



**Kendiliğinden Organize Evrimsel Sınıflandırıcı  
Ağları Bulutları ile Büyük Çokboyutlu SAR Görüntü  
Depoları Yönetimi**

**Program Kodu: 1001**

**Proje No: 114E135**

Proje Yürütücüsü:  
**Doç. Dr. Türker İNCE**

Araştırmacı(lar):  
Prof. Dr. Serkan KIRANYAZ

Bursiyer(ler):  
M. Mete AHISHALI

MAYIS 2017  
İZMİR



Büyük çokboyutlu SAR veri depolarında endeksleme, sınıflandırma, arama ve erişim problemini çözmek amacıyla makine öğrenme ve işaret işleme alanında en son gelişmiş teknolojileri kullanarak ağ/bulut ortamları üzerinde yeni bir dağıtılmış sistem çerçevesi geliştirmeyi amaçlayan “Kendiliğinden Organize Evrimsel Sınıflandırıcı Ağları Bulutları ile Büyük Çokboyutlu SAR Görüntü Depoları Yönetimi” başlıklı ve 114E135 numaralı araştırma projesi TÜBİTAK tarafından desteklenmiştir.



## İÇİNDEKİLER

### İçindekiler

ÖNSÖZ.....	2
İÇİNDEKİLER.....	3
ŞEKİLLER.....	4
TABLolar.....	6
ÖZET.....	7
ABSTRACT.....	8
1. GİRİŞ.....	9
LİTERATÜR ÖZETİ.....	14
3. GEREÇ VE YÖNTEM.....	17
4. BULGULAR.....	38
5. TARTIŞMA ve SONUÇ.....	69
KAYNAKLAR LİSTESİ VE ATIFLAR.....	71



## ŞEKİLLER

Şekil 1: Sınıf (C) ve öznitelik (N) vektörleri ile CNBC çerçevesi topolojisi.....	28
Şekil 2: San Francisco Bay AIRSAR görüntüsü ve CNBC sınıflandırıcının temel 3- {water, urban, forest} sınıf durumundan başlayarak sırasıyla {rocks} ve {flat areas} sınıfları için yersel gerçek verisi eklenmesiyle artımlı olarak geliştirilmesi ile elde edilen 4- ve 5- sınıf durumları için sınıflandırma sonuçları.....	30
Şekil 3: Flevoland polarimetrik SAR görüntüsü için CNBC sınıflandırıcı içinde sırasıyla MLP-BP, MLP-PSO ve RBF-PSO ikili sınıflandırıcılar kullanılarak elde edilen sonuçlar.....	31
Şekil 4: Kendiliğinden organize olan ikili sınıflayıcılar ağı (NBC) bulutlarına dayalı SAR görüntü veri tabanı yönetimi.....	33
Şekil 5: Flevoland polarimetrik SAR görüntüsü için görselleştirilmiş farklı öznitelik bileşenleri (sırasıyla RGB kodlanmış Tutarlılık matrisi T11, T22, T33 bileşenleri, ve ayrı olarak Tutarlılık matrisi öz-dönüşümünden elde edilen üç özdeğer).....	34
Şekil 6: İki-boyutlu (FS-1) ve bir-boyutlu (FS-2) öznitelik uzayları üzerinde gerçekleştirilen örnek öznitelik sentezi.....	35
Şekil 7: Örnek bir geleneksel Evrişimli Yapay Sinir Ağları (CNN) yapısı (üstte) ve önerilen uyarlanabilir (adaptive) CNN içinde evrişimli tabaka nöron yapısı.....	37
Şekil 8: San Francisco görüntüsü için seçilen eğitim (training) alanları.....	38
Şekil 9: San Francisco görüntüsü için seçilen test alanları.....	39
Şekil 10: Sınıfların renk bilgisi.....	39
Şekil 11: San Francisco C Band 5 sınıf için ortalama doğruluk oranları.....	41
Şekil 12: San Francisco L Band 5 sınıf için ortalama doğruluk oranları.....	41
Şekil 13: San Francisco C Band 5 sınıf için artırımlı öznitelik için ortalama doğruluk oranları.....	43
Şekil 14: San Francisco L Band 5 sınıf için artırımlı öznitelik için ortalama doğruluk oranları.....	43
Şekil 15: San Francisco 5 sınıf için C Band sınıflandırma sonucu.....	44
Şekil 16: San Francisco 5 sınıf için L Band sınıflandırma sonucu.....	44
Şekil 17: Flevoland arazisinin ortalama sınıflandırma sonuçları.....	45
Şekil 18: Flevoland arazisinin öznitelik tabanlı artırımlı sınıflandırma ortalama sınıflandırma sonuçları.....	46
Şekil 19: Flevoland görüntüsü 12 sınıf için sınıflandırma sonucu.....	46
Şekil 20: 2366x2069 boyutlu Long Beach polarimetrik SAR görüntüsü için eğitici olarak seçilen bölgeler.....	47
Şekil 21: 2366x2069 boyutlu Long Beach polarimetrik SAR görüntüsü için test dataset.....	48
Şekil 22: Long Beach için sınıf renkleri.....	49
Şekil 23: Long Beach C Band arazisinin ortalama sınıflandırma doğruluğu grafiği.....	51
Şekil 24: Long Beach L Band arazisinin ortalama sınıflandırma doğruluğu grafiği.....	51
Şekil 25: Long Beach P Band arazisinin ortalama sınıflandırma doğruluğu grafiği.....	52
Şekil 26: Long Beach C Band arazisinin öznitelik tabanlı artırımlı ortalama sınıflandırma sonuçları.....	54
Şekil 27: Long Beach L Band arazisinin öznitelik tabanlı artırımlı ortalama sınıflandırma sonuçları.....	54
Şekil 28: Long Beach P Band arazisinin öznitelik tabanlı artırımlı ortalama sınıflandırma sonuçları.....	55
Şekil 29: Long Beach C Band 4 sınıf için sınıflandırma sonucu.....	55
Şekil 30: Long Beach L Band 4 sınıf için sınıflandırma sonucu.....	56
Şekil 31: Long Beach P Band 4 sınıf için sınıflandırma sonucu.....	57



Şekil 32: San Diego 2437x3109 boyutlu 4 sınıf için eğitici bölgeler.....	58
Şekil 33: San Diego 2437x3109 boyutlu 4 sınıf için test bölgeleri.....	59
Şekil 34: San Diego sınıfların renk bilgisi.....	59
Şekil 35: San Diego C Band arazisinin ortalama sınıflandırma sonuçları.....	61
Şekil 36: San Diego L Band arazisinin ortalama sınıflandırma sonuçları.....	62
Şekil 37: San Diego P Band arazisinin ortalama sınıflandırma sonuçları.....	62
Şekil 38: San Diego C Band arazisinin öznitelik tabanlı arttırımlı ortalama sınıflandırma sonuçları.....	64
Şekil 39: San Diego L Band arazisinin öznitelik tabanlı arttırımlı ortalama sınıflandırma sonuçları.....	64
Şekil 40: San Diego P Band arazisinin öznitelik tabanlı arttırımlı ortalama sınıflandırma sonuçları.....	65
Şekil 41: San Diego C Band 4 sınıf için sınıflandırma sonucu.....	66
Şekil 42: San Diego L Band 4 sınıf için sınıflandırma sonucu.....	67
Şekil 43: San Diego P Band 4 sınıf için sınıflandırma sonucu.....	68



## TABLolar

Tablo 1: Polarimetrik SAR öznitelikleri ve oluşturulan temel öznitelik vektörleri listesi.....	26
Tablo 2: 2531x1168 çözünürlüklü San Francisco Bay C Band SAR görüntüsü için 5 sınıf için CNBC ve SVM sınıflandırıcıları kullanılarak yapılan arazi sınıflandırma ortalama doğruluk yüzdeleri.....	40
Tablo 3: 2531x1168 çözünürlüklü San Francisco Bay L Band SAR görüntüsü için 5 sınıf için CNBC ve SVM sınıflandırıcıları kullanılarak yapılan arazi sınıflandırma ortalama doğruluk yüzdeleri.....	40
Tablo 4: 2531x1168 çözünürlüklü San Francisco Bay C Band SAR görüntüsü için 5 sınıf için CNBC ve SVM sınıflandırıcıları kullanılarak yapılan arazi sınıflandırma ortalama doğruluk yüzdeleri.....	42
Tablo 5: 2531x1168 çözünürlüklü San Francisco Bay L Band SAR görüntüsü için 5 sınıf için CNBC ve SVM sınıflandırıcıları kullanılarak yapılan arazi sınıflandırma ortalama doğruluk yüzdeleri.....	42
Tablo 6: Flevoland, Hollanda 1024x750 boyutlu 12 sınıf CNBC ve SVM ortalama sınıflandırma doğruluk yüzdeleri.....	45
Tablo 7: Flevoland, Hollanda 1024x750 boyutlu 12 sınıf CNBC ve SVM ortalama sınıflandırma doğruluk yüzdeleri.....	46
Tablo 8: Long Beach C Band 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri.....	49
Tablo 9: Long Beach L Band 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri.....	50
Tablo 10: Long Beach P Band 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri.....	50
Tablo 11: Long Beach C Band 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri (Incremental Features).....	52
Tablo 12: 11. Long Beach L Band 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri (Incremental Features).....	53
Tablo 13: Long Beach P Band 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri (Incremental Features).....	53
Tablo 14: San Diego C Band 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri.....	60
Tablo 15: San Diego L Band 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri.....	60
Tablo 16: San Diego P Band 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri.....	61
Tablo 17: Long Beach C Band 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri (Incremental Features).....	63
Tablo 18: Long Beach L Band 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri (Incremental Features).....	63
Tablo 19: Long Beach P Band 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri (Incremental Features).....	63

Uzaktan algılama alanında önemli uygulamalardan birisi olan Polarimetrik SAR (PolSAR) görüntüleri üzerinden arazi sınıflandırması bu zamana kadar çeşitli öznitelikler ve sınıflandırıcıların önerildiği aktif bir araştırma alanı olmuştur. Ancak, bu alandaki hemen hemen tüm çalışmalar sadece tek bir SAR görüntüsünün sınıflandırılması problemini ele almış ve büyük SAR görüntü depolarının elde edilmesi aşamasından bu alandaki uzmanlar tarafından görüntülerin tüketimini (görselleştirme ve analizi) içeren etkin bir yönetimi hala büyük ölçüde keşfedilmemiş veya tamamen bilinmemektedir. Bunun temel nedeni, depolama, indeksleme, sınıflandırma ve aynı zamanda erişim ve görselleştirme alanlarında zorluklar çıkartan bu problemin büyüklüğüdür. Bu proje büyük çokboyutlu SAR veri depolarında endeksleme, sınıflandırma, arama ve erişim problemini çözmek amacıyla makine öğrenme ve işaret işleme alanında en son gelişmiş teknolojileri kullanarak yeni bir çerçeve yapı geliştirmektedir. Bu çalışmada SAR verisi karakteristiklerini tanımlamak için elektromanyetik öznitelikler ile bunların farklı dönüşümleri ve gösterimleri (örneğin hedef ayırıştırma teoremleri), ve diğer görüntü işlemeye dayalı ikincil öznitelikler (örneğin desen, renk) kullanılmıştır. Bu öznitelikler daha sonra kendiliğinden organize ve daha önce geliştirdiğimiz Çok boyutlu Parçacık Sürü Optimizasyonu (MD PSO) algoritması kullanılarak eğitimi eniyilenmiş olan İkili Sınıflayıcı Ağları (NBC) bulutlarını geliştirmek için kullanılmaktadır. NBC topolojisi, bir sınıflayıcı topluluğu prensibine dayalı olarak bir sınıfı öğrenmek veya diğerleri arasından ayırt etmek amacıyla, büyük çok doruklu (multimodal) öznitelikler kümesi kullanılmasına imkan vermektedir. Bu şekilde, sistem ile kullanıcı etkileşimi oluştuğunda her biri artımlı geliştirilebilecek ve her bir sınıf için NBC bulutları oluşacaktır. Böylece, bir uzman kullanıcı tarafından herhangi bir geri besleme sistemi doğrudan geliştirmek ve sınıflandırma hatalarını azaltmak mümkündür. Sistem belli bir olgunluğa ulaştıktan sonra, gerektiğinde artımlı geliştirmeler gerçekleştirerek depodaki diğer SAR görüntülerini sınıflandırmak için kullanılabilir. Mevcut uçak veya uydu tabanlı SAR sensörlerinden araştırma amaçlı sağlanan erişime açık gerçek veriler kullanılarak gerçekleştirilen testlerde önerilen sistemin farklı arazi türlerini yüksek başarı ve verimlilikle öğrenebildiği gösterilmiştir.

Anahtar Kelimeler: Sentetik açıklıklı radar (SAR), böl ve yönet, oto-veri organizasyonu, evrimsel makine öğrenme, bulut bilgi işlem



## ABSTRACT

As one of the most important applications, terrain classification over polarimetric SAR images has been an active research field where several features and classifiers have been proposed up to date. However, almost all studies in this field only addressed the problem of the classification of a single SAR image and the efficient management of large SAR image repositories, from the acquisition stage to the consumption (visualization and analysis) of images by the experts in this field is still vastly unexplored or entirely unknown. The main reason for this is the sheer magnitude of this problem, which is massive and presents challenges in storage, indexing, classification and also in retrieval and visualization. This project aims to develop a novel framework using the latest developments in the fields of machine learning and signal processing within a systematic approach to tackle the problem of classification and indexing within large multidimensional SAR data repositories. In this work, in order to describe SAR data characteristics, the low-level electromagnetic SAR features, different transforms and representations of them (i.e. target decomposition theorems), and other secondary features (i.e. texture, color) based on image processing have been used. These features are then used to evolve the set of “clouds” of self-organized networks of binary classifiers (NBCs), which are optimally trained by using the multi-dimensional particle swarm optimization (MD PSO) algorithm. The NBC topology allows using a large set of multimodal features with the objective of learning or discriminating a single class among the others. Therefore, there will be a cloud of NBCs for each class, each of which can incrementally be evolved whenever a user-interaction occurs with the system. In this way, any feedback from an expert user will directly be used to enhance the system and reduce the classification errors. Once the system achieves a certain maturity, it can be used to classify other SAR images in the repository while performing incremental evolutions whenever necessary. The results of the tests performed using the popular real SAR benchmark datasets prove the efficiency and robustness of the system in learning different terrain and object types.

**Keywords:** Synthetic aperture radar (SAR), divide & conquer, self-data organization, evolutionary machine learning, cloud computing





## 1. GİRİŞ

Sürekli performansı iyileştirilmiş yeni Sentetik Açıklıklı Radar (SAR) sensör sistemlerinin bulunması ve yakın zamanda geliştirilen ileri radar tekniklerinin, örneğin yüksek çözünürlüklü polarimetrik ve interferometrik SAR görüntüleme, birçok uzaktan algılama uygulama alanlarındaki metodları ilerletmesi beklenmektedir. Aynı zamanda, birçok çokboyutlu SAR görüntüleri elde edileceğinden bu büyük bir ölçekte SAR veri işleme dönemini başlatacak, ve bu çaptaki bir veritabanının etkin yönetimi için yakın zamanda ihtiyaç doğacaktır. Her hava koşulunda ve yüksek çözünürlüklü mikrodalga görüntüleme yeteneği sebebiyle atmosfer, deniz ve yeryüzüne ait SAR ölçümleri çevresel izlemeden (örneğin bitkilerin, ormanların, sellerin, buz akımlarının, petrol sızıntılarının vb. izlenmesi) arazi haritalamasına (yüzeylerin topografik haritalaması), atmosferik ve iklimbilimi araştırmalardan savunma uygulamalarına (keşif, gözetleme, ve hedefleme) kadar çok çeşitli alanlarda kullanılmaktadır. Zaman, frekans, uzamsal ve polarizasyon çeşitliliğinden yararlanan mevcut gelişmiş çok boyutlu (çok kanallı, polarimetrik ve/veya interferometrik) SAR sistem konfigürasyonları karmaşık SAR verisi elde edebilir ve daha sonra bu veri işlenerek ve analiz edilerek görüntülenen hedeflerin farklı yönleri (bazı biofiziksel ve geofiziksel özellikleri hem de geometrik ve saçılım özelliklerini içeren) hakkında bilgi çıkartılabilir. Çok büyük miktarda bilgi ve yüksek veri karmaşıklığına sahip SAR görüntü veritabanı için otomatik veri analizi ve sınıflandırma algoritmaları geliştirilmesi SAR uzağı algılama sahasında zorlu bir araştırma alanı olarak ortaya çıkmıştır. Literatürde, bu alandaki hemen hemen tüm çalışmalar sadece tek bir SAR görüntüsünün sınıflandırılması problemini ele almış ve büyük SAR görüntü depolarının elde edilmesi aşamasından bu alandaki uzmanlar tarafından görüntülerin tüketimini (görselleştirme ve analizi) içeren etkin bir yönetimi hala büyük ölçüde keşfedilmemiş veya tamamen bilinmemektedir.

Temel düzeyde herhangi bir SAR görüntüsü, büyüklük ve fazı gösteren karmaşık değerli bir görüntüdür. Bir polarimetrik SAR görüntüsü, her biri gönderici ve alıcının yatay ve dikey polarizasyonlarının kombinasyonlarına karşılık gelen dört benzer karmaşık kanal içerir. Elektromanyetik dalgalar polarize olduğu için ve doğal nesnelere (hedefler) gelen dalga polarizasyonuna göre farklı tepki gösterebildiğinden (tekrar yayımlanan dalga polarizasyonunu değiştirirler), görüntülenen alan içindeki her pikselin polarizasyona bağlı saçılma tepkisi kullanılarak hedefi karakterize edebilecek veya belirleyecek yeni bilgiler çıkartmak mümkündür. Halen yeryüzü gözlemleri

için kullanılan ve farklı çalışma frekans seçenekleri verebilen çeşitli polarimetrik SAR enstrümanları mevcuttur: X-bandı(8-12 GHz, yaklaşık 3 cm dalgaboyu); C-bandı-(4-8 GHz, 5 cm); L-bandı(1-2 GHz, 15-30 cm); ve P-bandı(0.3-1 GHz, 30-100 cm). Mikrodalgaların hedef ile etkileşimi çalışma frekansına güçlü bir şekilde bağlıdır ve farklı frekanstaki sensörler tarafından oldukça farklı özneliklerin gözlenmesi ile sonuçlanabilir.

Polarimetrik hedef ayırıştırma teoremleri polarimetrik SAR ölçümlerini geri saçılmış işareti oluşturan temel saçılma süreçleri cinsinden bölerek bunların göreceli katkısını ölçmeyi amaçlar. Bu metodlar polarimetrik SAR görüntülerinin tek-sıçramalı yüzey saçılması, çift-sıçramalı köşe saçılması ve bir hacimden çoklu rasgele saçılım gibi basit mekanizmalar olarak sezgisel yorumlanmasını sağlamaktadır. SAR işaretinden çıkartılan öznelikler SAR görüntüsünün analizi ve arazi sınıflandırması amaçlı olarak kullanılabilir. Polarimetrik SAR öznelikleri genel olarak üç kategoriye ayrılabilir: birinci gruba elde edilen SAR verisinden direk olarak çıkartılan öznelikler ve saçılım matrisi ve bundan elde edilen Stokes matrisi, kovaryans matrisi ve tutarlılık (coherency) matrisi dahil edilebilir; ikinci grup ise SAR verisinden bilgi çıkartmak için kullanılan polarimetrik hedef ayırıştırma teoremlerine dayalı öznelikleri içermektedir. Uyumlu (coherent) ayırıştırma teoremleri (örneğin Pauli [7], Krogager [30], Cameron [4], ve SDH (Küre, Diplane, Helis) ayırıştırması [30] gibi) radar tarafından ölçülen saçılım matrisini uyumlu saçıcıların saçılım tepkilerinin birleşimi cinsinden ifade etmeyi amaçlamaktadır. Bir diğer kategoride, Freeman [12], Huynen [17], ve Cloude-Pottier (özvektör-özdeğer veya  $H/\alpha/A$ ) [7] ayırıştırması gibi uyumsuz (incoherent) ayırıştırma metodları dağınık saçıcıları karakterize etmek için polarimetrik SAR verisinin ikinci derece polarimetrik açılımlarını (örneğin kovaryans matrisi veya tutarlılık matrisi) kullanmaktadır. Bunlara ilave olarak, üçüncü grupta desen (texture) ve renk gibi görüntü işleme öznelikleri sınıflandırma doğruluğunu artırmak için sıklıkla kullanılmaktadır. Her öznelik farklı SAR sınıf tiplerini ayırt etmek için kendi güçlü ve zayıf yanlara sahiptir ve bu gerçek birden çok öznelik ve farklı kombinasyonları kullanarak SAR görüntü sınıflandırmanın önemli ölçüde geliştirilebileceği sonucuna varmış bazı yakın zamandaki araştırmalar, örneğin [40] ve [52], tarafından onaylanmıştır. Özellikle yakın zamanda bir çalışma [52] birden çok öznelik kombinasyonunun rasgele kümeleme orman sınıflandırıcı (extremely randomized clustering forest) kullanarak sınıflandırma performansının %8'e kadar geliştirilebileceğini göstermiştir. Bu nedenle, öznelik ölçeklenebilirliği ve optimal öznelik seçimi önerilen sınıflandırma çerçevesinin amaçladığı temel hedefler olduğu için,



yukarıda bahsedilen bütün gruplardan büyük bir öznitelik kümesi oluşturularak bu çalışmada kullanılacaktır.

Önemli uygulamalardan birisi olan Polarimetrik SAR (PoSAR) görüntüleri üzerinden arazi sınıflandırma bu zamana kadar çeşitli öznitelikler ve sınıflandırıcıların önerildiği aktif bir araştırma alanı olmuştur. Ancak, bu alandaki hemen hemen tüm çalışmalar sadece tek bir SAR görüntüsünün sınıflandırılması problemini ele almış ve büyük SAR görüntü depolarının elde edilmesi aşamasından bu alandaki uzmanlar tarafından görüntülerin tüketimini (görselleştirme ve analizi) içeren etkin bir yönetimi hala büyük ölçüde keşfedilmemiş veya tamamen bilinmemektedir. Bunun temel nedeni, depolama, indeksleme, sınıflandırma ve aynı zamanda erişim ve görselleştirme alanlarında zorluklar çıkartan bu problemin büyüklüğüdür. Bu problem genellikle günlük dilde kullanılan "büyük veri"nin ("big data") analizi ve yönetimi ile ilgilidir ve biz bunun büyük optimizasyon teknikleri ile birlikte büyük öğrenme yaklaşımları gerektirdiğine inanıyoruz. Bu proje makine öğrenme alanında bu soruna etkin bir cevap bulmak ve mümkün olan eniyi şekilde öğrenilebilecek bölütlere gerçekten bölebilecek bir sistematik yaklaşım gerçekleştirmek hakkındadır.

Büyük veri depolarını sınıflandırma ve erişim için, anahtar sorular şöyle sıralanabilir: 1) belirli sınıflar üzerinde en yüksek ayırt edicilik elde etmek için bir takım özniteliklerin nasıl seçileceği, 2) bunların en verimli şekilde nasıl birleştirileceği, 3) hangi mesafe metriğinin uygulanacağı, 4) eldeki sınıflandırma problemi için eniyi sınıflandırıcı konfigürasyonunun nasıl bulunacağı, ve 5) çok sayıda sınıflar / öznitelikler varsa, sınıflandırıcının nasıl ölçekleneceği / uyarılacağı ve son olarak, 6) sınıflandırma doğruluğunu maksimize etmek için sınıflandırıcının verimli olarak nasıl eğitileceği. Bu sorular hala yanıtsızdır. İyi bilinen, en gelişmiş sınıflandırıcılar, örneğin Destek Vektör Makineleri (SVM), Rasgele Ormanlar (RF), Yapay Sinir Ağları (ANN), ve ayrıca Evrimsel ANN'ler gibi, bu sorular ile baş edemezler. Bunun sebebi bir tek sınıflandırıcı olarak, ne kadar güçlü ve iyi eğitilmiş olursa olsunlar, sınıfların ve özniteliklerin her ikisinde statik değil, ama oldukça dinamik olduğu bir durumda, belirsiz büyüklükte bir öznitelik kümesi üzerinde büyük miktarda sınıfları etkin ve verimli ayırt edemezler.

Bu projede PoSAR görüntü sınıflandırma için böl ve yönet (divide-and-conquer) filozofisine dayalı bazı gelişmiş teknikler ve sınıflandırma topolojileri kullanılarak "büyük veri"nin gerektirdiği büyük ölçekte çalışmalar yapılmıştır. Proje

çalışmaları kapsamında, büyük çokboyutlu SAR veri depolarında endeksleme, sınıflandırma, arama ve erişim problemini çözmek amacıyla bir sistematik yaklaşım içinde bilinen önceki teknolojinin ilerisinde yeni bir çerçeve geliştirilmiştir. Bu çalışmada polarimetrik SAR karakteristiklerini tanımlamak için düşük seviyeli elektromagnetik SAR öznelikleri, bunların farklı dönüşümleri ve gösterimleri (örneğin hedef ayrıştırma teoremleri), ve diğer görüntü işlemeyle dayalı ikincil öznelıklar (örneğin desen, renk) kullanılmıştır. Ayrımcılık gücünü artırmak amacıyla, bu öznelıklar öncelikle sürekli evrimsel süreçlere tabi tutularak ayrımcılık yeteneklerinin artırılacağı, kendiliğinden organize olan ikili öznelik sentezleyicileri tarafından işlenmektedir. Ayrıca bu projede sınıflandırma doğruluğunu maksimize etmek ve dolayısıyla erişim performansını artırmak amacıyla, ikili sınıflayıcılar toplu ağı (Collective Networks of Binary Classifiers, CNBC) içeren bir genel çerçeve tasarımı kullanılmıştır. Bu yapıda her bir ikili sınıflayıcı ağı (NBC) sadece bir sınıfı veritabanındaki diğer sınıflardan ayırt etmeye çalışan tek bir arazi sınıfına karşılık gelmektedir. Bundan başka, her NBC giriş katmanında herbirisi bir tek öznelik kullanarak ikili sınıflandırma gerçekleştiren değişen sayıda evrimsel ikili sınıflandırıcılar (BC'ler) içermektedir. CNBC topolojisi SAR görüntülerinin sınıflandırılması ve erişimi için önemli olabilecek 1) belirli sınıflar üzerinde en yüksek ayırt edicilik elde etmek için bir takım öznelıkların nasıl seçileceği, 2) bunların en verimli şekilde nasıl birleştirileceği, 3) eldeki sınıflandırma problemi için en iyi sınıflandırıcı konfigürasyonunun nasıl bulunacağı, 4) çok sayıda sınıflar ve öznelıklar varsa, sınıflandırıcının nasıl ölçekleneceği ve uyarlanacağı, ve 5) sınıflandırma doğruluğunu maksimize etmek için sınıflandırıcının verimli olarak nasıl eğitileceği sorularının tamamını çözümlenebilecek bir sınıflandırıcı topluluğu yapısına sahiptir. CNBC bir yüksek boyutta öğrenme problemini, bir tek öznelığe dayalı olarak bir sınıfı diğerlerinden ayırt etmek için özel bir sınıflandırıcı oluşturulması ve atanmasını sağlamak yoluyla bölebilir. Her bir ikili sınıflandırıcının önemli ölçüde daha basit bir görevi (tek bir öznelik ile tek bir sınıf) öğrenmek için eniyilenebilmesi amacıyla sınıf ve öznelik alanlarının her ikisinde bölme gerçekleştirilir. Her evrim seansı eğer varsa mevcut en iyi sınıflandırıcıdan başlayarak ve daha da geliştirilebilir. Ayrıca, her artımlı evrimsel geliştirme (incremental evolution) ile, yeni sınıflar/öznelıklar de eklenebilir, ki bu değişikliğe dinamik olarak uyarlanabilmesi (dynamic adaptation) amacıyla yeni karşılık gelen ağların ve sınıflandırıcıların CNBC içinde oluşumuna işaret eder. Böylece CNBC, sınıflandırma ve erişim doğruluklarını maksimize etmeye çalışırken, kendisini medya içeriğine ve veri rezervinin endeksleme gereksinimlerine dinamik olarak ölçekleyebilecektir. Bu projede kullanılan CNBC



sınıflayıcı ağı, hem farklı sınıflayıcıları (MLP-BP, MLP-PSO, SVM, RF gibi) hem de farklı özniteliklerin ölçeklenebilirliği ve optimal öznitelik seçimi açısından önem taşımaktadır.

Bu projede büyük ölçekli SAR görüntü sınıflandırma problemini çözmek amacıyla CNBC topolojisinden geliştirilmiş kendiliğinden organize NBC bulutları ve bunların girişlerinde sentezlenmiş en iyi ayırt edici öznitelikleri birlikte kullanan bir çerçeve yapı geliştirilmiştir. Bu geliştirilen sistem ile kullanıcı etkileşimi olduğunda her biri artımlı geliştirilebilecek her bir sınıf için NBC bulutları oluşacaktır. Diğer bir deyişle, bir uzman kullanıcı tarafından herhangi bir geri besleme sistemi doğrudan geliştirmek ve sınıflandırma hatalarını azaltmak için kullanılacaktır. Sistem belli bir olgunluğa ulaştıktan sonra, gerektiğinde artımlı geliştirmeler gerçekleştirerek depodaki diğer SAR görüntülerini sınıflandırmak için kullanılmaktadır. Özet olarak, bu önerilen sistem; 1) büyük bir öğrenme probleminin bütün alanlarda (öznitelik, sınıf ve SAR verisi) bölünmesini, 2) gerekli hız ve hesaplama verimliliğine ulaşmak amacıyla ağ/bulut (grid/cloud) bilgi işlem ortamında tam paralelleşmiş bir uygulamayı, ve 3) esnek bir veri ve öznitelik uyarlaması, ölçeklenebilirliği ve büyük ölçekli makine öğrenmede gerçekten eniyilenmiş bir yaklaşımı içermektedir.

Projede gerçekleştirilen çerçeve sistemin özgün değerleri şöyle sıralanabilir: 1) büyük, çok boyutlu SAR görüntü depolarını gerçekten tanımlayabilecek, sınıflandırabilecek ve kısaca arazi ve nesne türlerini yüksek hesaplama verimliliği ile öğrenebilecek sağlam bir sistem, 2) MD PSO algoritması ile optimal öznitelik sentezleyiciler ve kendiliğinden organize olan ikili sınıflandırıcı ağları geliştirilmesi, 3) bu ağları kullanarak büyük bir öğrenme probleminin her bir sınıf için öznitelik ve veri alanlarına göre bölünmesi, 4) önerilen makine öğrenme çerçevesinin SAR görüntü havuzundaki değişikliklere dinamik olarak uyarlanabilmesi için artımlı (incrementally) olarak geliştirilebilmesi, 5) ağ/bulut bilgi işlem ortamında depolanan ve hesaplanabilen ve kendiliğinden organize olan, ölçeklenebilir ve uyarlanabilir bir topoloji olması, ve 6) SAR veri yönetimi ve büyük çokboyutlu SAR görüntü depolarında böl ve yönet (divide & conquer) filozofisine dayalı öğrenme sonucunda makine öğrenme alanında yeni fikirler ve alanlar oluşturabilmesidir. Bu sistem ile mevcut uçak veya uydu tabanlı SAR sensörlerinden araştırma amaçlı sağlanan erişime açık gerçek (benchmark) veriler üzerinde gerçekleştirilen testlerde farklı arazi türlerini yüksek başarı ve verimlilikle öğrenebildiği gösterilmiştir.





## LİTERATÜR ÖZETİ

Literatürdeki metodlar tek bir SAR görüntüsünün sınıflandırması ile sınırlıdır ve bizim en iyi bilgimize göre büyük çokboyutlu SAR depolarının yönetimini yapabilen bir sistem veya çerçeve mevcut değildir. Tek bir görüntü için bile, polarimetrik SAR görüntülerinin doğru sınıflandırılması önemli ve zor bir iştir. Bu son üç on yıl için aktif bir araştırma alanı olmuştur. Çeşitli SAR görüntü türleri bir çok farklı uygulamalarda kullanılmıştır, örneğin AIRSAR [49], [51], ALOS PALSAR [34] kullanarak yeryüzü örtüsü sınıflandırması veya ALOS-PALSAR [36], TerraSAR-X [10] ile petrol sızıntısı gözlemi, ve yine Cosmo SkyMed ve TerraSAR-X ile bina yükseklik çıkartılması [13] gibi. Bu çalışmalar temelde üç gruba ayrılabilir: Birinci grupta veri yapısındaki fiziksel saçılım mekanizmalarına dayalı sınıflandırma teknikleri örneğin Lee ve Pottier [38] ve van Zyl [47] gibi öncü çalışmalar sayılabilir. İkinci grupta verinin istatistiksel karakteristiklerine dayalı bir takım çalışmalar örneğin Lee'nin denetimli [32] ve denetimsiz [31] karmaşık (complex) Wishart sınıflandırıcıları yer almaktadır. Son grupta görüntü işleme metodlarını içeren tekniklerin dahil olduğu daha yeni girişimler bulunmaktadır [42], [50]. Ayrıca, yukarıda bahsedilen teknikleri birleştiren bazı hibrid yaklaşımlar mevcuttur [31], [38]. Genel olarak, bunlar denetimli ve denetimsiz metodlar olarak da ayrılabilir, bunların performansı ve uygunluğu spesifik uygulamaya ve yerel gerçek verinin elverişliliğine bağlıdır. Denetimli metodlar denetimsiz benzerlerine göre çoğunlukla daha yüksek sınıflandırma doğruluğuna ulaşırlar; ancak, güvenilir yerel gerçek veri sağlanması külfetli olabilir. Ayrıca, denetimsiz yaklaşımlar etiketli eğitim örneklerinin yanında etiketsiz test örneklerinin daha verimli kullanılması ve genelleme performansının iyileştirilmesi avantajına sahiptir.

van Zyl [47] SAR görüntüsü içindeki her bir pikselin polarizasyon özelliklerini basit saçılım sınıfları örneğin çift sayıda yansıma, tek sayıda yansıma, ve yayınık yansıma ile karşılaştırarak ilk denetimsiz sınıflandırma algoritmasını önermiştir. Öncü çalışmalar en büyük olabilirlik sınıflandırıcı kullanmış ve kovaryans matrisinin istatistiklerini açıklamak için Wishart dağılımını uygulamışlardır [32], [31]. Cloude'un ayrıştırması [7] polarimetrik verinin direk sınıflandırılması için bir temel oluşturmak amacıyla daha sonra kullanıldığı [6] bir başka önemli girişimdir. Bu alanda en çok tercih edilen hedef algoritmalarından birisi Cloude'un ayrıştırması ile denetimsiz en büyük olabilirlik Wishart sınıflandırıcıyı birleştiren tekrarlamalı bir sınıflandırıcıyı önermiştir [38]. Ancak, bu tekrarlamalı sınıflandırıcı prosedürü gerçek kümeleme işlemi için *K*-means algoritmasına dayanmakta ve bu sebeble lokal minima yakınsaması,

performansın başlangıç durumuna ve parametrelerine bağımlı olması gibi önemli sakıncalara sahiptir. Ayrıca yakın zamanda gerçek (benchmark) Flevoland verisi üzerinde tarım alanlarının sınıflandırılması amaçlı bir çalışma elde edilen istatistiklerin öngörülen Wishart dağılımı ile iyi açıklanamadığını göstermiştir [15]. Bu özel önsel (prior) dağılımı varsayarak tasarlanan sınıflandırıcıların, öznitelik uzayı bu mesafe metriği ile ayrılabilir olmadıkça, performansları en iyi performansın altında kalacaktır. Zamanla, her arazi tipinin doğru sınıflandırılması için yeterli ve güvenilir bir tek öznitelik veya öznitelik kümesinin olmadığı anlaşılmıştır. Literatürde polarimetrik SAR verisinin istatistiksel modellenmesine dayalı geliştirilmiş bir çok kümeleme teknikleri mevcuttur [33], [20], [44]. Maalasef, daha önce polarimetrik SAR görüntülerine uygulanan genel kümeleme metodlarının çoğu bazı ortak sınıflandırma problemleri göstermektedir: 1) global arama ve global eniyiyi bulmak için yetersizlik, 2) optimal küme sayısını bulabilmek için yetersizlik, ve 3) başlangıç durumuna ve parametrelerine bağlı hassasiyet.

Bu tür eksiklikler daha önce bahsedilen mesafe metriği veya istatistiksel dağılım üzerine varsayımlar yapmadığı için odağı Yapay Sinir Ağları (Artificial Neural Networks, ANN) gibi doğrusal olmayan operatörler ile sınıflandırıcılar kullanan eğitilmiş tekniklere çekmiştir. Bunun yerine eğitim safhasında verinin dağılımına göre mesafe metriğini belirlerler, ve bu nedenle yakın zamanda SAR veya yüksek çözünürlüklü görüntülerin sınıflandırılması için önerilen ANN'ye dayalı tekniklerin [3], [8], [46], [11] söz konusu tekniklere göre daha iyi performans göstermesi sürpriz değildir. Ancak, eldeki problem için optimal ANN'yi tasarlamak önemli ve zor bir iştir. Örneğin, hiç veya çok az saklı hücreye (işlem elemanı) sahip ANN karmaşık örüntüleri ayırt edemeyebilir, bunun yerine muhtemelen doğrusal olmayan bir problemin doğrusal kestirimi ile sonuçlanabilir. Bunun aksine, ANN çok fazla hücreye ve katmanlara sahipse, fazla parametreleştirme nedeniyle veri içerisindeki gürültüden ciddi etkilenebilir, bu sonunda kötü genelleme ya da eğitime yol açar. Böyle karmaşık ağlarda, uygun eğitim mümkün olmayabilir ve/veya yüksek zaman alıcı olabilir. Optimal saklı hücre/katman sayıları giriş/çıkış vektörü büyüklüklerine, eğitim ve test veri büyüklüklerine, daha önemlisi problemin karakteristiklerine, örneğin kendi doğrusal olmayan yapısına, dinamik yapısına vb. bağlı olabilir. Tek (statik) sınıflandırıcı kullanılan bu çalışmalarda, genel performans direk olarak sınıflandırıcı seçimine ve parametrelerine bağlıdır. Ayrıca, öznitelik kümesi ve sınıf sayısı, artan karmaşıklık ve iyi bilinen boyutluluk laneti (curse of dimensionality) olgusu sebebiyle daha önce belirtilen eğitim sürecinde uygulanabilirlik problemlerine yol açmamak için, genellikle mümkün olduğu kadar





sınırlı tutulur. Bu amaçla, sadece özneliklerin belirli bir alt kümesini seçerek diğerlerini atmak veya Temel Bileşen Analizi (Principal Component Analysis, PCA) gibi öznelik boyutu düşürücü teknikler uygulamak yaygındır. Ayrıca bir başka önemli nokta bu sistemlerin statik olduğudur, yani, giriş veya çıkış katmanında herhangi bir güncelleme (yeni bir sınıf veya öznelik eklenmesi) sınıflandırıcıyı işe yaramaz hale getirmektedir ve yeni baştan bir sınıflandırıcı kurulumu (ve eğitimini) gerektirmektedir.





### 3. GEREÇ VE YÖNTEM

Bu projede büyük ve dinamik SAR görüntü depolarında etkin yönetim ve erişim için ağ/bulut (grid/cloud) ortamları üzerinde yeni bir dağıtılmış (distributed) sistem çerçevesi geliştirilmiştir. Bu "büyük veri"nin ("big data") tipik bir örneğidir ve bu nedenle, SAR görüntü havuzundaki dinamik değişikliklere göre artımlı (incrementally) geliştirilebilecek, ölçeklenebilir, eniyilenmiş ve interaktif bir makine öğrenme çerçevesi kullanılmaktadır. Bu çerçeve içinde kullanılan polarimetrik SAR öznitelik vektörleri ile yeni paradigma ve en son teknikler önerilen sistemin yapısal ve topolojik ayrıntılarına girmeden önce ilk olarak aşağıda açıklanacaktır.

#### 3.1 SAR Öznitelik Çıkartma ve FeX Kütüphanesi Oluşturulması

Polarimetrik SAR verileri ikinci derecede polarimetrik gösterimler olan zaman ortalama kovaryans  $\langle [C] \rangle$  ve tutarlılık  $\langle [T] \rangle$  matrisleri şeklinde PolSARpro yazılımı [1] kullanılarak okunabilmektedir ve daha sonra aynı yazılım araçları kullanılarak sınıflandırma amacıyla kullanılacak olan elektromanyetik (EM) tabanlı öznitelikler ve çeşitli ayrışmalar (decomposition) elde edilebilmektedir. Bu kısımda öncelikle projedeki deneysel çalışmalarımızda ve değerlendirmelerimizde kullanılan EM öznitelikleri, ayrışmalar, doku, renk ve diğer görüntü işleme öznitelikleri hakkında bilgiler verilerek daha sonra bu çıkartılan özniteliklerin önerilen çerçeve sistem üzerinden çeşitli deneylerde kullanılmak üzere gruplandırılarak çok boyutlu öznitelik vektörlerinin oluşturulması anlatılmaktadır. Radar sistemlerinden veri alınırken, hedef yüzeyden gelen çoklu yansıma ve gürültünün etkileri çoklu (multivariate) istatistiksel tanımlama gerektirir. Bu yüzden ortalama ya da dominant yansımayı tanımlayacak bir yol bulmak, öznitelik elde etmek ya da sınıflandırma gibi görevleri gerçekleştirmek için faydalıdır.

Polarimetrik SAR verisinden EM tabanlı özniteliklerin çıkartılması süreci genelde iki kategori altında incelenebilir: Birinci grupta Polarimetrik SAR verisinden direkt olarak çıkartılan öznitelikler (saçılım katsayıları) ve bu özniteliklerin kovaryans ve tutarlılık (coherency) matrislerinin elde edilebileceği saçılım matrisi (scattering matrix,  $[S]$ ) gibi dönüşümleri bulunmaktadır. İkinci grup Polarimetrik Hedef Ayrıştırma (Polarimetric Target Decomposition) teoremleriyle oluşturulan öznitelikleri kapsamaktadır. Bu teoremler genellikle kovaryans ve tutarlılık matrislerini temel alır ve elde edilen ortalama saçılımı bağımsız elemanların toplamları şeklinde tanımlarlar ve Polarimetrik SAR uygulamalarında kullanılırlar.

Polarimetrik SAR sistemleri çoğunlukla fiziksel özellikleri hakkında sonuç çıkarmak amacıyla çalışılan hedef tarafından üretilen karmaşık saçılım matrisini,  $[S]$ , ölçmektedir. Kısaca  $[S]$  çalışılan hedefle olan etkileşim ile oluşan bilgiyi taşıyor ve verici ve alıcı için doğrusal yatay ve dikey polarizasyonlar varsayarak aşağıdaki şekilde ifade edilebilir,

$$\begin{bmatrix} E_H^r \\ E_V^r \end{bmatrix} = [S] \begin{bmatrix} E_H^t \\ E_V^t \end{bmatrix} = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix} \begin{bmatrix} E_H^t \\ E_V^t \end{bmatrix} \quad (1)$$

Monostatik sistem konfigürasyonlarında (örneğin uçak sistemlerindeki gibi verici ve alıcı için tek bir anten kullanılması durumunda) karşılıklılık (reciprocity) teoremi uygulanır,  $S_{hv} = S_{vh}$ .

$[S]$  matrisinin elemanları genel olarak gelen ve saçılan dalgaların polarizasyonlarına karşılık gelen genlik ve faz bilgisinden oluşur. Polarimetrik SAR verisinin saçılım matrisinden ikinci derecede polarimetrik gösterimler olan zaman ortalama kovaryans  $\langle [C] \rangle$  ve tutarlılık  $\langle [T] \rangle$  matrisleri elde edilir.  $\langle [C] \rangle$  ve  $\langle [T] \rangle$  matrisleri dağıtık saçıcıları daha iyi karakterize edebilmesi sebebiyle veri elde edilen saçılım sürecinden fiziksel bilgi çıkartmada yaygın olarak kullanılmaktadır. Yüzeyden veya hacimden rasgele saçılım ve benek (speckle) gürültüsünün varlığı nedeniyle, polarimetrik SAR verisi sıklıkla  $n$  komşu pikselin ortalaması alınarak çoklu görünümlü (multi-look) olarak işlenir. Piksel  $i$  için Pauli tabanlı saçılım matrisi kullanılarak,  $k_i = [S_{hh} + S_{vv}, S_{hh} - S_{vv}, 2S_{hv}]^T / \sqrt{2}$ , çoklu görünümlü tutarlılık matrisi aşağıdaki gibi yazılabilir,

$$\langle [T] \rangle = \frac{1}{n} \sum_{i=1}^n k_i k_i^{*T} \quad (2)$$

Benzer şekilde  $k$  vektörü yerine Lexicographic saçılım vektörü  $\Omega$  kullanılarak, Kovaryans matrisi  $\langle [C] \rangle = \langle \Omega \cdot \Omega^{*T} \rangle$  şeklinde ifade edilebilir.  $\langle [T] \rangle$  ve  $\langle [C] \rangle$  3x3 Hermityen kesin artı (Hermitian positive definite) matrislerdir, ve bir doğrusal dönüşüm ile biri diğerine dönüştürebildiği için, her ikisi de hedefin aynı polarimetrik bilgisine, saçılım genlikleri, açıları ve korrelasyonları, sahiptir.

İlgilenilen hedefler üzerinde çalışırken, yüzey ve hacim saçılımların karışımından doğan etkileri karşılamak için çoklu istatistiksel tanımlama gerekmektedir. Bu sebeple ortalama (ya da dominant) yansımaların bulunması sınıflandırma için büyük avantaj getirmektedir. Hedef ayrıştırılmaları (Target decompositions) daha

iyi bir fiziksel tanımlama için ortalama saçılımları bağımsız elemanların toplamı şeklinde bulmayı hedefler. Günümüze kadar daha doğru bilgi çıkartmak ve arazi sınıflandırması yapabilmek amacıyla bir çok farklı polarimetrik hedef ayrıştırmaları geliştirilmiş ve halen yeni ayrıştırmalar ve olanların iyileştirilmeleri üzerine çalışmalar devam etmektedir. Polarimetrik hedef ayrıştırmaları tutarlı (coherent) ve tutarsız (incoherent) hedef ayrıştırmaları olarak iki teoriye ayrılabilir. Tutarlı hedef ayrıştırmaları teorisi, tüm polarimetrik bilgiyi tutan saçılım matrisinin içeriğindeki polarize saçılmış dalgaları bütünüyle karakterize eder. Ancak genellikle saçılım dalgası kısmen polarize edilmiştir ve tutarsız saçılımlara sahip doğal bir hedef yüzeyinden geo-fiziksel parametreleri elde etmek daha çok ilgi çekmektedir. Tutarsız hedef ayrıştırma teorilerinin geliştirilmesiyle hedef ortalama matrisinin tekli saçılım matrislerinin toplamı olarak tanımlanması mümkün olarak, böylece altta yatan saçılımların daha iyi yorumlanabilmesi ve radar ölçümlerinden geo-fiziksel parametrelerin daha kolay yollarla çıkartılabilmesi sağlanmaktadır.

### 3.1.1 Tutarlı (Coherent) Hedef Ayrıştırmaları

Tutarlı ayrıştırma teoremleri radar tarafından ölçülen  $[S]$  saçılım matrisini tutarlı (coherent) saçıcıların saçılım tepkilerinin birleşimi cinsinden ifade etmeyi amaçlamaktadır. Burada  $[S]$  tüm geri saçılım bilgisini içerir ve bu teoremler bütün saçılım bilgisini genel saçılım mekanizmalarının karışımı şeklinde ifade ederler:

$$[S] = \sum_{i=1}^k \alpha_i \cdot [S]_i \quad (3)$$

Burada temel hedef tüm geri saçılım bilgisini standart hedefler (düzlem, dihedral, helix gibi) cinsinden ayrıştırmak ve karşılıklılık ve simetri gibi özelliklere sahip bileşenlerini çıkartmaktır. Tutarlı (coherent) hedefleri analiz etmenin bir yolu  $[S]$  matrisini aşağıdaki gibi Pauli tabanı içinde ifade eden Pauli ayrıştırmasıdır [7],

$$S = \begin{bmatrix} S_{hh} & S_{hv} \\ S_{vh} & S_{vv} \end{bmatrix} = \alpha[S]_a + \beta[S]_b + \gamma[S]_c \quad \text{burada} \quad (4)$$

$$\left\{ [S]_a = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}, [S]_b = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}, [S]_c = \frac{1}{\sqrt{2}} \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \right\}$$



ve  $\alpha = (S_{hh} + S_{vv})/\sqrt{2}$ ,  $\beta = (S_{hh} - S_{vv})/\sqrt{2}$ ,  $\gamma = \sqrt{2}S_{hv}$ . Bundan dolayı Pauli ayrıştırması vasıtasıyla,  $[S]$  matrisi içerisindeki bütün polarimetrik bilgi, bir veya tek sıçramalı saçılım, iki veya çift sıçramalı saçılım, ve hacim saçılımı yoluyla dikey polarizasyon gibi farklı çeşit saçıcılar tarafından dağıtılan gücü belirleyen  $|\alpha|^2$ ,  $|\beta|^2$  ve  $|\gamma|^2$  yeğliliklerinin birleştirilmesi ile temsil edilebilir.

Krogager ayrıştırması [29] ise herhangi bir karmaşık, simetrik radar hedef saçılım matrisinin üç fiziksel elemana, bir küre, yönlü iki düzlem (diplane) ve sağ veya sol sarmal heliks, ayrıştırılarak yorumlanabileceği gerçeğinden faydalanır. Bir doğrusal dik bazlı (yatay, düşey) saçılım matrisi için Krogager açılımı formülü aşağıdaki gibidir:

$$[S_{(H,V)}] = e^{j\varphi} (e^{jq_s} k_s [S]_s + k_d [S]_d + k_h [S]_h) \quad (5)$$

$k_s$ ,  $k_d$  ve  $k_h$  küre, yönlü iki düzlem ve heliks parçalarının ağırlıklarına karşılık gelir. Temel hedef farklı saçılım karakteristiklerini geliş (incidence) açısından bağımsız çözümleyebilmektir.

Diğer tutarlı hedef ayrıştırılmaları, örneğin Cameron ayrıştırması, hakkında detaylı bilgi [7]'de bulunabilir.

### 3.1.2 Tutarsız (Incoherent) Hedef Ayrıştırılmaları

Alternatif olarak tutarsız (incoherent) hedef ayrıştırma metodları dağıtık saçıcıları karakterize etmek için polarimetrik SAR verisinin ikinci derece polarimetrik açılımlarını (örneğin kovaryans matrisi veya tutarlılık matrisi) kullanmaktadır. Bu algoritmalar çoğunlukla  $\langle [T] \rangle$  veya  $\langle [C] \rangle$  matrisinin özdeğer ve özvektör analizine dayalı cebirsel yaklaşımları kullanarak  $[S]$  matrisini tek sıçramalı, çift sıçramalı, ve hacim saçılımı gibi genel saçılım mekanizmalarına ayrıştırır.

Huynen ayrıştırması [17] dağıtık saçılmaların analizi üzerine ayrıştırma teorilerini düşünen ilk uygulamadır.  $\langle [T] \rangle$  matrisinin parametrizasyonunda üzerinde çalışılan hedefin fiziksel özelliklerinin yorumlanmasında dokuz bağımsız parametre bulunmaktadır. A0, B0+B, B0-B dağıtık hedeflerin yüzey, çift sıçrama ve hacim saçılımlarını temsil etmektedirler, diğer türlü saçıcıların pürüzsüz, konveks gibi olağan kısımlarından saçılmış toplam gücü, düz (pure) hedefler için sırasıyla toplam simetrik ve asimetric depolarize edilmiş güçle bağlantılıdır.

Cloude-Pottier ayrıştırması [7] polarimetrik tutarlılık matrisi,  $\langle [T] \rangle$ 'nin özeleştirisine dayalıdır:

$$\langle [T] \rangle = \lambda_1 e_1 e_1^{*T} + \lambda_2 e_2 e_2^{*T} + \lambda_3 e_3 e_3^{*T} \quad (6)$$

burada  $\lambda_1 > \lambda_2 > \lambda_3 \geq 0$  gerçek özdeğerler ve karşılık gelen ortonormal özvektörler  $e_i$  (üç saçılım mekanizmasını temsil eden),

$$e_i = e^{i\phi_i} \left[ \cos \alpha_i, \sin \alpha_i \cos \beta_i e^{i\delta_i}, \sin \alpha_i \sin \beta_i e^{i\gamma_i} \right]^T. \quad (7)$$

Cloude ve Pottier bir ortamın saçılım karakteristikleri ile ilgili fiziksel bilgiyi analiz etmek için entropi  $H$ , ortalama dört açı kümesi  $\bar{\alpha}$ ,  $\bar{\beta}$ ,  $\bar{\delta}$ , ve  $\bar{\gamma}$ , ve anisotropiyi  $A$  aşağıdaki gibi tanımlar:

$$H = - \sum_{i=1}^3 p_i \log_3 p_i \quad \text{burada} \quad p_i = \frac{\lambda_i}{\sum_{i=1}^3 \lambda_i}, \quad (8)$$

$$\bar{\alpha} = \sum_{i=1}^3 p_i \alpha_i, \quad \bar{\beta} = \sum_{i=1}^3 p_i \beta_i, \quad (9)$$

$$\bar{\delta} = \sum_{i=1}^3 p_i \delta_i, \quad \bar{\gamma} = \sum_{i=1}^3 p_i \gamma_i$$

$$A = \frac{p_2 - p_3}{p_2 + p_3}. \quad (10)$$

Çoklu görünümlü tutarlılık matrisi için, entropi,  $0 \leq H \leq 1$ , yönden bağımsız saçılım ( $H = 0$ ) ve tam rasgele saçılım ( $H = 1$ ) arasındaki saçılım ortamının rasgeleliğini temsil etmektedir, oysa ortalama alfa açısı ( $\bar{\alpha}$ ) tek sıçramalı (veya yüzey) saçılımdan ( $\bar{\alpha} \approx 0$ ) dipol (veya hacim) saçılımına ( $\bar{\alpha} \approx \pi/4$ ) ve çift sıçramalı saçılıma ( $\bar{\alpha} \approx \pi/2$ ) hedefin ortalama saçılım mekanizmaları ile ilgili olabilir. Hedef ayrıştırmasının taban değişmezliği nedeniyle,  $H$  ve  $\bar{\alpha}$  dönmeye karşı değişmezdir (rotational invariant) ve bundan dolayı radar görüş mesafesine göre hedefin yönüne bağlı değildir. Ayrıca, hedefin toplam geri saçılmış gücü ( $Span$ ) aşağıdaki gibi belirlenebilir,

$$Span = \sum_{i=1}^3 \lambda_i. \quad (11)$$

Yukarıda bahsedilen tutarsız hedef ayrıştırma metodu ile hesaplanabilen Entropi ( $H$ ), ortalama alfa açısı kestirimi ( $\bar{\alpha}$ ), ve  $Span$  bir çok polarimetrik SAR hedef

sınıflandırma tasarımlarında saçıcının polarimetrik öznelikleri olarak sıklıkla kullanılmıştır [31].

Touzi ayrıştırması [43], Cloude-Pottier ayrıştırmasına benzer ve o da  $\langle [T] \rangle$ 'nin tutarsız (incoherent) karakteristik ayrışması tabanlıdır. Karşılıklı (reciprocal) hedef için,  $\langle [T] \rangle$  matrisinin her biri  $\lambda_i$  ağırlığında üç farklı tekil saçıcıları temsil eden üç tutarlılık matrisi  $[T]_i$ 'nin tutarsız (incoherent) toplamları olarak gösterimine izin vermektedir. Cloude-Pottier ayrıştırması ile karşılaştırıldığında, Touzi ayrıştırması benzersiz hedef karakteristikleri bakımından Tutarlılık özdeğer vektörlerinin parametrizasyonu için dönmeye karşı değişmez tutarlı saçılım modeli kullanmasıyla farklılık gösterir.

van Zyl [47] ilk defa,  $\langle [C] \rangle$  matrisinin özdeğer / özvektör analizini monostatik durumdaki simetrik doğal arazileri tanımlamak için düşünmüştür:

$$\langle [C] \rangle = \sum_{i=1}^3 \lambda_i u_i \cdot u_i^{*T} = [C]_s + [C]_d + [C]_v \quad (12)$$

burada  $\lambda$  ve  $u$  sırasıyla özdeğerler ve özvektörlerdir.

Yukarıdaki ifade tekli ve ikili sekme saçılmaları olarak yorumlanabilen, ilk iki özvektörün eşdeğer saçılım matrislerini ve üçüncü özvektörün ise hacim saçılmalarını temsil ettiği üç elemanlı bir saçılım modeli olarak düşünülebilir. Daha sonra, bu özdeğer analizine dayalı, Kim ve van Zyl, PolSAR verisinden (orman) biyokütle tahminini, bir diğer adıyla Radar Bitki Örtüsü İndeksini (Radar Vegetation Index - RVI) ortaya koymuşlardır:

$$RVI = \left( \frac{4mn(\lambda_1, \lambda_2, \lambda_3)}{\lambda_1 + \lambda_2 + \lambda_3} \right) = \left( \frac{8\sigma_{hv}}{\sigma_{hh} + \sigma_{vv} + 2\sigma_{hv}} \right) \quad (13)$$

burada sigmalar çarpaz- ve aynı-polarizasyon radar saçılım kesit alanlarıdır (radar scattering cross section).

van Zyl'in  $\langle [C] \rangle$  matrisini ayrıştırması, arkasından gelen modele dayalı Freeman [12] ve Yamaguchi [48] ayrıştırmaları için bir başlangıç noktası olmuştur. Freeman ayrıştırması Kovaryans matrisini şu üç basit saçılım mekanizmasının birleşimi olarak ifade etmektedir: rastgele yönlü dipoller bulutundan hacim saçılımı, farklı dielektrik sabiti olan iki dik yüzeyden çift-sekmeli saçılım, ve orta pürüzlü bir yüzeyden Bragg (tek-sekmeli) saçılım.



Freeman ayrıştırmasında  $\langle [C] \rangle$  matrisi denklem (12) ile benzer şekilde ifade edilebilir ve tek-sekmeli ( $P_s$ ), çift-sekmeli ( $P_d$ ), ve hacim saçılımları ( $P_v$ ) için saçılım güçleri şöyle bulunur:

$$P_s = f_s(1+|\beta|^2), \quad P_d = f_d(1+|\alpha|^2) \quad \text{and} \quad P_v = \frac{8f_v}{3}, \quad (14)$$

burada  $f_s$ ,  $f_d$  ve  $f_v$   $\langle [C] \rangle$  matrisine tek-sekmeli, çift-sekmeli ve hacim saçılımları ile ilgili katkıları,  $\alpha$  ve  $\beta$  sırasıyla yüzey ve çift-sekmeli saçılıma karşılık gelmektedir. Bu bileşik saçılım modeli genellikle farklı doğal yüzey çeşitlerinden polarimetrik geri saçılımı diğer doğal olarak oluşan (mesela ormanlık yeşil alan) saçıcılardan ayırt etmektir.

Yamaguchi,  $\langle [C] \rangle$  matrisi için Freeman'ın üç elemanlı ayrıştırma metodunu genişleten dört elemanlı saçılım modelini ortaya koymuş, genellikle karmaşık geometrik saçılım yapılarında ortaya çıkan sarmal saçılım terimini eklemiştir. Bu terim genellikle insanlar tarafından yapılmış olan kentsel bölgelerle ilişkilidir. Saçılım güçleri  $P_s$  ve  $P_d$ 'nin formülleri, Freeman ayrıştırmasındakinin aynısıdır.  $P_v$  ise aşağıdaki gibi modifiye edilmiş ve  $P_c$  aşağıdaki gibi tanımlanmıştır:

$$P_c = 2|\text{Im}\langle S_{HV}^*(S_{HH} - S_{VV}) \rangle|, \quad P_v = \frac{15}{2} \left[ \langle |S_{HV}|^2 \rangle - \frac{f_c}{4} \right]. \quad (15)$$

Diğer bütün modele dayalı ayrıştırmalarda olduğu gibi, büyük çarpaz-polarizasyon bileşeninden dolayı hacim saçılımının fazla tahmin edilmesi ile ilgili bir dezavantaj mevcuttur. Yamaguchi'nin önerdiği genişletilmiş hacim saçılımı modeli ile yeşil alanların ve yönelimli binaların ayırt edilmesi belli oranda mümkün olmaktadır.

Burada bahsedilmeyen diğer mevcut hedef ayrıştırmaları ile ilgili ayrıntılı bilgiler [7]'de bulunabilir.

### 3.1.3 Doku (Texture) ve Renk Öznitelikleri

Yukarıda anlatılan saçılım (scattering) katsayıları ve hedef ayrıştırma bileşenleri gibi geleneksel Polarimetrik SAR öznitelikleri hedeflerin fiziksel, geometrik ve saçılım özelliklerine dayalıdır. Genel olarak bu tip SAR öznitelikleri yalnızca piksel bazlı seviyede bir tanımlama sağlamaktadır ve bu arazi yüzeyindeki değişiklikler (örneğin farklı orman çeşitleri veya insan yapımı alanlar) sebebiyle benzer sınıf çeşitleri için ayırt ediciliği sınırlayabilmektedir. Bu çalışmada piksel tabanlı elektromanyetik ile ilgili özniteliklere ilave olarak, doku ve renkten oluşan

saf görüntü işleme tabanlı öznelikler çıkartılarak özellikle gürültülü pikseller için uzamsal bilginin efektif kullanılması ve sınıflandırma performansının artırılması amaçlanmaktadır.

Gri seviye tekrarlanma matrisi (Gray Level Co-occurrence Matrix, GLCM) Haralick [14] tarafından ikinci derece istatistiklerden doku tanımlayıcı olarak belirlenmiştir ve ilgilenilen alanda (region of interest) piksellerin yön ve açı ilişkilerini iki farklı gri seviyesinin ne sıklıkla bir kesin yer değişme dolayısıyla birbirinden ayırdığını tanımlayarak verir. GLCM öznelikleri *enerji*, *entropi*, *kontrast*, *homojenlik* şeklinde hesaplanabilmekte ve tüm bunlar doku özelliklerini tarif edebilmektedir. GLCM özneliklerinin doku tanımlayabilme gücü seçilen uzaklık vektörleri kombinasyonuna bağlı olup çok azı oldukça zayıf tanımlama sağlarken çok fazlası öznelik çıkartma hesaplamalarının maliyetini artırmaktadır.

Dereceli tekrarlanma matrisi (The Ordinal Co-occurrence Matrix, OCM) yaklaşımı GLCM ve dereceli tanımlayıcıların (doku tanımlama için dereceli metodlar) birleşimidir. Ancak OCM ile GLCM'yi karşılaştırdığımızda ortaya çıkan önemli fark, gri seviye değerlerinden çok pikseller arası dereceli ilişkiler üzerine bir uygulama olmasıdır. OCM, SAR görüntüleri üzerinde GLCM kadar yaygın bir şekilde kullanılmamıştır. Doku sınıflandırma da özellikle insan yapımı alanlarda bulunan kalın dokular ve düzensiz örüntüler için OCM'nin GLCM'den daha iyi performansa sahip olduğu gösterilmiştir [37].

Gabor dalgacıkları popüler ve güçlü bir sinyal işleme doku tanımlayıcısıdır, çoklu çözünürlük (multi-resolution) yaklaşımı sunar. Burada ana fikir, görüntüdeki bölgeyi bir filtre bankasıyla farklı boyut ve oryantasyonlarda işlemektir, filtre işlemi uzamsal ya da frekans uzayında yapılabilir. Bir görüntü bölgesi Gabor filtresi ile filtrelendiğinde bu Gabor dalgacık dönüşümüyle sonuçlanır ve farklı frekanslarda ve farklı oryantasyonlarda doku bilgileri elde edilir. Gabor dalgacık dönüşümü aşağıdaki gibi formülize edilebilir:

$$W_{mn}(x, y) = \int I(x_1, y_1) g_{mn}^*(x - x_1, y - y_1) dx_1 dy_1. \quad (16)$$

Her bir derece ve oryantasyon için  $|W_{mn}|$  çıktı olarak hesaplanır ve birinci ve ikinci derece momentleri doku öznelikleri olarak hesaplanır.

Çok seviyeli lokal örüntü histogramı (Multilevel Local Pattern Histogram), diğer doku öznitelikleri ile karşılaştırdığımızda özellikle SAR görüntülerinin doku özelliklerini ortaya çıkarmak üzerine geliştirilmiş bir tekniktir. Hareketli bir pencere içerisindeki aydınlık, karanlık ve homojen örüntülerin dağılımlarını tarif eder. Lokal bilgi pencerenin piksel komşuluğu içerisinde yakalanır ve bir eşik değeri uygulanarak orta piksel değeri ve onun çevresine göre fazla, az ve eşit yoğunlukta (intensity) olan pikseller saptar. Bunun sonucunda üç ikili (binary) matris oluşur. Bu matrisler ayrı ayrı alt histogramlara ön plan nesnelerin boyutlarına göre sayılmasıyla işlenir. Bu üç alt histogram bağlanarak lokal örüntü histogramı (Local Pattern Histogram - LPH) elde edilir. Orjinal LPH'nin boyutu tek bir alt histogramın boyutuna,  $w^2$ , o da seçilen pencere büyüklüğüne ( $w$ ) bağlıdır. LPH, belirli aralıklarla değişen farklı eşik değerleriyle çok sefer hesaplandığında çok seviyeli lokal örüntü histogramı (MLPH) elde edilmiş olur.

Lokal ikili örüntü (Local Binary Pattern, LBP), doku / görüntü sınıflandırmasında kullanılan bir diğer popüler tanımlayıcıdır. LBP,  $n \times n$  piksel çıkartılan, rotasyona göre değişmeyen bir doku özniteliğidir. LBP'nin avantajlarından bir tanesi, doku sınıflandırması için güçlü bir betimleme sağlayan basit tasarımıdır. Kenar histogram tanımlayıcı (Edge Histogram Descriptor, EHD) genellikle sınıflandırma ve görüntü erişiminde kullanılan bir içerik tanımlayıcıdır. Adından da anlaşıldığı gibi kenar tabanlı bir doku özniteliğidir ve MPEG-7 tanımlayıcı ailesindedir. EHD, dördü yönlü ve biri yönsüz olmak üzere beş farklı tipteki kenarın uzaysal dağılımını temsil eder. Kenarlar  $2 \times 2$  piksel bloklarında basit kenar bulucular kullanılarak dikey, yatay, 45 derece köşegen, 135 derece köşegen ve yönbağımsız olarak beş kategoride gruplanabilir. Bu piksel gruplarından kenar kuvvetleri belli bir eşik değerini aşanlar histogram hesaplamasında kullanılırlar. Her bir lokal histogram beş "bin"den oluşur ve her bir "bin" birer kategoriye karşılık gelir. Bu lokal histogramların birleştirilmesiyle tüm görüntünün kenar tipi histogramı oluşturulmuş olur.

Doku özniteliklerinin SAR görüntü sınıflandırması için değerli bir kaynak olduğu ispatlanmış ve daha önceki deney sonuçları diğer SAR öznitelikleri ile birleştirildiğinde daha iyi bir sınıflandırma ve ayırt edicilik performansı elde edilebildiğini göstermiştir. Doku özniteliklerine benzer şekilde renk özniteliklerinin de Polarimetrik SAR görüntü sınıflandırmasında bir iyileştirme sağlaması beklenir. Nitekim içeriğe dayalı (content-based) görüntü erişimi ve nesne tanıma gibi alanlarda doku ve renk öznitelikleri birlikte sıklıkla kullanılmaktadır. Bu çalışmada dört farklı renk özniteliği kullanılması planlanmıştır: renk histogramı,

dominant renk tanımlayıcı, MPEG-7 renk yapısı tanımlayıcı ve MPEG-7 renk yerleşim (layout) tanımlayıcı.

Proje çalışmalarımızda kullandığımız ve yukarıda açıkladığımız polarimetrik SAR özneliklerinin gruplandırılması Tablo 1'de verilmiştir. Raporun deneysel bölümlerinde bu öznelik vektörlerinin farklı kombinasyonlarda bir arada kullanılmasıyla yapılan deneyler ve dolayısıyla öznelik vektörlerinin sınıflandırma başarısına ne kadar etki ettikleri incelenecektir.

Tablo 1: Polarimetrik SAR öznelikleri ve oluşturulan temel öznelik vektörleri listesi

Öznelik vektörü	Öznelik	Boyut
FV1	$\langle [T] \rangle$ ve $\langle [C] \rangle$ matris elemanları	12
FV2	H/A/Alfa ve özdeğer ayrıştırması parametreleri, RVI	11
FV3	Korelasyon katsayıları	6
FV4	Pauli, Kroger, Touzi ayrıştırma elemanları	10
FV5	Freeman ve Huynen ayrıştırma elemanları	6
FV6	Van Zyl ve Yamaguchi ayrıştırma elemanları	6
FV7	Doku öznelikleri	81
FV8	Renk öznelikleri	60

### 3.2 İkili Sınıflayıcılar Toplu Ağı (Collective Network of Binary Classifiers, CNBC)

Büyük veri depolarını sınıflandırma ve erişim için, anahtar sorular şöyle sıralanabilir: 1) belirli sınıflar üzerinde en yüksek ayırt edicilik elde etmek için bir takım özneliklerin nasıl seçileceği, 2) bunların en verimli şekilde nasıl birleştirileceği, 3) hangi mesafe metriğinin uygulanacağı, 4) eldeki sınıflandırma problemi için eniyi sınıflandırıcı konfigürasyonunun nasıl bulunacağı, ve 5) çok sayıda sınıflar / öznelikler varsa, sınıflandırıcının nasıl ölçekleneceği / uyarlanacağı ve son olarak, 6) sınıflandırma doğruluğunu maksimize etmek için sınıflandırıcının verimli olarak nasıl eğitileceği. Bu sorular hala yanıtsızdır. İyi bilinen, en gelişmiş sınıflandırıcılar, örneğin Destek Vektör Makineleri (SVM), Rasgele Ormanlar (RF), Yapay Sinir Ağları (ANN), ve ayrıca Evrimsel ANN'ler gibi, bu sorular ile baş edemezler. Bunun sebebi bir tek sınıflandırıcı olarak, ne kadar güçlü ve iyi eğitilmiş olursa olsunlar, sınıfların ve özneliklerin her ikisinde statik değil, ama oldukça dinamik olduğu bir durumda, belirsiz

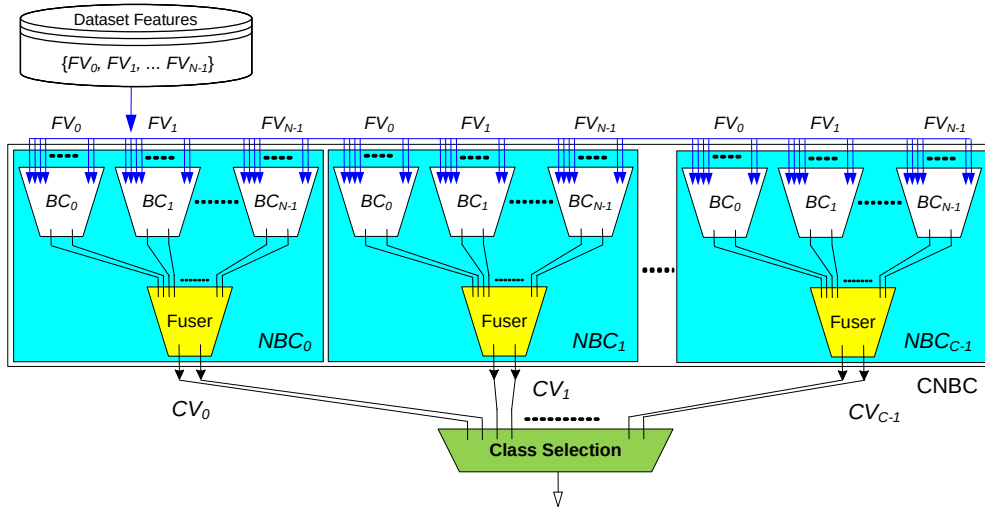


büyükölükte bir öznitelik kümesi üzerinde büyük miktarda sınıfları etkin ve verimli ayırt edemezler.

Bu nedenle, bu problemleri çözmek ve bunun sonucu sınıflandırma doğruluğunu maksimize etmek ve dolayısıyla erişim performansını artırmak amacıyla, biz ikili sınıflayıcılar toplu ağı (Collective Networks of Binary Classifiers, CNBC) içeren bir genel çerçeve tasarımı geliştirdik. Her bir ikili sınıflayıcı ağı (NBC) sadece bir sınıfı veritabanındaki diğer sınıflardan ayırt etmeye çalışan tek bir arazi sınıfına karşılık gelmektedir. Bundan başka, her NBC giriş katmanında herbirisi bir tek öznitelik kullanarak ikili sınıflandırma gerçekleştiren değişen sayıda evrimsel ikili sınıflandırıcılar (BC'ler) içermektedir. Belirli bir özniteliğe karşılık gelen her öznitelik vektörü her bir NBC içinde sadece kendine karşılık gelen ikili sınıflandırıcıya bağlanır. Bu nedenle, yeni bir öznitelik çıkartıldığında, kendisine karşılık gelen ikili sınıflandırıcı (BC) oluşturulur ve (mevcut yersel doğruluk verisi (Ground Truth Data, GTD) kullanılarak) geliştirilir ve her NBC'nin içine eklenir, bu sırada diğer BC'ler olduğu gibi devam etmektedir. Diğer taraftan, mevcut bir öznitelik kaldırıldığında, CNBC içinde her bir NBC'den karşılık gelen BC basitçe kaldırılır. Böylece, değişen sayıda özniteliklere göre ölçeklenebilirlik sağlanır ve genel sistem yeniden oluşturma ve geliştirme gerektirmeden değişikliklere uyarlanabilir. Her bir NBC çıkış katmanında bütün BC'lerin çıkışlarını toplayan ve birleştiren ve NBC'nin ilgili sınıfına ait bir ögenin her öznitelik vektörünün ilişkili düzeyini gösteren tek bir ikili çıktı üreten birleştirici (fuser) BC içerir. Bundan başka, CNBC ayrıca belirsiz sayıda sınıflara göre ölçeklenebilir, çünkü yeni bir sınıf tanımlandığında, karşılık gelen yeni bir NBC, bu yeni sınıfı kendi ilişkili sınıflarından ayırt edebildikleri sürece, diğer NBC'ler için bir değişikliğe gerek kalmadan sadece bu sınıf için basitçe oluşturulabilir (ve geliştirilebilir). Bu genel sistemin değişen sayıda sınıflara dinamik olarak uyarlanabilmesini sağlar.

CNBC topolojisi SAR görüntülerinin sınıflandırılması ve erişimi için önemli olabilecek 1) belirli sınıflar üzerinde en yüksek ayırt edicilik elde etmek için bir takım özniteliklerin nasıl seçileceği, 2) bunların en verimli şekilde nasıl birleştirileceği, 3) eldeki sınıflandırma problemi için en iyi sınıflandırıcı konfigürasyonunun nasıl bulunacağı, 4) çok sayıda sınıflar ve öznitelikler varsa, sınıflandırıcının nasıl ölçekleneceği ve uyarlanacağı, ve 5) sınıflandırma doğruluğunu maksimize etmek için sınıflandırıcının verimli olarak nasıl eğitileceği sorularının tamamını çözümlenebilecek bir sınıflandırıcı topluluğu yapısına sahiptir.

Bu gerçekten, büyük ve dinamik SAR görüntü depoları üzerinde böl ve yönet (divide & conquer) paradigmasını gerçekleştirebilen ilk sistemlerden birisidir, bu konuda daha fazla bilgi [22] ve [25]'de bulunabilir. Şekil 9'da temel topolojisi gösterildiği gibi, CNBC bir yüksek boyutta öğrenme problemini, bir tek özneliğe dayalı olarak bir sınıfı diğerlerinden ayırt etmek için özel bir sınıflandırıcı oluşturulması ve atanmasını sağlamak yoluyla bölebilir. Her bir ikili sınıflandırıcının önemli ölçüde daha basit bir görevi (tek bir öznelik ile tek bir sınıf) öğrenmek için eniyilenebilmesi amacıyla sınıf ve öznelik alanlarının her ikisinde bölme gerçekleştirilir. Her evrim seansı eğer varsa mevcut en iyi sınıflandırıcıdan başlayarak ve daha da geliştirilebilir. Ayrıca, her artımlı evrimsel geliştirme (incremental evolution) ile, yeni sınıflar/öznelikler de eklenebilir, ki bu değişikliğe dinamik olarak uyarlanabilmesi (dynamic adaptation) amacıyla yeni karşılık gelen ağların ve sınıflandırıcıların CNBC içinde oluşumuna işaret eder. Böylece CNBC, sınıflandırma ve erişim doğruluklarını maksimize etmeye çalışırken, kendisini medya içeriğine ve veri rezervinin indeksleme gereksinimlerine dinamik olarak ölçekleyebilecektir. CNBC yakın zaman önce tek gerçek (benchmark) SAR görüntülerinin sınıflandırılması için başarıyla kullanılmıştır Hata: Başvuru kaynağı bulunamadı ve literatürdeki en gelişmiş sınıflandırıcılar ile karşılaştırıldığında en yüksek sınıflandırma doğrulukları elde edilmiştir. Microsoft Visual Studio 2013 / C++ ortamında gerçekleştirilen CNBC sınıflandırıcı MuViSAR platformu içerisinde gerçekleştirilmiştir.




**Şekil 1:** Sınıf (C) ve öznelik (N) vektörleri ile CNBC çerçevesi topolojisi.

Bu proje kapsamında gerçekleştirilen deneylerde CNBC içinde kullanılan ikili sınıflandırıcılar (BC) ve son birleştirici (fuser) sınıflandırıcı olarak hem MLP-PSO hem de MLP-BP kullanılarak karşılaştırmalar yapılmıştır. Ayrıca her öznelik farklı SAR sınıf tiplerini ayırt etmek için kendi güçlü ve zayıf yanlara sahiptir ve

bu gerçek birden çok öznitelik ve farklı kombinasyonları kullanarak SAR görüntü sınıflandırmanın önemli ölçüde geliştirilebileceğini göstermektedir. Özellikle çalışmalarda çok öznitelik vektörü kombinasyonunun uygun sınıflandırıcı yapıları kullanılarak sınıflandırma performansının önemli ölçüde geliştirilebileceğini göstermiştir. Bu nedenle, öznitelik ölçeklenebilirliği ve optimal öznitelik seçimi CNBC'ye dayalı sınıflandırma çerçevesinin amaçladığı temel hedefler içindedir.

### **3.3 Kendiliğinden Organize Olan İkili Sınıflayıcılar Ağı Bulutları**

Yukarıda anlatılan CNBC topolojisi, SAR görüntülerinin sınıflandırılması ve erişimi için gerekli yüksek derece ölçeklenebilirlik ve uyarlanabilirlik özelliklerine sahip ve büyük ölçekli makine öğrenme problemini ayrı sınıflara ve özniteliklere bölebilmektedir. Bu projede ikili sınıflayıcılar topluluğu ağına (CNBC) dayalı olarak polarimetrik SAR görüntülerini içeren veritabanı içinde aynı sistem tarafından elde edilmiş görüntülere ait mevcut ortak sınıflar ve konum ve zaman farklılıkları sonucu oluşabilecek yeni sınıflar için yer yüzeyi sınıflandırması yapılabilmektedir. Önerilen süreç kapsamında ön-işleme olarak her bir polarimetrik SAR görüntüsü 5x5 pencereyle Lee speckle süzgeçinden geçirildikten sonra EM tabanlı temel öznitelikler, ayrışmalar, doku, renk ve diğer görüntü işleme öznitelikler çıkartılmaktadır. İkinci adımda, her bir SAR görüntüsü için o zamana kadar geliştirilmiş mevcut en iyi CNBC sınıflayıcı kullanılarak sınıflandırma işlemi gerçekleştirilir. CNBC veri güdümlü ve uyarlanabilir öznitelik ve sınıf ölçeklenebilirliği özellikleri sayesinde yeni SAR görüntüleri için yeni sınıflar veya özniteliklere ait yersel gerçek bilgileri sağlandığında artımlı öğrenme gerçekleştirebilmektedir. CNBC bu artımlı geliştirilebilir yeteneği sayesinde kullanıcı tarafından yeni yersel gerçek veriler veya özniteliklere dayalı geri besleme yapıldığında sınıflandırma doğruluğunu iyileştirebilmektedir. Örnek olarak 900x1024 boyutlu San Francisco Bay AIRSAR görüntüsü üzerinde yapılan deneyde yeni eklenen 2 sınıfa, kayalar ve düz alanlar, ait eğitim verileri kullanılarak CNBC sınıflandırıcı artımlı olarak geliştirilmiş ve Şekil 2'de gösterilen sınıflandırma sonuçları elde edilmiştir. Bu deneyde her sınıf için ortalama yaklaşık 200 eğitim verisi kullanılmış ve bu toplamda %0.1 oranında eğitim verisine karşılık gelmektedir. Bu deneyde CNBC içinde kullanılan ikili sınıflandırıcılar (BC) ve son birleştirici (fuser) sınıflandırıcı olarak MLP-BP kullanılmıştır.




Şekil 2: San Francisco Bay AIRSAR görüntüsü ve CNBC sınıflandırıcının temel 3- {water, urban, forest} sınıf durumundan başlayarak sırasıyla {rocks} ve {flat areas} sınıfları için yersel gerçek verisi eklenmesiyle artımlı olarak geliştirilmesi ile elde edilen 4- ve 5- sınıf durumları için sınıflandırma sonuçları.

Gözetimli öğrenmeye (supervised learning) dayalı CNBC sınıflayıcıların evrimsel gelişimi (incremental evolution) iki aşamalıdır: Birinci aşamada her sınıfa ait NBC'lerin içindeki ikili sınıflayıcılar (BCs) giriş öznitelik vektörleri (FVs) ve sınıf vektörleri (CVs) kullanılarak önceden belirlenmiş bir mimari uzayı (AS) içinde evrilerek verilen kritere (eğitim sınıflandırma hatası veya ortalama kare hata) göre en iyi BC konfigürasyonu bulunur ve kaydedilir. Her evrim seansı eğer varsa mevcut en iyi sınıflayıcıdan başlayarak daha da geliştirilebilir. İkinci aşamada, benzer prensiplere göre birleştirici ikili sınıflayıcıların (fuser BCs) evrimsel geliştirilmesi gerçekleştirilir. Bu aşamada, birleştirici BC'nin belirli bir sınıfın ayırt edilmesi için her bir BC'nin (ve ilgili özniteliklerin) önemini öğrenerek verimli bir öznitelik seçme mekanizması (feature selection) gerçekleştirmesi amaçlanır. Ayrıca, her artımlı evrimsel geliştirme (incremental evolution) ile, yeni sınıflar/öznitelikler de eklenebilir, ve bu değişikliğe dinamik olarak uyarlanabilmesi (dynamic adaptation) amacıyla yeni karşılık gelen ağların ve sınıflayıcıların CNBC içinde oluşumuna işaret eder. Böylece CNBC,



sınıflandırma ve erişim doğruluklarını maksimize etmeye çalışırken, kendisini veri içeriğine ve veri rezervinin indeksleme gereksinimlerine dinamik olarak ölçekleyebilecektir.

CNBC sınıflayıcı topluluğu (ensemble classifier) içinde ikili sınıflayıcılar (BC) için MLP-BP dışında MLP-PSO, RBF-PSO, SVM (Destek Vektör Makineleri) ve RF (Rasgele Orman) gibi farklı tip sınıflayıcılar kullanmak da mümkündür. Örneğin Flevoland polarimetrik SAR görüntüsü için MLP-BP, MLP-PSO ve RBF-PSO tipi BC'ler kullanılarak elde edilen sınıflandırma sonuçları görsel karşılaştırma amaçlı Şekil 3'de gösterilmiştir. CNBC içinde MLP-PSO ve RBF-PSO BC'lerde eğitim ve belirlenmiş mimari uzayı içinde evrilme amaçlı olarak, evrimsel yapay sinir ağlarında olduğu gibi Hata: Başvuru kaynağı bulunamadı, daha önce geliştirdiğimiz MD-PSO algoritması kullanılmaktadır.

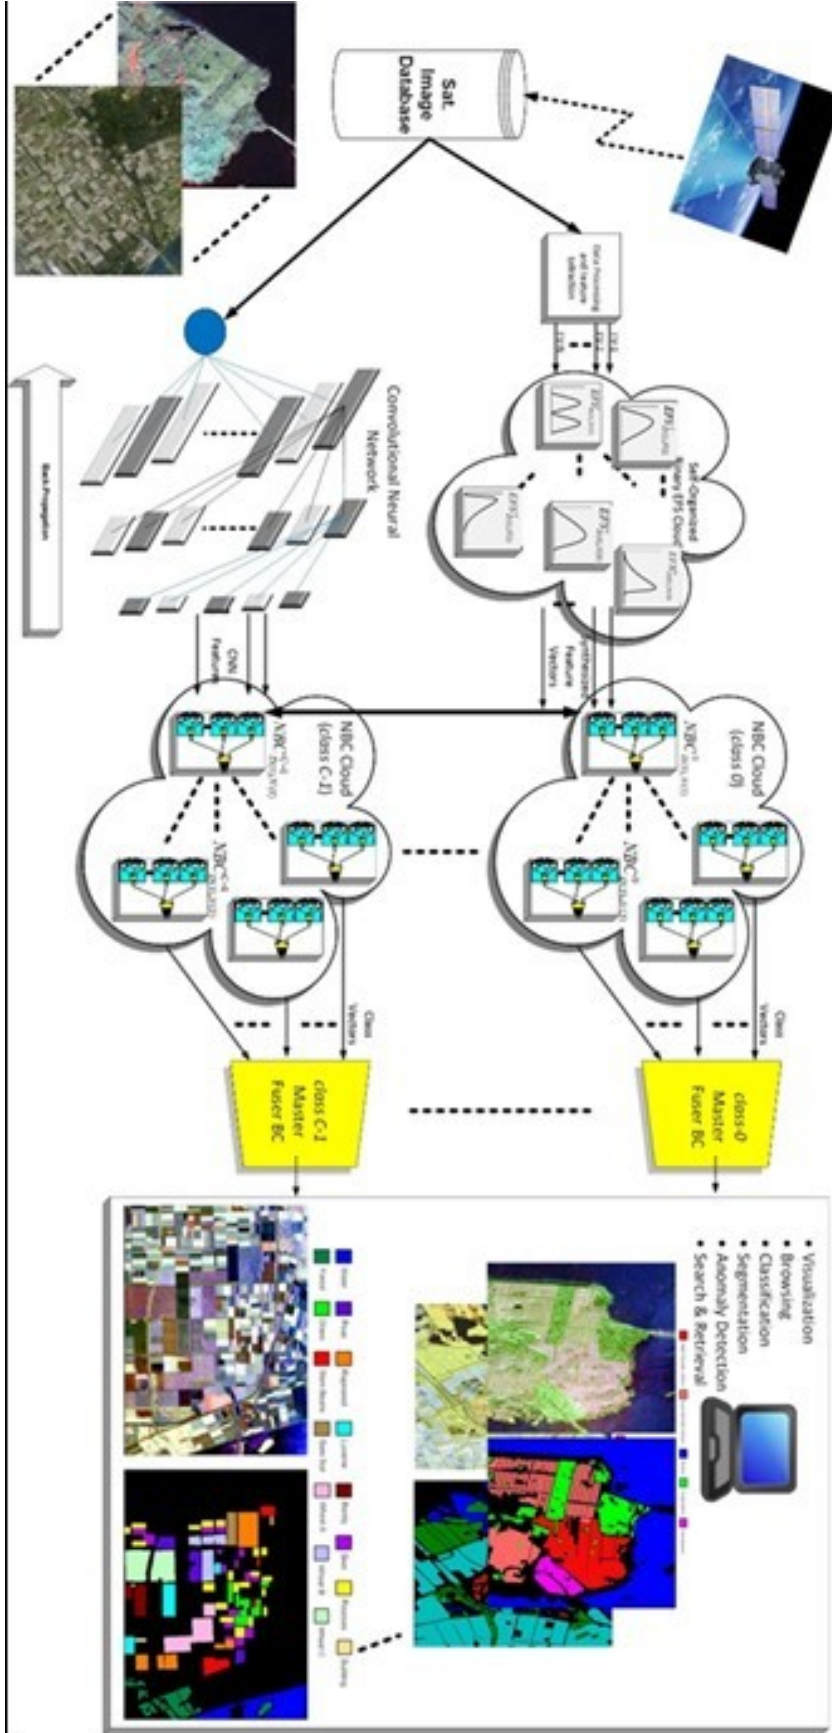


Şekil 3: Flevoland polarimetrik SAR görüntüsü için CNBC sınıflandırıcı içinde sırasıyla MLP-BP, MLP-PSO ve RBF-PSO ikili sınıflandırıcılar kullanılarak elde edilen sonuçlar.

"Büyük veri" (büyük hacimli, çok boyutlu SAR görüntü depoları) dikkate alındığında, CNBC topolojisi o büyüklükteki SAR veritabanını, veri alanında bölme yapmadan, öğrenmek için yeterli olamamaktadır. Bu durumda her bir sınıfın öğeleri için kendi kendine veri organizasyonu (Self Data Organization, SDO) geliştirilerek, her sınıfın öğelerini homojen parçalara bölmek ve her parça üzerinde özel bir ikili sınıflayıcılar ağı (NBC) geliştirmek gerekmektedir. Bunun




anlamı, büyük sayıda sınıf öğeleri arasında önemli değişimler nedeniyle ayrı veri bölümlerini öğrenmek için her sınıf için birden çok NBC gerekecektir. Bu SDO süreci sonunda, her NBC homojen veriyi bir öznelik yerine büyük öznelikler kümesini dikkate alarak bölebilecek ve kendi doğal öznelik seçimini kullanarak en ayırt edici öznelik veya özneliklere göre veri homojenliğini tanımlama imkanına sahip olacaktır. Bu nedenle, sadece ikili sınıflayıcılar (BC'ler) yerine ikili sınıflayıcı ağları (NBC'ler) için kendi kendine veri organizasyonu (SDO) işlemleri gerçekleştirilmektedir. Sınıf c için evrilen NBC'ler bulutu daha sonra  $NBC_{D(1),N(1)}^c$ ,  $NBC_{D(2),N(2)}^c$ , ..., olarak adlandırılabilir ve daha sonra Şekil 4'de görüldüğü gibi son sınıf kararı bir uzman birleştirici (master fuser) BC tarafından öğrenilebilmektedir. Bu şekilde kendiliğinden organize olan NBC bulutları topolojisi öğrenme problemini gerçekten bütün alanlarda (öznelik, sınıf ve veri) bölebilmeye yeteneğine sahip olmaktadır. Kendiliğinden organize olan ikili sınıflandırıcı ağı (NBC) bulutları geliştirdiğimiz MuviSAR platformu altında SAR büyük veri sınıflandırması problemlerine uygulanmak üzere Microsoft Visual Studio 2013 / C++ ortamında gerçekleştirilmiştir.



Şekil 4: Kendiliğinden organize olan ikili sınıflayıcılar ağı (NBC) bulutlarına dayalı SAR görüntü veri tabanı yönetimi.

### 3.4 Kendiliğinden Organize Olan Öznitelik Sentezleyicileri

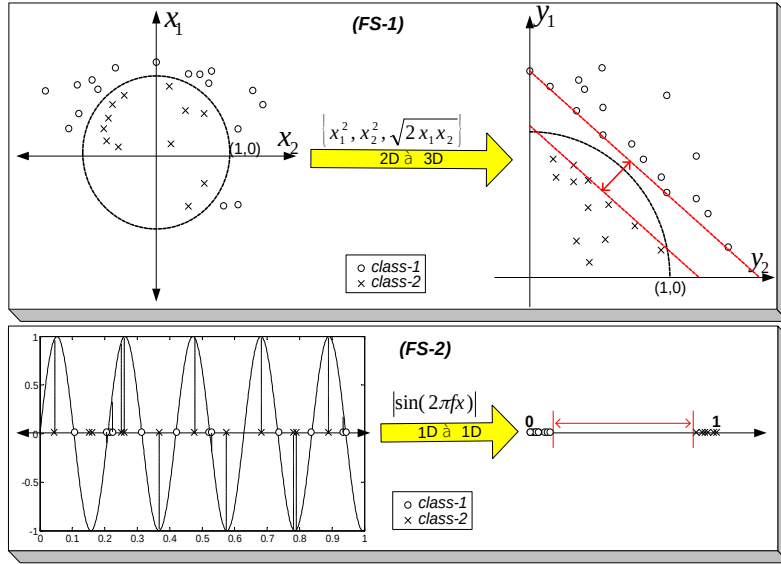
Her bir öznitelik herhangi bir sınıf türü için belirli bir ayrımcılık yeteneğine sahip olduğu bilinmektedir. Bu projede önerilen CNBC topolojisi, her bir özniteliğin kendi ayrımcılık gücünü ve her birinin zayıflıklarını diğerleri ile telafi ederek kullanabildiğinden, temel olarak mümkün olduğu kadar çok sayıda öznitelik kullanmanın avantajını elde ederek, ve böylece her bir özniteliğin artımlı katkısı ile genel sınıflandırma başarısını daha da geliştirebilmektedir. Şekil 5'de Flevoland polarimetrik SAR görüntüsü için görselleştirilmiş farklı öznitelik bileşenlerinin, sırasıyla RGB kodlanmış Tutarlılık matrisi  $T_{11}$ ,  $T_{22}$ ,  $T_{33}$  bileşenleri, ve ayrı olarak Tutarlılık matrisi öz-dönüşümünden (eigen-decomposition) elde edilen üç özdeğer (eigenvalue), bir veya birkaç sınıfı tüm sınıflar arasından oldukça iyi ayırt edebildiği açıkça görülmektedir.



Şekil 5: Flevoland polarimetrik SAR görüntüsü için görselleştirilmiş farklı öznitelik bileşenleri (sırasıyla RGB kodlanmış Tutarlılık matrisi  $T_{11}$ ,  $T_{22}$ ,  $T_{33}$  bileşenleri, ve ayrı olarak Tutarlılık matrisi öz-dönüşümünden elde edilen üç özdeğer).

Bununla birlikte, özellikle büyük ve çeşitli SAR veri rezervleri durumunda bu temel öznitelikler doğru arazi karakterizasyonu için gerekli ayırt edici güçten genellikle yoksun olurlar. Bu nedenle, ayrımcılık gücünü artırmayı amaçlayan bir Evrimsel Öznitelik Sentezleyici (EFS) çerçevesi kullanarak daha iyi ayırt edici

öznitelikler sentezlemek amaçlanmıştır. Bu çalışmada yüksek derecede ayırt edici öznitelikler sentezlemek amacıyla verilen öznitelikler üzerinde optimal doğrusal ve doğrusal olmayan operatörler kümesini araştıran bir EFS çerçevesi geliştirdik. EFS sürecinde en büyük performansı elde etmek amacıyla, doğru boyutta özniteliklerin sentezi için doğru öznitelikler üzerinde uygulanacak doğru operatörlerin araştırılmasının çok önemli olduğu bir gerçektir. Örneğin Şekil 6'da gösterilen iki basit öznitelik sentezleyicileri (FS-1 ve FS-2) göz önüne alabiliriz, burada gösterim amacıyla öznitelikler sadece bir- ve iki-boyutlu seçilmiş ve sadece iki-sınıflı problemler dikkate alınmıştır. FS-1 durumunda, karesel biçimdeki doğrusal olmayan operatör üç-boyutlu uzaya doğru dönüşümü yapabilmekte ve böylece yeni (sentezlenmiş) öznitelikler doğrusal ayırt edilebilir olmaktadır. Ancak, FS-2 durumunda, daha iyi sınıflandırma için onun yerine uygun frekanslı ( $f$ ) sinüs dalgası kullanılmalıdır.



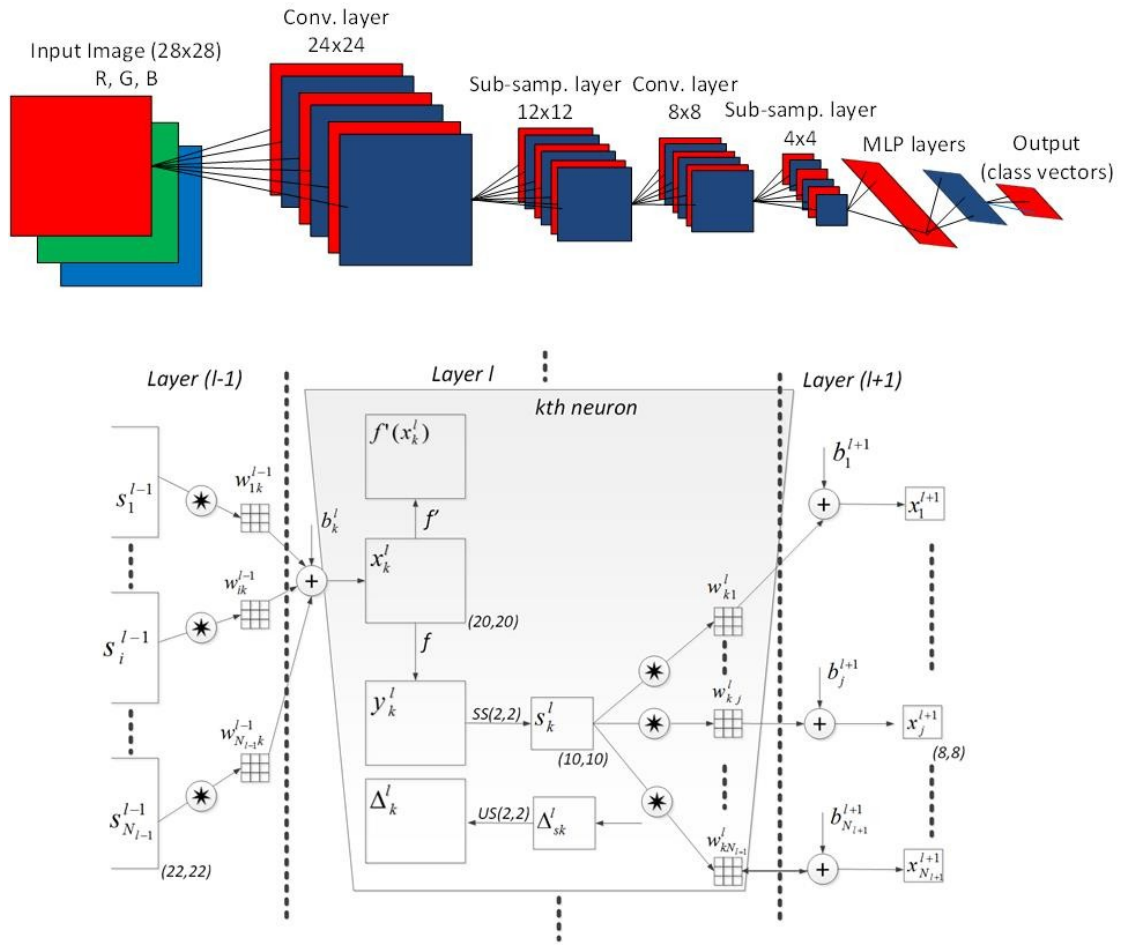
Şekil 6: İki-boyutlu (FS-1) ve bir-boyutlu (FS-2) öznitelik uzayları üzerinde gerçekleştirilen örnek öznitelik sentezi.

İkili öznitelik sentezleyicileri bu temelden yola çıkarak büyük, çok boyutlu SAR görüntü veri tabanları üzerinde EFS'den yararlanmak amacıyla sentezleme problemini belirli sayıda daha kolay ikili sentez problemlerine bölen bir yaklaşımı (divide and conquer) amaçlamaktadır. Bu durumda, tüm mevcut sınıfların daha iyi ayırımı için öznitelik vektörlerini dönüştüren tek bir sentezleyici evrimi yerine, amaç her biri sadece bir sınıfı diğerlerinden ayırt etmekle sorumlu ayrı ikili sentezleyiciler geliştirmektir. Bu nedenle, görev önemli ölçüde basitleşir çünkü her sentezleyici, kendisini geliştirdiği sınıfı diğerlerinden ayırt edebildiği sürece, başka bir sınıf özniteliklerinin dağılımı ile ilgilenmez. Diğer taraftan, birden çok sentezleyiciden bir bilinmeyen veri tabanı ögesine karşılık doğru sentezleyiciyi

seçmek doğal bir sınıflandırma süreci gerektireceğinden oldukça basittir. Bununla birlikte, "büyük veri" (büyük hacimli, çok boyutlu SAR görüntü depoları) dikkate alındığında, problemi ayrı sınıflara bölen ikili evrimsel öznitelik sentezleyici (EFS) yaklaşımı (CNBC topolojisi gibi) o büyüklükteki SAR veritabanını, veri alanında bölme yapmadan, öğrenmek için yeterli olamayacaktır. Özellikle bazı genel arazi sınıfları öznitelik alanında çok büyük değişim gösterirler, bu durumda tek bir ikili EFS geliştirerek böyle genel arazi sınıflarının diğerlerinden ayrımı hala çok zor ve bazen de imkansız bir probleme dönüşmektedir. Bu durumda, böyle değişken bir dağılıma sahip özniteliklerin herhangi biri için evrilmiş tek bir ikili EFS sentezleyici karakteristik örüntüyü öğrenemez ve dolayısıyla güçlü öznitelikler sentezleyemez. Bu problemi çözmek için her bir sınıfın öğeleri için kendi kendine veri organizasyonu (SDO) geliştirilmekte ve her ikili öznitelik sentezleyici sınıf veri kümesinin kendi homojen bölüntülerinde evrilmektedir. Burada homojenlik öznitelik karakteristikleri ve örüntülerin homojen kısımlarının öğrenilebilmesidir ve böylece verimli sentez yapılabilir. Kısaca, her ikili sentezleyici homojen veri bölüntüsünü çıkartarak ve sadece onun üzerinde evrilmektedir. Bunu gerçekleştirmek için MD-PSO'ya dayalı evrim ve kendi kendine veri organizasyonu (SDO) süreçleri birleştirilmektedir. Her öznitelik sentezleyici kendi veri bölüntüsü üzerinde evrilince (pozitif ve negatif örnekler kullanılarak), daha sonra o bölüntüdeki pozitif örnekler sınıf öğeleri listesinden çıkartılır ve süreç geri kalan sınıf öğeleri üzerinde bütün sınıf öğeleri işleninceye kadar yeni sentezleyiciler geliştirmek için tekrar edilir. Süreç diğer sınıflar için de tekrar edilerek sonunda sentezleyici bulutları olarak adlandırdığımız gruplar oluşturulmaktadır.

Ayrıca yukarıda anlattığımız ve MuviSAR platformu altında geliştirilen ikili evrimsel öznitelik sentezleyicilere alternatif olarak Evrişimli Yapay Sinir Ağlarının (Convolutional Neural Networks, CNN) kullanılması çalışmaları halen sürmektedir. Bu şekilde büyük ölçekli SAR görüntü sınıflandırma problemi için CNBC topolojisinden geliştirdiğimiz kendiliğinden organize NBC bulutlarının girişi için en iyi ayırt edici özniteliklerin sentezlenmesi amacına büyük veriyi kullanarak otomatik olarak ulaşılabileceği düşünülmektedir. Şekil 7'de büyük ölçekli ve dinamik SAR veri tabanlarında görüntü sınıflandırması problemine çözüm olarak tasarladığımız sistemin temel blokları gösterilmiştir. Buradan görüleceği üzere yukarıda anlattığımız ikili evrimsel öznitelik sentezleyicilere paralel olarak SAR öznitelikleri sentezlemesi amaçlı olarak Evrişimli Yapay Sinir Ağları (Convolutional Neural Networks, CNN) kullanılması çalışmalarına da başlanmıştır. CNN'ler son zamanlarda büyük görüntü veri tabanlarında nesne

tanıma gibi “derin öğrenme” işleri için fiili standart olmuş ve önemli bir performans aralığı ile en gelişmiş performansları başarmıştır [28]. Şekil 7’de örnek bir geleneksel CNN yapısı ve önerilen uyarlanabilir CNN içinde evrişimli tabaka nöron yapısı gösterilmiştir. Yakın zaman önce kendi gerçekleştirdiğimiz uyarlanabilir (adaptive) CNN’leri ham biyomedikal işaretlerden gerçek-zamanlı EKG sınıflandırması [27] ve ham elektrik akımı işaretinden elektrik motorlarında hata tespiti [19] problemlerine başarıyla uyguladık. Bu uygulamalarda uyarlanabilir CNN’ler eğitim süreci sonucunda büyük sayıda süzgeç kernellerini eniyilemek suretiyle çok yüksek ayırt ediciliğe sahip öznelikleri otomatik olarak çıkartabilmektedir.



Şekil 7: Örnek bir geleneksel Evrişimli Yapay Sinir Ağları (CNN) yapısı (üstte) ve önerilen uyarlanabilir (adaptive) CNN içinde evrişimli tabaka nöron yapısı.


## 4. BULGULAR

Proje kapsamında oluşturulan yöntem ve uygulamaları test etmek amacıyla, kamuya açık kaynaklardan elde edilen ve AIRSAR Polarimetrik SAR [2] sisteminden alınan Flevoland, San Francisco Bay, Long Beach ve San Diego SAR görüntüleri kullanılmıştır. Bu görüntüler kentsel alanın ve tarımsal alanların sınıflandırılması amacıyla oluşturulmuş test alanlarıdır.

Ön işleme olarak bütün polarimetrik SAR görüntüleri 5x5 pencereci Lee speckle filtresinden geçirildikten sonra öznitelik kümeleri Microsoft Visual Studio 2013 / C++ ortamında derlenmiştir ve İş Paketi 1.2 kapsamında açıklanan EM tabanlı ikili formatta kaydedilmiştir. Bütün polarimetrik SAR görüntüleri için yersel doğruluk verisi (GTD) el ile, Tutarlılık matrisinin köşegen elemanlarının RGB kodlanmış resminin görsel olarak incelenmesiyle oluşturulmuştur.


Her özniteliğin farklı SAR arazi sınıfları için kendine özgü ayırt ediciliği farklıdır ve proje kapsamında İş Paketi 1.2’de anlatılan tutarlı ve tutarsız hedef ayırtmalarından oluşturulan bu özniteliklerin bireysel ve arttırımlı performansları incelenmiştir. Ayrıca, polarimetrik SAR görüntülerinin sınıflandırılmasında farklı frekanslardan elde edilmiş SAR görüntülerinin (C-5.21 GHz, L-1.26 GHz ve P-440 MHz bantları) farklı sınıflar için birbirine göre üstün sınıflandırma güçleri CNBC ve SVM sınıflandırıcılarıyla karşılaştırılmıştır.

San Francisco Bay 2531x1168 boyutlu polarimetrik SAR görüntüsü için kullanılan yersel gerçeklik verisi Şekil 8 ve Şekil 9’da verilmiştir.



Şekil 8: San Francisco görüntüsü için seçilen eğitim (training) alanları.






Şekil 9: San Francisco görüntüsü için seçilen test alanları.

Sar Francisco görüntüsü için kullanılan sınıflar ve renk bilgileri Şekil 10'daki gibidir.

Ground Truth Data



Şekil 10: Sınıfların renk bilgisi.

Test görüntüsünden çıkartılan özneliklerin CNBC ve SVM sınıflandırıcı ile kullanıldığında ortaya çıkan ortalama başarı yüzdeleri C bandı için Tablo 2'de, L


bandı için Tablo 3’de verilmiştir. CNBC içinde kullanılan ikili sınıflandırıcılar (BC) ve son birleştirici sınıflandırıcı olarak MLP-BP kullanılmıştır.

SFBay Band	C	Öznitelik	Boyut	CNBC	SVM
FV1		[T] and [C] Matrices	12	0.9364	0.9304
FV2+V1		Span, H/A/Alpha	19	0.9526	0.9526
FV3+V1		Eigenanalysis -Eigenvalues, [T] and [C] Matrices	15	0.9309	0.9345
FV4+V1		Correlation Coefficients + Touzi	18	0.9406	0.9396
FV5+ V1		Touzi, [T] and [C]	16	0.9444	0.9326
FV6+V1		Krogager, [T] and [C]	15	0.9463	0.9464
FV7+ V1		Freeman, [T] and [C]	15	0.9551	0.9439
FV8+ V1		Huynen, [T] and [C]	15	0.9347	0.9344
FV9+ V1		VanZyl , [T] and [C]	15	0.9561	0.9415
FV10+V1		Yamaguachi, [T] and [C]	16	0.9507	0.9419

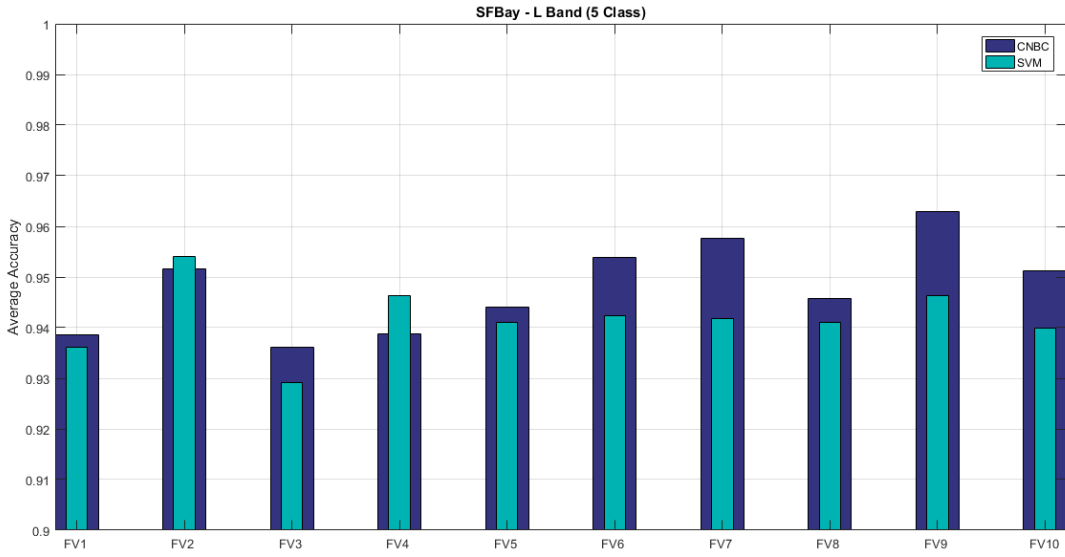
Tablo 2: 2531x1168 çözünürlüklü San Francisco Bay C bandı SAR görüntüsü için 5 sınıf için CNBC ve SVM sınıflandırıcıları kullanılarak yapılan arazi sınıflandırma ortalama doğruluk yüzdeleri.

SFBay Band	L	Feature	Boyut	CNBC	SVM
FV1		[T] and [C] Matrices	12	0.9387	0.9361
FV2+V1		Span, H/A/Alpha	19	0.9516	0.954
FV3+V1		Eigenanalysis -Eigenvalues, [T] and [C] Matrices	15	0.9361	0.9292
FV4+V1		Correlation Coefficients + Touzi	18	0.9388	0.9463
FV5+ V1		Touzi, [T] and [C]	16	0.9441	0.9411
FV6+V1		Krogager, [T] and [C]	15	0.9538	0.9424
FV7+ V1		Freeman, [T] and [C]	15	0.9576	0.9417
FV8+ V1		Huynen, [T] and [C]	15	0.9458	0.941
FV9+ V1		VanZyl , [T] and [C]	15	0.9629	0.9464
FV10+V1		Yamaguachi, [T] and [C]	16	0.9512	0.9399

Tablo 3: 2531x1168 çözünürlüklü San Francisco Bay L bandı SAR görüntüsü için 5 sınıf için CNBC ve SVM sınıflandırıcıları kullanılarak yapılan arazi sınıflandırma ortalama doğruluk yüzdeleri.



Şekil 11: San Francisco C bandı 5 sınıf için ortalama doğruluk oranları.



Şekil 12: San Francisco L bandı 5 sınıf için ortalama doğruluk oranları.

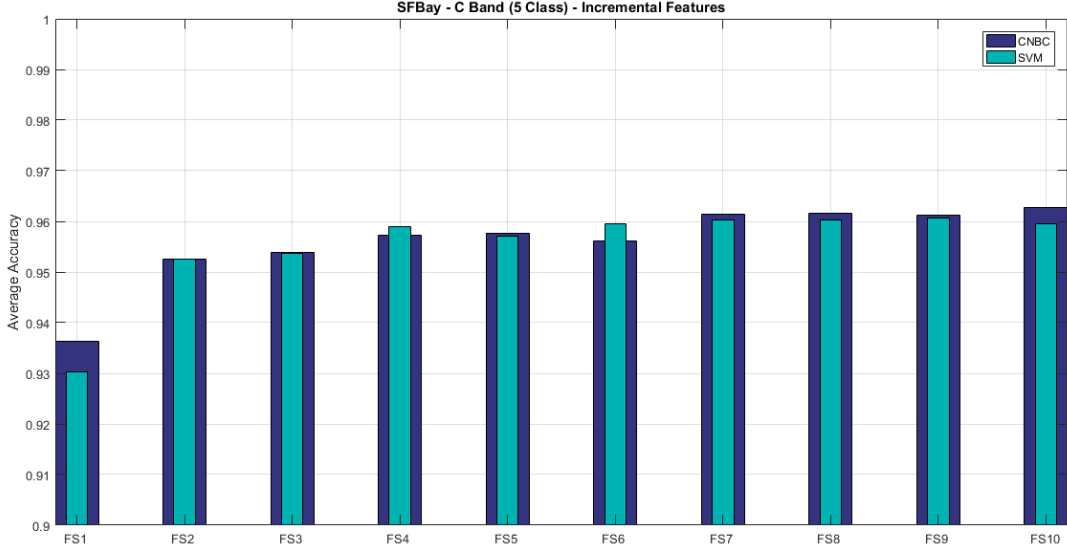
San Francisco Bay test görüntüsü için kullanılan öznelik sayısının artırılmasının önerilen CNBC modeline ve SVM sınıflandırıcısına etkisi C bandı için Tablo 4’de, L bandı için Tablo 5’de verilmiştir.

SFBay (C Band)	Dimensio n	CNBC	SVM
FV1	12	0.9364	0.9304
FV2+(FV1)	19	0.9526	0.9526
FV3+(FV1+FV2)	22	0.9539	0.9538
FV4+(FV1+FV2+FV3)	28	0.9573	0.9589
FV5+(FV1+...+FV3+FV4)	32	0.9576	0.9571
FV6+(FV1+...+FV4+FV5)	35	0.9561	0.9595
FV7+(FV1+...+FV5+FV6)	38	0.9613	0.9603
FV8+(FV1+...+FV6+FV7)	41	0.9616	0.9602
FV9+(FV1+...+FV7+FV8)	44	0.9612	0.9606
FV10+(FV1+... +FV8+FV9)	48	0.9627	0.9596

Tablo 4: 2531x1168 çözünürlüklü San Francisco Bay C bandı SAR görüntüsü için 5 sınıf için CNBC ve SVM sınıflandırıcıları kullanılarak yapılan arazi sınıflandırma ortalama doğruluk yüzdeleri.

SFBay (L Band)	Dimensio n	CNBC	SVM
FV1	12	0.9387	0.9361
FV2+(FV1)	19	0.9516	0.954
FV3+(FV1+FV2)	22	0.9482	0.9527
FV4+(FV1+FV2+FV3)	28	0.9562	0.9595
FV5+(FV1+...+FV3+FV4)	32	0.9543	0.9604
FV6+(FV1+...+FV4+FV5)	35	0.9571	0.9639
FV7+(FV1+...+FV5+FV6)	38	0.9651	0.9639
FV8+(FV1+...+FV6+FV7)	41	0.9601	0.9639
FV9+(FV1+...+FV7+FV8)	44	0.9625	0.9658
FV10+(FV1+... +FV8+FV9)	48	0.9617	0.9629

Tablo 5: 2531x1168 çözünürlüklü San Francisco Bay L bandı SAR görüntüsü için 5 sınıf için CNBC ve SVM sınıflandırıcıları kullanılarak yapılan arazi sınıflandırma ortalama doğruluk yüzdeleri.




Şekil 13: San Francisco C bandı 5 sınıf için arttırımlı öznelik için ortalama doğruluk oranları.




Şekil 14: San Francisco L bandı 5 sınıf için arttırımlı öznelik için ortalama doğruluk oranları.

CNBC sınıflandırıcı kullanılarak yapılan sınıflandırma sonuçları C bandı için Şekil 15'de ve L bandı için Şekil 16'da verilmiştir.



Şekil 15: San Francisco 5 sınıf için C bandı sınıflandırma sonucu



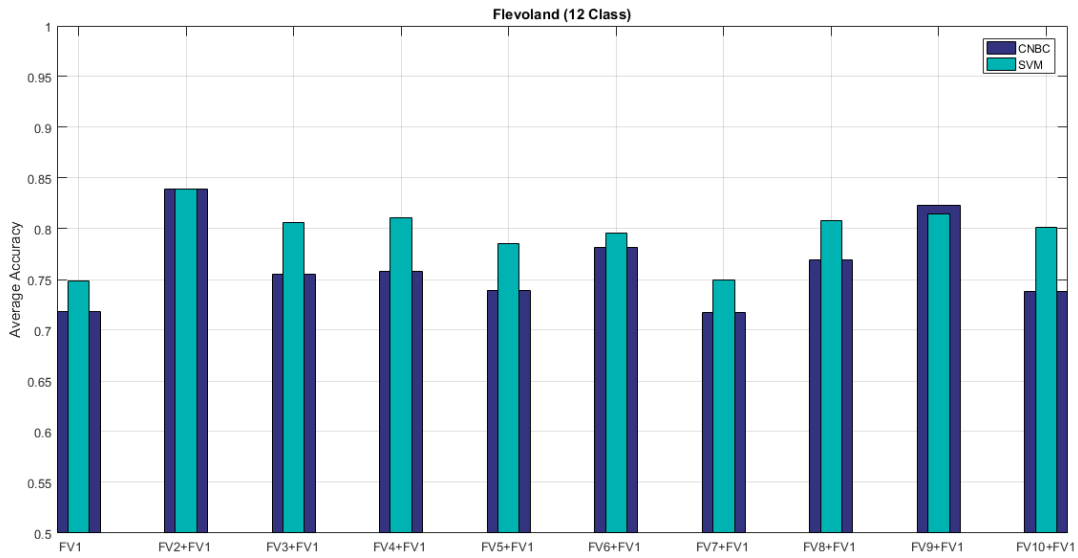
Şekil 16: San Francisco 5 sınıf için L bandı sınıflandırma sonucu

Flevoland, Hollanda 1024x750 boyutlu L bandı 12 sınıf polarimetrik SAR görüntüsü kullanılarak yapılan sınıflandırmanın ortalama doğruluk grafiği Şekil 17'de verilmiştir. Kullanılan özniteliklerin sınıflandırmadaki başarısı Tablo 6'daki gibidir.

L Band	Feature	Dimensio n	CNBC	SVM
FV1	[T] and [C] Matrices	12	0.7183	0.7488
FV2+FV1	Span, H/A/Alpha	19	0.839	0.8388
FV3+FV1	Eigenanalysis -Eigenvalues, [T] and [C] Matrices	15	0.7555	0.8062
FV4+FV1	Correlation Coefficients + Touzi	18	0.7580	0.811

FV5+ FV1	Touzi, [T] and [C]	16	0.7396	0.7851
FV6+ FV1	Krogager, [T] and [C]	15	0.7818	0.796
FV7+ FV1	Freeman, [T] and [C]	15	0.7173	0.7494
FV8+ FV1	Huynen, [T] and [C]	15	0.7691	0.8083
FV9+ FV1	VanZyl, [T] and [C]	15	0.8233	0.815
FV10+ FV1	Yamaguachi, [T] and [C]	16	0.7381	0.8014

Tablo 6: Flevoland, Hollanda 1024x750 boyutlu 12 sınıf CNBC ve SVM ortalama sınıflandırma doğruluk yüzdeleri.



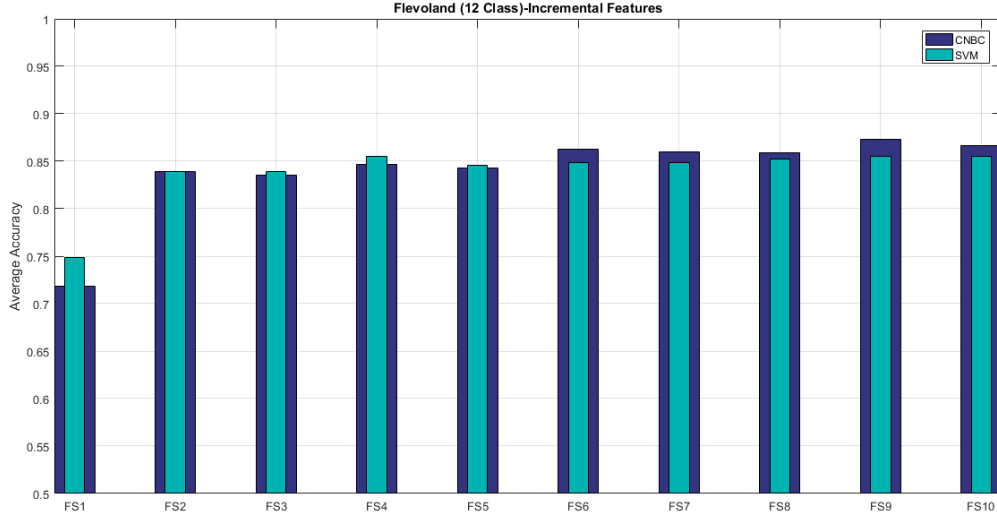
Şekil 17: Flevoland arazisinin ortalama sınıflandırma sonuçları.

Kullanılan Flevoland test resminde öznelik sayısının artırılmasının sınıflandırma başarısına etkisi Tablo 7’de karşılaştırılmıştır ve grafiği Şekil 18’de verilmiştir. Örnek sınıflandırma sonucu ise Şekil 19’da verilmiştir.

	Dimension	CNBC	SVM
FS1	12	0.7183	0.7488
FS2	19	0.839	0.8388
FS3	22	0.8357	0.8395
FS4	28	0.8463	0.855
FS5	32	0.8432	0.8453
FS6	35	0.8629	0.84824
FS7	38	0.8595	0.84823

FS8	41	0.8594	0.852
FS9	44	0.8729	0.855
FS10	48	0.8667	0.8556

Tablo 7: Flevoland, Hollanda 1024x750 boyutlu 12 sınıf CNBC ve SVM ortalama sınıflandırma doğruluk yüzdeleri.




Şekil 18: Flevoland arazisinin öznelik tabanlı arttırımlı sınıflandırma ortalama sınıflandırma sonuçları.




Şekil 19: Flevoland görüntüsü 12 sınıf için sınıflandırma sonucu.



San Diego polerimetrik SAR görüntüsünün 4 sınıf için girilen yersel gerçeklik verisi (GTD) Şekil 20 ve Şekil 21’de verilmiştir.




Şekil 20: 2366x2069 boyutlu Long Beach polerimetrik SAR görüntüsü için eğitici olarak seçilen bölgeler.



Şekil 21: 2366x2069 boyutlu Long Beach polerimetrik SAR görüntüsü için test dataset.

Ground Truth Data



Şekil 22: Long Beach için sınıf renkleri.

San Diego görüntüsü için sınıflandırma ortalama doğruluk oranları ve kullanılan öznelikler C, L ve P bantları için sırasıyla Tablo 8, Tablo 9 ve Tablo 10'da verilmiştir.

LBeach C Band	Feature	Dimensio n	CNBC
FV1	[T] and [C] Matrices	12	0.9174
FV2+FV1	Span, H/A/Alpha	19	0.9323
FV3+FV1	Eigenanalysis -Eigenvalues, [T] and [C] Matrices	15	0.9207
FV4+FV1	Correlation Coefficients + Touzi	18	0.9156
FV5+ FV1	Touzi, [T] and [C]	16	0.9303
FV6+FV1	Krogager, [T] and [C]	15	0.9211
FV7+ FV1	Freeman, [T] and [C]	15	0.9019
FV8+ FV1	Huynen, [T] and [C]	15	0.8993
FV9+ FV1	VanZyl , [T] and [C]	15	0.9623
FV10+FV1	Yamaguachi, [T] and [C]	16	0.9551

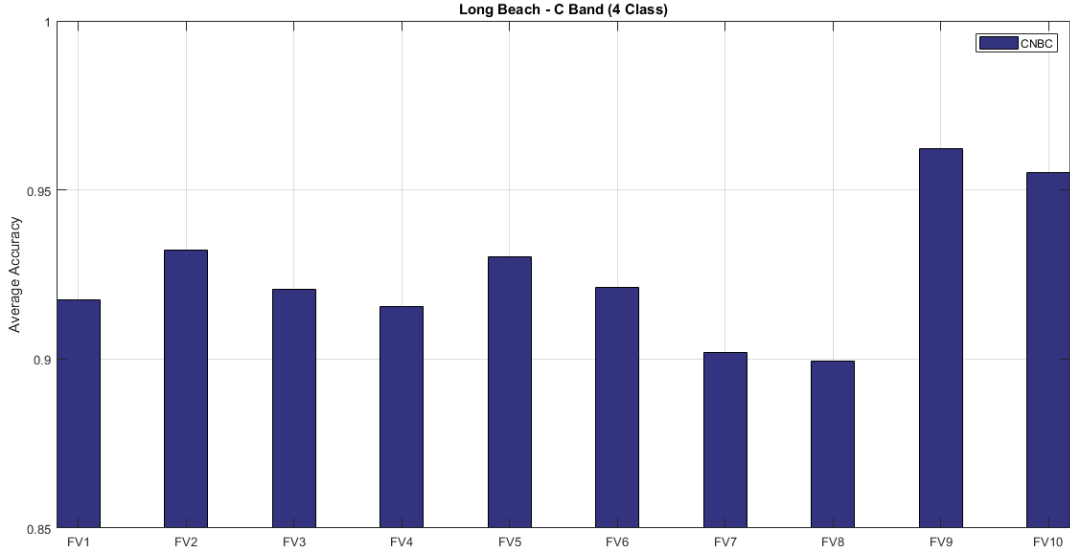
Tablo 8: Long Beach C Band 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri.

LBeach L Band	Feature	Dimensio n	CNBC
FV1	[T] and [C] Matrices	12	0.9573
FV2+FV1	Span, H/A/Alpha	19	0.9675
FV3+FV1	Eigenanalysis -Eigenvalues, [T] and [C] Matrices	15	0.9613
FV4+FV1	Correlation Coefficients + Touzi	18	0.9703
FV5+ FV1	Touzi, [T] and [C]	16	0.9681
FV6+FV1	Krogager, [T] and [C]	15	0.9669
FV7+ FV1	Freeman, [T] and [C]	15	0.9664
FV8+ FV1	Huynen, [T] and [C]	15	0.962
FV9+ FV1	VanZyl , [T] and [C]	15	0.9696
FV10+FV1	Yamaguachi, [T] and [C]	16	0.9741

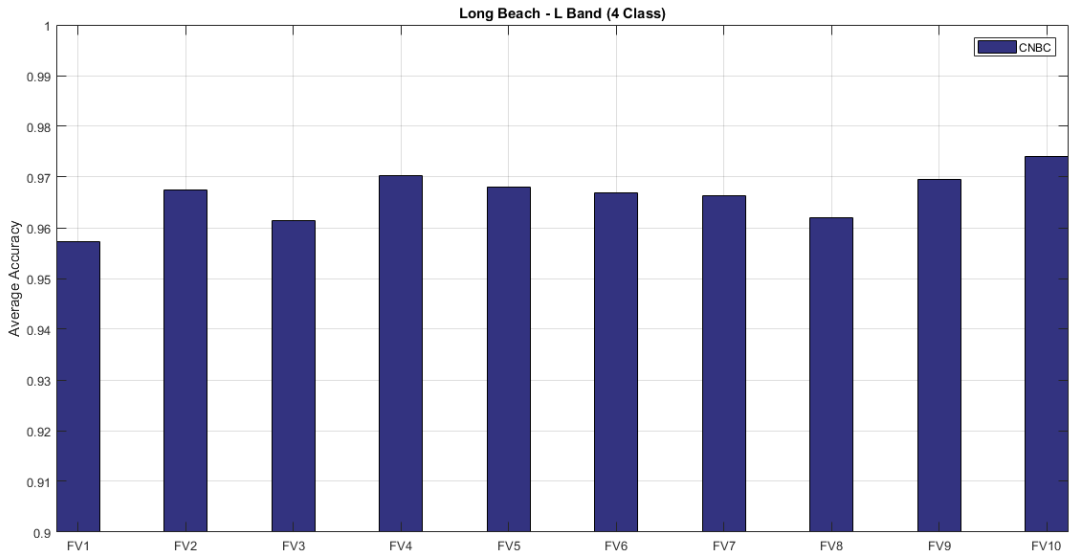
Tablo 9: Long Beach L bandı 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri.

LBeach P Band	Feature	Dimensio n	CNBC
FV1	[T] and [C] Matrices	12	0.9317
FV2+FV1	Span, H/A/Alpha	19	0.9817
FV3+FV1	Eigenanalysis -Eigenvalues, [T] and [C] Matrices	15	0.9484
FV4+FV1	Correlation Coefficients + Touzi		0.9493
FV5+ FV1	Touzi, [T] and [C]	16	0.9522
FV6+FV1	Krogager, [T] and [C]	15	0.9394
FV7+ FV1	Freeman, [T] and [C]	15	0.9409
FV8+ FV1	Huynen, [T] and [C]	15	0.9377
FV9+ FV1	VanZyl , [T] and [C]	15	0.9835
FV10+FV1	Yamaguachi, [T] and [C]	16	0.9754

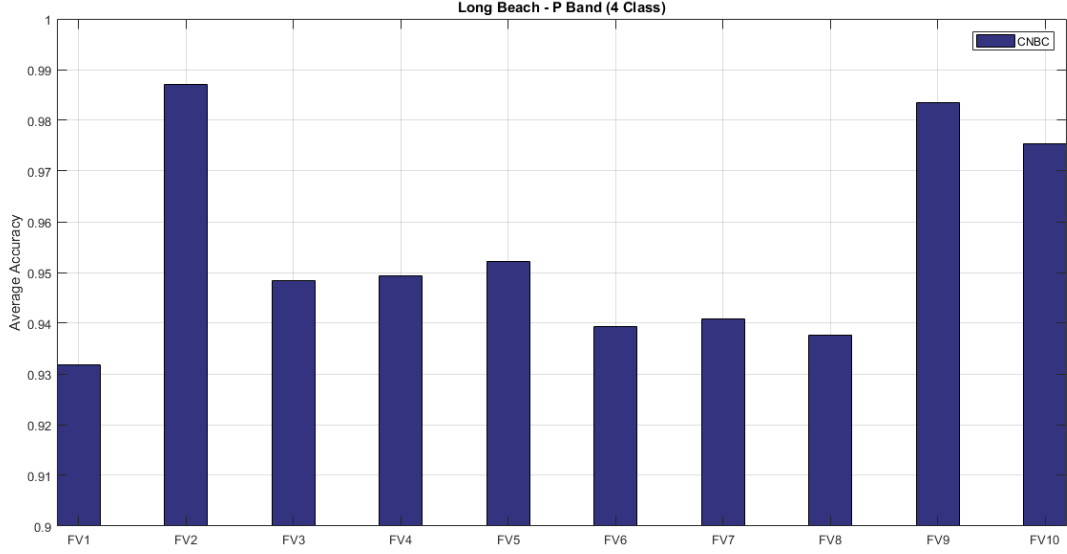
Tablo 10: Long Beach P bandı 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri.



Şekil 23: Long Beach C bandı arazisinin ortalama sınıflandırma doğruluğu grafiği



Şekil 24: Long Beach L bandı arazisinin ortalama sınıflandırma doğruluğu grafiği.



Şekil 25: Long Beach P bandı arazisinin ortalama sınıflandırma doğruluğu grafiği.

Kullanılan Long Beach test görüntüsünde öznelik sayısının artırılmasının sınıflandırma başarısına etkisi C,L ve P band'ler için sırasıyla Tablo 11, Tablo 12 ve Tablo 13'te karşılaştırılmıştır ve ortalama sınıflandırma başarılarının grafikleri Şekil 26, Şekil 27 ve Şekil 28'de verilmiştir. Her bir frekans bandının sınıflandırma sonuçları ise Şekil 29, Şekil 30 ve Şekil 31'de verilmiştir.

Long Beach (C bandı)	Dimension	CNBC
FV1	12	0.9174
FV2+(FV1)	19	0.9323
FV3+(FV1+FV2)	22	0.9355
FV4+(FV1+FV2+FV3)	28	0.9312
FV5+(FV1+...+FV3+FV4)	32	0.9318
FV6+(FV1+...+FV4+FV5)	35	0.9304
FV7+(FV1+...+FV5+FV6)	38	0.94
FV8+(FV1+...+FV6+FV7)	41	0.9401
FV9+(FV1+...+FV7+FV8)	44	0.9405
FV10+(FV1+...+FV8+FV9)	48	0.9415

Tablo 11: Long Beach C bandı 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri (Incremental Features).

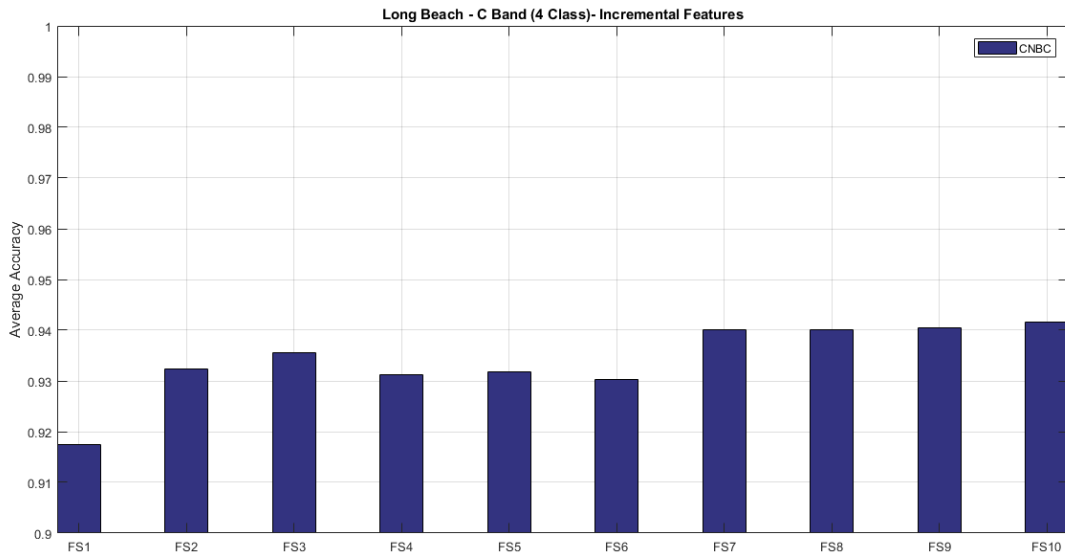
LBeach (L Band)	Dimension	CNBC
FV1	12	0.9573

FV2+(FV1)	19	0.9675
FV3+(FV1+FV2)	22	0.9717
FV4+(FV1+FV2+FV3)	28	0.9713
FV5+(FV1+...+FV3+FV4)	32	0.9741
FV6+(FV1+...+FV4+FV5)	35	0.9734
FV7+(FV1+...+FV5+FV6)	38	0.9772
FV8+(FV1+...+FV6+FV7)	41	0.9753
FV9+(FV1+...+FV7+FV8)	44	0.9766
FV10+(FV1+...+FV8+FV9)	48	0.9789

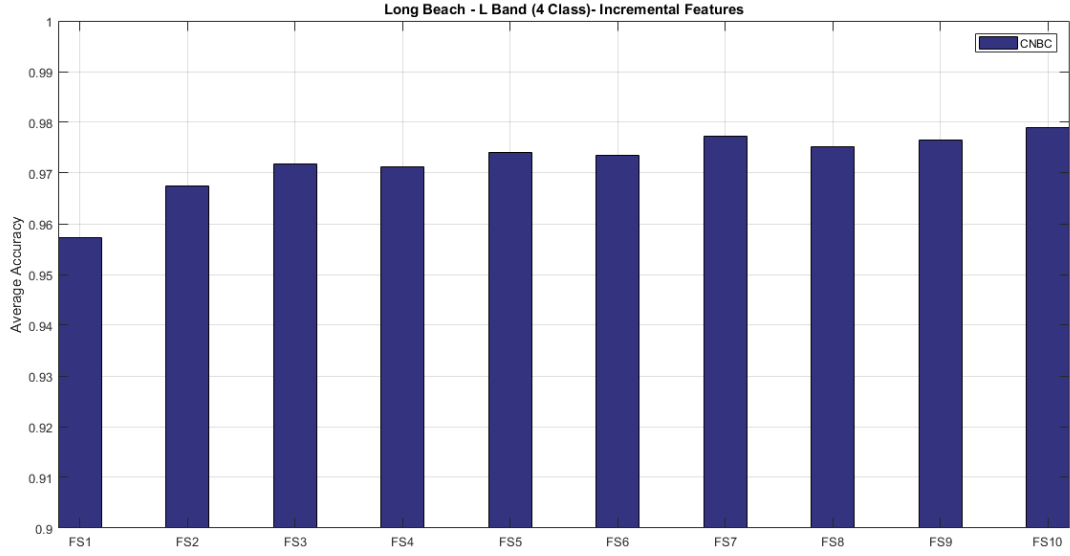
Tablo 12: 11. Long Beach L bandı 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri (Incremental Features).

LBeach (P Band)	Dimension	CNBC
FV1	12	0.9317
FV2+(FV1)	19	0.9871
FV3+(FV1+FV2)	22	0.9877
FV4+(FV1+FV2+FV3)	28	0.9852
FV5+(FV1+...+FV3+FV4)	32	0.9848
FV6+(FV1+...+FV4+FV5)	35	0.9767
FV7+(FV1+...+FV5+FV6)	38	0.9853
FV8+(FV1+...+FV6+FV7)	41	0.9851
FV9+(FV1+...+FV7+FV8)	44	0.9857
FV10+(FV1+... +FV8+FV9)	48	0.9849

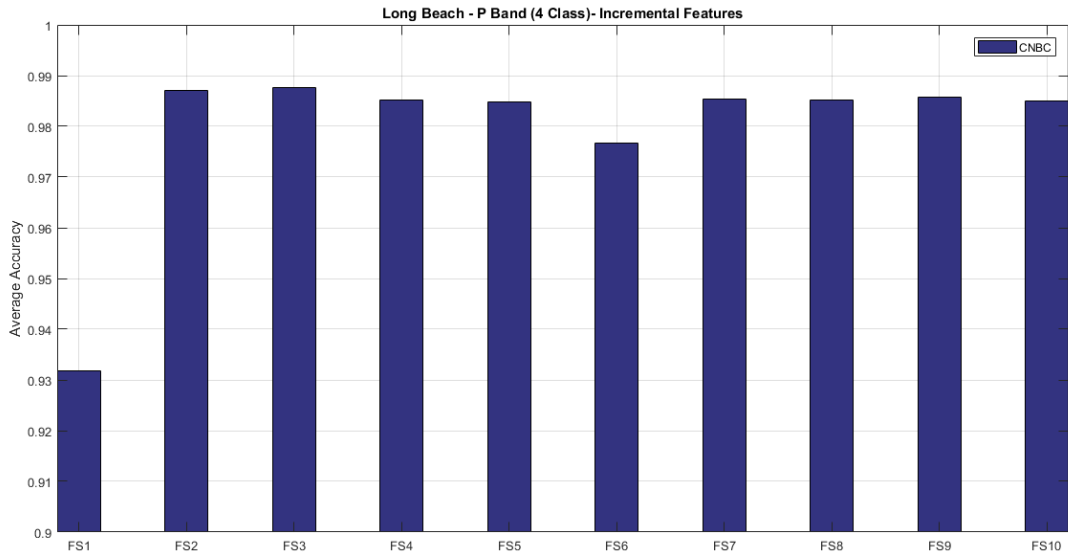
Tablo 13: Long Beach P bandı 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri (Incremental Features).



Şekil 26: Long Beach C bandı arazisinin öznelik tabanlı arttırımlı ortalama sınıflandırma sonuçları.




Şekil 27: Long Beach L bandı arazisinin öznelik tabanlı arttırımlı ortalama sınıflandırma sonuçları.




Şekil 28: Long Beach P bandı arazisinin öznelik tabanlı arttırımlı ortalama sınıflandırma sonuçları.






Şekil 29: Long Beach C bandı 4 sınıf için sınıflandırma sonucu.




Şekil 30: Long Beach L bandı 4 sınıf için sınıflandırma sonucu.




Şekil 31: Long Beach P bandı 4 sınıf için sınıflandırma sonucu.

San Diego polarimetrik test görüntüsü için el ile hazırlanan yersel gerçeklik bölgeleri Şekil 31 ve Şekil 32’de verilmiştir.



Şekil 32: San Diego 2437x3109 boyutlu 4 sınıf için eğitici bölgeler.



Şekil 33: San Diego 2437x3109 boyutlu 4 sınıf için test bölgeleri.

Ground Truth Data



Şekil 34: San Diego sınıfların renk bilgisi

Tablo 14: San Diego C bandı 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri.

SDiego Band	C	Feature	Dimensio n	CNBC
FV1		[T] and [C] Matrices	12	0.9501
FV2+FV1		Span, H/A/Alpha	19	0.9671
FV3+FV1		Eigenanalysis -Eigenvalues, [T] and [C] Matrices	15	0.9496
FV4+FV1		Correlation Coefficients + Touzi	18	0.9418
FV5+ FV1		Touzi, [T] and [C]	16	0.9589
FV6+FV1		Krogager, [T] and [C]	15	0.9599
FV7+ FV1		Freeman, [T] and [C]	15	0.9604
FV8+ FV1		Huynen, [T] and [C]	15	0.9524
FV9+ FV1		VanZyl , [T] and [C]	15	0.9676
FV10+FV1		Yamaguachi, [T] and [C]	16	0.9678

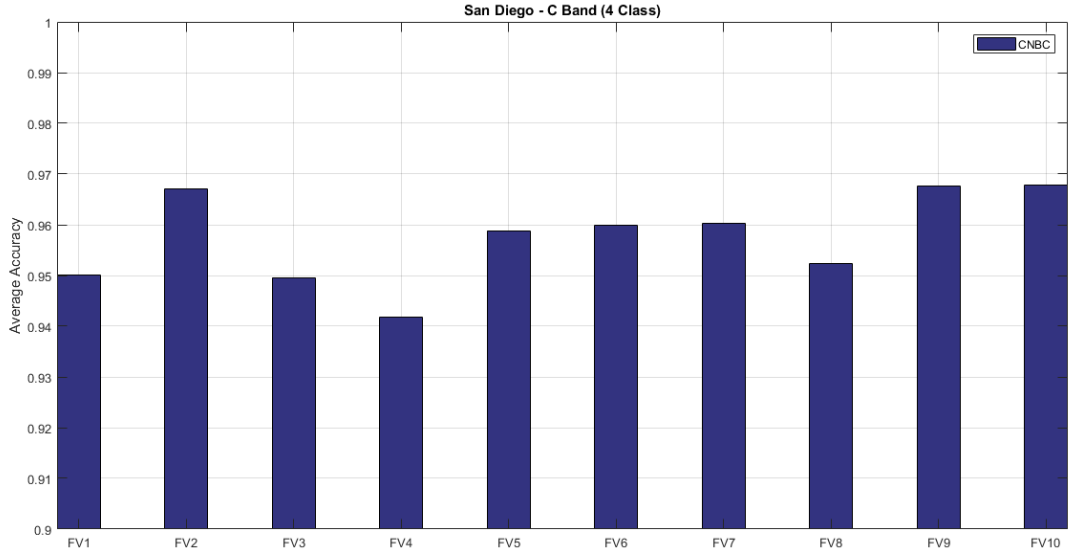
Tablo 15: San Diego L bandı 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri.

SDiego Band	L	Feature	Dimensio n	CNBC
FV1		[T] and [C] Matrices	12	0.9356
FV2+FV1		Span, H/A/Alpha	19	0.9501
FV3+FV1		Eigenanalysis -Eigenvalues, [T] and [C] Matrices	15	0.929
FV4+FV1		Correlation Coefficients + Touzi	18	0.9326
FV5+ FV1		Touzi, [T] and [C]	16	0.9381
FV6+FV1		Krogager, [T] and [C]	15	0.9253
FV7+ FV1		Freeman, [T] and [C]	15	0.9304
FV8+ FV1		Huynen, [T] and [C]	15	0.9355
FV9+ FV1		VanZyl , [T] and [C]	15	0.9251
FV10+FV1		Yamaguachi, [T] and [C]	16	0.9293


Tablo 16: San Diego P bandı 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri.

SDiego Band	P	Feature	Dimensio n	CNBC
-------------	---	---------	------------	------


FV1	[T] and [C] Matrices	12	0.8976
FV2+V1	Span, H/A/Alpha	19	0.9113
FV3+V1	Eigenanalysis -Eigenvalues, [T] and [C] Matrices	15	0.9007
FV4+V1	Correlation Coefficients + Touzi	18	0.9024
FV5+ V1	Touzi, [T] and [C]	16	0.9019
FV6+V1	Krogager, [T] and [C]	15	0.9001
FV7+ V1	Freeman, [T] and [C]	15	0.9063
FV8+ V1	Huynen, [T] and [C]	15	0.8983
FV9+ V1	VanZyl , [T] and [C]	15	0.9086
FV10+V1	Yamaguachi, [T] and [C]	16	0.9091



Şekil 35: San Diego C bandı arazisinin ortalama sınıflandırma sonuçları.



Şekil 36: San Diego L bandı arazisinin ortalama sınıflandırma sonuçları.



Şekil 37: San Diego P bandı arazisinin ortalama sınıflandırma sonuçları.

SanDiego (C Band)	Dimensio n	CNBC
FV1	12	0.9501
FV2+(FV1)	19	0.9671
FV3+(FV1+FV2)	22	0.9614
FV4+(FV1+FV2+FV3)	28	0.9735
FV5+(FV1+...+FV3+FV4)	32	0.9687
FV6+(FV1+...+FV4+FV5)	35	0.9716
FV7+(FV1+...+FV5+FV6)	38	0.9709



FV8+(FV1+...+FV6+FV7)	41	0.9735
FV9+(FV1+...+FV7+FV8)	44	0.9752
FV10+(FV1+... +FV8+FV9)	48	0.9774

Tablo 17: Long Beach C bandı 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri (Incremental Features).

SanDiego (L Band)	Dimension	CNBC
FV1	12	0.9356
FV2+(FV1)	19	0.9501
FV3+(FV1+FV2)	22	0.9517
FV4+(FV1+FV2+FV3)	28	0.9498
FV5+(FV1+...+FV3+FV4)	32	0.9507
FV6+(FV1+...+FV4+FV5)	35	0.9453
FV7+(FV1+...+FV5+FV6)	38	0.9411
FV8+(FV1+...+FV6+FV7)	41	0.9373
FV9+(FV1+...+FV7+FV8)	44	0.943
FV10+(FV1+...+FV8+FV9)	48	0.9393

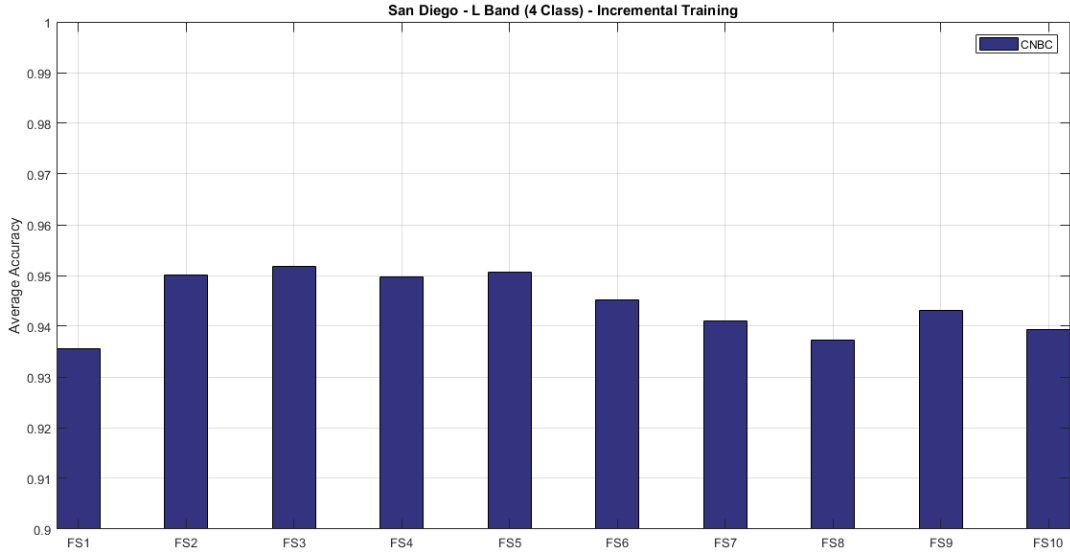
Tablo 18: Long Beach L bandı 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri (Incremental Features).

LBeach (P Band)	Dimension	CNBC
FV1	12	0.8976
FV2+(FV1)	19	0.9113
FV3+(FV1+FV2)	22	0.9118
FV4+(FV1+FV2+FV3)	28	0.9154
FV5+(FV1+...+FV3+FV4)	32	0.9127
FV6+(FV1+...+FV4+FV5)	35	0.9127
FV7+(FV1+...+FV5+FV6)	38	0.9164
FV8+(FV1+...+FV6+FV7)	41	0.9148
FV9+(FV1+...+FV7+FV8)	44	0.9148
FV10+(FV1+...+FV8+FV9)	48	0.9183

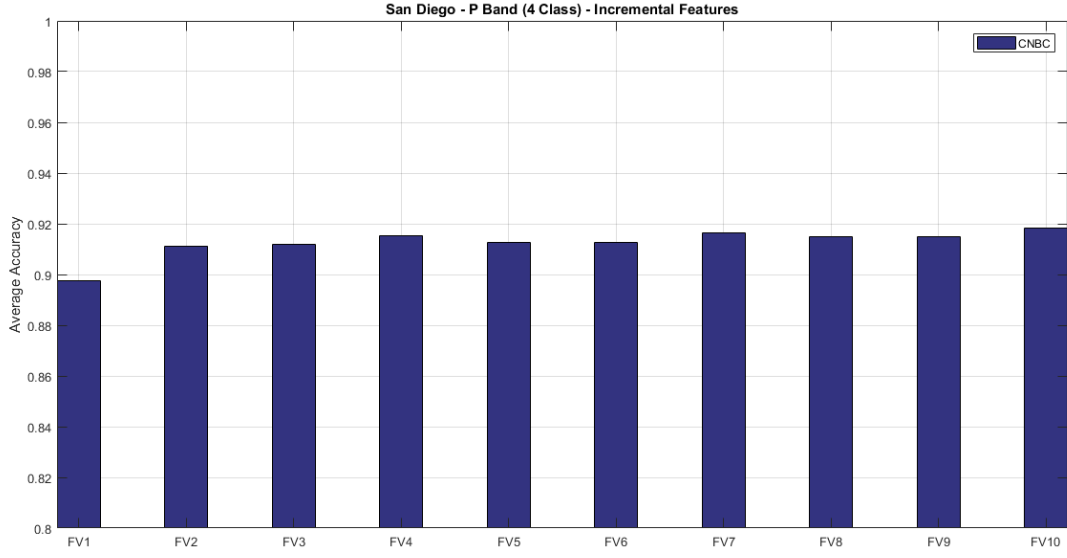
Tablo 19: Long Beach P bandı 4 sınıf CNBC ortalama sınıflandırma doğruluk yüzdeleri (Incremental Features).




Şekil 38: San Diego C bandı arazisinin öznelik tabanlı arttırımlı ortalama sınıflandırma sonuçları.




Şekil 39: San Diego L bandı arazisinin öznelik tabanlı arttırımlı ortalama sınıflandırma sonuçları.




Şekil 40: San Diego P bandı arazisinin öznelik tabanlı arttırımlı ortalama sınıflandırma sonuçları.



Şekil 41: San Diego C bandı 4 sınıf için sınıflandırma sonucu.



Şekil 42: San Diego L bandı 4 sınıf için sınıflandırma sonucu.



Şekil 43: San Diego P bandı 4 sınıf için sınıflandırma sonucu.



## 5. TARTIŞMA VE SONUÇ

Önemli uygulamalardan birisi olan Polarimetrik SAR (PolSAR) görüntüleri üzerinden arazi sınıflandırma bu zamana kadar çeşitli öznelilikler ve sınıflandırıcıların önerildiği aktif bir araştırma alanı olmuştur. Ancak, bu alandaki hemen hemen tüm çalışmalar sadece tek bir SAR görüntüsünün sınıflandırılması problemini ele almış ve büyük SAR görüntü depolarının elde edilmesi aşamasından bu alandaki uzmanlar tarafından görüntülerin tüketimini (görselleştirme ve analizi) içeren etkin bir yönetimi hala büyük ölçüde keşfedilmemiş veya tamamen bilinmemektedir. Bunun temel nedeni, depolama, indeksleme, sınıflandırma ve aynı zamanda erişim ve görselleştirme alanlarında zorluklar çıkartan bu problemin büyüklüğüdür. Bu problem genellikle günlük dilde kullanılan "büyük veri"nin ("big data") analizi ve yönetimi ile ilgilidir ve biz bunun büyük optimizasyon teknikleri ile birlikte büyük öğrenme yaklaşımları gerektirdiğine inanıyoruz.

Bu projede PolSAR görüntü sınıflandırma için böl ve yönet (divide-and-conquer) filozofisine dayalı bazı gelişmiş teknikler ve sınıflandırma topolojileri kullanılarak "büyük veri"nin gerektirdiği büyük ölçekte çalışmalar yapılmıştır. Proje çalışmaları kapsamında, büyük çokboyutlu SAR veri depolarında indeksleme, sınıflandırma, arama ve erişim problemini çözmek amacıyla bir sistematik yaklaşım içinde bilinen önceki teknolojinin ilerisinde yeni bir çerçeve geliştirilmiştir. Bu çalışmada polarimetrik SAR karakteristiklerini tanımlamak için düşük seviyeli elektromagnetik SAR öznelilikleri, bunların farklı dönüşümleri ve gösterimleri (örneğin hedef ayrıştırma teoremleri), ve diğer görüntü işleme dayalı ikincil öznelilikler (örneğin desen, renk) kullanılmıştır. Önerilen sistematik çerçeve tasarımı içinde sınıflandırma doğruluğunu maksimize etmek ve dolayısıyla erişim performansını artırmak amacıyla ikili sınıflayıcılar toplu ağı (Collective Networks of Binary Classifiers, CNBC). CNBC bir yüksek boyutta öğrenme problemini, bir tek özneliliğe dayalı olarak bir sınıfı diğerlerinden ayırt etmek için özel bir sınıflandırıcı oluşturulması ve atanmasını sağlamak yoluyla bölebilir. CNBC topolojisi SAR görüntülerinin sınıflandırılması ve erişimi için önemli olabilecek 1) belirli sınıflar üzerinde en yüksek ayırt edicilik elde etmek için bir takım özneliliklerin nasıl seçileceği, 2) bunların en verimli şekilde nasıl birleştirileceği, 3) eldeki sınıflandırma problemi için en iyi sınıflandırıcı konfigürasyonunun nasıl bulunacağı, 4) çok sayıda sınıflar ve öznelilikler varsa, sınıflandırıcının nasıl ölçekleneceği ve uyarlanacağı, ve 5) sınıflandırma doğruluğunu maksimize etmek için sınıflandırıcının verimli olarak nasıl



eğitileceği sorularının tamamını çözümlenebilecek bir sınıflandırıcı topluluğu yapısına sahiptir. Bu çalışmada kullanılan CNBC sınıflayıcı ağı, hem farklı sınıflayıcıları (MLP-BP, MLP-PSO, SVM, RF gibi) kullanabilmesi hem de farklı özniteliklerin ölçeklenebilirliği ve optimal öznitelik seçimi açısından önemli katkılar sağlamıştır.

Bu projede büyük ölçekli SAR görüntü sınıflandırma problemini çözmek amacıyla CNBC topolojisinden geliştirilmiş kendiliğinden organize NBC bulutları ve bunların girişlerinde sentezlenmiş en iyi ayırt edici öznitelikleri birlikte kullanan bir çerçeve yapı geliştirilmiştir. Bu geliştirilen sistem ile kullanıcı etkileşimi olduğunda her biri artımlı geliştirilebilen her bir sınıf için NBC bulutları oluşmaktadır. Böylelikle bir uzman kullanıcı tarafından herhangi bir geri besleme sistemi doğrudan geliştirmek ve sınıflandırma hatalarını azaltmak için kullanılabilir. Bu sistem belli bir olgunluğa ulaştıktan sonra, gerektiğinde artımlı geliştirmeler gerçekleştirerek depodaki diğer SAR görüntülerini sınıflandırmak için kullanılmaktadır. Özet olarak, bu çalışmada önerilen sistem; 1) büyük bir öğrenme probleminin bütün alanlarda (öznitelik, sınıf ve SAR verisi) bölünmesini, 2) gerekli hız ve hesaplama verimliliğine ulaşmak amacıyla ağ/bulut (grid/cloud) bilgi işlem ortamında tam paralelleşmiş bir uygulamayı, ve 3) esnek bir veri ve öznitelik uyarlaması, ölçeklenebilirliği ve büyük ölçekli makine öğrenmede gerçekten eniyilenmiş bir yaklaşımı içermektedir.

Bu çalışmada önerilen sistem ile mevcut uçak veya uydu tabanlı SAR sensörlerinden araştırma amaçlı sağlanan erişime açık gerçek (benchmark) veriler üzerinde gerçekleştirilen testlerde farklı arazi türlerini yüksek başarı ve verimlilikle öğrenebildiği gösterilmiştir. Özellikle çok sıklıkla kullanılan San Francisco Bay, Flevoland, Long Beach ve San Diego polarimetrik SAR görüntülerinde yer alan farklı arazi türlerinin sınıflandırılması problemlerinde sadece yaklaşık tüm verinin %0.1'i kadar eğitim verisi kullanılarak ortalama %90'ın üzerinde çok yüksek sınıflandırma doğruluk oranları elde edilmiştir. Aynı coğrafi bölgelerde farklı frekans bantlarında alınmış (L, C ve P bantları) SAR verileri üzerinde testler yapılarak farklı arazi türlerinin sınıflandırılmasında SAR çalışma frekansına bağlı hassasiyetleri incelenmiştir. Bu sonuçlar bazı veriler için SVM sınıflandırıcı ile karşılaştırılmış ve genelde daha iyi sonuçların elde edildiği görülmüştür. Ayrıca öznitelik bazında yapılan sınıflandırma doğruluğu testleri ile her bir sınıf için daha güçlü özniteliklerin eklenmesi ile sınıflandırma doğruluğunun daha da artırılacağı gösterilmiştir.





Önerilen sistemin önemli avantajlarından bir diğeri de artımlı olarak farklı veriler kullanılarak geliştirilebilmesi ve benzer sınıfları öğrenme performansının artırılabilmesidir. Sistemin artımlı öğrenme performansı üzerine gerçekleştirdiğimiz testlerin sonuçları ile sistemin bu yeteneği doğrulanmış ve bazı arazi sınıflarında sistemin artımlı öğrenme sonucu sınıflandırma hatalarını azalttığı görülmüştür. Özellikle özniteliğe bağlı artımlı testler sonucunda farklı sınıfların birbirinden ayırt edilebilmesi için her bir özniteliğin kendine özgü güçlü ve zayıf tarafları olduğu ortaya çıkmıştır.

Yakın zaman içinde önerilen sistemin içine daha yüksek ayırt ediciliğe sahip özniteliklerin otomatik olarak sentezlenebilmesi amacıyla iki-boyutlu uyarlanabilir Evrişimli Yapay Sinir Ağlarının (CNN) entegre edilmesi çalışmaları tamamlanarak sistemin performansı test edilecektir. Bu çalışma için özellikle derin yapıda CNN'ler yerine daha yüzeysel (shallow) CNN yapılar kullanılarak SAR görüntüleri üzerinde sınıflara ait eğitim bölgelerindeki piksellerin düşük seviyeli EM öznitelikleri ile eğitimleri öngörülmektedir.

## KAYNAKLAR LİSTESİ VE ATIFLAR

- [1] ESA PolSARPro Sample Datasets [Online]. Available: <http://earth.eo.esa.int/polsarpro/datasets.html>.
- [2] NASA AIRSAR website, <http://airsar.jpl.nasa.gov/>
- [3] Bruzzone L., Marconcini M., Wegmuller U., Wiesmann A., Jun. 2004, “An advanced system for the automatic classification of multitemporal SAR images”, *IEEE Trans. on Geoscience and Remote Sensing*, vol. 42, pp. 1321–1334.
- [4] Cameron W. L., Youssef N. N., and Leung L. K., May 1990, “[Feature motivated polarization scattering matrix decomposition](#),” in *Proceedings of the IEEE International Radar Conference*, pp. 549–557, Arlington, VA, USA.
- [5] Cao F., Hong W., Wu Y., Pottier E., Nov. 2007, “An Unsupervised Segmentation With an Adaptive Number of Clusters Using the Span/H/alpha/A Space and the Complex Wishart Clustering for Fully Polarimetric SAR Data Analysis,” *IEEE Trans. on Geoscience and Remote Sensing*, vol. 45, pp. 3454–3466.
- [6] Cloude S. R. and Pottier E., Jan. 1997, “An entropy based classification scheme for land applications of polarimetric SAR,” *IEEE Trans. on Geoscience and Remote Sensing*, vol. 35, pp. 68–78.
- [7] Cloude S. R. and Pottier E., March 1996, “A review of target decomposition theorems in radar polarimetry,” *IEEE Trans. on Geoscience and Remote Sensing*, vol. 34, no. 2, pp. 498–518.
- [8] delFrate F., Pacifici F., Schiavon G., Solimini C., Apr. 2007, “Use of Neural Networks for Automatic Classification From High-Resolution Images”, *IEEE Trans. on Geoscience and Remote Sensing*, vol. 45, pp. 800–809.
- [9] Du L. J. and Lee J. S., 1996, “Fuzzy classification of earth terrain covers using multi-look polarimetric SAR image data,” *Int. Journal of Remote Sensing*, vol. 17, no. 4, pp. 809–826.
- [10] Duk-jin K., Moon W.M., and Youn-Soo K., Feb. 2010, “Application of TerraSAR-X Data for Emergent Oil-Spill Monitoring”, *IEEE Trans. on Geoscience and Remote Sensing*, vol.48, no.2, pp. 852–863.
- [11] Ersahin, K., Scheuchl, B., Cumming, I., 2004, “Incorporating texture information into polarimetric radar classification using neural networks,” In Proc. of the IEEE Int. Geoscience and Remote Sensing Symp., Anchorage (USA), pp. 560-563.
- [12] Freeman A. and Durden S. L., 1998, “A three-component scattering model for polarimetric SAR data”, *IEEE Trans. on Geoscience and Remote Sensing*, vol. 36, no.3, pp. 963–973.
- [13] Guida R., Iodice A., and Riccio D., Jul. 2010, “Height Retrieval of Isolated Buildings From Single High-Resolution SAR Images”, *IEEE Trans. on Geoscience and Remote Sensing*, vol.48, no.7, pp. 2967–2979.
- [14] Haralick R., Shanmugam K., and Dinstein I., November 1973, “Textural Features for Image Classification”, *IEEE Transactions on Systems, Man and Cybernetics*, vol. 3, no. 6, pp. 610–621.
- [15] Hoekman D. H. and Vissers M. A. M., 2003, “A New Polarimetric Classification Approach Evaluated for Agricultural Crops,” *IEEE Trans. on Geoscience and Remote Sensing*, vol.41, no.12, pp. 2881–2889.
- [16] Horta M. M., Mascarenhas N. D. A., and Frery A. C., 2008, “A comparison of clustering fully polarimetric SAR images using SEM algorithm and GOP mixture model with different initializations”, *Proc. of the Int. Conf. Pattern Recognition*, pp. 1–4.
- [17] Huynen J. R., 1970, “Phenomenological Theory of Radar Targets,” Ph.D. Dissertation, Tech. Univ. Delft, Delft, Netherlands.
- [18] Ince T., Kiranyaz S., and Gabbouj M., May 2009, “A Generic and Robust System for Automated Patient-specific Classification of Electrocardiogram Signals”, *IEEE Transactions on Biomedical Engineering*, vol. 56, issue 5, pp. 1415-1426.
- [19] Ince, T., Kiranyaz, S., Eren, L., Askar, M., Gabbouj, M., 2016, “Real-Time Motor Fault Detection by 1D Convolutional Neural Networks,” *IEEE Transactions on Industrial Electronics*, 63(11), 7067-7075, 2016.
- [20] Kersten P., Lee J. S., and Ainsworth T., Mar. 2005, “Unsupervised classification of polarimetric synthetic aperture radar images using fuzzy clustering and EM clustering,” *IEEE Trans. on Geoscience and Remote Sensing*, vol. 43, no. 3, pp. 519–527.
- [21] Khan K. U., Yang J., and Zhang W., 2007, “Unsupervised classification of polarimetric SAR images by EM algorithm,” *IEICE Transactions on Communications*, vol. 90, no.12, pp. 3632–3642.
- [22] Kiranyaz S., Ince T., Gabbouj M., 2013. *Multidimensional Particle Swarm Optimization for Machine Learning and Pattern Recognition*, Springer-Verlag, Berlin Heidelberg, 321 pages, ISBN: 978-3-642-37846-1.
- [23] Kiranyaz S., Ince T., Yildirim A. and Gabbouj M., Dec. 2009, “Evolutionary Artificial Neural Networks by Multi-Dimensional Particle Swarm Optimization”, *Neural Networks*, vol. 22, pp. 1448–1462.
- [24] Kiranyaz S., Ince T., Yildirim A., and Gabbouj M., April 2010, “Fractional Particle Swarm Optimization in Multi-Dimensional Search Space”, *IEEE Transactions on Systems, Man, and Cybernetics – Part B*, (doi: 10.1109/TSMCB.2009.2015054), pp. 298 – 319, vol. 40, No. 2.
- [25] Kiranyaz S., Ince T., Uhlmann S., and Gabbouj M., August 2012, “Collective Network of Binary Classifier Framework for Polarimetric SAR Image Classification: *An Evolutionary Approach*”, *IEEE Transactions on Systems, Man, and Cybernetics – Part B*, pp. 1169-1186.

- [26] Kiranyaz S., Pulkkinen J., Ince T. and Gabbouj M., Sep. 2011, "Multi-dimensional Evolutionary Feature Synthesis for Content-based Image Retrieval", on Proc. of Int. Conf. On Image Processing, ICIP'2011, pp. 1-4, Brussels, Belgium.
- [27] Kiranyaz, S., Ince, T., Gabbouj, M., "Real-Time Patient-Specific ECG Classification by 1D Convolutional Neural Networks," *IEEE Transactions on Biomedical Engineering*, 63(3), 664-675.
- [28] Krizhevsky A., Sutskever I., and Hinton G., 2012, "Imagenet classification with deep convolutional neural networks", In Proc. *Advances in Neural Information Processing Systems (NIPS)*.
- [29] Krogager E., 1990, "A new decomposition of the radar target scattering matrix," *Electron. Letters*, vol. 26, no. 18, pp. 1525–1526.
- [30] Krogager E., and Czyz Z. H., Mar. 1995, "Properties of the sphere, diplane, helix (target scattering matrix decomposition)", in Proc. *JIPR-3*, J. Saillard, et al., Eds., pp. 106–114, Nantes, France.
- [31] Lee J. S., Grunes M. R., Ainsworth T., Du L.-J., Schuler D., and Cloude S. R., Sep. 1999, "Unsupervised classification using polarimetric decomposition and the complex Wishart classifier," *IEEE Trans. on Geoscience and Remote Sensing*, vol. 37, no. 5, pp. 2249–2257.
- [32] Lee J. S., Grunes M. R., and Kwok R., 1994, "Classification of multi-look polarimetric SAR imagery based on complex Wishart distribution," *Int. Journal of Remote Sensing*, vol. 15, no. 11, pp. 2299–2311.
- [33] Liu G., Xiong H., and Huang S., 2000, "Study on segmentation and interpretation of multi-look polarimetric SAR images", *Int. Journal Remote Sensing*, vol. 21, no. 8, pp. 1675–1691.
- [34] Lönnqvist A., Rauste Y., Molinier M., and Häme T., Oct. 2010, "Polarimetric SAR Data in Land Cover Mapping in Boreal Zone", *IEEE Trans. on Geoscience and Remote Sensing*, vol. 48, no. 10, pp. 3652–3662.
- [35] Mäkinen T., Kiranyaz S., Raitoharju J. and Gabbouj M., 2012, "Evolutionary Feature Generation for Content-based Audio Classification and Retrieval", *EURASIP Journal on Audio, Speech, and Music Processing*.
- [36] Migliaccio M., Gambardella A., Nunziata F., Shimada M., and Isoguchi O., Dec. 2009, "The PALSAR Polarimetric Mode for Sea Oil Slick Observation", *IEEE Trans. on Geoscience and Remote Sensing*, vol. 47, no. 12, pp. 4032–4041.
- [37] Partio M., Cramariuc B., and Gabbouj M., 2007, "An Ordinal Co-occurrence Matrix Framework for Texture Retrieval", *EURASIP Journal on Image and Video Processing*, vol. 2007, Article ID 17358, 15 pages.
- [38] Pottier E. and Lee J.S., May 2000, "Unsupervised classification scheme of POLSAR images based on the complex Wishart distribution and the H/A/alpha-Polarimetric decomposition theorem," in Proc. of the 3<sup>rd</sup> *EUSAR 2000 Conf.*
- [39] Rignot E., Chellappa R., and Dubois P., Jul. 1992, "Unsupervised segmentation of polarimetric SAR data using the covariance matrix," *IEEE Trans. on Geoscience and Remote Sensing*, vol. 30, pp. 697–705.
- [40] She X. L., Yang J., and Zhang W. J., November 2007, "The boosting algorithm with application to polarimetric SAR image classification," in *Proceedings of the 1st Asian and Pacific Conference on Synthetic Aperture Radar (APSAR '07)*, pp. 779–783, Huangshan, China.
- [41] Shimoni M., Borghys D., Heremans R., Perneel C., and Acheroy M., 2009, "Fusion of PolSAR and PolInSAR data for land cover classification," *Int. Journal of Applied Earth Observation and Geoinformation*, vol. 11, no. 3, pp. 169–180.
- [42] Tan C. P., Lim K. S., Ewe H. T., Sep. 2007, "Image processing in polarimetric SAR images using a hybrid entropy decomposition and maximum likelihood (EDML) ," In Proc. *Int. Symposium on Image and Signal Processing and Analysis (ISPA)*, pp. 418–422.
- [43] Touzi R., January 2007, "Target scattering decomposition in terms of roll invariant target parameters", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 45, no. 1, pp. 73–84.
- [44] Tran T. N., Wehrens R., Hoekman D. H., and Buydens L. M. C., Aug. 2005, "Initialization of Markov random field clustering of large remote sensing images," *IEEE Trans. on Geoscience and Remote Sensing*, vol. 43, pp. 1912–1919.
- [45] Uhlmann, S., Kiranyaz, S. and Gabbouj, M., accepted 2013, "Integrating Color Features in Polarimetric SAR Image Classification," *IEEE Transactions on Geoscience and Remote Sensing*.
- [46] Ulaby, F. T., Kouyate, F., Brisco, B., & Williams, T. H. L. (1986). Textural information in SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 24(2), 235–245.
- [47] van Zyl J. J., Jan. 1989, "Unsupervised classification of scattering mechanisms using radar polarimetry data," *IEEE Trans. Geoscience and Remote Sensing*, vol. 27, pp. 36–45.
- [48] Yamaguchi Y., Moriyama T., Ishido M., and Yamada H., August 2005, "Four-component scattering model for polarimetric SAR image decomposition", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, no. 8, pp. 1699–1706.
- [49] Yang S. Y., Wang M., and Jiao L. C., 2009, "Radar target recognition using contourlet packet transform and neural network approach", *Signal Processing*, vol. 89, no. 4, pp. 394–409.
- [50] Ye Z., Lu C.-C., 2002, "Wavelet-Based Unsupervised SAR Image Segmentation Using Hidden Markov Tree Models" In Proc. of the 16<sup>th</sup> *International Conference on Pattern Recognition (ICPR'02)*, vol. 2, pp. 729–732.
- [51] Zhang Y.-D., Wu L., and Wei G., 2009, "A new classifier for polarimetric sar images", *Progress In Electromagnetics Research*, doi:10.2528/PIER09041905, PIER 94, pp. 83–104.



- [52] Zou T., Yang W., Dai D., and Sun H., Oct. 2009, "Polarimetric SAR Image Classification Using Multifeatures Combination and Extremely Randomized Clustering Forests," *EURASIP Journal on Advances in Signal Processing*, doi:10.1155/2010/465612, vol. 2010, Article ID 465612.



## YAYINLARIN LİSTESİ

Bu proje çalışması kapsamında hazırlanmış veya hazırlık aşamasında olan yayınların listesi aşağıda verilmiştir:

- [P1] Ince, T., Ahishali, M., Kiranyaz, S. "Comparison of Polarimetric SAR Features for Terrain Classification Using Incremental Training," In Proc. *Progress In Electromagnetics Research (PIERS) 2017 Symposium*, St. Petersburg, 22-25 May 2017.
- [P2] Ince, T., Ahishali, M., Kiranyaz, S. "Supervised vs. Semi-supervised Polarimetric SAR Image Classification by MD PSO Clustering," *Radioengineering*, Mar 2017 (yayın hakem değerlendirmesinde).
- [P3] Ince, T., Ahishali, M., Kiranyaz, S. "Comparison of Polarimetric SAR Features for Terrain Classification Using Incremental Training," *Remote Sensing*, 2017 (yayın gönderilmek üzere hazırlık aşamasında).
- [P4] Ince, T., Ahishali, M., Kiranyaz, S. "Learned Features for Polarimetric SAR Image Classification by 1D Convolutional Neural Networks," *Remote Sensing*, 2017 (test sonuçlarının tamamlanması ve yayın hazırlık aşamasında).

**TÜBİTAK**  
**PROJE ÖZET BİLGİ FORMU**

Proje Yürütücüsü:	Doç. Dr. TÜRKER İNCE
Proje No:	114E135
Proje Başlığı:	Kendiliğinden Organize Evrimsel Sınıflandırıcı Ağları Bulutları ile Büyük Çokboyutlu SAR Görüntü Depoları Yönetimi
Proje Türü:	1001 - Araştırma
Proje Süresi:	30
Araştırmacılar:	MUSTAFA SERKAN KIRANYAZ (Yurt Dışı)
Danışmanlar:	
Projenin Yürütüldüğü Kuruluş ve Adresi:	İZMİR EKONOMİ Ü.
Projenin Başlangıç ve Bitiş Tarihleri:	01/11/2014 - 01/05/2017
Onaylanan Bütçe:	313447.0
Harcanan Bütçe:	231193.35
Öz:	<p>Uzaktan algılama alanında önemli uygulamalardan birisi olan Polarimetrik SAR (PolSAR) görüntüleri üzerinden arazi sınıflandırması bu zamana kadar çeşitli öznelilikler ve sınıflandırıcıların önerildiği aktif bir araştırma alanı olmuştur. Ancak, bu alandaki hemen hemen tüm çalışmalar sadece tek bir SAR görüntüsünün sınıflandırılması problemini ele almış ve büyük SAR görüntü depolarının elde edilmesi aşamasından bu alandaki uzmanlar tarafından görüntülerin tüketimini (görselleştirme ve analizi) içeren etkin bir yönetimi hala büyük ölçüde keşfedilmemiş veya tamamen bilinmemektedir. Bunun temel nedeni, depolama, indeksleme, sınıflandırma ve aynı zamanda erişim ve görselleştirme alanlarında zorluklar çıkartan bu problemin büyüklüğüdür. Bu proje büyük çokboyutlu SAR veri depolarında endeksleme, sınıflandırma, arama ve erişim problemini çözmek amacıyla makine öğrenme ve işaret işleme alanında en son gelişmiş teknolojileri kullanarak yeni bir çerçeve yapı geliştirmektedir. Bu çalışmada SAR verisi karakteristiklerini tanımlamak için elektromanyetik öznelilikler ile bunların farklı dönüşümleri ve gösterimleri (örneğin hedef ayrıştırma teoremleri), ve diğer görüntü işlemeyle dayalı ikincil öznelilikler (örneğin desen, renk) kullanılmıştır. Bu öznelilikler daha sonra kendiliğinden organize ve daha önce geliştirdiğimiz Çok boyutlu Parçacık Sürü Optimizasyonu (MD PSO) algoritması kullanılarak eğitimi eniyilenmiş olan İkili Sınıflayıcı Ağları (NBC) bulutlarını geliştirmek için kullanılmaktadır. NBC topolojisi, bir sınıflayıcı topluluğu prensibine dayalı olarak bir sınıfı öğrenmek veya diğerleri arasından ayırt etmek amacıyla, büyük çok doruklu (multimodal) öznelilikler kümesi kullanılmasına imkan vermektedir. Bu şekilde, sistem ile kullanıcı etkileşimi oluştuğunda her biri artımlı geliştirilebilecek ve her bir sınıf için NBC bulutları oluşacaktır. Böylece, bir uzman kullanıcı tarafından herhangi bir geri besleme sistemi doğrudan geliştirmek ve sınıflandırma hatalarını azaltmak mümkündür. Sistem belli bir olgunluğa ulaştıktan sonra, gerektiğinde artımlı geliştirmeler gerçekleştirilerek depodaki diğer SAR görüntülerini sınıflandırmak için kullanılabilir. Mevcut uçak veya uydu tabanlı SAR sensörlerinden araştırma amaçlı sağlanan erişime açık gerçek veriler kullanılarak gerçekleştirilen testlerde önerilen sistemin farklı arazi türlerini yüksek başarı ve verimlilikle öğrenebildiği gösterilmiştir.</p>
Anahtar Kelimeler:	Sentetik açıklıklı radar (SAR), böl ve yönet, evrimsel makine öğrenme, bulut bilgi işlem
Fikri Ürün Bildirim Formu Sunuldu Mu?:	Hayır