



## Hyperspectral image classification using convolutional neural network and two-dimensional complex Gabor transform

Kazım Hanbay

Bingöl University, Faculty of Engineering and Architecture, Computer Engineering Department, Bingol, 12000, Turkey

### Highlights:

- Deep-learned and Gabor filtering-based feature fusion approach is proposed.
- A seven layer deep convolutional network is designed to learn deep features.
- Classification performance of the proposed hybrid method is comprehensively evaluated.

### Keywords:

- Hyperspectral image classification
- Deep learning
- Gabor filtering

### Article Info:

Research Article

Received: 05.11.2018

Accepted: 22.04.2019

### DOI:

10.17341/gazimmfd.479086

### Correspondence:

Author: Kazım Hanbay

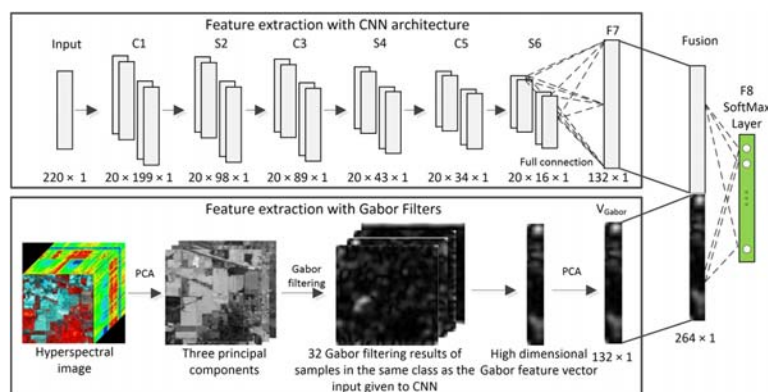
e-mail:

khanbay@bingol.edu.tr

phone: +90 505 093 1244

### Graphical/Tabular Abstract

In this paper, a new hyperspectral image classification method based on 2-dimensional complex Gabor filtering and deep convolutional neural network is proposed. To extract a set of features at multiple orientations and frequencies, the 2-D complex Gabor filtering is performed on the first three principal components of the hyperspectral image. The designed deep neural network contains seven layers with weights, including the input layer, the three convolutional layers C1, C3 and C5, the three max pooling layer S2, S4 and S6, the full connection layer F7. In this paper, the deep-learned and Gabor features are simultaneously calculated for the input samples. The proposed Gabor-filtering-assisted deep neural network classifier has been tested on two hyperspectral datasets. The experiments have showed that the proposed deep neural network yields highly accurate classification results in most cases.



**Figure A.** The overall flowchart of the proposed Gabor filtering and ESA-based hyperspectral image classification method

**Purpose:** The aim of this study is to investigate the contribution of the 2-dimensional complex Gabor transform to deep convolutional neural network architectures. The performance of the proposed hybrid method has been tested on the problem of classification of hyperspectral images.

### Theory and Methods:

Two different kinds of features are calculated. The first one is the deep-learned features. The second one is the Gabor transform features, which are extracted by applying at multiple orientations and frequencies on three principal components of the hyperspectral image. A softmax classifier is trained on the obtained hybrid features for hyperspectral image classification.

### Results:

Hyperspectral images have successfully classified. The proposed Gabor-filtering-assisted deep learning network generally provides higher accuracy than conventional deep learning-based classifier, support vector machine classifier and elastic net representation-based classifier.

### Conclusion:

The experimental results demonstrated that conventional deep learning architectures can still be improved using hybrid feature extraction strategies. The superiority of the proposed method comes from the combination of Gabor transform-based textural features and deep-learned features.



## Evrişimsel sinir ağı ve iki-boyutlu karmaşık Gabor dönüşümü kullanılarak hiperspektral görüntü sınıflandırma

Kazım Hanbay\*

Bingöl Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Bingöl, 12000, Türkiye

### Ö N E Ç İ K A N L A R

- Derin öğrenilen ve Gabor filtreleme temelli özellik birleştirme yaklaşımı önerilmiştir
- Derin özellikleri öğrenmek için yedi katmanlı bir derin evrişimsel ağ tasarlanmıştır
- Önerilen hibrit yöntemin sınıflandırma performansı kapsamlı bir şekilde değerlendirilmiştir

### Makale Bilgileri

Araştırma Makalesi  
Geliş: 05.11.2018  
Kabul: 22.04.2019

### DOI:

10.17341/gazimmfd.479086

### Anahtar Kelimeler:

Hiperspektral görüntü sınıflandırma, derin öğrenme, gabor filtreleme

### ÖZET

Bu çalışmada 2-boyutlu karmaşık Gabor filtreleme ve derin evrişimsel sinir ağları kullanılarak yeni bir hiperspektral görüntü sınıflandırma yöntemi önerilmiştir. Spesifik olarak, derin bir öğrenme modeli olarak, evrişimsel sinir ağının kendine özgü üst düzey özellikler çıkarması amaçlanmaktadır. Derin öğrenilen ve Gabor özellik çıkarma metodolojileri giriş hiperspektral örnekler üzerinde eş zamanlı olarak gerçekleştirilmiştir. Gabor özellikleri hiperspektral görüntünün sadece ilk üç temel bileşeni üzerinde karmaşık Gabor filtreleme uygulanarak hesaplanmaktadır. Önerilen hibrit model Gabor dönüşümünü kenarlar, köşeler ve doku gibi bölgesel görüntü özelliklerini elde etmek için kullanmaktadır. Görüntülerin Gabor özellikleri çoklu yönelimlerde ve frekanslarda hesaplanır. Sonra derin özellikler ve Gabor özellikleri daha güçlü ve ayırt edici özellik vektörü elde etmek için birleştirilir. Hibrit özellik vektörü hiperspektral görüntü sınıflandırmak için softmax sınıflandırıcıya giriş olarak kullanılır. Önerilen derin öğrenme mimarisinin parametreleri küçük bir eğitim kümesi kullanılarak optimize edilmiştir. Böylece önerilen evrişimsel sinir ağının ezberleme problemi bir dereceye kadar azaltılmıştır. İki popüler hiperspektral veri seti üzerinde gerçekleştirilen deneyler önerilen yöntemin bazı geleneksel yöntemlerden daha iyi sınıflandırma performansı elde edebildiğini göstermiştir. Sınıflandırma sonuçları önerilen hibrit modelin hiperspektral görüntülerin sınıflandırılması ve özelliklerinin çıkarılması için etkili bir yöntem olduğunu göstermektedir.

## Hyperspectral image classification using convolutional neural network and two-dimensional complex Gabor transform

### H I G H L I G H T S

- Deep-learned and Gabor filtering-based feature fusion approach is proposed
- A seven layer deep convolutional network is designed to learn deep features
- Classification performance of the proposed hybrid method is comprehensively evaluated

### Article Info

Research Article  
Received: 05.11.2018  
Accepted: 22.04.2019

### DOI:

10.17341/gazimmfd.479086

### Keywords:

Hyperspectral image classification, deep learning, gabor filtering

### ABSTRACT

In this paper, a new hyperspectral image classification method based on 2-dimensional complex Gabor filtering and deep convolutional neural networks is proposed. Specifically, as a deep learning model, convolutional neural network is aimed to extract distinctive high-level features. Deep-learned and Gabor feature extraction methodologies are simultaneously performed on the input hyperspectral samples. Gabor features are calculated by implementing complex Gabor filtering only on the first three principal components of the hyperspectral image. The proposed hybrid model uses Gabor transform to obtain local image features, such as edges, corners and texture. The Gabor features of the images are calculated at multiple orientations and frequencies. Then, deep features and Gabor features are fused to obtain a more robust and discriminative feature vector. Hybrid feature vector is used as input to a softmax classifier for hyperspectral image classification. The parameters of the proposed deep learning architecture are optimized using a small training set. Thus, the over-fitting problem of the proposed convolutional neural network has been reduced to some extent. Experiments performed on two popular hyperspectral datasets show that the proposed method can achieve better classification performance than some conventional methods. Classification results demonstrates that the proposed hybrid model is an efficient method for feature extraction and classification of hyperspectral images.

\*Sorumlu Yazar/Corresponding Author: khanbay@bingol.edu.tr / Tel: +90 505 093 1244

## 1. GİRİŞ (INTRODUCTION)

Hiperspektral görüntüleme elektromanyetik spektrumun görünür ışık ve kızılaltı bant aralıklarının da dâhil olduğu geniş bir bölümünden alınan görüntüleri toplamakta ve işlemekte kullanılmaktadır. Uydu sensörleri tarafından elde edilen hiperspektral görüntüler her piksel için yüzlerce farklı spektral bantlara sahiptir. Bu bantlarda saklanan zengin spektral bilgi farklı maddelerin fiziksel özellikleri ile ilişkilidir. Bu nedenle gözlemlenen bölgedeki maddeleri ve alanları ayırt etmede bu spektral bilgiler kullanılabilir. Özellikle bu görüntülerin sunmuş olduğu yüksek spektral çözünürlük, geleneksel görüntülerin içermediği detaylı spektral özellikleri ortaya çıkarabilmektedir. Bunun sonucunda son yıllarda hedef tespiti [1], hassas tarım uygulamaları [2] ve yer altı maden tespiti [3] gibi çalışmalarda hiperspektral görüntüler akıllı yöntemler ile analiz edilip sınıflandırılarak kullanılmaktadır.

Hiperspektral görüntülerin sınıflandırılmasında en yakın komşu, karar ağaçları, destek vektör makinesi (DVM) ve yapay sinir ağları (YSA) gibi farklı makine öğrenmesi temelli metotlar kullanılmaktadır. En yakın komşu metodu Öklid uzaklığı kullanan en basit sınıflandırıcıdır [4]. DVM çekirdek metodu kullanarak yüksek boyutlu uzayda farklı hiperspektral sınıflar arasında sınıflandırma sınırı belirlemektedir [5]. DVM kadar yüksek sınıflandırma doğruluğu elde edememelerine rağmen, YSA kullanılarak yapılan hiperspektral görüntü sınıflandırma çalışmaları da bulunmaktadır [6]. Bu tür geleneksel spektral sınıflandırıcıların çoğu hiperspektral görüntülerdeki bazı bölgelerin tespit edilip ayırt edilmesinde halen yetersiz kalabilmektedir. Bunun temel nedeni sınırlı sayıda etiketlenmiş hiperspektral görüntü verisinin bulunmasıdır [7]. Ayrıca hiperspektral görüntülerin yüksek spektral çözünürlükleri farklı nesne ve yapıları tanımlamada olanaklar sunmakla birlikte, bu yüksek boyutlu verinin işlenmesi oldukça yüksek işlem maliyetini de beraberinde getirmektedir. Bu problemleri çözmek için birçok özellik çıkartma metodu geliştirilerek hiperspektral verilerdeki yüksek boyutluluk problemi çözülmeye çalışılmıştır. Özellikle temel bileşenler analizi (TBA) gibi boyut indirme metotları kullanılarak en az spektral bilgi kaybı ile veri boyutları düşürülmekte ve işlem maliyeti azaltılmaktadır [8].

Hiperspektral görüntü sınıflandırmada karşılaşılan bir diğer zorluk ise farklı maddelerin benzer spektral değerlere sahip olması durumudur. Bu durumda sadece spektral bilgi ile sınıflandırma yapmak zordur. Bu problemi çözmek için uzaysal ve spektral bilgileri birlikte kullanan markov rastgele alanlar (MRA) yöntemi kullanılmıştır [9]. Li vd. uzaysal ve spektral bilgileri birlikte kullandıkları çalışmalarında aşırı öğrenme makinesi ile ağırlıklandırılmış AdaBoost algoritması geliştirmiştir [10]. Bu algoritma ile karma çekirdek mimarisi önerilmiştir. Bu sayede uzaysal piksel bilgisini ve spektral görüntü bantlarını dengeli bir şekilde bir araya getirerek hiperspektral görüntüler sınıflandırılmıştır. Bu yöntem DVM yöntemine göre daha yüksek sınıflandırma

başarısı elde etmiştir. Hiperspektral görüntülerdeki sınıf içi değişimleri daha iyi vurgulamak ve sınıflar arası karışımı engellemek için geliştirilen bir çalışmada ise işbirlikçi temsil ve ayrık temsil olarak adlandırılan yöntemler birlikte kullanılmıştır [11]. Daha az sayıda eğitim örneği kullanılarak sınıflandırıcı ağırlıkları elde edilmiştir. Böylece aralarında yüksek korelasyon ilişkisi bulunan karmaşık veri sınıfları arasında bile etkin sonuçlara ulaşılmıştır. Debba vd. [12] İspanya'nın Rodalquilar bölgesindeki alunit mineralinin tespiti için hiperspektral verileri sınıflandırmışlardır. 350×225 çözünürlüğünde ve 126 spektral band içeren görüntüler spektral açılı haritalaması yapan bir sınıflandırıcı ile sınıflandırılmıştır. Önceden belirlenen referans görüntüler hem açılı hem de eşikleme değerine göre yapılan sınıflandırma işlemleri esnasında kullanılmıştır.

Yukarıda bahsedilen metotlar görüntü özelliklerini sınıflandırmadan bağımsız bir dizi işlem ile çıkartılmaktadır. Ayrıca gerekli durumlarda uzman deneyiminden faydalanılmakta olup parametre ayarlaması gibi bazı işlemlere de ihtiyaç duyabilmektedirler. Derin öğrenme metotları daha dinamik ve yüksek seviyeli görüntü özellikleri sunarak hiperspektral görüntülerin sınıflandırılmasında yoğun bir şekilde kullanılmaktadır [13, 14]. Derin sinir ağları etkin ve adaptif öğrenme modelleridir. Çok katmanlı yığılmış oto-kodlayıcı, derin Boltzmann makineleri ve evrimsel sinir ağları yaygın bir şekilde kullanılan derin sinir ağları arasında yer almaktadır. Evrimsel sinir ağları (ESA) iki boyutlu sinir ağı olup hem uzaysal hem de spektral bilgiyi daha iyi yakalayabilmektedir. Chen vd. [15] TBA, oto-kodlayıcı ve lojistik regresyonu birlikte kullanarak hiperspektral görüntü sınıflandırması yapan bir yöntem geliştirmişlerdir. ESA kullanan bir diğer çalışmada ise beş katmanlı bir ESA mimarisi inşa edilerek hiperspektral görüntülerini optimum şekilde analiz edebilecek bir ağ tasarlanmıştır [16]. Zabalza vd. [17] yığılmış oto-kodlayıcı kullanarak hiperspektral görüntüyü farklı bölgelere bölütlemişlerdir. Derin öğrenme modellerinin sahip olduğu ağır parametre yükü hafifletilerek geliştirilen bir ESA mimarisinde ise hiperspektral görüntüleme komşu piksellerin iç korelasyon bilgilerinden faydalanılmıştır [18]. Piksel çiftlerinin korelasyon bilgilerinin kullanımı klasik ESA mimarilerinde bulunmadığı için, geliştirilen yöntemin başarısı daha yüksektir. Son yıllarda derin öğrenme yöntemleri ile yapılan yüz tanıma, yaya-nesne tespiti ve hiperspektral görüntülerin sınıflandırılması gibi bazı çalışmalarda daha ayırt edici özelliklerinin hesaplanması için ağ mimarisine bazı özellik çıkartma yöntemleri entegre edilmiştir. Bu tür çalışmalarda temel motivasyon sınırlı örnek sayısının olduğu çalışmalarda derin ağ mimarisinin ağırlıklarını elde edip ağı eğitmek için ihtiyaç duyulan uzaysal özellik bilgilerinin ağ katmanlarına sağlanmasıdır [19]. Gabor dönüşümündeki farklı yön ve ölçeklerdeki filtreler sayesinde ESA mimarisine giriş olarak bu filtreler ile hesaplanmış olan dönme ve yönelim bağımsız uzaysal özellikler verilmiştir. Böylece bölütleme-sınıflandırma çalışmalarında zengin uzaysal bilgilerin kullanılması sağlanarak kenar bölgelerinde görüntü

sınıflandırma sonuçları önlenmiştir. Kullanılan ESA mimarileri incelendiğinde, mimarideki ikinci ve üçüncü evrişim (konvolüsyon) katmanlarının genellikle dokusal özellikleri hesaplamak için kullanıldıkları görülmektedir. İlk evrişim katmanında ise daha çok kenar ve nesne (blob) tespiti yapan filtreler kullanılmaktadır. Dolayısıyla elde edilen Gabor özelliklerinin ESA mimarisinin ikinci veya üçüncü katmanlarına verilmesi görüntülerdeki bazı sınıflarda daha etkili sonuçlar verebilecektir. Klasik ESA algoritması 3 boyutlu spektral-uzaysal özellik çıkarımı için uygun değildir. Bu yüzden dalgacık dönüşümü ile güçlendirilen bir ESA mimarisi 3 boyutlu özellik çıkararak hiperspektral görüntülerin sınıflandırılmasında kullanılmıştır [20]. Ayrıca dönüşüm sonucu elde edilen yüksek boyutlu alt bantlardan özellik seçme prosedürü kullanımına gerek duyulmamıştır. ESA mimarileri yaya cinsiyet tanıma işleminde cinsiyet belirlemede yardımcı olan özel karakteristikleri göz önünde bulunduramaz. Bu nedenle özellikle düşük çözünürlüklü durumlarda bölgesel uzaysal özellikler yönlü histogram yönelimi yöntemi ile elde edilip geliştirilen ESA temelli bir yaya cinsiyet tanıma yöntemine kazandırılmıştır [21]. Yayaların cinsiyetlerinin tanınması için giriş görüntüsünün eş zamanlı ve birbirinden bağımsız olarak hem derin öğrenme tabanlı özellik çıkarımı hem de yönlü histogram yönelimi özellikleri hesaplanmıştır. Özellikler elde edildikten sonra bir birleştirme katmanında her iki özellik vektörü birleştirilmiş ve  $1 \times 2560$  boyutunda özellik vektörü softmax sınıflandırıcıya verilmiştir.

Yukarıda bahsedilen yöntemler dışında literatürde derin öğrenme algoritmalarının geleneksel yöntemler ile güçlendirildiği birçok çalışma mevcuttur. Özellikle ele alınan probleme ilişkin kullanılacak derin öğrenme mimarisinin zayıf kaldığı nokta iyi tespit edildiğinde, bu güçlü mimari ile daha güvenilir ve yüksek doğrulukta sonuçlar elde edilecektir. Hiperspektral görüntü sınıflandırmada yapılan derin öğrenme tabanlı çalışmalar genellikle başarılı sonuçlar vermiştir. Ancak hiperspektral görüntülerde benzer spektral özelliklere sahip olmakla birlikte farklı sınıflar ifade eden bölgelerin tespit edilmesinde halen çalışmalar yapılmasına ihtiyaç duyulmaktadır. Tarımsal ürünler içeren hiperspektral görüntülerde bu ihtiyaç daha belirgin bir şekilde kendini göstermektedir. Çünkü birçok tarım ürünü benzer görsel özelliklere sahiptir. Bunun sonucunda bu ürünlerin spektral görünümünde yanılmalar olabilmektedir. Bu tür durumlarda kenar-renk özelliklerinin yanında, matematiksel altyapısı güçlü dokusal özelliklerin de çıkarılması gerekmektedir. Bu noktalardan hareketle, bu çalışmada derin öğrenme modellerinden olan ESA algoritmasının dokusal özellik hesaplama kapasitesine literatürde bulunan en güncel Gabor filtresi kullanılarak katkıda bulunulmuştur. ESA mimarisinin dokusal özellikleri hesaplayan üçüncü evrişim katmanından elde edilen özellikler ile hiperspektral görüntünün ilk üç temel bileşen görüntüsünün Gabor filtreleme sonuçları birleşme katmanı kullanılarak birleştirilmiştir. Birleştirilen özellikler bu noktadan itibaren ağız eğitiminde aktif olarak kullanılmıştır. Kullanılan iki boyutlu hızlı Gabor filtreleri sayesinde hiperspektral

görüntülerin en ayırt edici dokusal bilgileri ölçekleme ve dönme bağımsız bir şekilde hesaplanarak ESA mimarisinin dokusal özellik hesaplama yeteneği güçlendirilmiştir. Yapılan literatür incelemesinde görülebildiği kadarı ile ifade etmek gerekirse; kullanılan Gabor filtrelerinin hem türü hem de bu filtrelerin ESA mimarisine entegre edilişi bakımından yapılan bu çalışma ilk olma özelliği taşımaktadır. Çalışmanın geri kalan kısmı şu şekilde organize edilmiştir. Bölüm 2’de ilk olarak bu çalışmada kullanılan güncel ve hızlı iki boyutlu Gabor dönüşümü detaylı bir şekilde irdelenmiştir. Bölüm 3’te Gabor dönüşümü ile dokusal özelliklerin elde edilmesi kısa bir şekilde sunulmuştur. Daha sonra Gabor dönüşümü ile elde edilen ayırt edici özellikler ile dokusal özellik çıkarım yeteneği güçlendirilmiş olan yeni ESA mimarisinin çalışma prensibi ve temel ağ yapısı hakkında bilgilere yer verilmiştir. Bölüm 4’te önerilen yeni yöntemin iki hiperspektral veri kümesi üzerindeki sınıflandırma başarısı diğer yöntemlerle karşılaştırmalı olarak sunulmuştur. Bölüm 5’te ise önerilen yöntemden elde edilen sonuçlara ilişkin değerlendirmelere ve önerilere değinilmiştir.

## 2. HIZLI 2-BOYUTLU (2-B) KARMAŞIK GABOR FİLTRE BANKASI (FAST 2-DIMENSIONAL (2-D) COMPLEX GABOR FILTER BANK)

İnsan görme sistemine benzer bir çalışma prensibine sahip olan Gabor filtreleri her görüntü pikseli için iyi bir uzaysal-frekans analiz kabiliyeti sağlar. Görüntülerden çoklu yönlere ve frekanslarda bir dizi özellik çıkarmak için Gabor filtreleri birçok bilgisayar görmesi uygulamasında yoğun bir şekilde kullanılmıştır [19, 22, 23]. Geleneksel Gabor filtre bankası üzerinde birçok çalışma yapılarak Gabor filtrelerinin birçok farklı çeşidi geliştirilmiştir. Burada temel amaç her bir pikseli tarayarak yapılan filtreleme işleminin hızını ve verimliliğini arttırmaktır. Özellikle Gauss fonksiyonu ve sinüsoidal modülasyonların entegre edildiği Gabor filtreleri oldukça hızlı çalışan Gabor filtreleri arasındadır [24]. Yapılan güncel çalışmalarla Gabor filtreleri halen etkinliğini korumakta ve birçok görüntü işleme probleminde kullanılmaktadır.

Son yıllarda hiperspektral görüntülerin sınıflandırılmasında da Gabor filtrelerinden faydalanılmıştır [19, 25]. Bu çalışmalarda Gabor filtrelerinin kullanım amacı genel olarak piksellerin uzaysal, spektral ve hibrid uzaysal-spektral karakteristiklerinin elde edilmesi olarak vurgulanmıştır. Gabor filtreleri içerdikleri farklı ölçek ve açılarda frekans bileşenleri ile yukarıda sayılan piksel bilgilerini sağlayabilmektedir. Gabor filtre bankası kısa dönemli Fourier dönüşümünün geliştirilmiş hali olduğu için incelenen görüntülerde Fourier dönüşümünün avantajlarını sunmaktadır. Hiperspektral görüntülerdeki bazı ayırt edilmesi zor piksel bölgelerinin tanınmasında bu bilgiler katkı sağlamıştır. Kim vd. [23] tarafından geliştirilen iki boyutlu karmaşık Gabor filtreleri çeşitli yüz ve doku görüntüleri üzerinde test edilmiş ve başarılı sonuçlar elde etmiştir. Bu çalışmada ise geliştirilmiş olan bu güncel ve

güçlü Gabor filtreleri literatürden araştırıldığı kadarıyla ilk defa hiperspektral görüntülerin sınıflandırılmasında derin öğrenme mimarileri ile birlikte kullanılmış ve başarılı sonuçlar vermiştir. Bu noktada kullanılan Gabor filtrelerinin en temel bileşenleri hakkında bilgi verilecektir. Daha detaylı bilgi [23] nolu kaynaktan elde edilebilir.

$\theta$  yönü ve  $\lambda$  dalga boylu  $\omega = 2\pi/\lambda$  frekansı için, bir  $f$  görüntüsünün iki boyutlu Gabor filtreleme çıktısı  $F_{\omega,\theta,\sigma}$  aşağıdaki gibi ifade edilir:

$$F_{\omega,\theta,\sigma}(x, y) = \sum_{k,l} f(k, l) C_{\omega,\theta}(x - k, y - l) G_{\sigma}(x - k, y - l) \quad (1)$$

Burada  $G_{\sigma}(x, y)$  sıfır ortalamalı ve  $\sigma$  standart sapmalı 2-B Gauss fonksiyonudur. Gabor filtrelerinin tasarımında literatüre uygun olarak hem  $x$  hem de  $y$  yönleri için eş yönlü olan Gauss çekirdek fonksiyonu kullanılmıştır. Karmaşık üstel fonksiyon  $C_{\omega,\theta}(x, y) = H_{\omega,\theta}(x) V_{\omega,\theta}(y)$  şeklinde tanımlanmış olup,  $H_{\omega,\theta}(x) = e^{i\omega x \cos \theta}$  ve  $V_{\omega,\theta}(y) = e^{i\omega y \sin \theta}$  olarak açık yazılmaktadır [23]. Filtre fonksiyonlarının ayırt ediciliklerini sağlamak ve esnek filtre tasarımı gerçekleştirmek için Gauss ve karmaşık fonksiyonlar  $x$  ve  $y$  boyutlarında ayrılabilir bir yapıda tasarlanırlar. Dolayısıyla Eş. 1 aşağıdaki gibi yeniden yazılabilir:

$$J_{\omega,\theta,\sigma}(x, y) = \sum_k f(k, y) H_{\omega,\theta}(x - k) S_{\sigma}(x - k), \quad (2)$$

$$F_{\omega,\theta,\sigma}(x, y) = \sum_l J_{\omega,\theta,\sigma}(x, l) V_{\omega,\theta}(y - l) S_{\sigma}(y - l), \quad (3)$$

Kullanılan hızlı Gabor filtrelemede 1-B yatay ve dikey Gabor filtreleme uygulanarak sırasıyla  $J_{\omega,\theta,\sigma}(x, y)$  ve  $F_{\omega,\theta,\sigma}(x, y)$  elde edilir. Böylece görüntünün Gabor filtreleme yanıtları hesaplanmış olur. Bu çalışmada kullanılan yeni Gabor filtrelerinin en önemli özelliği uygulanan 1-B yatay ve dikey Gabor filtreleme hesaplamalarının hızlı gerçekleştirilmesidir.

1-B yatay Gabor filtrelemeyi hızlı yapabilmek için Eş. 2'deki  $J_{\omega,\theta,\sigma}(x, y)$  aşağıdaki gibi gerçek ve sanal kısımları ifade eden iki terime ayrıştırılmıştır:

$$\Re\{J_{\omega,\theta,\sigma}(x, y)\} = \cos(\omega_{\theta}^c x) \sum_k f_c(k) S_{\sigma}(x - k) + \sin(\omega_{\theta}^c x) \sum_k f_s(k) S_{\sigma}(x - k) \quad (4)$$

$$I\{J_{\omega,\theta,\sigma}(x, y)\} = -\cos(\omega_{\theta}^c x) \sum_k f_s(k) S_{\sigma}(x - k) + \sin(\omega_{\theta}^c x) \sum_k f_c(k) S_{\sigma}(x - k) \quad (5)$$

Burada  $\Re\{J_{\omega,\theta,\sigma}(x, y)\}$  ve  $I\{J_{\omega,\theta,\sigma}(x, y)\}$  ifadeleri gerçek ve sanal kısımları gösterir. Kim vd. [23] Eş. 4 ve Eş. 5'teki 1-B yatay Gabor filtrelemeyi yaparken  $f_c$  ve  $f_s$  gibi iki özyinelemeli Gauss filtreleme sinyali kullanmışlardır. Ancak Gabor filtreleri ile hiperspektral görüntülerin özellikleri hesaplanırken, görüntülerde bulunan gürültü etkisinin en aza

indirgenmesi sınıflandırma sonuçlarına olumlu yansımaktadır. Bu çalışmada hiperspektral görüntülerdeki gürültü bileşenlerini en aza indirmek amacıyla özyinelemeli Gauss filtreleme yerine [26] nolu kaynaktaki ayrılabilir Gauss fonksiyonu bileşenleri kullanılmıştır. Bu fonksiyonlar ile tasarlanan  $f_c$  ve  $f_s$  sinyalleri ile Eş. 4 ve Eş. 5 evrişim işlemine dayalı olarak elde edilmiştir. Deneysel çalışmalarda kullanılan ayrılabilir Gauss fonksiyonu ile evrişime dayalı yapılan  $\Re\{J_{\omega,\theta,\sigma}(x, y)\}$  ve  $I\{J_{\omega,\theta,\sigma}(x, y)\}$  hesaplamalarının Kim vd. [23] tarafından gerçekleştirilen filtrelemeye göre gürültüden daha az etkilendiği gözlemlenmiştir. Aynı işlem prosedürü 1-B dikey Gabor filtrelemede de uygulanmıştır.

1-B dikey Gabor filtrelemede, yatay filtrelemede olduğu gibi Eş. 3 deki  $F_{\omega,\theta,\sigma}(x, y)$  aşağıdaki gibi gerçek ve sanal kısımlara ayrılmıştır:

$$\Re\{F_{\omega,\theta,\sigma}(x, y)\} = \cos(\omega_{\theta}^s y) (f'_{cr}(x, y) + f'_{si}(x, y)) + \sin(\omega_{\theta}^s y) (f'_{sr}(x, y) - f'_{ci}(x, y)), \quad (6)$$

$$I\{F_{\omega,\theta,\sigma}(x, y)\} = \sin(\omega_{\theta}^s y) (f'_{cr}(x, y) + f'_{si}(x, y)) - \cos(\omega_{\theta}^s y) (f'_{sr}(x, y) - f'_{ci}(x, y)), \quad (7)$$

Burada  $\omega_{\theta}^s = \omega \sin \theta$  olarak tanımlanır. Eş. 5 ve Eş. 6'daki  $f'_{cr}$ ,  $f'_{sr}$ ,  $f'_{ci}$  ve  $f'_{si}$  terimleri özyinelemeli Gauss filtreleme sinyallerini göstermektedirler. Yukarıda bahsedildiği gibi bu çalışmada ise kullanılan yeni Gabor filtreleme yöntemindeki aksine, ayrılabilir Gauss fonksiyonu ile evrişime dayalı filtrelemeler yapılarak yöntem farklı bir bakış açısı kazandırılmıştır. Böylece daha hızlı ve hiperspektral görüntülerdeki gürültüye karşı etkili olan ayrılabilir Gauss filtreleri inşa edilip kullanılmış ve bu yöntemin hızında görece bir iyileştirme daha sağlanmıştır. Kullanılan Gauss temelli ayrılabilir filtreler hakkında detaylı bilgiye [26] nolu kaynaktaki bölüm 3.1'den ulaşılabilir.

Gabor filtreleme işlemi tüm görüntü üzerinde ve çok farklı frekans ve açıda filtreleme içerdiği için ortaya ciddi bir işlem yükü çıkmaktadır. Bazı matematiksel notasyonlar üzerinde yapılan dönüşümler ile bu işlemler hızlandırılmıştır. Filtreleme işlemindeki temel hesapsal maliyeti teşkil eden  $\theta$  açı ve  $\omega$  frekans değişkenleri formülleri sadeleştirmek için göz ardı edilebilir. Eş. 1'de  $F_{\theta}$  ifadesi Eş. 4 ile Eş. 7 arasında verilen ayrıştırma yöntemi kullanılarak hesaplanır ve saklanır.  $J_{\pi-\theta}$  ve  $F_{\pi-\theta}$  bileşenleri ise saklanan sonuçlar dönüştürülerek hesaplanır. \* ifadesi karmaşık eşleniği ifade etmek üzere,  $H_{\omega,\pi-\theta}(x) = H_{\omega,\theta}^*(x)$  eşitliği kullanılarak 1-B yatay Gabor filtreleme sonucu  $J_{\theta}$  için karmaşık eşlenik olarak aşağıdaki ifade elde edilir [23]:

$$J_{\pi-\theta}(x, y) = J_{\theta}^*(x, y), \quad (8)$$

Benzer dönüşüm kullanılarak, yani  $V_{\omega,\pi-\theta}(x) = V_{\omega,\theta}^*(x)$ , 1-B dikey filtreleme aşağıdaki gibi ifade edilir:

$$F_{\pi-\theta}(x, y) = \sum_l J_{\theta}^*(x - l) V_{\omega,\theta}(y - l) S_{\sigma}(y - l), \quad (9)$$

Yukarıdaki eşitlikte karmaşık eşlenik işaret olan  $J_{\theta}^*$  ya 1-B dikey Gabor filtreleme uygulanır ve  $F_{\pi-\theta}$  daha az işlem maliyeti ile hesaplanır [23]. Son olarak Eş. 6 ve Eş. 7'de benzer dönüşüm uygulanır ve aşağıdaki eşitlikler elde edilir:

$$\Re\{F_{\pi-\theta}(x, y)\} = \cos(\omega_{\theta}^s y)(f'_{cr}(x, y) - f'_{si}(x, y)) + \sin(\omega_{\theta}^s y)(f'_{sr}(x, y) + f'_{ci}(x, y)), \quad (10)$$

$$I\{F_{\pi-\theta}(x, y)\} = \sin(\omega_{\theta}^s y)(f'_{cr}(x, y) - f'_{si}(x, y)) - \cos(\omega_{\theta}^s y)(f'_{sr}(x, y) + f'_{ci}(x, y)), \quad (11)$$

### 3. ESA VE GABOR DÖNÜŞÜMÜ KULLANILARAK GELİŞTİRİLEN HİBRİT ÖZELLİK ÇIKARMA METODOLOJİSİ (THE DEVELOPED HYBRID FEATURE EXTRACTION METHODOLOGY USING ESA AND GABOR TRANSFORM)

Önerilen hiperspektral görüntü sınıflandırma modeli Şekil 1'de gösterilmiş olup genel olarak iki adımdan oluşmaktadır. Şekil 1'deki akış şemasının alt kısmında (Gabor Filtreleri ile Özellik Çıkartma) Gabor dönüşümü ile hiperspektral görüntülerin sadece ilk üç temel bileşeninin çoklu yön ve frekanslarda dokusal özellikleri hesaplanmaktadır. Bu temel bileşenler temel bileşenler analizi (TBA) yöntemi kullanılarak elde edilmiştir. Bu işlem sonucunda  $132 \times 1$  boyutunda özellik vektörleri elde edilmektedir. Şekil 1'deki akış şemasının üst kısmında ise (ESA Mimarisi ile Özellik Çıkartma) orijinal hiperspektral görüntünün tüm alt bantlarının sadece ESA mimarisi ile yüksek seviyeli derin özellikleri hesaplanmaktadır. Dolayısıyla ESA girişine Gabor dönüşümünden elde edilen herhangi bir özellik verisi verilmemektedir. Şekil 1'de Giriş katmanında görülen  $220 \times 1$  bilgisi Indian Pines veri kümesinin alt bant sayısını ifade etmektedir. Pavia Üniversitesi verisi için bu giriş  $103 \times 1$  olup diğer katmanlarda bu giriş boyutuna göre hesaplanmaktadır. Birleşme katmanında ise hem derin özellikler hem de Gabor temelli özellikler birleştirilerek softmax sınıflandırıcıya giriş olarak verilmektedir. Kullanılan ESA mimarisinin eğitim işlemi çok sayıda veriye ihtiyaç duyulmaktadır. İhtiyaç duyulan yüksek boyutlu veri kümesi bazı çalışmalarda sentetik hiperspektral görüntü örnekleri oluşturularak karşılanmıştır. Ancak bu çalışmada hiperspektral görüntünün tüm alt bantları kullanılarak bu ihtiyaç giderilmeye çalışılmıştır.

#### 3.1. Gabor Özelliklerinin Çıkarılması (Extraction of Gabor features)

Hiperspektral görüntülerin Gabor özelliklerini çıkartmak için farklı frekans ve açılal yönlerde bir dizi Gabor filtresine ihtiyaç duyulmaktadır. Bölüm 2'de detaylı olarak belirtildiği gibi,  $\theta$  yönü ve  $\lambda$  dalga boyu  $\omega = 2\pi/\lambda$  frekansı için, bu çalışmada bir  $f$  hiperspektral görüntüsünün ilk üç temel bileşeninin Gabor özellikleri Gabor filtre bankası ile hesaplanır. Gabor filtre bankası  $\Phi_{u,v}$  4 farklı frekans ve 8 farklı açılal yön kullanılarak inşa edilmiştir. Görüntü üzerinde evrişim işlemi yolu ile filtreleme yapılırken kullanılan Gabor penceresi boyutu  $M = 8 \times 8$  olarak ayarlanmıştır. Filtre bankasındaki 8 farklı açı değeri ise,  $\theta =$

$0, \pi/8, 2\pi/8, 3\pi/8, 4\pi/8, 5\pi/8, 6\pi/8, 7\pi/8$  olarak ayarlanmıştır. Hiperspektral bir görüntünün bir temel bileşeni  $f^{TBA}(x, y)$  ile gösterilirse, Gabor filtresi  $\Phi_{u,v}(x, y)$  ile  $f^{TBA}(x, y)$  nin evrişim işlemi aşağıdaki gibi tanımlanır:

$$G_{u,v}(x, y) = |f^{TBA}(x, y) * \Phi_{u,v}(x, y)| \quad (12)$$

Burada  $G_{u,v}(x, y)$  elde edilen Gabor özelliğini göstermekte olup,  $u$  açılal yönünde ve  $v$  frekansındaki Gabor filtresi ile hiperspektral görüntünün temel bileşeni  $f^{TBA}(x, y)$  nin evrişim işlemine tabi tutulması ile elde edilir. Eş. 12'de  $|$  ise evrişim sonucunun büyüklüğünü ifade etmektedir.

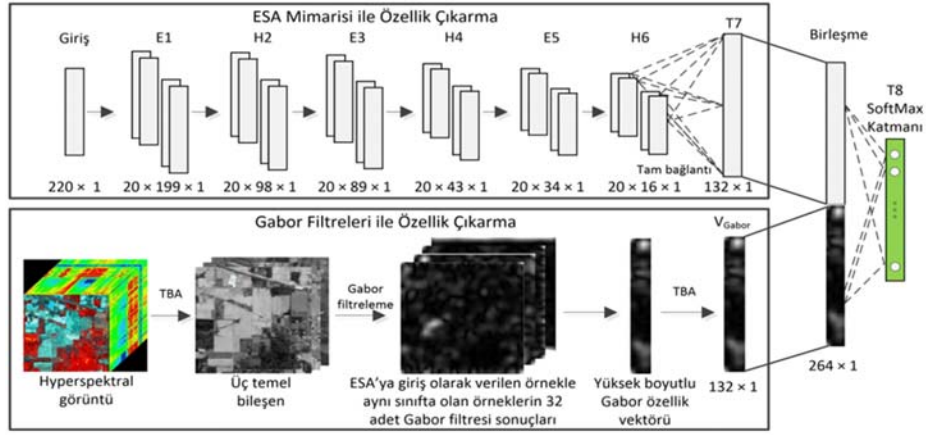
Gabor özellikleri hesaplanırken, eş-zamanlı olarak ESA mimarisinin eğitim işlemi sırasında kullanılan eğitim verisinin ait olduğu sınıfa ait farklı örneklerin toplam 32 farklı Gabor filtresi kullanılarak filtrelenmesi sonucu toplam 32 adet Gabor özellik matrisleri elde edilir. Bu çalışmada filtre sonuçlarının gerçek ve karmaşık (sanal) sonuç matrislerinin büyüklükleri (magnitüde) Eş. 6 ve 7'de olduğu gibi hesaplanmıştır. Elde edilen büyüklük matrisi boyut küçültme işlemi sonrasında vektörleştirilerek ESA mimarisindeki tam bağlı katmandan (T7) elde edilen özellik vektörü ile birleştirilir. Softmax sınıflandırıcıya giriş olarak  $264 \times 1$  boyutunda olan bu hibrit vektör verilir. Böylece ağı eğitim işlemi sırasında aynı sınıfa eğitim örneklerin hem derin özellikleri hem de Gabor temelli özellikler kullanılmış olur. Test işlemi sırasında da aynı hibrit ve eş-zamanlı özellik çıkarma yöntemi izlenir. Şekil 2'de aynı frekans değerinin 4 farklı açılal yönünde tasarlanan Gabor filtreleri ve bu filtreler kullanılarak hiperspektral bir görüntünün 4 farklı açılal yöndeki Gabor filtresi özellikleri görülmektedir.

#### 3.2. Özellik Öğrenme ve ESA Mimarisi Temelinde Sınıflandırma


(Classification Based on Feature Learning and ESA Architecture)

Derin öğrenme algoritmaları arasında en sık kullanılanı Evrişimsel Sinir Ağlarıdır (ESA). ESA mimarisi birçok katmandan oluşan bir mimariye sahip olup klasik Yapay Sinir Ağlarının (YSA) bir türüdür. Bu katmanlar ele alınan probleme göre sayıları değişebilen evrişim (konvolüsyon) katmanları, havuzlama (pooling) katmanları, doğrultulmuş doğrusal ünite (ReLU) ve tam bağlı (fully-connected) katmanlardır [27]. Mevcut ESA mimarileri herhangi bir düzenleme yapılmadan doğrudan hiperspektral görüntü sınıflandırma problemine uygulandıklarında başarı oranı istenen düzeylerde olmamaktadır. Özellikle benzer renk ve dokusal içerik bulunan sınıflar için evrişimsel özelliklere ek olarak daha farklı özelliklerin de elde edilmesi gerekmektedir. Ayrıca ESA mimarileri çok büyük ölçekte eğitim örneğine ihtiyaç duyarken, hiperspektral görüntü veri tabanlarının sınırlı sayıda örnek içermesi derin öğrenme mimarisinin eğitilmesinde yetersiz kalınmasına yol açmaktadır. Bu çalışmada bahsedilen zorlukların üstesinden gelebilecek bir mimariye sahip olmakla birlikte, özellik çıkarma ve öğrenme kapasitesi yüksek bir ESA mimarisi tasarlanmıştır.





**Şekil 1.** Önerilen Gabor filtreleme ve ESA temelli hiperspektral görüntü sınıflandırma yönteminin genel akış şeması. (The overall flowchart of the proposed Gabor filtering and ESA-based hyperspectral image classification method.)



**Şekil 2.** Hiperspektral görüntü için 2-B karmaşık Gabor filtre bankası ile hesaplanan filtre çıkışları. a)-d) 4 farklı yönlü Gabor filtreleri e) Indian Pines görüntüsünün birinci temel bileşeni f)-i) Indian Pines görüntüsünün birinci temel bileşeninin Gabor filtreleme sonuçları. (2-D complex Gabor filter bank outputs computed with 2-D Gabor filter bank for hyperspectral image. (a)-(d) Gabor filters with 4 different orientations (e) First principal component of the Indian Pines image (f)-(i) Gabor filtering outputs of first principal component of the Indian Pines image.)

Şekil 1'de görüldüğü gibi, bu çalışmada kullanılan ESA mimarisi üç evrişim katmanı (E1, E3, E5), üç havuzlama katmanı (S2, S4, S6) ve 132 nöron hücreğine sahip bir tam bağlı katman (T7) içermektedir. ESA mimarisinin giriş katmanı bir boyutlu ses sinyal verilerine benzer şekilde  $(n_1, 1)$  boyutundadır. Tüm evrişim katmanlarında 20 tane  $f_i \times 1$  boyutunda evrişim filtresi kullanılmıştır. Tek boyutlu evrişim katmanlarındaki düğüm sayısı  $DS \times FS$  formülü ile bulunur.  $FS$  değişkeni bu katmandaki filtre sayısını göstermektedir.  $DS$  değeri ise aşağıdaki formül ile hesaplanır:

$$DS = \frac{W-F+2P}{s} + 1 \quad (13)$$

Burada  $W$  değeri evrişim katmanına giren  $W \times d$  boyutundaki giriş verisinin birinci boyutudur.  $d$  değeri ise giriş katmanında giriş katmanının derinliğini, sonraki katmanlarda ise bir önceki katmanın derinlik boyutunu ifade eder. Eş. 13'te  $F$  filtre boyutunu,  $P$  genişletme (padding)

katsayısını,  $S$  ise adım genişliğini (stride) ifade etmektedir. Havuzlama katmanlarındaki düğüm sayısı ise  $DS \times d$  ile ifade edilir. Evrişim katmanlarındaki eğitilecek parametre sayısı  $PS$  aşağıdaki formül ile hesaplanır:

$$PS = FS \times (F \times d + 1) \quad (14)$$

Literatürdeki benzer ESA mimarilerinden faydalanılarak yukarıda katman bazında detayları verilen ağız temel parametreleri ayarlanmıştır [16]. Bu çalışmada pencere adım genişliği evrişim katmanlarında 1, havuzlama katmanlarında ise 2 olarak sabit tutulmuştur. Deneysel çalışmalarda elde edilen tecrübeler ışığında filtre boyutları ayarlanarak ilk evrişim katmanlarında (özellikle E1 ve E3) hiperspektral görüntülerde birbirine benzeyen alanlar arasındaki ayırt edici kenar ve renk bilgilerinin detaylı olarak çıkarılması sağlanmıştır. E5 evrişim katmanında ise yine filtre boyutu sayesinde daha çok dokusal özelliklerin çıkarılması amaçlanmıştır. Havuzlama katmanlarında  $f_i \times 1$  boyutunda

filtre kullanarak bir önceki evrişim katmanından elde edilen evrişimsel özelliklerin boyutları küçültülür [21]. Bu filtre kayan pencere yöntemi ile gezdirilerek filtrenin karşılık geldiği penceredeki piksellerin en büyüğünün seçildiği (max pooling) havuzlama yöntemi uygulanır. Elde edilen daha küçük boyutlu özellik haritası bir sonraki evrişim katmanında işleme alınır. Evrişim katmanlarından elde edilen özellikler ara normalizasyon ve ReLU (Rectified Linear Unit) aktivasyon fonksiyonundan geçirilir. Normalizasyon işlemi ağ içerisinde katmanlar arası işlemler sonucunda meydana gelen veri dağılımını normalize ederek sınıflandırma sonuçlarına olumlu katkıda bulunmaktadır. Normalize edilen özellik haritaları ReLU aktivasyon fonksiyonundan geçirilir. Tam bağlı katman T7’de ki her nöron S6 alt örnekleme katmanındaki tüm nöronlara tam olarak bağlanır. Yine bu katmanda ReLU aktivasyon fonksiyonu ve normalizasyon işlemi uygulanır.

Bu çalışmada iki farklı hiperspektral veri seti üzerinde sınıflandırma çalışmaları yapılmıştır. Bu nedenle her veri seti için inşa edilen ESA mimarisinin katmanlarında farklı filtre parametreleri kullanılmıştır. Örnek olması açısından daha önce Şekil 1’de verilen ve Indian Pines verisi için inşa edilen derin ağ mimarisinin tüm katmanlarına ait parametre, filtre, düğüm sayısı ve ilgili evrişim katmanlarında eğitilecek parametre sayısı bilgileri Tablo 1’de verilmiştir. Pavia Üniversitesi verisi için inşa edilen ESA’da evrişim katmanlarında filtre sayısı Indian Pines verisinde olduğu gibi 20 olarak alınmıştır. Ancak E1 katmanında  $11 \times 1$ , E3 katmanında  $7 \times 1$  ve E5 katmanında  $7 \times 1$  boyutunda evrişim filtreleri kullanılmıştır. Havuzlama katmanı H2’de  $5 \times 1$ , H4’te  $5 \times 1$  ve H6’da ise  $3 \times 1$  boyutunda filtre kullanılmıştır. Tam bağlı katman olan T7 katmanında her iki veri seti için 132 düğüm vardır. T7 katmanından sonra bir birleştirme katmanı eklenerek ESA mimarisinden elde edilen özellik vektörü ile Gabor dönüşümünden elde edilen özellik

vektörü birleştirilmiş ve  $264 \times 1$  boyutunda hibrit özellik vektörü elde edilmiştir. Bu özellik vektörü T8 katmanı olarak adlandırılan ve veri setindeki sınıf sayısı kadar düğüm içeren softmax sınıflandırıcıya giriş olarak verilmiştir.

### 3.3. ESA Öğrenme ve Gabor Özellik Birleştirilmesi (ESA Learning and Gabor Feature Fusion)

ESA mimarilerinin özellik öğrenme ve çıkarma kapasitelerinin güçlendirilmesi bu çalışmanın temel motivasyonudur. Bu nedenle hiperspektral görüntülerdeki çok benzer renk ve doku özelliğine sahip farklı alanları ayırt edebilmek için evrişim işlemine dayalı ESA mimarisinin ele alınan problemin doğasına uygun olan Gabor dönüşümü yöntemi ile desteklenmesi amaçlanmıştır. Şekil 1’de görüldüğü gibi, ESA mimarisinden öğrenilen özellikler Gabor dönüşümü ile hesaplanan özelliklerle birleştirilmiştir. Birleştirilen özellik vektörü  $V_{HF}$   $264 \times 1$  boyutunda olup aşağıdaki şekilde ifade edilmiştir:

$$V_{HF} = [V_{ESA}, V_{Gabor}] = [V_{1,ESA}, V_{2,ESA}, \dots, V_{132,ESA}, V_{133,Gabor}, \dots, V_{264,Gabor}] \quad (15)$$

Burada  $V_{ESA}$  ESA ile elde edilen özellik vektörlerini gösterirken ve  $V_{Gabor}$  ise Gabor dönüşümü yöntemi ile elde edilen özellik vektörlerini ifade etmektedir. Eş. 15’teki özellik birleştirme stratejisi sayesinde mimaride T8 katmanında bulunan softmax sınıflandırıcının amaç fonksiyonu optimal değerlere hızlı bir şekilde yakınsama göstermiştir.

ESA’nın eğitim işlemi iki adım içermektedir: ileri yayılım ve geri yayılım. İleri yayılımda mevcut parametrelerle giriş verisinin sınıflandırma performansının hesaplanması amaçlanır. Geri yayılım ise eğitilebilir parametreleri

**Tablo 1.** Indian Pines veri kümesi için inşa edilen ağın detaylı parametre bilgileri.

(The detailed parameter informations of constructed network for Indian Pines dataset.)

Katmanlar	Katman türü	Filtre boyutu	Filtre sayısı	Çıkış boyutu (Düğüm sayısı)	Eğitilecek parametre sayısı
E1	Giriş	–	–	$220 \times 1$	–
	Evrişim	$22 \times 1$	20	$199 \times 20$	460
	ReLU	–	–	$199 \times 20$	–
H2	Havuzlama	$5 \times 1$	–	$98 \times 20$	–
E3	Evrişim	$10 \times 1$	20	$89 \times 20$	4020
	ReLU	–	–	$89 \times 20$	–
H4	Havuzlama	$5 \times 1$	–	$43 \times 20$	–
E5	Evrişim	$10 \times 1$	20	$34 \times 20$	4020
	ReLU	–	–	$34 \times 20$	–
H6	Havuzlama	$3 \times 1$	–	$16 \times 20$	–
T7	Tam bağlı	–	–	$132 \times 1$	32100
	ReLU	–	–	$132 \times 1$	–
$V_{Gabor}$	Tam bağlı	–	–	$132 \times 1$	–
	ReLU	–	–	$132 \times 1$	–
Birleşme	Concat	–	–	$264 \times 1$	–
T8	Tam bağlı	–	–	$8 \times 1$	2120



güncellemek için kullanılır. Softmax sınıflandırıcının tahmin skoru  $ts$  ileri yayılım algoritmasına göre aşağıdaki gibi hesaplanmıştır [21]:

$$ts(V_{HF}) = W^T V_{HF} + b \quad (16)$$

Burada  $W$  ve  $b$  sırasıyla ağ ağırlıklarını ve bias değişkenini göstermektedir. Hesaplanan tahmin skoru kayıp değerini hesaplamak için softmax sınıflandırıcıya verilir. Softmax sınıflandırıcı ele alınan hiperspektral görüntüde bulunmaya çalışılan sınıf sayısına göre yapılandırılmıştır. Sınıflandırıcıda oluşan kayıp değeri birçok lineer kayıp fonksiyonu ile hesaplanabilmektedir. Bu çalışmada çapraz-entropi fonksiyonu kullanılarak kayıp değeri hesaplanmıştır. Böylelikle kullanılan modelin ürettiği tahmin skorları kullanılarak çapraz-entropi fonksiyonu ile olasılıksal hesaplama yapılır ve hiperspektral görüntüdeki her bir sınıf için softmax sınıflandırıcı olasılık değerleri üretir. Eş. 16'dan da görüleceği üzere hem ileri yayılım hem de geri yayılım süreçlerinde ağırlık parametreleri hibrit özellik vektörü ile optimize edilmektedir. ESA mimarisinin geri yayılım işleminde amaç fonksiyonu  $J$  Olasılıksal Dereceli Azalma (Stochastic Gradient Descent) yaklaşımı kullanılarak optimize edilmiştir. Bu yaklaşımla iteratif olarak ağ parametreleri güncellenir. Kullanılan ayırt edici özellik vektörü  $V_{HF}$  ve ESA mimarisinin tasarımından dolayı amaç fonksiyonu lokal minimumlara takılmadan ağı optimize edebilmiştir. Olasılıksal Dereceli Azalma yaklaşımında başlangıç öğrenme oranı  $l = 0,013$  olarak alınmış ve her 1300 iterasyonda bir  $l = 0,13$  oranında bu değer azaltılmıştır. Bu değerler deneysel çalışmalarla belirlenmiştir. ESA'nın eğitimi sırasında ağırlıklar 0-0,013 aralığında normal dağılım oluşturularak başlatılırken, bias değerleri ise başlangıçta 0 olarak ayarlanmıştır.

#### 4. DENEYSEL SONUÇLAR (EXPERIMENTAL RESULTS)

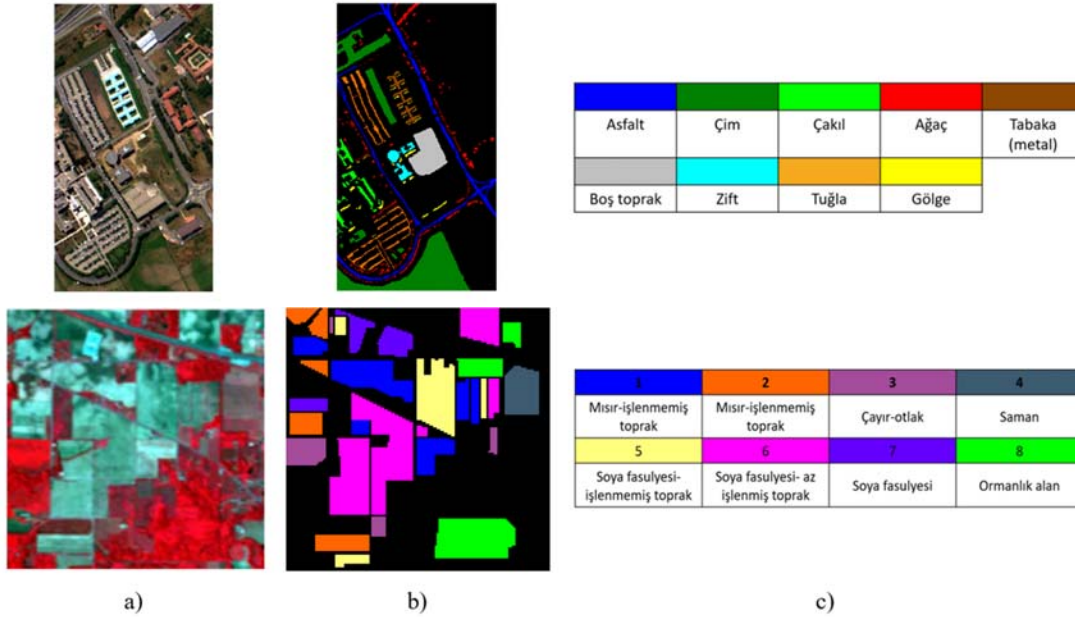
Önerilen GB-ESA yönteminin performansını test etmek için Python dili ve Theano Kütüphanesi [28] kullanılmıştır. Theano kütüphanesinde kullanılan ESA mimarisi tasarlanmıştır. Üretilen sonuçlar Intel Core i7 2.2GHz işlemci ve Nvidia GeForce GT 750M ekran kartına sahip bilgisayardan elde edilmiştir.

##### 4.1. Deneysel Veri (Experimental Data)

Önerilen Gabor özellik birleştirmeli ESA mimarisinin (kolaylık açısından GB-ESA olarak gösterilecektir) performansını test etmek için gerçek hiperspektral görüntülerden oluşan iki farklı veri tabanı kullanılmıştır. Kullanılan iki veri setinin renkli görüntüsü, gerçek sınıflandırma görüntüleri ve görüntülerde bulunan farklı sınıflar Şekil 3'te görülmektedir.

Deneysel çalışmalarda gerçek bölütleme görüntüsünden 9 farklı sınıf ve 42776 etiketlenmiş piksel kullanılmıştır. Bu veri setine ait eğitim ve test örneklerinin sayısı Tablo 2'de verilmiştir.

Literatürdeki hiperspektral görüntü sınıflandırma çalışmaları incelendiğinde, genel olarak eğitim verisi sayısının test verisi sayısına göre daha az sayıda olduğu görülmektedir. Bunun bir nedeni hiperspektral görüntülerin aynı sınıfa ait çok sayıda farklı spektral bant içermesi olabileceği öngörülmektedir. Dolayısıyla eğitim örnek sayısı az alınarak



**Şekil 3.** a) Deneysel çalışmalarda kullanılan Pavia Üniversitesi ve Indian Pines veri kümelerinin üç bant renkli görüntüleri b) Gerçek zemin sınıflandırma görüntüleri c) Her sınıf ve karşılık gelen renkler. (Three band color images of Pavia University and Indian Pines data sets used in experimental studies (b) Ground-truth classification images (c) Each class and the corresponding colors.)

ağın özellik uzayını aşırı öğrenmesinin ve ezberlemesinin önüne geçilebilir. Dolayısıyla gerek karşılaştırılan yöntemlerle objektif kıyaslama yapmak gerekse literatüre uygunluk açısından bu çalışmada da ağın eğitimi için her iki veri kümesinin farklı sınıflarından 200'er adet örnek sayısı eğitim işlemi için kullanılmıştır.

İkinci deneysel görüntü AVIRIS (Airborne Visible/Infrared Imaging Spectrometer) sensörü ile kuzeybatı Indiana'dan alınan Indian Pines veri kümesidir (Şekil 3a ikinci satır). Bu veri kümesinde 20 m konumsal çözünürlüklü ve 145×145 piksel boyutunda 220 spektral kanal bulunmaktadır. Literatürdeki benzer çalışmalarda olduğu gibi, bu çalışmada da 104-108 ve 150-162 bant aralıkları arasında kaydedilen ve su buharı emme alanlarını içeren bantlar kullanılmamıştır. Indian Pines verisinde 16 farklı kara parçası içeren sınıflar vardır. Ancak bazı sınıflar az sayıda eğitim örneği içerdiği için [5], bu çalışmada sadece 8 sınıf kullanılmıştır. Bu görüntü verisi için eğitim ve test örneklerinin sayısı Tablo 3'te verilmiştir.

#### 4.2. Sınıflandırma Performansı (Classification Performance)

Önerilen GB-ESA mimarisinin etkinliğini göstermek için hem derin öğrenme kullanan hem de geleneksel sınıflandırıcılar kullanan yöntemler ile karşılaştırmalar yapılmıştır. Karşılaştırma çalışmalarında kullanılan ilk yöntem 5 katmanlı bir ESA ağ mimarisi tasarlayarak etkin bir ağ eğitimi ile hiperspektral görüntüleri sınıflandırmıştır [16]. Karşılaştırma işlemlerinde bu yöntem orijinal ismi ile yani CNN olarak adlandırılmıştır. Önerilen GB-ESA

mimarisi Gabor dönüşümü ve geleneksel sınıflandırıcılardan olan DVM'yi birlikte kullanan ve Gabor-SVM olarak adlandırılan güncel bir başka metod ile karşılaştırılmıştır [29]. Gabor temelli DVM yönteminde hiperspektral görüntülerin Gabor dönüşümü ile özellik vektörleri hesaplanarak DVM sınıflandırıcıya verilmiştir. Diğer bir yöntem ise ENRC olarak adlandırılan yöntem olup  $\ell_1$  ve  $\ell_2$  norm düzenleme metodolojisi kullanılmaktadır [11]. Hiperspektral görüntülerin optimal ağırlıklandırılmış özellik vektörleri kullanılarak aralarında yüksek korelasyon ilişkisi bulunan sınıf pikselleri arasındaki ilişki ortaya çıkarılmaktadır. Böylece daha ayırt edici sınıflandırıcı ağırlıkları elde edilmiştir. DVM uygulaması için *libsvm* yazılım paketi (<https://www.csie.ntu.edu.tw/~cjlin/libsvm/>) kullanılmıştır. Son olarak karşılaştırma çalışmalarında önerilen GB-ESA yöntemi ile benzerlikler içeren ve oldukça güçlü sonuçlar üreten GFDN yöntemidir [19]. GFDN yöntemi hiperspektral görüntülerin ilk üç temel bileşeni üzerinde öncelikle Gabor filtreleme uygulamaktadır. Daha sonra bu bileşenlerin Gabor özelliklerini ve spektral özelliklerini elde ederek yığılmış oto-kodlayıcı ağına giriş olarak vermektedir. Derin öğrenme ağının eğitim verisi ihtiyacını karşılamak için hiperspektral görüntülerin sentetik örnekleri üretilmiştir. Hem gerçek hem de sentetik örnekler kullanılarak derin ağ mimarisinin parametreleri güncellenmiştir.

Tablo 4'te Pavia Üniversitesi veri seti için yöntemlerin hem sınıf bazındaki doğrulukları hem de genel doğrulukları (GD) görülmektedir. Karşılaştırmada kullanılan yöntemlerin sonuçları objektif karşılaştırma yapılması bakımından

**Tablo 2.** Pavia Üniversitesi veri setinde kullanılan eğitim ve test örneklerinin sayısı.  
(Number of training and test samples used in the Pavia University data set.)

Numara	Sınıf	Eğitim	Test
1	Asfalt	200	6431
2	Çim	200	18449
3	Çakıl	200	1899
4	Ağaç	200	2864
5	Tabaka (metal)	200	1145
6	Boş toprak	200	4829
7	Zift	200	1130
8	Tuğla	200	3482
9	Gölge	200	747
	<b>Toplam</b>	<b>1800</b>	<b>40976</b>

**Tablo 3.** Indian Pines veri setinde kullanılan eğitim ve test örneklerinin sayısı.  
(Number of training and test samples used in the Indian Pines data set.)

Numara	Sınıf	Eğitim	Test
1	Mısır-işlenmemiş toprak	200	1228
2	Mısır-az işlenmiş toprak	200	630
3	Çayır-otlak	200	283
4	Saman	200	278
5	Soya fasulyesi- işlenmemiş toprak	200	772
6	Soya fasulyesi- az işlenmiş toprak	200	2255
7	Soya fasulyesi	200	393
8	Ormanlık alan	200	1065
	<b>Toplam</b>	<b>1600</b>	<b>6904</b>

**Tablo 4.** Pavia Üniversitesi veri kümesi için sınıflandırma doğrulukları (%) ve genel doğruluk (GD).  
(Classification accuracies (%) and overall accuracy (OA) for University of Pavia data set (%).)

Sınıf	CNN	Gabor-DVM	ENRC	GFDN	GB-ESA
Asfalt	87,34	79,16	78,89	98,47	96,35
Çim	94,63	89,82	81,00	97,99	98,54
Çakıl	86,47	89,90	88,22	99,87	95,68
Ağaç	96,29	90,31	94,00	98,38	97,24
Tabaka (metal)	99,65	99,78	100	99,90	100
Boş toprak	93,23	88,67	89,36	99,13	97,25
Zift	93,19	90,90	92,67	99,96	96,57
Tuğla	86,42	76,83	47,71	98,62	93,48
Gölge	100,00	93,03	99,89	99,93	100
GD	93,02	88,71	85,74	99,13	97,23

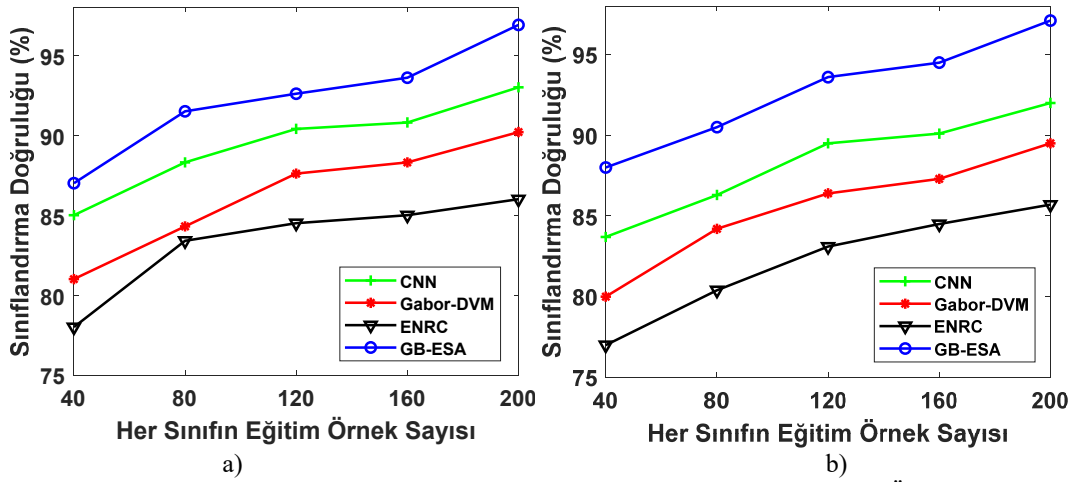
yöntemlerin kendi makalelerinden alınmıştır. Tablo 4'ten görüleceği üzere, önerilen GB-ESA yöntemi hiperspektral görüntüdeki çim bölgesini en yüksek doğrulukta sınıflandırmıştır. Bununla birlikte tabaka (metal) bölgesi ENRC yöntemi ile gölge bölgesi ise CNN yöntemi ile aynı doğruluk oranlarında sınıflandırılmıştır. Güncel ve güçlü bir yöntem olan GFDN yöntemi kalan 6 sınıfı en yüksek doğruluk oranı ile sınıflandırmıştır. GFDN yöntemi eğitim ve test kümesi örnek sayıları arasında dengesizliğin olduğu sınıfları sentetik örnekler oluşturarak sınıflandırmaktadır. Böylece ağır eğitimi daha kararlı bir şekilde yürütülmüş olup sınıflandırma başarısı artırılmıştır. Önerilen GB-ESA yönteminde ise herhangi bir sentetik örnek oluşturma prosedürü kullanılmamıştır. Buna rağmen genel doğrulukta GFDN ile önerilen GB-ESA yöntemi arasında sadece %2'lik bir başarı farkı bulunmaktadır. CNN yöntemi hiperspektral görüntüyü ham giriş olarak alıp ağır eğitiminde kullandığı için, görüntüde bulunan gürültü bileşenleri evrişim işlemlerinin performansını ve ayırt edici özellik çıkarma kapasitesini olumsuz etkilemiştir. Gabor-DVM yöntemi her bir hiperspektral görüntünün Gabor özellik vektörlerini 3 farklı yönde tasarlanan Gabor filtre bankası ile çıkarmaktadır. Hesaplanan özellik vektörleri DVM sınıflandırıcıya giriş olarak verilerek özellikle zift ve tabaka (metal) sınıfları başarılı şekilde sınıflandırılmıştır. Ancak kullanılan Gabor filtreleri görüntüden bölgesel ayırt edici özellikler yerine genel özellikler çıkardıkları için, arka plana ve diğer sınıflara benzeyen asfalt, çim, çakıl ve tuğla sınıflarında istenen başarı elde edilememiştir. ENRC yöntemi bir bölgede aralarında korelasyon ilişkisi olan pikselleri gruplamaya dayanan stratejisi sayesinde amaç fonksiyonunu etkili bir şekilde optimize edebilmiştir. Bu sayede ağaç, zift ve gölge sınıflarını daha başarılı bir şekilde tanımlayabilmiştir. Ancak piksel seviyesinde işlemler yürüttüğü için, gürültü ve sınıflar arası benzerliğin yüksek olduğu bölgeleri istenen düzeyde ayırt edememiştir. Ayrıca bu yöntem içerdiği dengeleme parametresi yüzünden farklı görüntülerde farklı sonuçlar üretebilmektedir. Yapılan karşılaştırmalarda bu parametre 0,5 olarak sabitlenmiştir. Şekil 1'de görsel olarak ifade edildiği gibi, hibrit özellik çıkarma metodolojisi ile CNN yöntemine benzer bir derin ağ mimarisine sahip olan GB-ESA yöntemi CNN mimarisinin hiperspektral görüntü sınıflandırma başarısını önemli oranda arttırmıştır. Önerilen GB-ESA yöntemi hiperspektral

görüntülerde özellik çıkarırken, sınıf içi benzerliği artırıp sınıflar arası benzerliği minimize etmeyi sağlayan özellik çıkartma mekanizması sayesinde başarılı sonuçlar vermiştir. Özellikle CNN yöntemi ile yapılan karşılaştırmalarda, iki boyutlu karmaşık Gabor özelliklerinin CNN mimarisini elde edilen derin özelliklerle birlikte kullanılmasının olumlu katkıları olduğu sonucuna varılmıştır. Kullanılan güçlü Gabor filtreleri sayesinde sınıf bölgelerinin renk, kenar ve köşe bilgilerinin yanı sıra, her bir sınıfı ayrı ayrı tanımlayan dokusal özellikler elde edilmiştir.

Yapılan ikinci karşılaştırma çalışması Indian Pines veri seti ile yürütülmüştür. Bu veri setinde bulunan 8 farklı sınıfa ait yöntemlerin sınıflandırma sonuçları Tablo 5'te görülmektedir. Önerilen GB-ESA Çayır-otlak ve Ormanlık alan bölgelerini en başarılı şekilde sınıflandıran yöntem olmuştur. GFDN yöntemi hariç olmak üzere, tüm yöntemler tespit edilmesi kolay olan Saman bölgesini %100 doğrulukta tespit edebilmiştir. Yine Çayır-otlak sınıfında tüm yöntemler benzer başarılı sonuçlar üretmişlerdir. En belirgin başarı farkı Mısır-az işlenmiş toprak, Soya fasulyesi-işlenmemiş toprak ve Soya fasulyesi-az işlenmiş toprak sınıflarında göze çarpmaktadır. GFDN yöntemi bu bölgeleri en yüksek doğrulukta sınıflandırmıştır. GFDN yöntemi sentetik örnek üretme mekanizması ile kullandığı oto-kodlayıcı ağır eğitim-test örnek sayısını daha dengeli bir noktaya taşımıştır. Yine bu yöntem hiperspektral görüntünün ilk üç temel bileşenini kullandığı için, görüntüdeki kenar bilgilerinin çoğunluğu korunabilmiş ve üretilen sentetik örneklerle de bu üstünlük aktarılmıştır. Bununla birlikte ağır eğitilmesi için çok sayıda ve doğru bir şekilde etiketlenmiş örnek görüntüye ihtiyaç duyması GFDN yönteminin en önemli dezavantajıdır. Önerilen GB-ESA yöntemi sadece CNN mimarisini ile sınıflandırma yapan CNN yönteminden yaklaşık %10 oranında daha başarılı sonuçlar elde etmiştir. Bu sonuçlar Gabor filtreleri ile elde edilen özelliklerle güçlendirilmiş olan derin ağ mimarilerinin sadece CNN mimarisini kullanılarak elde edilen özelliklere göre daha güçlü ve kararlı özellikler vektörleri ve sınıflandırıcı davranışları ürettiğini göstermektedir. ENRC yöntemi bölgesel piksel ilişkilerini daha iyi yorumlamaktadır. Ancak bu özellik sınıflar arası farklılıkların ortaya çıkarılmasında yeterli olmadığı için, bu yöntem bazı sınıflarda oldukça düşük başarı elde etmiştir. Ancak Gabor temelli yapılacak

**Tablo 5.** Indian Pines veri kümesi için sınıflandırma doğrulukları (%) ve genel doğruluk (GD).  
(Classification accuracies (%) and overall accuracy (OA) for Indian Pines data set (%).)

Sınıf	CNN	Gabor-DVM	ENRC	GFDN	GB-ESA
Mısır-işlenmemiş toprak	86,43	83,61	90,21	97,17	93,86
Mısır-az işlenmiş toprak	93,68	91,85	69,18	98,23	97,25
Çayır-otlak	97,05	97,59	96,38	96,63	97,63
Saman	100	100	100	99,93	100
Soya fasulyesi-işlenmemiş toprak	86,74	86,26	72,60	96,70	94,68
Soya fasulyesi-az işlenmiş toprak	85,94	74,35	70,54	99,01	95,38
Soya fasulyesi	94,68	99,53	87,79	97,32	97,24
Ormanlık alan	98,72	91,58	99,92	99,94	100
GD	92,90	90,59	85,82	98,11	96,98

**Şekil 4.** Farklı eğitim örnek sayıları için yöntemlerin sınıflandırma performansları. a) Pavia Üniversitesi veri seti. b) Indian Pines veri kümesi. (Classification performances of methods for different numbers of training sample sizes. (a) University of Pavia data. (b) Indian Pines data.)

iyileştirmeler ile ENRC yönteminin genel dokusal özellik çıkarma yeteneği artırılabilir. Bununla birlikte Gabor dönüşümü ile birçok farklı ölçek ve açıda özellik çıkaran Gabor-DVM yöntemi Mısır-işlenmemiş toprak ve Soya fasulyesi-az işlenmiş toprak sınıflarında yeterli başarıya ulaşamamıştır. Bu yöntemdeki temel eksiklik yöntemin bölgesel piksel analizinden yoksun olmasıdır. Bu yöntemde bölgesel ikilik örüntüler yöntemi gibi bölgesel analize dayalı yöntemler entegre edilerek başarılı sonuçlar elde edileceği öngörülmektedir.

Şekil 4 yöntemlerin farklı eğitim örnek sayısına göre elde ettikleri sınıflandırma sonuçlarını göstermektedir. Özellikle derin öğrenme temelli yapılan hiperspektral görüntü sınıflandırma çalışmalarında eğitim örnek sayısı yetersiz kalmaktadır. Bu çalışmada ESA mimarisinin eğitim verisi ihtiyacı hiperspektral görüntülerin tüm alt bantlarından alınan sınıf örnekleri ile giderilmiştir. Sadece Indian Pines veri setinde 104-108 ve 150-162 bant aralıkları kullanılmamıştır. Yöntemlerin kullandıkları eğitim veri sayısı ile elde ettikleri sınıflandırma sonuçları arasındaki ilişkiyi analiz etmek için farklı sayıda eğitim örneği ile ağ ve sınıflandırıcı eğitimleri yapılmıştır. Pavia Üniversitesi ve

Indian Pines veri kümeleri için elde edilen sonuçlar Şekil 4'te görülmektedir. Eğitim örnek sayısı 50 ile 200 aralığında 40 artımla değiştirilmiştir. Özellikle CNN ve önerilen GB-ESA yöntemleri eğitim örnek sayısının artışıyla beklenildiği gibi olumlu etkilenmiştir. Ancak tüm yöntemlerin eğitim örnek sayısının artışıyla olumlu etkilendiği görülmektedir. Önerilen GB-ESA yönteminin eğitim sonucunda elde edilen özellik vektörü aynı sınıfa ait görüntülerin Gabor temelli özellikleri ile birleştirildiğinde ağ performansının olumlu etkilendiği gözlemlenmiştir. Eğitim örnek sayısının artışı ile sadece ESA mimarisinin parametre optimizasyonunda kararlılık sağlandığı anlaşılmıştır. ESA temelli yöntemlerde eğitim örnek sayısının daha fazla artırılmasının sınıflandırma doğruluğu üzerinde kayda değer bir olumlu etkisi gözlemlenmemiştir.

## 5. SONUÇLAR (CONCLUSIONS)

Bu çalışmada hiperspektral görüntülerin sınıflandırılması için iki boyutlu karmaşık karmaşık Gabor dönüşümü ve ESA mimarisinin birlikte kullanıldığı yeni bir yöntem geliştirilmiştir. Tasarlanan ESA mimarisi ile de görüntülerin yüksek seviyeli kenar, renk ve köşe bilgilerini içeren özellik

vektörleri elde edilmiştir. Güçlü bir özellik çıkarımı prosedürü inşa etmek için ESA mimarisine verilen sınıfa ait farklı örneklerin eş zamanlı olarak Gabor özellikleri de hesaplanmıştır. Aynı sınıf verisine ait Gabor dönüşümünden ve ESA mimarisinden elde edilen özellik vektörleri birleştirilerek sınıflandırıcıya giriş olarak verilmiştir. İki farklı hiperspektral veri kümesi üzerinde karşılaştırmalı deneysel çalışmalar yapılmıştır. Bu çalışmalarda önerilen yöntemin geleneksel ESA mimarisine göre daha başarılı sonuçlar ürettiği görülmüştür. Bununla birlikte görüntülerdeki bazı sınıflarda gürültü etkileri ve benzer renk bilgisi gibi etkilerden dolayı istenen düzeyde başarı elde edilememiştir.

Gelecekte yapılacak çalışmalar ile hiperspektral görüntülerdeki uzaysal ve spektral sınıf bilgilerinin hesaplanıp analiz edilmesi ile farklı derin öğrenme mimarilerinin başarılarını arttıracak çalışmalar yapılması hedeflenmektedir. Her bir farklı sınıfı karakterize eden nitelikli ve ayırt edici piksel ve sınıf tanımlayıcıları sayesinde derin öğrenme mimarilerinin ihtiyaç duyduğu eğitim verisi miktarında azalma sağlanması amaçlanmaktadır. Bununla birlikte önerilen yöntem mevcut hali ile yaya özellik tespiti ve yüz tanıma gibi farklı problemlerde de istenen düzeye yakın sonuçlar üretebilmektedir. Yöntemin hassasiyetini ve ayırt ediciliğini arttıracak çalışmalarla bu problemler üzerindeki performansı geliştirilecek ve ilgili literatüre katkı sağlanacaktır.

#### KAYNAKLAR (REFERENCES)

- 1 Kang, X., Zhang, X., Li, S., Li, K., Li, J., Benediktsson, J.A., Hyperspectral Anomaly Detection With Attribute and Edge-Preserving Filters, *IEEE Trans. Geosci. Remote Sens.*, 55 (10), 5600–5611, 2017.
- 2 Lanthier, Y., Bannari, A., Haboudane, D., Miller, J.R., Tremblay, N., Hyperspectral Data Segmentation and Classification in Precision Agriculture: A Multi-Scale Analysis, *IEEE International Geoscience and Remote Sensing Symposium*, 585-588, 2008.
- 3 Hörig, B., Kühn, F., Oschütz, F., Lehmann, F., HyMap hyperspectral remote sensing to detect hydrocarbons, *Int. J. Remote Sens.*, 22 (8), 1413–1422, 2001.
- 4 Blanzieri, E., Melgani, F., Nearest Neighbor Classification of Remote Sensing Images With the Maximal Margin Principle, *IEEE Trans. Geosci. Remote Sens.*, 46 (6), 1804–1811, 2008.
- 5 Melgani, F., Bruzzone, L., Classification of hyperspectral remote sensing images with support vector machines, *IEEE Trans. Geosci. Remote Sens.*, 42 (8), 1778–1790, 2004.
- 6 Ratle, F., Camps-Valls, G., Weston, J., Semisupervised Neural Networks for Efficient Hyperspectral Image Classification, *IEEE Trans. Geosci. Remote Sens.*, 48 (5), 2271–2282, 2010.
- 7 Kang, X., Li, S., Fang, L., Benediktsson, J.A., Intrinsic Image Decomposition for Feature Extraction of Hyperspectral Images, *IEEE Trans. Geosci. Remote Sens.*, 53 (4), 2241–2253, 2015.
- 8 Prasad, S., Bruce, L.M., Limitations of Principal Components Analysis for Hyperspectral Target Recognition, *IEEE Geosci. Remote Sens. Lett.*, 5 (4), 625–629, 2008.
- 9 Tarabalka, Y., Fauvel, M., Chanussot, J., Benediktsson, J.A., SVM- and MRF-Based Method for Accurate Classification of Hyperspectral Images, *IEEE Geosci. Remote Sens. Lett.*, 7 (4), 736–740, 2010.
- 10 Li, L., Wang, C., Li, W., Chen, J., Hyperspectral image classification by AdaBoost weighted composite kernel extreme learning machines, *Neurocomputing*, 275, 1725–1733, 2018.
- 11 Li, W., Du, Q., Zhang, F., Hu, W., Hyperspectral Image Classification by Fusing Collaborative and Sparse Representations, *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, 9 (9), 4178–4187, 2016.
- 12 Debba, P., van Ruitenbeek, F.J.A., van der Meer, F.D., Carranza, E.J.M., Stein, A., Optimal field sampling for targeting minerals using hyperspectral data, *Remote Sens. Environ.*, 99 (4), 373–386, 2005.
- 13 Li, Y., Xie, W., Li, H., Hyperspectral image reconstruction by deep convolutional neural network for classification, *Pattern Recognit.*, 63, 371–383, 2016.
- 14 Yu, S., Jia, S., Xu, C., Convolutional neural networks for hyperspectral image classification, *Neurocomputing*, 219 (5), 88–98, 2017.
- 15 Chen, Y., Lin, Z., Zhao, X., Wang, G., Gu, Y., Deep Learning-Based Classification of Hyperspectral Data, *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, 7 (6), 2094–2107, 2014.
- 16 Hu, W., Huang, Y., Wei, L., Zhang, F., Li, H., Deep Convolutional Neural Networks for Hyperspectral Image Classification, *J. Sensors*, 2015, 1–12, 2015.
- 17 Zabalza, J., Ren, J., Zheng, J., et al., Novel segmented stacked autoencoder for effective dimensionality reduction and feature extraction in hyperspectral imaging, *Neurocomputing*, 185, 1–10, 2016.
- 18 Li, W., Wu, G., Zhang, F., Du, Q., Hyperspectral Image Classification Using Deep Pixel-Pair Features, *IEEE Trans. Geosci. Remote Sens.*, 55 (2), 844–853, 2017.
- 19 Kang, X., Li, C., Li, S., Lin, H., Classification of Hyperspectral Images by Gabor Filtering Based Deep Network, *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, 11 (4), 1166–1178, 2018.
- 20 Shi, C., Pun, C.-M., 3D multi-resolution wavelet convolutional neural networks for hyperspectral image classification, *Inf. Sci.*, 420, 49–65, 2017.
- 21 Cai, L., Zhu, J., Zeng, H., Chen, J., Cai, C., Ma, K.-K., HOG-assisted deep feature learning for pedestrian gender recognition, *J. Franklin Inst.*, 355 (4), 1991–2008, 2018.
- 22 Altun, A.A., Allahverdi, N., A new approach to recognition of fingerprints enhanced by filtering techniques with artificial neural networks, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 22(2), 227–236, 2007.
- 23 Kim, J., Um, S., Min, D., Fast 2D Complex Gabor Filter With Kernel Decomposition, *IEEE Trans. Image*

- Process., 27 (4), 1713–1722, 2018.
- 24** Bernardino, A., Santos-Victor, J., Fast IIR Isotropic 2-D Complex Gabor Filters With Boundary Initialization, *IEEE Trans. Image Process.*, 15 (11), 3338–3348, 2006.
- 25** Kavitha, K., Arivazhagan, S., Fuzzy inspired image classification algorithm for hyperspectral data using three-dimensional log-Gabor features, *Opt. - Int. J. Light Electron Opt.*, 125 (20), 6236–6241, 2014.
- 26** Zhang, J., Zhao, H., Liang, J., Continuous rotation invariant local descriptors for texton dictionary-based texture classification, *Comput. Vis. Image Underst.*, 117, (1), 56–75, 2013.
- 27** Kaya, A., Keçeli, A.S., Can, A.B., Examination of various classification strategies in classification of lung nodule characteristics, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34(2), 709-725, 2019 <https://doi.org/10.17341/gazimmfd.416530>.
- 28** Bergstra, J., Bastien, F., Breuleux, O., et al., Theano: Deep Learning on GPUs with Python - LISA - Publications - Aigaion 2.0', in *Proceedings of the NIPS, Big Learning Workshop*, 712–721, 2011.
- 29** Li, W., Chen, C., Su, H., Du, Q., Local Binary Patterns and Extreme Learning Machine for Hyperspectral Imagery Classification, *IEEE Trans. Geosci. Remote Sens.*, 53, (7), 3681–3693, 2015.