versiyonudur. Radar platformu ileri yönde bir doğru üzerine hareket ederek aşağı doğru yönlü bir veya birkaç anten ile hedefe dik olarak elektromanyetik sinyaller yayarlar. Yerdeki hedeften bu elektromanyetik sinyallerin bir kısmı geri yansır ve yansıyan bu sinyaller SAR platformu üzerinde farklı pozisyonlardaki radar antenleri tarafından toplanır. Bu aşamada radar sistemlerinin hedef tarama yöntemine göre farklı özelliklerde SAR imgeleri elde edilebilir. Bunlar Spotlight-SAR ve Stripmap-SAR'dır. Spotlight-SAR yönteminde, hedef noktasından yüksek çözünürlüklü SAR imgesi elde etmek için radar sisteminden gönderilen sinyaller hedefe yönlendirilerek radar platformu hareket halindeyken dahi ölçüm yapılabilir. Bu yöntemle daha fazla sinyal gönderilerek azimut çözünürlüğü artırılır ve elektronik sinyallerin yönlendirilmesi ile daha uzun süre hedef taraması yapılabilir. Şekil 3.1' de Spotlight-SAR sistemi görülmektedir [41]. Bu radar sisteminden gönderilen sinyaller sadece hedeflenen noktayı taradığı için geriye kalan diğer yüzey alanı hakkında detaylı bir tarama gerçekleştirmez.



Şekil 3.1: Spotlight-SAR Yöntemi.


Diğer bir yöntem ise Stripmap-SAR'dır. Bu yöntemde sabit platform üzerinde hareket eden radar antenlerinin hareket doğrultusu boyunca yaptığı tarama ile oluşan imgelerdir. Şekil 3.2' de görülen Stripmap-SAR yöntemi ile elde edilen SAR imgeleri, radar anten hareket alanı boyunca tarama yaparak daha geniş bir yüzey alanı bilgisi çıkarılır [41].



Şekil 3.2: Stripmap-SAR Yöntemi.

Toplanan sinyallerin evreyumlu (coherent) kombinasyonlarına fiziksel anten aralığında daha uzun sanal açıklık yapısı sunmaktadır. Geri saçılan sinyalin genlik ve faz karakteristiği hedef nesnesinin fiziksel ve elektriksel özelliklerine bağlıdır.

Basit anlamda SAR sistemi gözlemlenen alandan 2-B yansıma haritası oluşturmaktadır. Hedef nesnesinden yüksek geri saçılan sinyaller parlak noktalar, düz yüzeylerden geri saçılan sinyaller karanlık noktalar ile gösterilmektedir. SAR sisteminde belirli bir yörüngede hareket eden bu platformla bütünleşik olan anten ve bu antenin SAR tarama sistemiyle çalışma biçimi Şekil 3.3’ de gösterilmektedir.

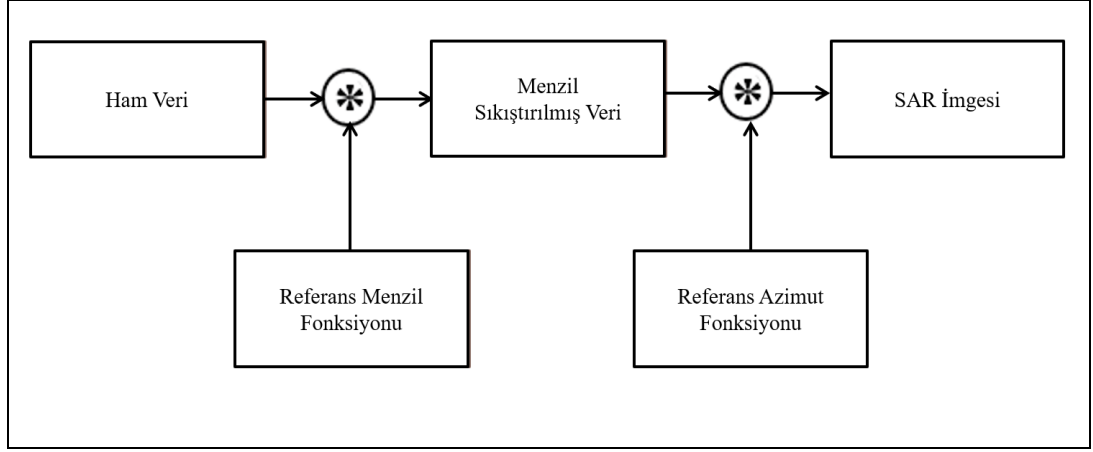


Şekil 3.3: SAR sistemi geometrisi.

SAR sisteminde anten, yatay doğrultuda hareket ederek menzil (range) ve çapraz menzil (azimuth) yönlerinde hedef taraması yapar. Anten ile hedef arasındaki doğrusal uzaklığa eğik menzil (slant range) denir [27 – 28].

SAR sisteminde her bir pikselde kompleks bir sinyali oluşturacak şekilde geri saçılan enerjinin, hem genlik hem de fazının kaydedildiği iki boyutlu karmaşık veri matrisi oluşur.

Standart optik sensörlere oranla, işlenmemiş SAR verisi doğrudan sahne hakkında kullanılabilir bilgi sunmamaktadır. Sinyal işleme adımları ile SAR görüntüsü kullanılabilir hale gelmektedir. Bu adımlar Şekil 3.2’ de gösterildiği gibi menzil ve azimut boyutları için iki ayrı uyumlu süzgeç ile gerçekleştirilmektedir [29 - 42].



Şekil 3.4: SAR görüntülerinin oluşturulması sırasındaki sinyal işleme süreci.

İlk süzgeç işlenmemiş SAR sinyallerini referans menzil fonksiyonu ile evrimleşmesiyle kısa darbelere sıkıştırılmaktadır. Bu süreç radar ile zemindeki herhangi bir noktanın uzaklığını vermektedir. İkinci süzgeç ile sıkıştırılmış görüntüyü uzaklığa göre değişimi ve geometri ile alakalı referans azimut fonksiyonu ile evrimleşmesiyle sahne resmi oluşturmaktadır [29 - 30].

SAR görüntüleri, menzil çözünürlüğü darbe sıkıştırma yöntemleri ile geliştirilebilir. Azimut çözünürlüğü ise anten büyüklüğü ve radar dalga uzunluğuna bağlıdır.  $N_r$  menzil genişliği,  $N_a$  azimut hücre sayısı ise, çözünürlük hücre sayısı  $N_r N_a$  şeklinde hesaplanmaktadır [31]. SAR görüntüleri yüzeyden saçılan birçok farklı sinyallerin çözünürlük hücresinde evreyumlu toplanması sonucu elde edilirken ayrıca tuz-biber gürültüsü görünümünde benek gürültüsünde toplanan veride oluşmaktadır.

Genlik ve fazların evreyumlu toplanması hücreden hücreye güçlü dalgalanmalı geri saçılıma neden olmaktadır. Bu sebepten dolayı nihai görüntünün yoğunluk ve faz değerleri deterministik olmamaktadır. Benek gürültüsü çarpımsal karakteristiğe sahiptir ve anten verici gücü artırılarak azalmamaktadır. Benek gürültüsünü azaltmak için çok-bakışlı görüntüleme tekniği kullanılabilir. Çoklu-bakış tekniğinde benek gürültüsünü azaltmak için görüntü spektral bant genişliğinde örtüşmeyen birkaç bölgeye bölünerek birbirinden bağımsız görüntülerin eş zamanlı olmayan toplanmasını içerir ve sinyal çözünürlüğünde azalmaya ve veri istatistiklerinin değişimine neden olur. Bu imgelerin birleştirilmesi sonucu görüntü oluşmaktadır ve bakış sayısı arttıkça benek gürültüsü azalmaktadır.

SAR sistemlerinde sahnenin kapsamlı nicel ve nitel fiziksel özelliklerinin çıkarımında polarizasyon tekniği kullanılmaktadır. Elektromanyetik dalganın polarizasyon durumu, uzayda yayılması boyunca, elektrik alan vektörünün nominal referans düzlemine göreceli hareketini ifade eder. Geleneksel radarlar, tek polarizasyonlu elektromanyetik sinyali yaymak ve almak için tek anten kullanırlar. Tam polarize olmuş veya polarizasyon tekniğinin kullanan SAR sistemleri, her biri dik olarak polarize olmuş iki sinyalden birini yayabilen ve alabilen iki antene sahiptir. Mesela, bir polarimetrik radar hem yatay olarak (H) hem de dikey (V) olarak polarize olmuş sinyalleri yayabilir (iletebilir) ve iki eş-polarize olmuş (HH ve VV) ve iki karşı-polarize olmuş (HV ve VH) dönüş sinyallerini ölçebilir. HH kanalı alınan ve gönderilen polarizasyonun türünün yatay olduğunu, VV kanalı alınan ve gönderilen polarizasyonun türünün dikey olduğunu, HV kanalı gönderilen yatay iken alınan dalganın polarizasyon türünün dikey olması ve VH kanalı da gönderilen dikey iken alınan dalganın polarizasyon türünün yatay olduğunu göstermektedir [32]. Polarizasyon tekniğinin kullanan radarlar görüntülenen yüzeylerin polarizasyon özelliklerini de içermesiyle daha zengin görüntüler oluştururlar.

### **3.2. SAR İmgesi Veri Kümesi**

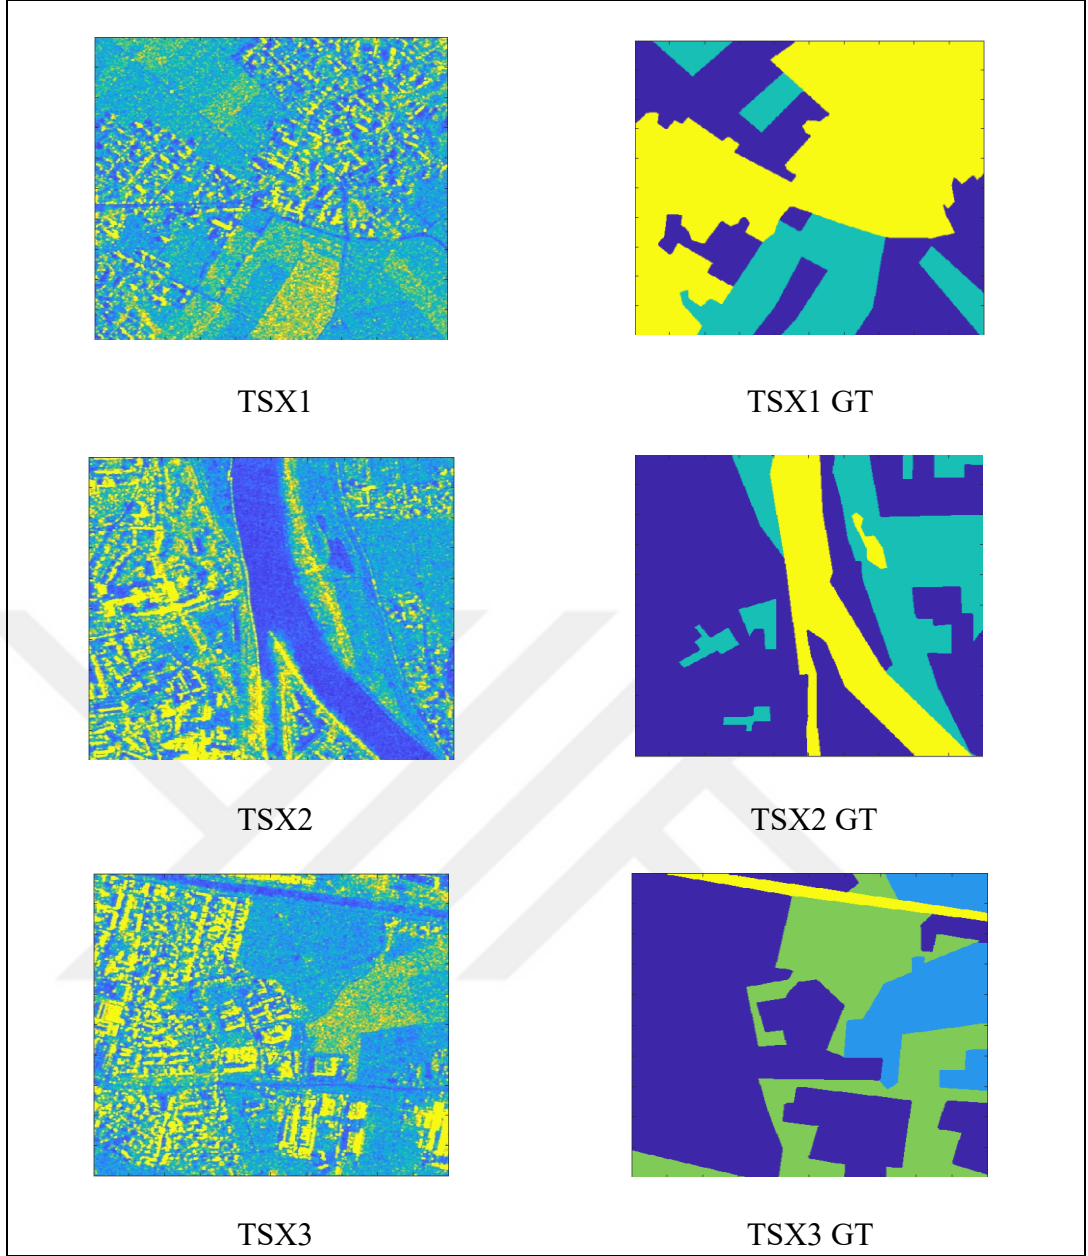
Almanya'nın 2007 yılında uzaya gönderdiği TerraSAR-X uydusu tarafından elde edilen SAR görüntüleri tez çalışması kapsamında kullanılmıştır. Bu imgeler Almanya'nın Rosenheim kentinden ve ABD'nin Mississippi eyaleti üzerinden çekilmiş imgelerdir.

### 3.2.1. Rosenheim İmgesi

Rosenheim imgesi, TerraSAR-X SpotLight uydusu tarafından 27 Ocak 2008 tarihinde Almanya'nın Rosenheim kenti üzerinde elde edilmiştir. HH polarizeli, çoklu-bakış tekniğiyle çekilmiş olup bakış sayısı 4'tür. 8.2 m uzamsal çözünürlüğe sahiptir. İmge boyutu 9142 x 9428' tür. Şekil 3.5' te Rosenheim görüntüsünün tamamı gösterilmektedir. Bu imgenin üç farklı bölgesinde 500x500 boyutlarında farklı TSX1, TSX2 ve TSX3 imgeleri alınarak sınıflandırılma yapılmaktadır. Kullanılan imgeler ve yer-gerçekliği haritaları Şekil 3.6' da gözlemlenmektedir.



Şekil 3.5: Rosenheim şehri imgesi.




Şekil 3.6: Rosenheim şehri imgesinden elde edilen TSX1, TSX2, TSX3 SAR imgeleri ve yer-gerçekliği haritaları.


### 3.2.1. Mississippi İmgesi

ABD eyaletlerinden Mississippi'nin güneyinden 2 Ocak 2008 tarihinde TerraSAR-X StripMap uydusu tarafından çekilmiştir. HH polarizeli, çoklu-bakış tekniğiyle elde edilmiştir ve 6.9 m uzamsal çözünürlüğüne sahiptir. İmge boyutu 21666 x 15666 olup Şekil 3.7' de gösterilmektedir. Bu resim üzerinden 600x500' lik

bir bölge alınarak sınıflandırma yapılmaktadır. Kullanılan imge TSX4 ve yer-gerçekliği haritası Şekil 3.8’ de görülmektedir.



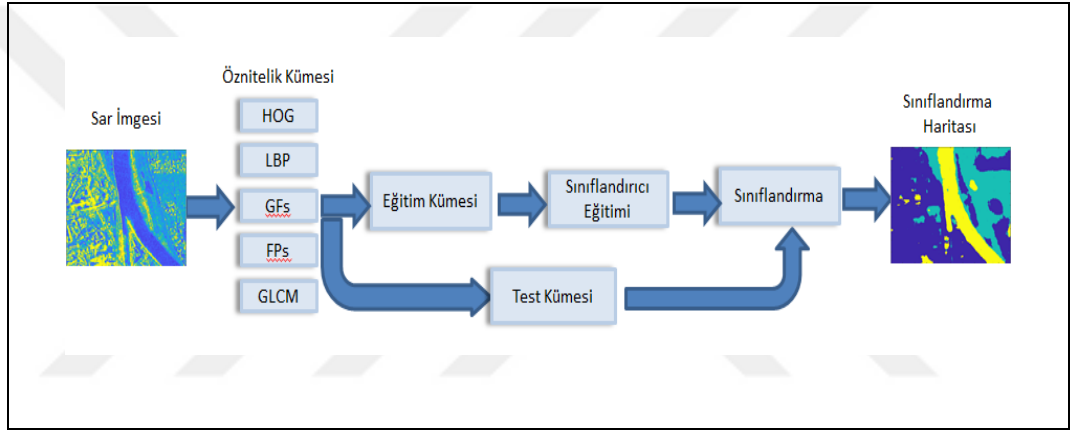
Şekil 3.7: Mississippi şehri imgesi.



Şekil 3.8: Mississippi şehri imgesinden elde edilen TSX4 SAR imgeleri ve yer-gerçekliği haritası.

## 4. DENEYSEL ÇALIŞMALAR

Bu bölümde yukarıda anlatılan farklı öznitelik çıkarma yöntemleri TSX1, TSX2, TSX3 ve TSX4 SAR imgelerine uygulanarak BGMM sınıflandırma işlemi yapılmıştır ve kullanılan farklı öznitelik yöntemlerinin başarı oranları karşılaştırılmıştır. İlk olarak sınıflandırma algoritmasının öğrenmesi için farklı oranlarda veriler sınıflandırıcıya girilmiştir ve bu aşamada veriler eğitim ve test verisi olarak ayrılmıştır. Bu çalışmada izlenen algoritmanın akış diyagramı Şekil 4.1’de gösterilmektedir.



Şekil 4.1: Akış Diagramı.

BGMM sınıflandırma işleminde ilk olarak üç boyutlu veriler sınıflandırıcı eğitimi için belirlenen oranda eğitim ve test verisi olarak ayrılmıştır. Eğitim verisi değeri imgedeki her bir sınıfın toplam piksel değeri göz önüne alınarak belirlenmiştir. Yapılan denemeler sonucunda sınıflandırıcı eğitim aşaması için her sınıftan rastgele 20, 1000 ve 20.000 piksel kullanılmıştır. SAR verisinde eğitim verisi dışında kalan diğer pikseller de test aşamasında kullanılmıştır. BGMM sınıflandırıcısı ile gerçekleştirilen sınıflandırma işleminin performansı ve karşılaştırması verilen Tablo 4.1, Tablo 4.2, Tablo 4.3 ve Tablo 4.4’de görülmektedir.

Tezin ikinci bölümünde bahsedilen öznitelik çıkarma yöntemleri kullanılarak SAR imgesindeki her bir piksel için öznitelik vektörü oluşturulmuştur. İlk olarak HOG öznitelik çıkarma yönteminde imgedeki her piksel için gradyanların büyüklükleri ve yönelimleri hesaplanmıştır. Bu çalışmada kullanılan HOG

yönteminin parametreleri ve değerleri; pencere boyutu 25 x 25, hücre boyutu 5x5 ve kutu sayısı (number of bins) 4 olarak belirlenmiştir. Seçilen parametre değerlerine göre tek bir piksel için 36 tane öznitelik çıkarılmıştır. LBP için rotasyonu değişmeyen pencere kullanılmıştır ve boyutu 25 x 25, komşu piksel sayısı ise 8 olarak tanımlanmıştır ve bu yöntem ile tek bir piksel için 59 tane öznitelik oluşturulmuştur. Diğer bir yöntem Gabor süzgeçleri içinse imgelere 2-D boyutlu farklı yönlerde ve ölçekte Gabor süzgeçleri uygulanmıştır. Bu çalışmada pencere boyutu 30 x 30 olarak seçilmiştir ve süzgeç parametre değerleri ölçek değeri 5 ve rotasyon değeri 6 olarak belirlenmiştir. SAR imgesine oluşturulan 30 farklı Gabor süzgeci kullanılarak tek bir piksel için 30 öznitelik oluşturulmuştur. GLCM yönteminde ise 8 gri seviyede ve 25 x 25 pencere boyutunda 9 farklı doku parametresi hesaplanmıştır. GLCM öznitelik vektörünü oluşturan parametreler; varyans, entropi, kontrast, korelasyon, enerji, homojenlik, otokorelasyon, GLCM ortalama ve maksimum değerleridir. GLCM yöntemi ile tek bir piksel için 33 öznitelik çıkarılmıştır. FPs yönteminde tek bir piksel için 31 öznitelik çıkarılmıştır ( $L=15$ ). İlk olarak yapısal eleman  $r$  yarıçaplı disk elemanı kullanılarak Afs (nitelik süzgeçleri) uygulanmıştır.  $r$  değeri 1'den 15'e kadar bir birim artarak değiştirilmiştir ve  $m$  değeri 2 kullanılarak FPs öznitelikleri çıkarılmıştır. Bu şekilde imgeye farklı yarıçaplı ayırık diskler kullanılarak verideki en büyük bileşen de dahil edilerek çalışma durumu test edildi.

Yukarıda adı geçen yöntemlerden elde edilen öznitelik vektörleri BGMM sınıflandırıcısı kullanılarak sınıflandırılmıştır. Sınıflandırma başarımlarına göre karışıklık matrisi (Confusion matrix) oluşturulmuştur. Şekil 4.2'de görülen yapıda mavi renkle gösterilen köşegen matrisi sınıflandırması doğru yapılmış test verisi sayısını göstermektedir ve doğru sınıflandırılmış örnek sayısı toplanarak test kümesindeki toplam veri sayısına bölünmesi ile genel doğruluk (overall accuracy – OA) oranı çıkarılır.

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

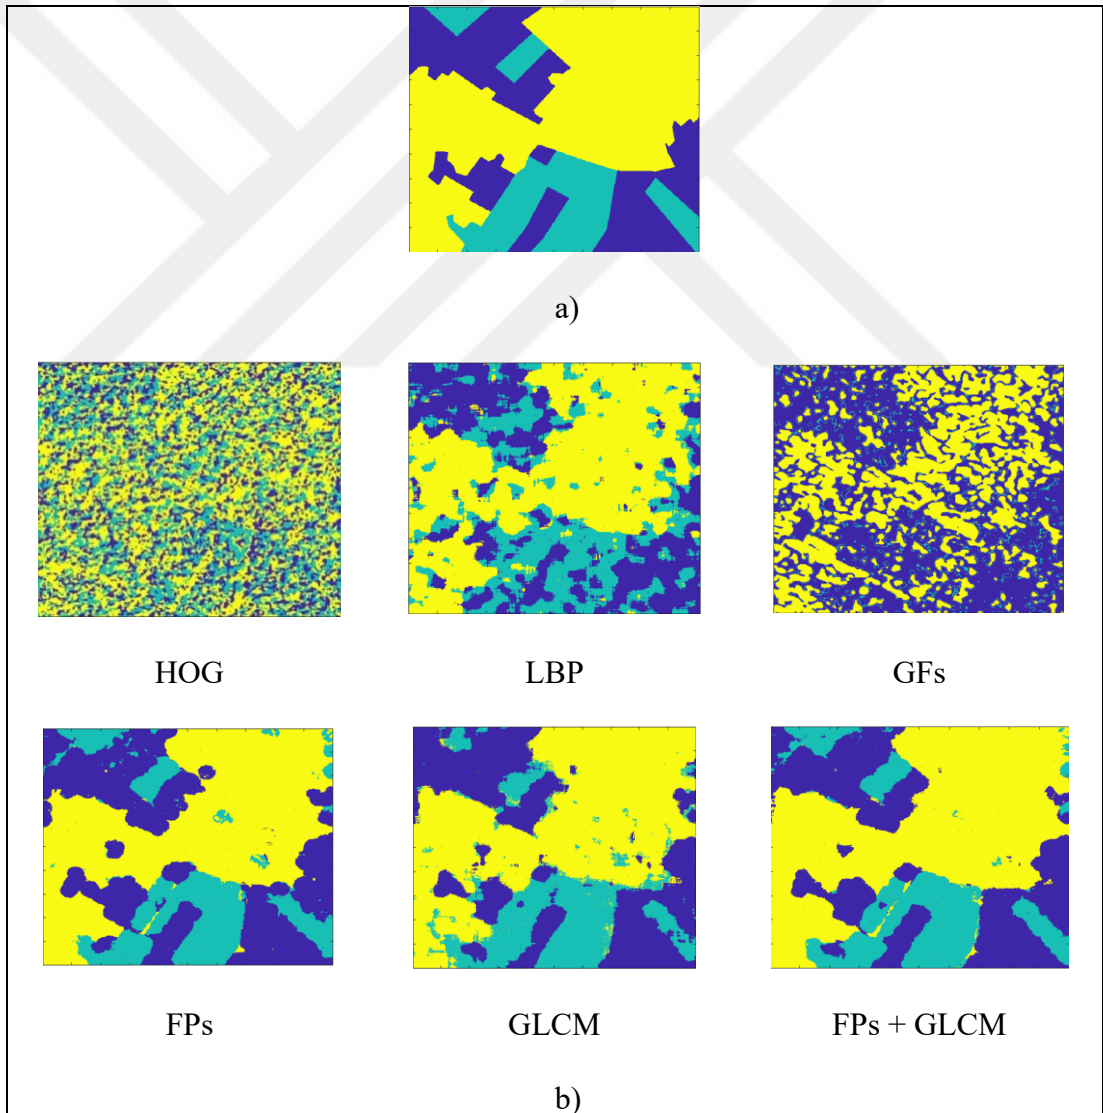
Şekil 4.2: Karışıklık Matrisi.

Eğitim ve test verisi olarak ayrılan SAR verisi sınıflandırma yapısı 20 kez çalıştırılarak başarı oranı belirlenmiştir. Her bir sınıflandırma işlemi öncesinde eğitim ve test verisi rastgele olarak tekrar belirlenmiştir. Bu şekilde birçok farklı eğitim ve test veri kümeleri oluşturulup kullanılarak sınıflandırıcının değişen yapıdaki veri kümelerindeki başarıyı test edilmiştir.

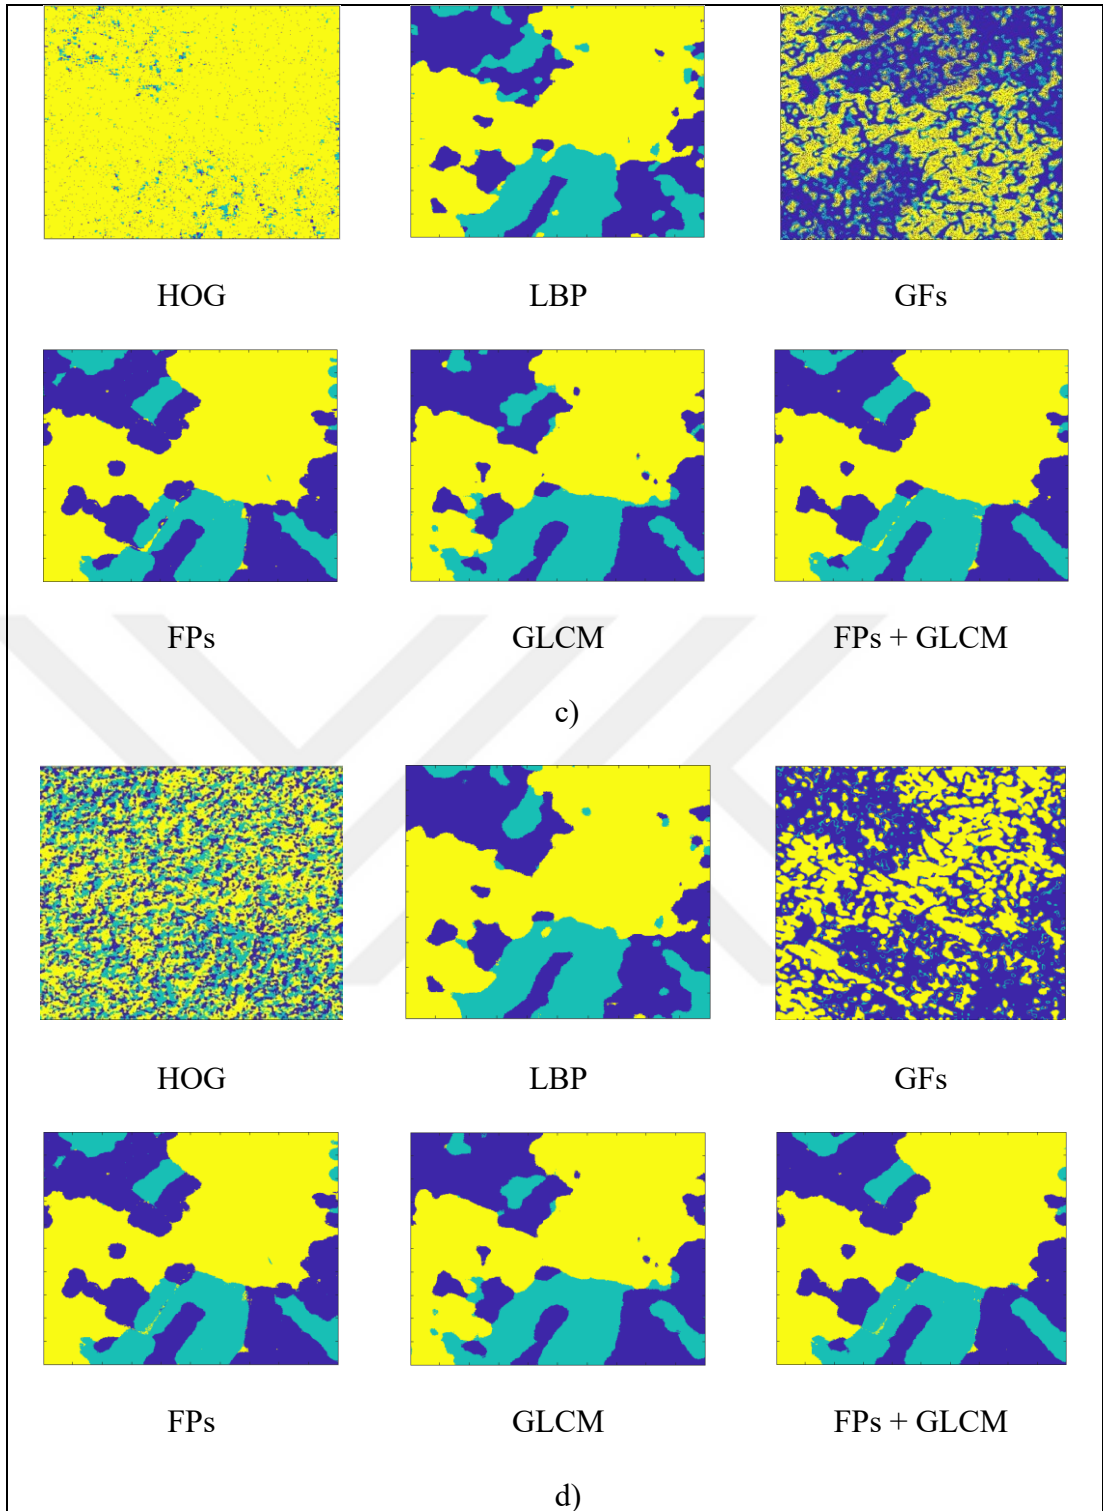
Başarı kriteri her bir sınıflandırma sonucunun kapa ve OA değerleridir. Her sınıflandırma işleminde eğitim ve test verileri rastgele seçilerek ayrılmıştır SAR verileri sınıflandırma işleminin sınıflandırma haritaları sırası ile Şekil 4.3, Şekil 4.4, Şekil 4.5 ve Şekil 4.6' da bulunmaktadır . TSX1 imgesinin BGMM sınıflandırma sonuçları Tablo 4.1' de , TSX2 imgesinin BGMM Sınıflandırma sonuçları Tablo 4.2' de , TSX3 imgesinin BGMM sınıflandırma sonuçları Tablo 4.3' te , TSX4 imgesinin BGMM sınıflandırma sonuçları Tablo 4.4' te bulunmaktadır.

Tablo 4.1: TSX1 İmgesinin BGMM Sınıflandırma Başarımı.

Öznitelik Çıkarma Yöntemi	Kappa			OA		
	N=20	N=1000	N=20000	N=20	N=1000	N=20000
HOG	0.3455±0.024	0.3685±0.001	0.3710±0.0	32.25±2.18	36,54±0,18	37,01±0,10
LBP	0.5805±0.023	0.6885±0.03	0.7059±0.0	58,27±2.23	68,85±0,32	70,61±0,09
GFs	0.5254±0.016	0.5326±0.001	0.5453±0.0	53.94±1.71	54,60±0,15	55,87±0,10
FPs	<b>0.8981±0.009</b>	<b>0.9027±0.001</b>	<b>0.9050±0.0</b>	<b>89.85±0.94</b>	<b>90,21±0.13</b>	<b>90.60±0.04</b>
GLCM	0.8587±0.013	0.8752±0.001	0.8802±0.0	85.04±1.33	87.92±0,15	88.42±0,04
FPs + GLCM	<b>0.910±0.010</b>	<b>0.9292±0.001</b>	<b>0.9315±0.0</b>	<b>91.03±1.08</b>	<b>92.92±0,12</b>	<b>93.55±0,04</b>




Şekil 4.3: TSX1 (eğitim ve test pikselleri) imgesinin sınıflandırma haritaları; a) Yer Gerçeklik, b) Eğitim kümesi N=20 ,c) Eğitim kümesi N=1000, d) Eğitim kümesi N=20000.




Şekil 4.3: Devam.

Tablo 4.2: TSX2 İmgesinin BGMM Sınıflandırma Başarımı.

Öznitelik Çıkarma Yöntemi	Kappa			OA		
	N=20	N=1000	N=20000	N=20	N=1000	N=20000
<b>HOG</b>	0.2987±0.024	0.3398±0.001	0.3651±0.0	29.25±2.18	35,87±0,18	36,50±0,18
<b>LBP</b>	0.6370±0.023	0.6885±0.03	0.6959±0.0	64,27±2.23	69,55±0,32	69,61±0,09
<b>GFs</b>	0.5254±0.016	0.5325±0.001	0.5470±0.0	53.94±1.71	54,60±0,15	55,87±0,10
<b>FPs</b>	<b>0.8827±0.009</b>	<b>0.8850±0.001</b>	<b>0.8908±0.0</b>	<b>88.55±0.94</b>	<b>89.01±0.13</b>	<b>89.20±0.04</b>
<b>GLCM</b>	0.8715±0.013	0.8801±0.001	0.8856±0.0	87.04±1.33	88.42±0,15	88.92±0,04
<b>FPs + GLCM</b>	<b>0.8950±0.015</b>	<b>0.9010±0.00</b>	<b>0.9130±0.0</b>	<b>89.59±1.16</b>	<b>90.14±0.11</b>	<b>91.34±0,03</b>



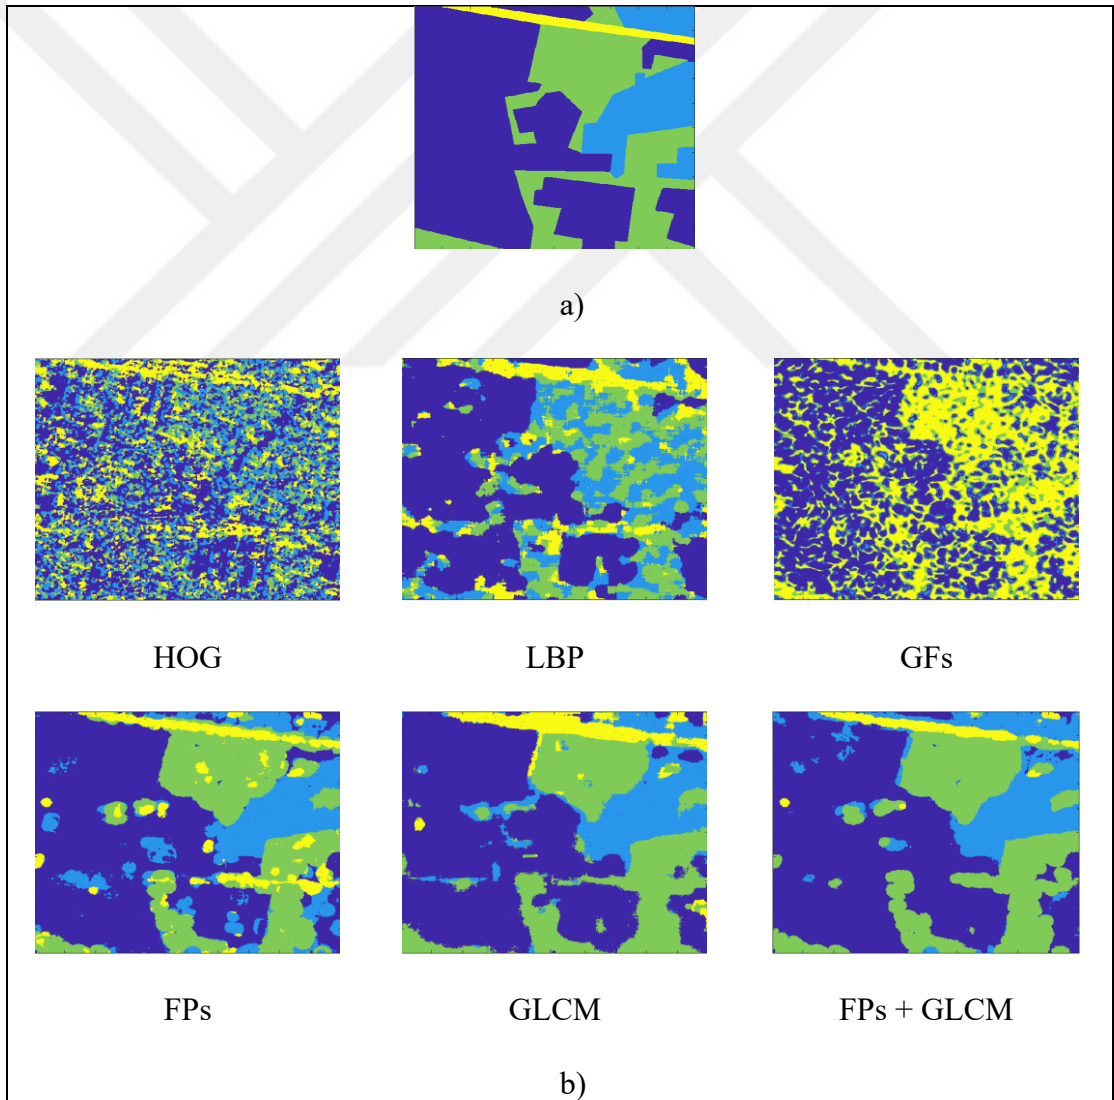
Şekil 4.4: TSX2 (eğitim ve test pikselleri) imgesinin sınıflandırma haritaları; a) Yer Gerçeklik, b) Eğitim kümesi N=20, c) Eğitim kümesi N=1000, d) Eğitim kümesi N=20000.



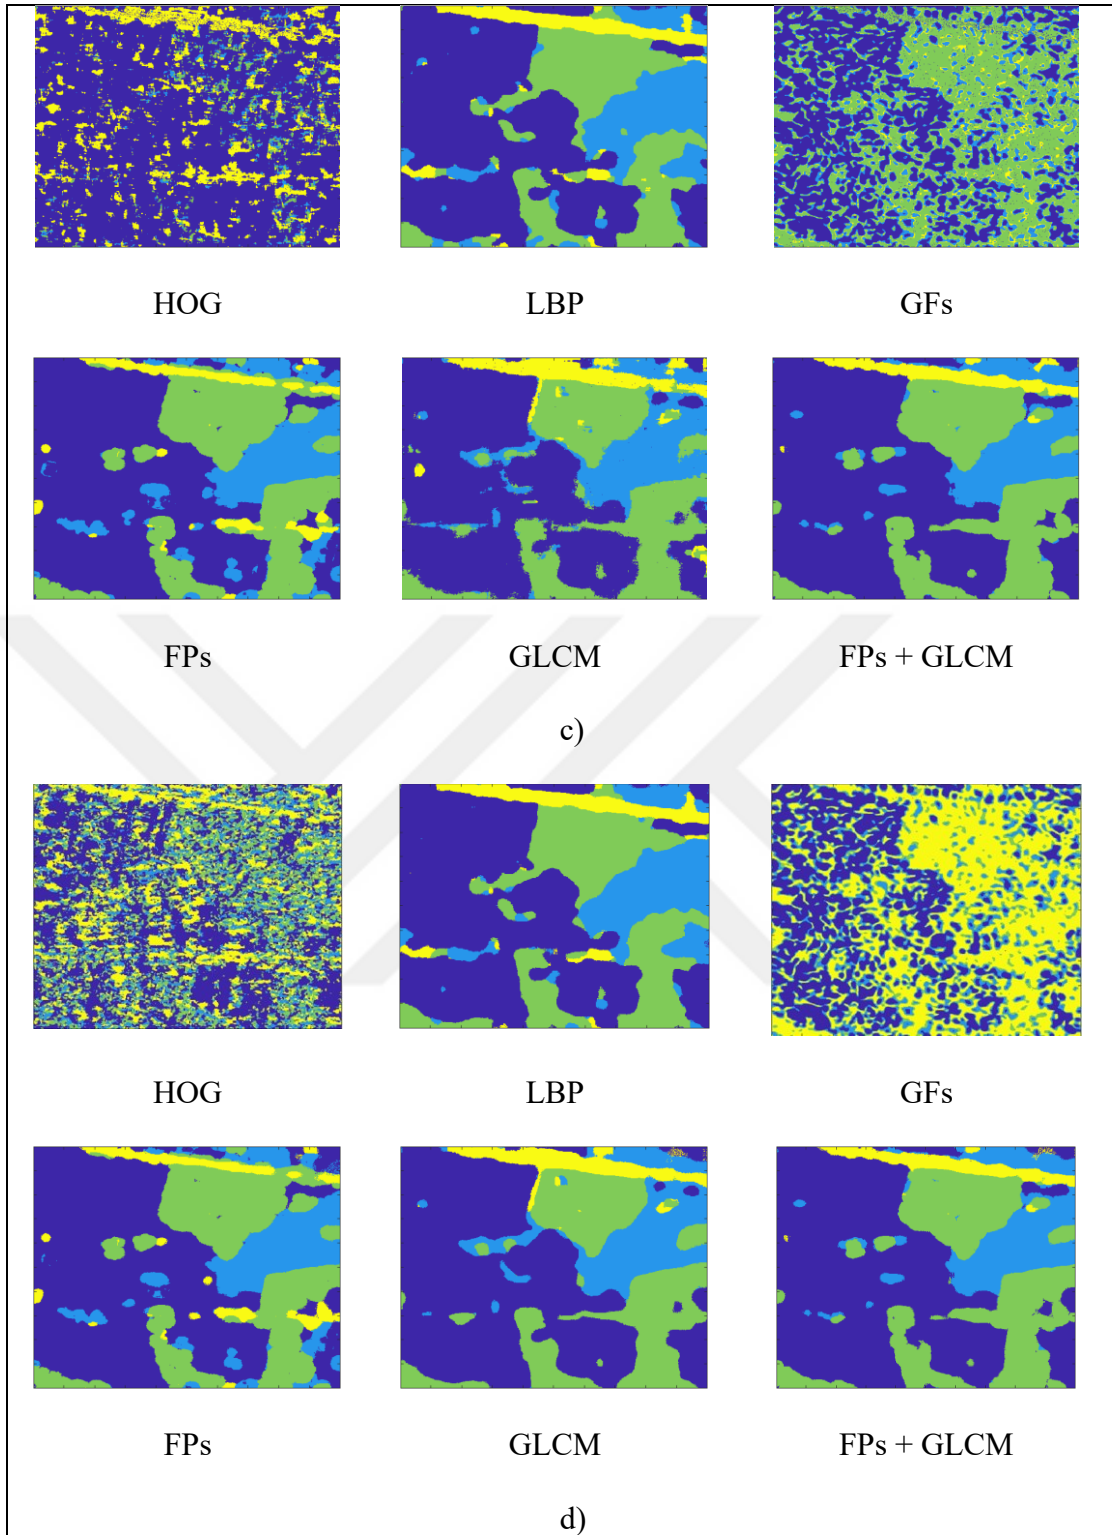
Şekil 4.4: Devam.

Tablo 4.3: TSX3 İmgesinin BGMM Sınıflandırma Başarımı.

Öznitelik Çıkarma Yöntemi	Kappa			OA		
	N=20	N=1000	N=20000	N=20	N=1000	N=20000
HOG	0.3272±0.037	0.3534±0.0	0.3602±0.0	32.95±3.43	34.88±0.41	36,01±0,13
LBP	0.6650±0.020	0.730±0.0	0.7883±0.0	66.87±1.99	73.05±0,43	78,61±0,11
GFs	0.5245±0.019	0.5260±0.0	0.5521±0.0	53.33±1.99	53.54±0,46	55,87±0,11
FPs	<b>0.8221±0.013</b>	<b>0.8451±0.0</b>	<b>0.8526±0.0</b>	<b>82.28±1.33</b>	<b>84.20±0,18</b>	<b>85.27±0,06</b>
GLCM	0.8142±0.016	0.8260±0.0	0.8388±0.0	81,51±1.60	82.73±0.25	83,83±0.07
FPs + GLCM	<b>0.8391±0.014</b>	<b>0.8588±0.0</b>	<b>0.8724±0.0</b>	<b>83.99±1.17</b>	<b>85.840±0.1</b>	<b>87.29±0.06</b>




Şekil 4.5: TSX3 (eğitim ve test pikselleri) imgesinin sınıflandırma haritaları; a) Yer Gerçeklik, b) Eğitim kümesi N=20 ,c) Eğitim kümesi N=1000, d) Eğitim kümesi N=20000.




Şekil 4.5: Devam.

Tablo 4.4: TSX4 İmgesinin BGMM Sınıflandırma Başarımı.

Öznitelik Çıkarma Yöntemi	Kappa			OA		
	N=20	N=1000	N=2000	N=20	N=1000	N=20000
HOG	0.2742±0.024	0.2881±0.011	0.2914±0.0	26.98±1.96	28.58±0,81	29.51±0.25
LBP	0.5740±0.026	0.5872±0.05	0.5945±0.0	57.50±2.44	58.58±0,50	59.46±0.15
GFs	0.5025±0.042	0.5158±0.002	0.5211±0.0	50.94±3.74	51.91±0,20	52.10±0.07
FPs	<b>0.8294±0.018</b>	<b>0.8492±0.002</b>	<b>0.8570±0.0</b>	<b>83.50±1.80</b>	<b>85.03±0.23</b>	<b>85.84±0.04</b>
GLCM	0.8155±0.019	0.8220±0.002	0.8250±0.0	81.08±1.87	82.35±0,25	82.70±0.07
FPs + GLCM	<b>0.8445±0.012</b>	<b>0.8578±0.001</b>	<b>0.8870±0.0</b>	<b>84.63±1.12</b>	<b>85.84±0.14</b>	<b>88.80±0.05</b>



Şekil 4.6: TSX3 (eğitim ve test pikselleri) imgesinin sınıflandırma haritaları; a) Yer Gerçeklik, b) Eğitim kümesi N=20, c) Eğitim kümesi N=1000, d) Eğitim kümesi N=20000.



Şekil 4.6: Devam.

Tablo 4.1, Tablo 4.2, Tablo 4.3 ve Tablo 4.4 de bulunan sonuçlar incelendiğinde sınıflandırıcı eğitim verisinin büyüklüğünün sınıflandırma performansını olumlu yönde etkilediği görülmektedir. Tüm SAR imgeleri için 3

farklı orandaki eğitim verisinde de en iyi performansın FPs öznitelikleri ile yapılan sınıflandırmada alındığı görülmektedir. Bir sonraki en iyi performans da GLCM öznitelikleri ile yapılan sınıflandırmada gerçekleşmiştir. En düşük sınıflandırma performansı ise HOG yöntemine aittir.

En iyi iki sonucun alındığı yöntemlerden GLCM ve FPs öznitelikleri kaynaştırılarak sınıflandırma işlemi yapıldığında iki yöntemde uyumlu çalıştığı ve daha iyi bir başarımlı sağladığı görülebilir. N=20 000 için FPs ve GLCM kaynaştırılmış sınıflandırma sonuçlarının karışıklık matrisi sırası ile TSX1 imgesinin Tablo 4.5’ te , TSX2 imgesinin Tablo 4.6’ da , TSX3 imgesinin Tablo 4.7’ de ve TSX4 imgesinin Tablo 4.8’ de bulunmaktadır.

Tablo 4.5: TSX1 İmgesinin N=20 000 FPs + GLCM Sınıflandırma Sonucunun Karışıklık Matrisi.

Karışıklık Matrisi		Tahmin edilen		
		Sınıf 1	Sınıf 2	Sınıf 3
Gerçek	Sınıf 1	49080	1649	1799
	Sınıf 2	1999	23417	1054
	Sınıf 3	3503	2161	104437

Tablo 4.6: TSX2 İmgesinin N=20 000 FPs + GLCM Sınıflandırma Sonucunun Karışıklık Matrisi.

Karışıklık Matrisi		Tahmin edilen		
		Sınıf 1	Sınıf 2	Sınıf 3
Gerçek	Sınıf 1	123156	7563	1506
	Sınıf 2	3960	32401	1514
	Sınıf 3	957	850	19093

Tablo 4.7: TSX3 İmgesinin N=20 000 FPs + GLCM Sınıflandırma Sonucunun Karışıklık Matrisi.

Karışıklık Matrisi		Tahmin edilen			
		Sınıf 1	Sınıf 2	Sınıf 3	Sınıf 4
Gerçek	Sınıf 1	109071	3000	4708	2584
	Sınıf 2	1413	9907	1687	699
	Sınıf 3	4633	3782	39896	2482
	Sınıf 4	37	7	10	3090

Tablo 4.8: TSX4 İmgesinin N=20 000 FPs + GLCM Sınıflandırma Sonucunun Karışıklık Matrisi.

Karışıklık Matrisi		Tahmin edilen		
		Sınıf 1	Sınıf 2	Sınıf 3
Gerçek	Sınıf 1	60866	2434	2349
	Sınıf 2	2744	105192	9381
	Sınıf 3	1081	8670	47282

Yukarıda bahsedildiği gibi HOG yöntemi gradyan hesabına dayanmaktadır ve SAR imgelerinde bulunan benek gürültü nedeniyle çok uygun bir yöntem olmayabilir. Diğer kullanılan yöntemlerden LBP ve GFs de gürültülü sınıflandırma sonuçları vermiştir. FPs yönteminin ise yer gerçeklik haritasına en yakın bölütleme sonuçları verdiği görülmektedir.

## 5. SONUÇLAR

Bu yüksek lisans tezinde, yüksek çözünürlüklü SAR imgelerinin öznitelik tabanlı sınıflandırılması üzerine bir çalışma gerçekleştirilmiştir. Farklı öznitelik çıkarma yöntemleri kullanılarak aynı sınıflandırma sisteminde başarımları karşılaştırılmıştır. Literatürde piksel tabanlı sınıflandırmada kullanılan FPs öznitelik çıkarma yöntemleri ile elde edilen sonuçların diğer öznitelik çıkarma yöntemlerine kıyasla SAR imge sınıflandırmada daha iyi sonuçlar verdiği görülmektedir. FPs ile gerçekleştirilen sınıflandırma sonucu oluşan sınıflandırma haritası ile imge yer-gerçeklik haritası karşılaştırıldığında, sınıflandırmanın doğruya en yakın olarak yapıldığı görülmektedir.

Uzamsal bilgi öznitelik çıkarma işlemi sırasında dahil edildiğinden sınıflandırma sonrası Markov rasgele alanları veya koşullu rastgele alanlar gibi pürüzsüzleştirme işlemlerine gerek duyulmamıştır. Fakat bu tür pürüzsüzleştirme işlemleri uygulanarak başarımları artırılabilir. İlerleyen çalışmalarda FPs yönteminin farklı yapısal elemanlar kullanılarak çıkarılmış süzgeçler ve farklı bağlı bileşenlerin ele alınarak analizi gerçekleştirilmiş birçok FPs öznitelikleri oluşturulabilir ve bu şekilde piksel komşuluk bilgilerinin daha detaylı bulunduğu öznitelik vektörleri oluşturulabilir. Ayrıca morfolojik ölçek – alan (morphological scale – space) akışı incelenebilir ve lojik tahmin yöntemleri araştırılabilir.

Kullanılan veri kümesindeki örnek sayıları az olduğundan derin öğrenme yöntemlerine başvurulmamış olup ileriki çalışmalarda veri çoğaltma ve transfer öğrenme yöntemleri kullanılarak SAR imgelerin derin öğrenme ile sınıflandırılması denenebilir. Ayrıca FP yöntemi ile SAR imgelerinden çıkartılmış öznitelik vektörleri derin ağ girişlerine uygulanarak sınıflandırma gerçekleştirilebilir.

## KAYNAKLAR

- [1] Frost V. S., Yurovsky L. S., (1985), "Maximum likelihood classification of synthetic aperture radar imagery," *Computer Vision, Graphics, and Image Processing*, 32, (3), 291–313.
- [2] Nicolas J. M., Tupin F., (2002), "Gamma mixture modeled with 'second kind statistics': Application to SAR image processing", *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2489–2491, Toronto Canada, 28 June.
- [3] Krylov V. A., Moser G., Serpico S. B., Zerubia J., (2012) "Probability density function estimation for classification of high resolution SAR images", *Signal and Image Processing for Remote Sensing*, Chapter 17, 7 September.
- [4] Shokr M. E., (1991), "Evaluation of second-order texture parameters for sea ice classification from radar images", *Journal of Geophysical Research*, 96, (C6), 10625–10640.
- [5] Soh L.-K., Tsatsoulis C., (1999), "Texture analysis of SAR sea ice imagery using gray level co-occurrence matrices", *IEEE Transactions on Geoscience and Remote Sensing*, 37, 2, 780–795, March.
- [6] Haralick R. M., Shanmugam K., Dinstein I. H., (1973), "Textural features for image classification", *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3, (6), 610–621, November.
- [7] Barber D. G., Shokr M. E., Fernandes R. A., Soulis E. D., Flett D. G., (1993), "A comparison of second order classifiers for SAR sea ice discrimination", *Photogramm. Eng. Remote Sens.*, 59, (9), 1397–1408.
- [8] Jain A. K., Farrokhnia F., (1991), "Unsupervised texture segmentation using Gabor filters", *Pattern Recognit.*, 24, (12), 1167–1186.
- [9] Dai D., Yang W., Sun H., (2011), "Multilevel local pattern histogram for SAR image classification", *IEEE Geosci. Remote Sens. Lett.*, 8, (2), 225–229, March.
- [10] Ojala T., Pietikäinen M., Mäenpää T., (2002), "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns", *IEEE Trans. Pattern Anal. Mach. Intell.*, 24, 7, 971–987, July.
- [11] Song S., Xu B., Yang J., (2016), "SAR target recognition via supervised discriminative dictionary learning and sparse representation of the SAR HOG feature", *Remote Sens.*, 8, (8), 683.
- [12] Dalal N., Triggs B., (2005), "Histograms of oriented gradients for human detection", *IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR'05)*, 886–893, 20–25 June.

- [13] Pham M.-T., Aptoula E., Lefèvre S., (2018), “Local feature-based attribute profiles for optical remote sensing image classification”, *IEEE Transactions on Geoscience and Remote Sensing*, 56, (2), 1199–1212, February.
- [14] Pham M.-T., Aptoula E., Lefèvre S., (2018), “Feature profiles from attribute filtering for classification of remote sensing images”, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 11, (1), 249–256, January.
- [15] Boldt M., Thiele A., Schulz K., Hinz S., (2014), “SAR image segmentation using morphological attribute profiles”, *Int. Arch. Photogram. Remote Sens. Spatial Inf. Sci.*, (XL-3), 39–44, September.
- [16] Marpu P. R., Chen K.-S., Chu C.-Y., Benediktsson J. A., (2011), “Spectral-spatial classification of polarimetric SAR data using morphological profiles”, *Int. Asia–Pacific Conf. Synth. Aperture Radar*, 1–3, October.
- [17] Kayabol K., Kutluk S., (2016), “Bayesian classification of hyperspectral images using spatially-varying Gaussian mixture model”, *Digit. Signal Process.*, vol. 59, pp. 106–114, December.
- [18] Ojala T., Pietikäinen M., Harwood D., (1996), “A comparative study of texture measures with classification based on featured distributions”, *Pattern Recognit.*, 29, (1), 51–59, January.
- [19] He D. C., Wang L., (1990), “Texture Unit, Texture Spectrum, and Texture Analysis”, *IEEE Transactions on Geosci. And Remote Sens.*, 28, (4), 509–512.
- [20] Kaya Y., Ertuğrul Ö. F., Tekin R., (2015), “Two novel local binary pattern descriptors for texture analysis”, *Appl. Soft Comput.*, 34, 728–735, September.
- [21] Yi J., Su F., (2014), “Histogram of Log-Gabor Magnitude Patterns for face recognition”, *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 519–523, Florence.
- [22] Singh S., Dhir R., (2012), “Recognition of Handwritten Gurmukhi Numeral using Gabor Filters,” *International Journal of Computer Applications*, 47, (1), 7–11, June.
- [23] Dalla M., Benediktsson J. A., Waske B., Bruzzone L., (2010), “Morphological attribute profiles for the analysis of very high resolution images,” *IEEE Trans. Geosci. Remote Sens.*, 48, (10), 3747–3762.
- [24] Gonzalez R. C., Woods R. E., (2008), *Digital Image Processing*, 3rd Edition, Prentice Hall.
- [25] Roumi M., (2009), “Implementing Texture Feature Extraction Algorithms on FPGA”, Master Thesis, Delft University of Technology.

- [26] Chandra A.M., Ghosh S.K., (2007), “Remote Sensing and Geographical Information System”, Alpha Science International, Oxford U.K. 16-24, 97-114.
- [27] Franceschetti G., Lanari R., (1999), “Synthetic Aperture Radar Processing, 30-70, CRC Press, 30 March.
- [28] Soumekh M., (1999), “Synthetic Aperture Radar Signal Processing with MATLAB Algorithms”, 1st Edition ,Wiley-Interscience.
- [29] Arisoy S., (2016), “Uzaktan Algılama Görüntülerinin Süperpiksel Tabanlı Sınıflandırılması”, Yüksek Lisans Tezi, Gebze Teknik Üniveristesi.
- [30] Moreira A., Iraola P. P., Younis M., Krieger G., Hajnsek I., Papathanassiou K. P., (2013), “A Tutorial on Synthetic Sperture Radar”, IEEE Geoscience and Remote Sensing Magazine, DLR, Germany.
- [31] Mahafza R. B., (2000), “Radar Systems Anlysis and Design Using Matlab” , 1st Edition, Chapman&Hall/Crc.
- [32] Web 1, (2014), <http://www.nrcan.gc.ca/earth-sciences/geomatics/satellite-imagery-air-photos/stallite-imagery-product/educational-resources/9567>, (ErişimTarihi:13/11/2014)
- [33] Eleyan A., Demirel H., (2011), “Co-occurrence matrix and its statistical features as a new approach for face recognition”, Turk J Elec Eng & Comp Sci., 19, (1).
- [34] Turkmenli I., Kayabol K., Aptoula E., (2018), “Comparison of semantic classification algorithms on SAR images”, 26. IEEE Signal Processing and Communications Applications Conference (SIU'18), İzmir, Turkey, May 2018.
- [35] Ahonen T., Pietikaninen M., (2007), “Soft histogram for local binary patterns”, Finnish Signal Processing Symposium (FINSIG).
- [36] Pham M. T., Aptoula E., Lefèvre. S., (2018), “Classification of remote sensing images using attribute profiles and feature profiles from different trees: A comparative study”, 2018 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 18 June.
- [37] Tombak A., Turkmenli I., Aptoula E. , Kayabol K., (2019), “Pixel-based classification of SAR images using feature attribute profiles”, IEEE Geoscience and Remote Sensing Letters, 16, (4), 564-567.
- [38] Cavallaro G., Falco N., Dalla M., Benediktsson J. A., (2017), “Automatic attribute profiles” IEEE Transactions on Image Processing, Institute of Electrical and Electronics Engineers, 26, (4), 1859-1872.

- [39] Dalla M., Benediktsson J. A., Waske B., Bruzzone L., (2010), “Extended profiles with morphological attribute filters for the analysis of hyperspectral data” *International Journal of Remote Sensing*, 31:22, 5975-5991.
- [40] Web 2, (2019), [www.mathworks.com/help/matlab/math/multidimensional-arrays.html](http://www.mathworks.com/help/matlab/math/multidimensional-arrays.html) , ( EriřimTarihi:15/10/2019)
- [41] Saeedi J., (2015) “Synthetic aperture radar signal processing using nonlinear frequency modulation and phase error compensation”, Doctoral Thesis, Amirkabir University of Technology.
- [42] Karabayır O., (2010), “Yapay aıklık radar iřaret iřleme ve Doppler merkez frekansının kestirimi”, Yksesk Lisans Tezi, İstanbul Teknik niversitesi.



## ÖZGEÇMİŞ

Ayşe TOMBAK 1992 yılında İstanbul’da doğdu. 2010 yılında başladığı Gebze Teknik Üniversitesi Mühendislik Fakültesi Elektronik Mühendisliği Bölümünü 2015 yılında başarıyla tamamlayarak aynı yıl yüksek lisans eğitimine Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik Mühendisliği Anabilim Dalında başladı. 2016 yılından bu yana özel sektörde Elektronik Mühendisi olarak çalışmaktadır.



## EKLER

### Ek A: Tez Çalışması Kapsamında Yapılan Yayınlar

Tombak A., Aptoula E., Kayabol K., (2018) "Pixel-based classification of SAR images using features", 26. IEEE Signal Processing and Communications Applications Conference (SIU'18), İzmir, Turkey, May.

Tombak A., Aptoula E., Kayabol K., (2019) "Pixel-based classification of SAR images using feature attribute profiles", IEEE Geoscience and Remote Sensing Letters, 16, (4), 564-567, April.

### Ek B: Açıklamalar

Gauss:

$$\mathcal{N}(\mathbf{x}|\mathbf{m}, \Sigma) = \frac{1}{(2\pi)^{\frac{D}{2}} |\Sigma|^{\frac{1}{2}}} \exp\left\{-\frac{1}{2}(\mathbf{x} - \mathbf{m})^T \Sigma^{-1}(\mathbf{x} - \mathbf{m})\right\} \quad (\text{B.1})$$

buradaki  $D$  ,  $\mathbf{x}$ ' in boyutudur.

Ters - Wishart:

$$\mathcal{W}^{-1}(\Sigma|\mathbf{P}, \nu) = \frac{|\mathbf{P}|^{\frac{\nu}{2}}}{(2)^{\frac{\nu D}{2}} \Gamma_D\left(\frac{\nu}{2}\right)} |\Sigma|^{-\frac{\nu+D+1}{2}} \exp\left\{-\frac{1}{2}tr(\mathbf{P}\Sigma^{-1})\right\} \quad (\text{B.2})$$

burada  $\Gamma_D$  çok değişkenli gama fonksiyonudur.