

Hiperspektral görüntülerin graf tabanlı boyut indirgenerek sınıflandırılmasında parçacık sürü optimizasyonu yaklaşımı

Particle swarm optimization approach for graph-based dimensionality reduction classification of hyperspectral images

Betül DOLAPCI*¹, Caner ÖZCAN², Emrah ÖZKAYNAK²

¹Karabük Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, 78000, Karabük

²Karabük Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, 78000, Karabük

• Geliş tarihi / Received: 31.05.2024

• Kabul tarihi / Accepted: 28.10.2024

Öz

Hiperspektral görüntü verilerinden hem uzamsal hem spektral öznelik çıkarımı ile analiz işlemi için gerekli detaylı bilgiler elde edilmektedir. Yüksek boyutlu görüntü verilerinin daha düşük boyutlu temsillerini sağlamada Laplacian Özharitaları (LÖ) ve Schrödinger Özharitaları (SÖ) graf tabanlı boyut azaltma algoritmalarının etkili olduğu bilinmektedir. Ancak bu yöntemler kapsamında kullanılan boyut azaltma parametresi değerinin literatürde sabit bir değer olarak kullanıldığı görülmektedir. Önerdiğimiz çalışma kapsamında bu parametre Parçacık Sürü Optimizasyonu (PSO) ile optimize edilmiştir. Öncelikle görüntüden Basit Doğrusal Yinelemeli Kümeleme (BDYK) algoritması ile kümelenebilir süperpikseller elde edilmiştir. Daha sonra süperpikseller graf veri yapısına dönüştürülüp girdi olarak LÖ ve SÖ algoritmalarına verilmiştir. Boyut azaltma işlemi sürecinde elde edilen farklı boyutlar için araya eklenen PSO algoritması ile en iyi özvektör değeri hesaplanmaktadır. En iyi özvektör değeri Indian Pines, Salinas ve Pavia Üniversitesi veri setleri için, 130, 120 ve 40 olarak hesaplanmıştır. Son aşamada optimizasyon tabanlı yöntemle elde edilen en iyi sonuçlar üzerinde Destek Vektör Makinesi (DVM) ile sınıflandırma işlemi gerçekleştirilmiştir. Tüm veri setleri için sınıflandırma doğruluklarının en iyi özvektör değeri ile artırılması sağlanmıştır.

Anahtar kelimeler: Boyut indirgeme, DVM, Hiperspektral, PSO, Sınıflandırma

Abstract

By extracting both spatial and spectral features from hyperspectral image data, detailed information required for the analysis process is obtained. It is important to provide lower dimensional representations of high-dimensional image data and Laplacian Eigenmaps (LÖ) and Schrödinger Eigenmaps (SÖ) graph-based dimension reduction algorithms are known to be effective for this. However, it is seen that the dimensionality reduction parameter value used in these methods is used as a fixed value in the literature. In our proposed work, this parameter is optimized with Particle Swarm Optimization (PSO). First, superpixels clustered by Simple Linear Iterative Clustering (LLICC) algorithm are obtained from the image. Then, the superpixels are transformed into a graph data structure and given as input to the LÖ and SÖ algorithms. The best eigenvector value is calculated with the PSO algorithm added for different dimensions obtained during the dimensionality reduction process. The best eigenvector values were calculated as 130, 120 and 40 for Indian Pines, Salinas and Pavia University datasets. In the last stage, classification process was performed with Support Vector Machine (SVM) on the best results obtained with the optimization-based method. Classification accuracies for all data sets were increased with the best eigenvector value.

Keywords: Dimension reduction, SVM, Hyperspectral, PSO, Classification

*Betül DOLAPCI; dolapcibetul@gmail.com

1. Giriş

1. Introduction

Uzaktan algılama ile elde edilen görüntü verileri insan gözünün algılayamadığı geniş spektrumda bilgi sağlamalarından kaynaklı oldukça detaylı bilgi içermektedir. İnsan gözünün görebildiği aralık elektromanyetik spektrumun 400 ile 700 nanometre arasına sahip dalga boyu aralığıdır. Hiperspektral görüntü elektromanyetik spektrumun görünür ve kızılötesi bölgeleri boyunca dar ve bitişik alanların yüzlerce dalga boyu bandını içermektedir. Dar bantlar ile hiperspektral görüntülerde insan gözünden kaçan farklılıklar daha kolay tespit edilebilmektedir.

Hiperspektral görüntülerin içerdiği yüzlerce bant sayesinde barındırdığı bilgi üç veya daha fazla banttan oluşan görüntüden elde edilecek bilgidен çok daha kapsamlı ve detaylı olmaktadır (Datta vd., 2022). Hiperspektral görüntünün içerdiği veriyi anlamlı bilgiye dönüştürmek için görüntünün hem uzamsal hem spektral özellikleri kullanılmaktadır. Görüntü analizinde uygulanacak tekniklere göre spektral imza özelliği de kullanılabilir. Hiperspektral görüntülerin barındırdığı spektral imzalar ile sınıflandırma işlemlerinde çok daha hassas analizler yapmak mümkündür (He vd., 2018). Spektral imza hiperspektral görüntü bantlarının farklı dalga boylarındaki yansıyan enerji miktarı bilgini içermektedir. Görüntü veri hacminin yüksek olması ve görüntünün karmaşık yapısı nedeniyle spektral imzalardan yararlanılarak yapılan görüntü analizi çalışmaları mevcuttur (Özdemir & Polat, 2020). Spektral imza yerine görüntü verisinin kullanıldığı analiz işlemlerinde veri hacminin getirdiği başka maliyet problemleri de bulunmaktadır. Görüntüden hem uzamsal hem spektral öznitelik çıkarımı görüntü hakkında detaylı bilgi sunarken verinin işlenmesini zorlaştırmaktadır (Bernabe vd., 2014). Verinin işlenmesini zorlaştırmakla birlikte uzamsal-spektral öznitelik çıkarımı görüntü analizinde yüksek başarı elde edilmesini sağlamaktadır (Wang vd., 2019). Bu noktada verinin analiz esnasında nasıl ele alındığı çok önemlidir. Verinin piksel düzeyinde ya da tercih edilen belli bir blok yöntemi uygulanarak analiz edilmesi gerekebilir. Örneğin piksel düzeyinde işlem yapmak maliyetli olduğu için ön işleme adımı olarak süperpiksel bölütleme algoritmaları kullanılması yaygındır (Alasvand vd., 2017). Süperpikseller görüntü hakkında yüksek miktarda uzamsal ve spektral bilgi içermektedir (Acosta vd., 2020). Bireysel pikselleri küçük kümeler veya süperpikseller halinde gruplamak, birçok görüntüleme analizi uygulamasında yararlı bir ön işleme adımı olarak görülmektedir. Bir görüntüdeki süperpiksel sayısı piksel sayısından çok daha az olduğundan, süperpikselleri girdi olarak kullanacak şekilde değiştirilebilen algoritmalar çok daha verimli çalışma potansiyeline sahiptir. Gri tonlamalı ve renkli görüntüleri süperpiksellerle temsil etmek için çeşitli teknikler geliştirilmiştir ve multispektral ve hiperspektral görüntüleme analizi algoritmalarında çeşitli süperpiksel algoritma türleri kullanılmıştır (Özer & Özkaya, 2018). Süperpiksel bölütleme algoritmalarından Basit Doğrusal Yinelemeli Kümeleme (BDYK) tabanlı bölütleme ile hiperspektral görüntülerin analizinde yüksek başarımlar elde edilmiştir (Jia vd., 2021). Piksel bazlı sınıflandırma ile karşılaştırıldığında BDYK yönteminin kullanılması ile başarı performansının arttırıldığı gösterilmiştir (Zhang vd., 2015). BDYK işlemi sonrası elde edilen süperpiksellerin doğrusal olmayan graf veri yapısına dönüştürülmesi ile yapılan çalışmalarda boyut indirgemenin sınıflandırmaya katkısı belirtilmiştir (Zhang vd., 2016).

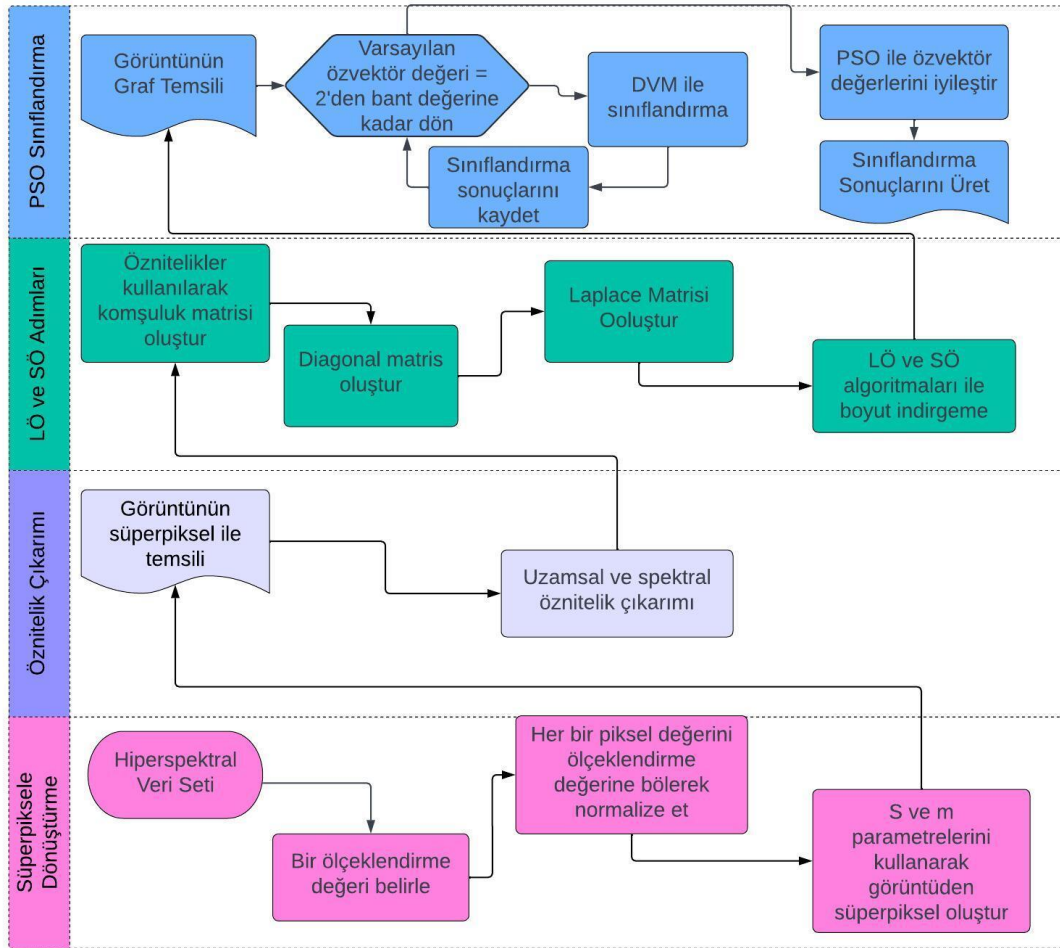
Hiperspektral görüntü verilerinde boyut azaltma genellikle kümeleme, segmentasyon, sınıflandırma, hedef tespiti gibi amaçlar için uygulanmaktadır (Kennedy vd., 2020). Bu amaçlar doğrultusunda ön işleme adımı olarak görüntü boyutunu indirgeme adımı önem kazanmaktadır (Kim & Finkel, 2003). Bir çalışmada makine öğrenmesi yöntemlerinin sınıflandırma amaçlı analizlerinde boyut indirgeme için temel bileşenler analizi yöntemi uygulanmıştır (Üstüner, 2023). Süperpiksel oluşturma ön işleme adımı temel bileşenler analizi yönteminden daha yaygın kullanılmaktadır. Boyut indirgeme algoritmaları için hiperspektral görüntülerde BDYK adımı sonrası elde edilen süperpikseller girdi olarak kullanılmaktadır. Graf tabanlı doğrusal olmayan boyut indirgeme yöntemleri, hiperspektral görüntülerin hem uzamsal hem spektral analizinde detaylı bilgi sağlamaktadır (Zhao & Yan, 2021). BDYK ve diğer süperpiksel algoritmaları ile Laplacian Özharitaları (LÖ) ve Schrödinger Özharitaları (SÖ) gibi doğrusal olmayan graf tabanlı boyut azaltma algoritmalarının, üzerinde orijinal verilerin bulunduğu yüksek boyutlu uzaydaki manifoldların yapısını yansıtan düşük boyutlu temsiller elde etmede çok etkili olduğu gösterilmiştir (Belkin & Niyogi, 2003). SÖ algoritmasının uzaktan algılama görüntü verisi olan biyomedikal verilerin analizinde maliyeti düşürmede etkili olduğu gösterilmiştir (Czaja & Ehler, 2013). Bununla birlikte, LÖ ve SÖ'nün gerektirdiği graf oluşturma ve özvektör hesaplama adımları, hiperspektral görüntü piksellerinin sayısı arttıkça aşırı derecede maliyetli olabilmektedir (Gao vd., 2018). Bu hesaplama yükünün üstesinden gelmek için, hiperspektral görüntünün süperpikselleri halinde önceden kümelenebilir. Her süperpiksel onlarca, yüzlerce ve hatta binlerce orijinal görüntü pikselini temsil edebilmektedir. Süperpiksellerle girdi olarak LÖ veya SÖ tabanlı boyut azaltma işlemi gerçekleştirmek

hem graf oluşturma hem de özvektör hesaplaması için gereken hesaplama çabasını önemli ölçüde azaltmaktadır. Bu çalışmanın amacı hiperspektral görüntü verisinin graf temsili kullanılarak boyut indirgeme algoritmaları ile sınıflandırma başarısını optimize etmektir. PSO optimizasyonu ile en iyi sınıflandırma özvektör değeri bulunarak görüntüde sınıflandırma yapılmaktadır. Hiperspektral görüntü sınıflandırmada benzer çalışmalar yaygın olarak tek veri seti üzerinde sınıflandırma yapmışlardır (Zhang vd., 2015). Çalışmamıza 2 veri seti daha ekleyerek sonuçların farklı veri setlerinde nasıl değişim gösterdiği ve PSO algoritmasının verimliliği ölçülmüştür. Yapılan analizler sayısal sonuç ve görsellerle detaylandırılmıştır. Çalışmamızda birden fazla hiperspektral veri setinin graf veri yapısına dönüştürülerek boyut indirgenmesi işleminde bant sayısının ve verinin içerdiği sınıf adedinin sınıflandırma doğruluğu üzerindeki performansının iyileştirilmesi incelenmiştir. Bu doğrultuda literatürde varsayılan özvektör değerinin veri setlerine göre değiştiği sonucuna ulaşılmıştır. Her veri seti için farklı değerlerde özvektör ile elde edilen sınıflandırma başarısının PSO algoritması ile artırıldığı ortaya konmuştur. Çalışmanın geri kalanı materyal ve yöntem, bulgular ve tartışma, sonuç ve öneriler bölümleri'nden oluşmaktadır. Hiperspektral görüntünün graf veri temsili Materyal ve Yöntem kısmında detaylandırılmış, PSO ile sınıflandırma sonucu Bulgular ve Tartışma Bölümü'nde irdelenmiştir.

2. Materyal ve yöntem

2. Material and method

Şekil 1'de ilk adım olarak süperpiksele dönüştürme, ikinci adım olarak öznitelik çıkarımı işlemleri anlatılmaktadır. Son 2 adımda ise özniteliklerden faydalanılarak matris tipinde yeni görüntü verisinin LÖ ve SÖ algoritmaları ile boyutu indirgenerek graf elde edilme süreci ve son olarak bu graf temsili ile sınıflandırma işleminin gerçekleştirildiği anlatılmaktadır. Çalışmada kullanılan veri setlerinde ön işleme adımı olarak bir ölçeklendirme faktörü belirlenmiş olup, görüntü piksel değerleri bu faktör kullanılarak normalize edilmiştir.



Şekil 1. Çalışma akış şeması

Figure 1. Algorithm schema


2.1. Hiperspektral görüntü veri setleri

2.1. Hyperspectral image datasets

Çalışmada kullanılan ilk veri seti Kuzeybatı Indiana'da bulunan Indian Pines sahasından AVIRIS sensörü ile toplanmıştır. Görüntü 145x145 piksel çözünürlüğünden ve 220 spektral banttan oluşmaktadır. Indian Pines sahnesinin üçte ikisi tarım ve üçte biri orman veya diğer çok yıllık doğal bitki örtüsünü içermektedir. İki ana çift şeritli otoyol, bir demiryolu hattının yanı sıra bazı düşük yoğunluklu konutlar, diğer inşa edilmiş yapılar ve daha küçük yollar bulunmaktadır. Görüntü haziran ayında çekilmiş olduğundan, mevcut mahsullerden bazıları, mısır ve soya fasulyesi %5'ten az kapsama alanıyla büyümenin ilk aşamalarında. Görüntü veri seti 16 sınıfa ayrılmıştır. 20 metre uzamsal çözünürlüğe sahiptir.

Diğer veri seti Salinas Vadisi, Kaliforniya üzerinden AVIRIS sensörü tarafından toplanmış ve yüksek uzaysal çözünürlük sayılan 3,7 metre piksel düzeyinde karakterize edilmiştir. Görüntü 512x217 piksel çözünürlüğünden ve 224 spektral banttan oluşmaktadır. Kapsanan alan 217 örnekle 512 hattan oluşmaktadır. Sebze, çıplak toprakları ve bağ tarlalarını içermektedir. Veri seti 16 sınıf içermektedir. Son veri seti olan Pavia Üniversitesi, İtalya'nın Pavia şehri üzerinden elde edilmiş görüntü veri setidir. Yansıtıcı optik sistem görüntüleme spektrometresi (ROSIS-3) kullanılarak sensör tarafından toplanmıştır. Görüntü 610x340 piksel ve 103 spektral banttan oluşmaktadır. Görüntü, asfalt, çayır, çakıl, ağaçlar, metal levha, çıplak toprak, bitüm, tuğla ve gölge dahil olmak üzere toplam 42.776 etiketli örnekle 9 sınıfa bölünmüştür. Şekil 2'de üç spektral veri seti de üç bantta görselleştirilerek ifade edilmiştir. Şekil 2'de görüldüğü üzere RGB bant değerleri bütün veri setleri için sırasıyla 29, 15 ve 12 değerlerine sahiptir.

Çalışmada kullanılan ve herkesin erişimine açık olan hiperspektral görüntü veri setleri Bask Ülkesi Üniversitesi Hesaplamalı Zeka Grubu web sitesinden 16.01.2024 tarihinde indirilmiştir (Grupo De Inteligencia Computacional (GIC), 2021). Yaygın olarak Indian Pines veri seti üzerinde sınıflandırma yapılan çalışmalara ek olarak Salinas ve Pavia Üniversitesi veri setleri de çalışmamıza eklenmiştir. Bu veri setlerinden Salinas veri seti Indian Pines ile aynı adette sınıf sayısı içermektedir. Pavia Üniversitesi ise 9 adet sınıfla daha az sayıda sınıf içermektedir. Salinas veri setinin tercih edilme sebebi aynı sınıf sayısına sahip farklı bir veri seti olmasıdır ve Pavia Üniversitesi veri seti ise farklı sınıf sayısına sahip başka bir veri seti olması nedeniyle tercih edilmiştir. Indian Pines veri setine iki veri seti daha eklenerek boyut indirgeme işleminin farklı veri setleri üzerindeki sınıflandırma performansları irdelenmiş olup sonuçlar PSO algoritması ile iyileştirilmiştir.



Şekil 2. a) Indiana pines veri seti, b) Salinas veri seti, c) Pavia üniversitesi veri seti
Figure 2. a) Indiana Pines dataset, b) Salinas dataset, c) Pavia university dataset

Tablo 1. Veri setlerine ilişkin tanımlayıcı istatistikler
Table 1. Descriptive statistics for datasets

Indian Pines		Salinas	Pavia Üniversitesi
Sınıf No	Örnek Sayısı	Örnek Sayısı	Örnek Sayısı
1	46	2009	824
2	1428	3726	820
3	830	1976	816
4	237	1394	808
5	483	2678	808
6	730	3959	1260
7	28	3579	476
8	478	11271	824
9	20	6203	820
10	972	3278	
11	2455	1068	
12	593	1927	
13	205	916	
14	1265	1070	
15	386	7268	
16	93	1807	

Tablo 1’de her üç veri seti için yer gerçeği bilgilerinin piksel bazında adedi paylaşılmıştır. Bu sınıf bilgileri veri setlerini meydana getirmektedir. Örneğin Indian Pines veri setinde 2 numaralı sınıf 1428 pikselden oluşmaktadır. Çalışma kapsamında bu pikseller eğitim ve test veri seti olarak ayrılıp sınıflandırma işlemi yapılmaktadır.


2.2. Basit doğrusal yinelemeli kümeleme (BDYK) algoritması

2.2. Simple linear iterative clustering (SLIC) algorithm

BDYK süperpiksel algoritması, diğer süperpiksel yöntemlerine nispeten literatürde yaygın kullanılan bir algoritmadır (Achanta vd., 2012). Görüntüdeki her pikselin hem spektral hem de uzamsal özelliklerini içeren bir özellik uzayında uygulanan k-ortalama kümelemenin bir versiyonu olarak tanımlanmaktadır. Süperpiksellerin boyutunun ve düzenliliğinin kontrolünü sağlayan parametrelere ve yüksek hesaplama hızına sahiptir. Bununla birlikte birden fazla spektral banda kolayca genelleştirilebilmektedir. BDYK ile ön işleme adımında S ve m parametreleri kullanılmıştır. Bu parametlerden S süperpiksel büyüklüğünü m ise süperpiksel düzenliliğini ifade etmektedir. BDYK süperpikselleri aşağıdaki şekilde hesaplanabilmektedir: İlk adım olarak görüntüdeki her piksel için bir $\Psi(x, y)$ öznitelik vektörü oluşturulur:

$$\Psi(x, y) = \begin{bmatrix} \lambda x \\ \lambda y \\ I(x, y) \end{bmatrix} \quad (1)$$

Burada x ve y uzamsal konumu belirtmektedir. $I(x, y)$ her bant için kod değerlerinin vektörüdür ve λ ise uzamsal ve spektral bilgilerin etkisini değiştiren bir parametredir. λ parametresi, bir süperpikselin nominal boyutunun $S \times S$ olduğu varsayıldığında ve m'nin doğrudan süperpiksel düzenliliğiyle ilişkili olduğu düşünüldüğünde m/S oranı olarak ifade edilmektedir (Zhang vd., 2015). İkinci adım boyutu S olan düzenli bir ızgara üzerinde $C_k = \Psi(x_k, y_k)$ küme merkezlerinin başlangıç kümesini oluşturulur. Her küme merkezi $n \times n$ komşuluk ilişkisindeki en düşük eğim konumuna taşınır. (x, y) ile gösterilen her piksel $\|\Psi(x, y) - \Psi(x_k, y_k)\|$ mesafesine göre en yakın küme merkezine atanır. Algoritmayı hızlandırmak için bu adım yalnızca $2S \times 2S$ komşuluğundaki küme merkezleri aranarak basitleştirilebilir. Her küme merkezi, tanımlandığı piksellerin merkezine göre güncellenir. Ardışık küme merkezi güncellemeleri arasındaki mesafe önceden belirlenmiş bir eşiğin altına düşene kadar tekrarlanır. Son adım olarak en büyük komşu kümeye bağlanacak ayrık bölümler yeniden etiketlenir.




Şekil 3. a) Indiana Pines pines süperpikselleri, b) Salinas süperpikselleri, c) Pavia üniversitesi süperpikselleri
Figure 3. a) Superpixels of Indiana Pines, b) Superpixels of Salinas, c) Superpixels of Pavia university

2.3. Laplacian özharitaları (LÖ) ve schrödinger özharitaları (SÖ) boyut indirgeme algoritmaları

2.3. Laplacian eigenmaps (LE) and schrödinger eigenmaps (SE) dimension reduction algorithms

Hiperspektral görüntü veri setlerinde bant sayısının artmasının yanı sıra uzamsal olarak bilgi içeren piksel çözünürlüğü arttıkça da işlem kapasitesi artmaktadır. Çalışma kapsamında Indiana Pines veri setinde uzamsal çözünürlük 145x145 olduğu için BDYK ile süperpiksel elde etme işlemi diğer iki veri setine nispeten daha kısa sürmektedir. Fakat Salinas 512x217 uzamsal çözünürlük ile işlem kapasitesini arttırmakta, bu kapasite 610x340 uzamsal çözünürlükteki Pavia Üniversitesi veri seti ile en fazla ve maliyetli boyutuna ulaşmaktadır. Maliyeti azaltmak için, süperpiksellerin her birinin bir düğüm olarak ifade edildiği graf veri yapısı kullanılması önerilmektedir. Graf veri yapısı sayesinde her bir süperpiksel düğüm, süperpiksellerin en yakın komşuları ile ilişkileri ise düğümleri birbirine bağlayan kenarlar ile temsil edilmektedir. Böylece süperpiksellerin hem uzamsal hem spektral komşuluk bilgileri elde edilmekte ve graf veri yapısı ile tüm detaylar etraflıca ele alınmaktadır.



Şekil 4. Salinas veri seti süperpiksellerinin graf ile temsili
Figure 4. Graph representation of Salinas dataset superpixels

Şekil 4’te görülen graf boyut indirgeme algoritmalarına süperpikselerin girdi olarak verildiği yöntemde çıktı olarak üretilmiştir. Graf tabanlı boyut indirgeme algoritmalarında en yaygın kullanılan iki algoritma LÖ ve SÖ algoritmalarıdır (Zhang vd., 2015). BDYK ile oluşturulan süperpikseller graf veri yapısına dönüştürülerek boyut indirgeme algoritmalarına girdi olarak verilmektedir. LÖ ile SÖ temelde aynı işlem adımlarından geçerek görüntüyü graf veri yapısına dönüştürür ve bu veri üzerinde indirgeme yapmaktadır (Verdoja & Grangetto, 2020). Fakat SÖ algoritmasında farklı olarak Schrödinger potansiyeli matrisi kullanılmakta ve bu matris üzerinden görüntü graf veri yapısına dönüştürülmektedir (Ghasrodashti vd., 2017). Schrödinger potansiyeli matrisi, hiperspektral görüntülerdeki piksel değerlerinin bir matrisini oluşturur. Bu matris, görüntüdeki renk veya spektral değerlerin fiziksel olarak ifadesidir ve genellikle hiperspektral görüntülerin spektral bantlarındaki yoğunlukların dağılımını içerir. Schrödinger özharitası ise bu potansiyel matrisi kullanarak hiperspektral görüntüleri düşük boyutlu bir uzaya dönüştüren bir boyut indirgeme tekniğidir. Bu sayede, hiperspektral verilerdeki önemli özelliklerin korunması ve analiz edilmesi daha etkili hale gelir (Cahill vd., 2014). Bu iki algoritma ile graf veri yapısı elde edildikten sonra uzamsal ve spektral olarak boyut indirgemenin son adımı olan Uzamsal Spektral Schrödinger Özharitaları (USSÖ) kullanılmaktadır (Fejjari vd., 2021). Bu yöntemle graf tabanlı veri ikinci kez indirgenmekte, veri daha düşük boyutta temsil edilmektedir.

Görüntünün graf temsili oluşturmakta ilk adım LÖ ve SÖ algoritmaları ile süperpikselerin komşuluk ilişkisini incelemektir. Her bir süperpikselin komşuluğu k -en yakın ortalamalar yöntemi kullanılarak oluşturulmaktadır. Görüntünün spektral ve uzamsal olarak komşuluk ilişkisi ayrı ayrı incelenmektedir. Bu iki komşuluk matrisi LÖ ve SÖ boyut indirgeme algoritmaları ile indirgenerek graf temsili elde edilmektedir. LÖ aşağıdaki adımları içeren kullanımı yaygın bir graf tabanlı boyut azaltma algoritmasıdır:

1. Dğümlerin her birinin X ve kenarların her birinin E ile ifade edildiği köşeler arasındaki ilişkinin temsil edildiği yönlendirilmemiş bir $G = (X, E)$ grafiği oluşturulmaktadır.
2. E 'de tanımlanmış kenarlar için ağırlıklar tanımlanmaktadır.
3. $L = D - A$ ile Laplacian matrisi elde edilmektedir. Burada D derece matrisi, A ise dğümlerin her biri için komşuluk matris bilgisini içermektedir.

Kenar ağırlıklarını tanımlamak için ısı çekirdeği yaygın bir seçimdir; yani $W_{i,j}$ ağırlığı şu şekilde tanımlanır:

$$\exp\left(-\|x_i - x_j\|^2 / \sigma\right) \quad (2)$$

LÖ'nün basit ancak güçlü bir genellemesi olan SÖ, mevcut olabilecek veriler hakkında ekstra bilgileri kodlayan potansiyel bir V matrisi içerir. Potansiyel matrisi, X 'teki noktalar için Y 'deki karşılık gelen noktaları orijine doğru çeken bariyer potansiyellerini veya X 'teki noktalar için Y 'deki karşılık gelen noktaları birbirine doğru çeken küme potansiyellerini içerir. Bariyer potansiyelleri, V 'nin negatif olmayan bir diyagonal matris olarak tanımlanmasıyla oluşturulur; $V_{i,i}$ seçilen x_i 'lerin her biri için pozitif olarak tanımlanır. Küme potansiyelleri, V 'nin, x_i ve x_j arasındaki bireysel küme potansiyellerini kodlayan köşegen olmayan $V_{i,j}$ matrislerinin ağırlıklı toplamı olarak tanımlanmasıyla oluşturulur:

$$V_{k,l}^{(i,j)} = \begin{cases} 1, & (k, l) \in (i, i), (j, j) \\ -1, & (k, l) \in (i, i), (j, j) \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

Tanımlanmış bir potansiyel matris ile SÖ, LÖ ile aynı şekilde ilerler, ancak 3. adımdaki geliştirilmiş özvektör probleminin yerini $(L + \alpha V)f = \lambda Df$ problemi alır, burada α , Laplace matrisi ve potansiyel matrisin katkılarını göreceli olarak ağırlıklandırmak için seçilen bir parametredir. Bir çalışmada, grafleri spektral bilgilerle tanımlayan ve uzamsal yakınlığı kodlamak için küme potansiyellerini kullanan Uzamsal-Spektral Schrödinger Öz Haritaları (USSÖ) algoritması önerilmiştir (Cahill vd., 2015). Kenarlar, köşelerin spektral bileşenleri arasındaki yakınlığa göre tanımlanır ve kenar ağırlıkları aşağıdakilere göre tanımlanır:

$$W_{i,j} = \begin{cases} \exp\left(\frac{-\|x_i^f - x_j^f\|^2}{\sigma_f^2}\right), & (x_i, x_j \in \varepsilon) \\ 0, & \text{otherwise} \end{cases} \quad (4)$$

Bir küme potansiyeli matrisi V , köşelerin uzaysal bileşenleri arasındaki yakınlığı kodlamak için tanımlanır:

$$V = \sum_{i=1}^k \sum_{x_j \in N_{\alpha}^p(x_i)} V^{(i,j)} \cdot Y_{(i,j)} \cdot \exp\left(\frac{-\|x_i^p - x_j^p\|^2}{\sigma_p^2}\right) \quad (5)$$

Burada $N_{\alpha}^p(x_i)$, uzaysal bileşenleri x_i 'nin uzaysal bileşenlerinin α -komşuluğunda olan X 'teki noktalar kümesidir.


$$N_{\alpha}^p(x_i) = \{x \in X - x_i \mid \|x_i^p - x^p\| \leq \alpha\} \quad (6)$$

2.4. Hiperspektral görüntü verisinin graf tabanlı temsili

2.4. Graph-Based representation of hyperspectral image data

Hiperspektral görüntü verisinin graf veri yapısına dönüştürülme aşamasında ön işlem adımı olarak süperpikselle bölme işlemi gerçekleştirilmiştir. Süperpikselle bölme için çok çeşitli yaklaşımlar bulunmaktadır. Bu yaklaşımlardan çalışma kapsamında BDYK yöntemini uygulama tercih edilmiştir. BDYK algoritması için süperpiksel boyutu (S) ve süperpiksel düzenliliği için (m) parametreleri kullanılmıştır. Daha sonra süperpiksellerin her biri için k -en yakın ortalamalar yöntemi kullanılarak hem uzamsal hem spektral uzayda komşuluk matris bilgileri çıkarılmıştır. Bu matrisler LÖ ve SÖ yöntemi ile boyut indirgeme adımlarından geçirilmiş ve görüntünün graf temsili çıktı olarak elde edilmiştir. Son adım olarak elde edilen graf temsili USSÖ algoritması ile işlenerek öz vektörler çıkarılmış ve değerleri analiz edilerek bu vektörlerle sınıflandırma işlemi gerçekleştirilmiştir.

Görüntü verisinden graf temsili elde edilmesi sürecine kadar birçok algorithmadan faydalanılmıştır. Süperpiksel oluşturma için SLIC algoritmasının tercih edilme sebebi diğer algoritmalara göre hızlı, basit ve daha düzenli olmasıdır. SLIC hem renkli hem gri tonlamalı görüntülerde bant sayısından bağımsız daha iyi sonuçlar üretmektedir. Süperpiksel merkezleri, uzaysal bir yakınlık ve renk benzerliği ölçütü ile güncellenir. Bu, süperpiksel segmentlerinin daha homojen ve düzgün olmasına yol açmaktadır. Diğer algoritmalar bu düzenliliği her zaman sağlayamayabilmektedir. Boyut indirgeme aşamasında kullanılan LÖ ve SÖ algoritmaları hiperspektral görüntü verileri için bant bazında daha detaylı bilgiler sunmaktadır. Piksel bazında ve tüm bant bilgilerini en ince ayrıntısına kadar işleyip graf temsil elde etmede başarılı sonuçlar sunmaktadır.



Şekil 5. Hiperspektral görüntü verisinin graf tabanlı temsili
Figure 5. Graph-based representation of hyperspectral image data

Şekil 5’te belirtildiği üzere hiperspektral veriden BDYK algoritması ile süperpikseller elde edilmektedir. Süperpikseller hem spektral hem uzamsal olmak üzere uzayda 3 boyutlu temsil edilen görüntünün her boyutta özvektör bilgisine hakim olmaktadır. Graf tabanlı boyut indirgeme algoritmaları olan LÖ ve SÖ ile veri boyutu ilk adımda BDYK ile indirgenmiş görüntü graf ile temsil edilmektedir. Son olarak USSÖ yöntemi ile elde edilen graf veri yapısı ikinci kez indirgenmekte ve böylece sınıflandırma işlemi için gerekli girdi graf verisi hazır hale getirilmektedir. LÖ adımı sonrası elde edilen graf veri yapısı süperpiksellerin her birinin düğüm olarak ifade edildiği, kenarların ise komşuluk bilgilerini temsil ettiği veri yapısıdır. Schrödinger Özharitalarında potansiyel matrisin kullanımı ile veri daha sade ve işlemesi kolay hale getirilmektedir.

2.5. Parçacık sürü optimizasyon tabanlı boyut indirgeme

2.4. Particle swarm optimization based size reduction


PSO evrimsel hesaplama teorisine göre sürü halinde hareket eden hayvanlardan esinlenerek geliştirilmiş bir optimizasyon yöntemidir. Sürü halinde hareket eden hayvanların güvenlik ve yiyecek arayışı esnasında hareketleri gözlemlenerek sorun karşısında optimum amaca ulaşma biçimleri incelenmiştir. Bu yöntemde her birey parçacık, parçacıkların oluşturduğu küme ise sürüdür. Her bir parçacık kendi pozisyonunu, bir önceki tecrübesinden yararlanarak sürüdeki en iyi pozisyona doğru ayarlar. Boyut indirgeme algoritmaları ile sınıflandırma işleminde varsayılan özvektör sayısı 50 olarak belirlenmiştir. Bunun nedeni yaygın olarak sınıflandırma işlemlerinde bu değerin kullanılmasıdır. Çalışma kapsamında USSÖ algoritması ile görüntü verilerinden optimum özvektör sayısı çıkarımı yapılmıştır. Görüntüden elde edilen özvektör sayı adedinin sınıflandırma başarısı üzerindeki etkisi büyüktür. Bu nedenle PSO algoritması ile optimize edilen parametre özvektör sayısıdır. Görüntüden çıkarılacak en iyi özvektör sayısı PSO ile belirlenmiş ve bu değerlere göre ikinci bir sınıflandırma işlemi daha gerçekleştirilmiştir. Kullanımı yaygın özvektör sayısı ile yapılan sınıflandırma PSO ile karşılaştırıldığında, PSO ile yapılan sınıflandırmada başarı artışı görülmektedir. Sonuçlar Bulgular ve Yöntemler Bölümü’nde belirtilmiştir. Parçacık Sürü Optimizasyon Algoritması ile yapılan çalışmalarda hiperspektral görüntünün spektral uzamsal sınıflandırması üzerine yaklaşımların yüksek başarı ortaya koyduğu gözlemlenmiştir (Suresh & Lal, 2019). Algoritma sözde kodu aşağıdaki gibidir:

```

Initialization:
  for i=1 to max_iter
    Xmin < Xi < Xmax (for randomly position)
    Vmin < Vi < Vmax (for randomly velocity)
    Pi=Xi
  end for
  Evaluate particle
  Determine current best position for particle
While:
  (until termination stop criterion & t < max_time)
  for i=1 to max_iter
    update Vi and Xi
    If Xi > limit ise Xi=limit
    Evaluate objective function
    update Vi and Xi
  end for
end while

```

Çalışmamızda PSO ile optimize işleminin odak noktası, graf tabanlı boyut indirgeme işlemi ne kadar indirgendiğinde optimum sınıflandırma başarısı elde edileceğidir. Boyut indirgeme için kullanılan bu parametre özvektör parametresidir. Görüntü veri setlerinin her biri farklı sayıda bantlardan oluşmaktadır. Bu nedenle literatürde yaygın olarak kullanılan 50 adet özvektör bilgisinin her veri seti için farklılık oluşturması gerekliliği beklenmektedir. 1 adet özvektör değeri ise anlamlı bilgi açısından oldukça kısır kalmaktadır. PSO ile bu parametrenin değeri 2’den başlanıp görüntünün içerdiği bant sayısına kadar tüm değerlere eşitlenerek sınıflandırma başarısı ölçülmüştür. PSO optimum sınıflandırma başarısını verecek özvektör sayısını bu şekilde belirlemiştir. Uygunluk fonksiyonunun amacı, belirli bir boyut sayısında (eigenvectors) hiperspektral görüntülerin en iyi şekilde sınıflandırılmasını sağlamaktır. Varsayılan özvektör değerinin parametre olarak alındığı PSO sürecinde uygunluk fonksiyonu 1 – GD olarak tanımlanmıştır. Genel doğruluk bilgisinin 1’den çıkarılması sınıflandırma hatası olarak değerlendirilmektedir. PSO algoritması bu hatayı minimize etmeye çalışmaktadır. Sonuç olarak PSO, fonksiyona verilen özvektör değeri parametresini optimize ederek sınıflandırma hatasını minimize etmeye çalışmaktadır. Böylece en iyi sonuca ulaşılmaktadır. Şekil 6’da ayrıca PSO iterasyon-genel doğruluk grafikleri paylaşılmıştır.



Şekil 6. PSO iterasyon-genel doğruluk grafiği
Figure 6. PSO iteration-overall accuracy graph

3. Bulgular ve tartışma

3. Results and discussion

Çalışma kapsamında 3 veri seti olan Indian Pines, Salinas ve Pavia Üniversitesi verileri kullanılmıştır. Doğruluk metrikleri olarak genel doğruluk (GD), ortalama doğruluk (OD), ortalama kesinlik (OK), ortalama hassasiyet (OH) ve ortalama özgüllük (OÖ) belirlenmiştir. Bu doğruluk metrikleri temelinde Tablo 2’de yer alan metriklere dayanarak oluşturulmuştur. Tablo 2’de belirtilen True Positive (TP), True Negative (TN), False Positive (FP) ve False Negative (FN) sınıflandırma metriklerinin bir makine öğrenmesi yönteminde sınıflandırma işleminde neyi ifade ettiği aşağıdaki gibi açıklanmaktadır:

TP: Sınıflandırma işleminde doğru olarak sınıflandırılmış sınıfı doğru sınıf olarak tahmin etme sayısı.
TN: Sınıflandırma işleminde yanlış olarak sınıflandırılmış sınıfı yanlış sınıf olarak tahmin etme sayısı.
FP: Sınıflandırma işleminde doğru olarak sınıflandırılmış sınıfı yanlış sınıf olarak tahmin etme sayısı.
FN: Sınıflandırma işleminde yanlış olarak sınıflandırılmış sınıfı doğru sınıf olarak tahmin etme sayısı.

Tablo 2. Sınıflandırma performansı metrikleri ve formülleri
Table 2. Classification performance metrics and formulas

Metrik	Formül	Metrik	Formül
	$\frac{TP + TN}{TP + FP + FN + TN}$		$\frac{TP}{TP + FP}$
Doğruluk		Kesinlik	
	$\frac{TP + FN}{TP + FN}$	Özgüllük	$\frac{FP + TN}{FP + TN}$

GD, doğru tahmin edilen test piksellerinin sayısının toplam test piksellerinin sayısına oranı olarak tanımlanır. OD, OK, OH ve OÖ, Tablo 2’de gösterildiği gibi her bir sınıf karışıklık matrisinden hesaplanan sınıf başına doğruluk, hassasiyet, duyarlılık ve özgüllüğün ortalamasıdır.

Tablo 3. Varsayılan özvektör değeri (n=50) ve PSO sonrası iyileştirilmiş özvektör değerlerine (n) göre DVM sınıflandırma doğrulukları

Table 3. SVM classification accuracies based on default eigenvector value (n=50) and post-PSO improved eigenvector values (n)

	Indian Pines		Salinas		Pavia Üniversitesi	
	n=50	n=130	n=50	n=120	n=50	n=40
GD	0.9730	0.9770	0.9275	0.9409	0.9273	0.9299
OD	0.9966	0.9971	0.9909	0.9926	0.9838	0.9844
OK	0.9165	0.9119	0.9370	0.9445	0.9033	0.9097
OH	0.9763	0.9796	0.9351	0.9469	0.9210	0.9276
OÖ	0.9981	0.9984	0.9948	0.9958	0.9903	0.9906

Varsayılan değerler olarak yaygın kullanılan 50 değerinin manuel olarak belirlendiği (Zhang vd., 2015) özvektörlerle sınıflandırma sonuçları Tablo 3'te görüldüğü gibidir. Indian Pines verisinin bant sayısı 220'dir. Bant sayısı 130'a indirgenerek yapılan sınıflandırma sonucunda OK dışında tüm doğruluk metriği bilgilerinde artış gözlemlenmektedir. Salinas verisi 224 banttan oluşmakta ve PSO ile bulunan 120 özvektör sayısında en iyi sınıflandırma başarısının elde edildiği görülmüştür. Pavia Üniversitesi verisi içinse tüm metriklerde başarı artışı görülmekte ve 103 bant 40 banta indirgenmiş olarak sonuç elde edilmiş olmaktadır. Sonuç olarak en iyi doğruluğun nasıl sağlanması gerektiği noktasında boyut indirgeme sonrası n değeri PSO ile iyileştirilmiş ve her bir veri seti için en yüksek sınıflandırma başarısını veren sayılar elde edilmiştir. Her bir görüntü veri setinin barındırdığı sınıf sayıları ve bu sınıfların her biri için hesaplanmış doğruluk değerleri Tablo 4'te belirtilmiştir.

Tablo 4. Hiperspektral veri seti sınıflarının GD doğrulukları
Table 4. GD accuracies of hyperspectral dataset classes


Indian Pines			Salinas		Pavia Üniversitesi	
Sınıf No	Sınıf Adı	GD (%)	Sınıf Adı	GD (%)	Sınıf Adı	GD (%)
1	Yonca	0.9992	Brokoli 1	0.9957	Asfalt	0.9767
2	Mısır-işlenmemiş	0.9918	Brokoli 2	0.9942	Çayırklar	0.9644
3	Mısır-az işlenmiş	0.9950	Nadas toprak	0.9943	Çakıl	0.9850
4	Mısır	0.9989	Nadas toprak kaba	0.9983	Ağaçlar	0.9924
5	Çimen-otlak	0.9972	Nadas toprak düz	0.9961	Boyalı Metal Levhalar	0.9993
6	Çimen-ağaç	0.9979	Anız	0.9986	Çıplak Toprak	0.9690
7	Çimen-biçilmiş otlak	1.0000	Kereviz	0.9960	Zift	0.9914
8	Saman	1.0000	Üzümler	0.9633	Bloke Tuğla	0.9825
9	Yulaf	0.9982	Yetişen Üzüm	0.9967	Gölgeler	0.9990
10	Soya fasulyesi-işlenmemiş	0.9928	Mısır	0.9910		
11	Soya fasulyesi-az işlenmiş	0.9913	Roman Marulu 4. Hafta	0.9976		
12	Soya fasulyesi	0.9953	Roman Marulu 4. Hafta	0.9987		
13	Buğday	0.9995	Roman Marulu 4. Hafta	0.9980		
14	Orman	0.9984	Roman Marulu 4. Hafta	0.9962		
15	Bina-Çimen-Ağaç-Araç	0.9997	Üzüm Bağı	0.9716		
16	Kaya-Çelik-Bina	0.9988	Üzüm Bağı Çift Düşey	0.9955		

Varsayılan özvektör değerinin 50 olarak belirlendiği çalışmada (Zhang vd., 2015) bu değer tek bir veri seti için belirlendiği görülmektedir. Çalışmamızda Indian Pines veri seti için belirlenen bu değer diğer hiperspektral veri setleri için optimum olup olmayacağı incelenmiştir. Ayrıca Indian Pines veri seti için belirlenen bu özvektör değerinin PSO ile iyileştirilip iyileştirilmeyeceği analiz edilmiştir. PSO ile yapılan analiz sonucunda 130 özvektör değeri kullanıldığında daha iyi sınıflandırma başarısı elde edilmiştir. Tablo 3'te görüldüğü üzere 50 özvektör değeri ile elde edilen sınıflandırma başarılarının PSO sonrası tüm GD ve OD metriklerinde arttırıldığı gözlemlenmiştir. Indian Pines ve Salinas veri setleri için optimum özvektör sayısı 130 ve 120 iken Pavia Üniversitesi için bu değer 40'tır. PSO ile belirlenmiş bu değerlerin veri setlerinin bant sayıları ile ilgili olduğu düşünülmektedir. Indian Pines veri seti 220 banttan, Salinas veri seti 224 banttan ve Pavia Üniversitesi veri seti ise 103 banttan oluşmaktadır. Her üç veri seti için sahip olduğu bant sayısının yaklaşık yarıya indirgendiği zaman iyi sonuçlar verdiği gözlemlenmiştir. 220 bant 130'a, 224 bant ise 120'ye ve 103 bant 40'a indirgenerek en iyi sınıflandırma sonucu elde edilmiştir. Pavia Üniversitesi'nde özvektör değerinin 50'den daha düşük olması veri setinin içerdiği sınıf sayısı ile ilgilidir. Diğer veri setleri 16'şar sınıf içerirken Pavia Üniversitesi veri seti 9 sınıf içermektedir. Veri setinde sınıf sayısı ve bant sayısı arttıkça veri

daha karmaşık bir graf ile temsil edilmekte ve indirgenme işleminde özvektör değeri buna göre daha yüksek bir değere sahip olmaktadır. Özvektör değeri 50 iken Indian Pines ve Salinas veri setleri için programın çalışma süresi değer 130 ve 120 olduğunda artmaktadır. Pavia Üniversitesi için ise süre azalmaktadır. Çalışma süresi özvektör değeri ile doğru orantılıdır. Tablo 3'te belirtildiği gibi PSO kullanılarak elde edilen optimum özvektör sayısı ile GD, OD, OK, OH, OÖ metriklerinin bütün değerlerinin Salinas ve Pavia Üniversitesi veri setleri için artırılması sağlanmıştır. Indian Pines veri setinde ise OK dışında tüm metrik değerleri artırılmıştır.

Tablo 3'te Zhang'a göre elde edilen sonuçlar özvektör yani n parametresinin 50 değerinde iken bulunmuş sınıflandırma sonuçlarıdır (Zhang vd., 2015). Bu çalışmada PSO optimizasyon algoritması kullanılarak Indian Pines veri seti için en iyi sınıflandırma sonucunun verilmesini sağlayan n parametresi 130 olarak iyileştirilmiştir. Tüm doğruluk metriklerinde sınıflandırma başarısının artırıldığı gözlemlenmiştir. Çalışmada kullanılan veri setlerinin her biri için eğitim test veri seti ayrımı farklı oranlardadır. Indian Pines ve Pavia Üniversitesi veri seti için verinin %10'u eğitime geri kalanı teste ayrılmıştır. Salinas veri seti için ise eğitim kısmına ayrılan veri %1 olarak belirlenmiştir. Her veri setinin barındırdığı sınıf ve bu sınıfların içerdiği piksel sayısı bu ayırmada rol oynamaktadır.

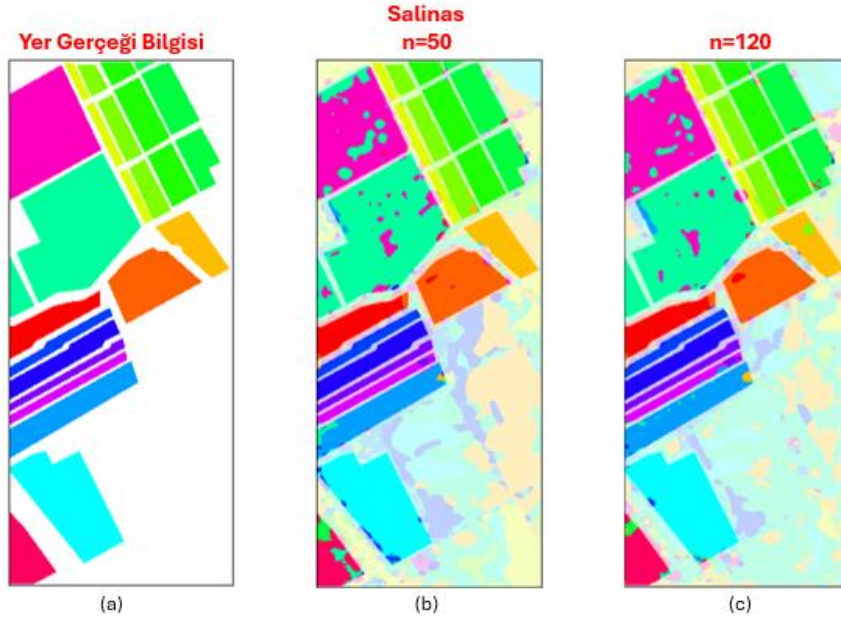
Tablo 4'te görüldüğü üzere hiperspektral verilerinin barındırdığı sınıfların her biri için doğruluk bilgilerinin PSO ile bulunan özvektör sayısı ile veri indirgenmesinde en yüksek sonuçları verdiği gösterilmiştir. Indian Pines ve Salinas 16 sınıf, Pavia Üniversitesi veri seti ise 9 sınıf barındırmaktadır. Her bir sınıfın genel doğruluk metriği ile sınıflandırıldığında elde edilen sonuçlara bakıldığında en düşük tahminin Salinas veri seti içindeki Üzümler sınıfı için 0.9633 olduğu görülmüştür. Çalışma odağında hiperspektral veri, boyut indirgeme yöntemleri ile graf veri yapısına dönüştürülmüştür. Graf verisi görüntünün spektral ve uzamsal özneliklerini içermektedir. Bu öznelikler kullanılarak Tablo 3 ve Tablo 4 sınıflandırma sonuçları için sınıflandırma algoritmalarından kolay olan DVM makine öğrenmesi yöntemi tercih edilmiştir. Çalışmada kullanılan bilgisayar Windows 10 Pro işletim sistemine sahiptir. 128 gb ram ve 3.00 Ghz Intel işlemci gücünde özellikleri mevcuttur. Çalışma kapsamında geliştirilen uygulama MATLAB R2019a ortamında gerçekleştirilmiş ve sonuçlar alınmıştır.



Şekil 7. Indian Pines veri seti sınıflandırma sonuçlarının görsel temsili a) Indiana Pines yer gerçeği bilgisi, b) Özvektör değeri 50 iken oluşan sınıflandırma sonucu, c) Özvektör değerinin PSO ile iyileştirilmesi sonucu oluşan sınıflandırma sonucu

Figure 7. Visual representation of Indian Pines dataset classification results a) Indiana Pines ground truth b) Classification result when the eigenvector value is 50, c) Classification result as a result of improving the eigenvector value with PSO


Şekil 7'de görüldüğü üzere yer gerçekliği bilgisine en yakın sınıflandırma başarısı PSO ile optimize edilen $n = 130$ eşitliği sağlandığında elde edilmektedir.



Şekil 8. Salinas veri seti sınıflandırma sonuçlarının görsel temsili a) Salinas yer gerçeği bilgisi, b) Özvektör değeri 50 iken oluşan sınıflandırma sonucu, c) Özvektör değerinin PSO ile iyileştirilmesi sonucu oluşan sınıflandırma sonucu

Figure 8. Visual representation of Salinas dataset classification results a) Salinas ground truth b) Classification result when the eigenvector value is 50, c) Classification result as a result of improving the eigenvector value with PSO

Şekil 8 ve Şekil 9’de yer gerçekliği bilgisi ile karşılaştırılarak PSO optimizasyon algoritmasının sınıflandırmaya katkısı görsel olarak da belirtilmiştir.



Şekil 9. Pavia Üniversitesi veri seti sınıflandırma sonuçlarının görsel temsili a) Pavia Üniversitesi yer gerçeği bilgisi, b) Özvektör değeri 50 iken oluşan sınıflandırma sonucu, c) Özvektör değerinin PSO ile iyileştirilmesi sonucu oluşan sınıflandırma sonucu

Figure 9. Visual representation of Pavia University dataset classification results a) University ground truth b) Classification result when the eigenvector value is 50, c) Classification result as a result of improving the eigenvector value with PSO

Hiperspektral görüntü veri tiplerinde sınıflandırma algoritmalarından DVM çok sınıflı bir sınıflandırma işlemi gerçekleştirmektedir (Gurram & Kwon, 2011). Bu çalışmada DVM makine öğrenmesi yöntemi kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Matlab ortamında geliştirilen uygulamada veri setlerinin her bir sınıfı

için bir DVM modeli oluşturulmaktadır. Fıtsvm fonksiyonu ile bu modeller oluşturulmuştur. KernelFunction parametresi radial basis function olarak ayarlanmıştır. RBF çekirdeğinin kullanılması gerekliliği belirtilmiştir. Standardize parametresi true ayarlanarak verinin standartlaştırılması sağlanmıştır. KernelScale parametresi auto olarak ayarlanmış ve çekirdek ölçeği otomatik olarak belirlenmiştir. DVM modelinin MATLAB ortamında oluşturulduğu kod bilgisi aşağıdaki gibidir:

```
% train SVM for each class
SVMModel = cell(numClasses,1);
for i = 1:numClasses
    currentClass = (trainLabels==uniqueLabels(i));
    SVMModel{i} = fitsvm(trainData,currentClass,...
        'KernelFunction','rbf',...
        'Standardize',true,...
        'ClassNames',[false,true],...
        'KernelScale','auto');
end
```

4. Sonuç ve öneriler

4. Conclusions and recommendations

Bu çalışmada, BDYK yöntemi ile ön işlenmiş hiperspektral görüntü verilerinin LÖ ve SÖ graf tabanlı boyut indirgeme adımı sonrası sınıflandırma kabiliyeti araştırılmıştır. Her veri seti için varsayılan sayıda kullanılan özvektör değerlerinin performansı PSO sonrası iyileştirme ile belirlenen özvektör değerlerinin sınıflandırma üzerindeki performansı araştırılmış ve sonuçlar gösterilmiştir. Görüntülerin sınıflandırılması DVM makine öğrenmesi algoritması kullanılmıştır. Boyut indirgeme aşamasında kullanılan LÖ ve SÖ adımlarından sonra USSÖ yöntemi ile özvektörler belirlenmiştir. Varsayılan özvektör değerleri ile sınıflandırma yapılmıştır. Bu sonuçlar PSO ile iyileştirilmiş ve çalışma kapsamında irdelenmiştir. Özvektör değerleri Indian Pines veri seti için 130, Salinas veri seti için 120 ve Pavia Üniversitesi için 40 olarak bulunmuştur. Bu değerler sonucu görüntülerin sınıflandırma performansları artırılmıştır fakat sonuçların elde edilme süresi de özvektör sayısı ile doğru orantılı olarak uzamıştır. Özvektör sayılarının veri setinin içerdiği sınıf sayısına bağlı olarak yine doğru orantılı artış ya da azalış gösterdiği görülmüştür. Bu sayı 16 sınıflık Indian Pines ve Salinas için 130 ve 120 iken 9 sınıftan oluşan Pavia Üniversitesi veri seti için 40'tır. Gelecek çalışmalar için diğer hiperspektral görüntü veri seti olan KSC, Botswana, Houston2013 ve Kennedy Uzay Merkezi görüntüleri üzerinde çalışmalar yapılabilir. Özvektör sayıları arttıkça uzayan görüntü işleme ve sınıflandırma sürelerinin nasıl kısaltılabileceği üzerine analizler yapılabilir.

Kaynaklar

References

- Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P. & Süsstrunk, S. (2012). SLIC superpixels compared to state-of-the-art superpixel methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34(11), 2274-2282. [https://doi: 10.1109/TPAMI.2012.120](https://doi.org/10.1109/TPAMI.2012.120).
- Acosta, I., C., C., Khodadadzadeh, M., Tolosana-Delgado, R. & Gloaguen, R. (2020). Drill-Core hyperspectral and geochemical data integration in a superpixel-based machine learning framework. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 4414-4228. [https://doi: 10.1109/JSTARS.2020.3011221](https://doi.org/10.1109/JSTARS.2020.3011221).
- Alasvand, Z., Naderan, M. & Akbarizadeh, (2017). Superpixel-based feature learning for joint sparse representation of hyperspectral images. *2017 3rd International Conference on Pattern Recognition and Image Analysis (IPRIA)*, 156-159. [https://doi: 10.1109/PRIA.2017.7983037](https://doi.org/10.1109/PRIA.2017.7983037).
- Belkin, M., & P. Niyogi. (2003). Laplacian eigenmaps for dimensionality reduction and data representation. *Neural Computation* 15(6): 1373–1396. [https://doi:10.1162/089976603321780317](https://doi.org/10.1162/089976603321780317).
- Bernabe, S., P. Reddy Marpu, A. Plaza, M. Dalla Mura, & J. Atli Benediktsson (2014). Spectral–Spatial classification of multispectral images using kernel feature space representation. *IEEE Geoscience and Remote Sensing Letters* 11 (1): 288–292. [https://doi:10.1109/LGRS.2013.2256336](https://doi.org/10.1109/LGRS.2013.2256336).
- Cahill, N., D., W. Czaja, D. & W., Messinger, (2014). Schrodinger eigenmaps with nondiagonal potentials for spatial-spectral clustering of hyperspectral imagery. *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XX, Vol. 9088*, International Society for Optics and Photonics, p. 908804.

- Cahill, N. D., S. E. Chew, & P. S. Wenger (2015). Spatial-Spectral dimensionality reduction of hyperspectral imagery with partial knowledge of class labels. *proceedings SPIE Defense & Security: Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XXI 94720: 1–14*. <https://doi.org/10.1117/12.2177139>.
- Czaja, W., & M. Ehler (2013). Schroedinger eigenmaps for the analysis of biomedical data. *IEEE Transactions on Pattern Analysis and Machine Intelligence 35*: 1274–1280. <https://doi.org/10.1109/TPAMI.2012.270>.
- Datta, D., Mallick, P., K., Bhoi, A., K., Ijaz, M., F., Shafi, J. & Choi, J (2022). Hyperspectral image classification: potentials, challenges, and future directions. *Advanced Computational Intelligence Algorithms for Signal and Image Processing*, <https://doi.org/10.1155/2022/3854635>.
- Fejjari, A., Saheb Etabaa, K. & Korbaa, O. Spatial spectral schroedinger eigenmaps approach based on spectral angle distance for hyperspectral imagery classification. *Indian Soc Remote Sens 49*, 2689–2700 (2021). <https://doi.org/10.1007/s12524-021-01417-3>.
- Gao F, Wang Q, Dong J & Xu Q. Spectral and spatial classification of hyperspectral images based on random multi-graphs. *Remote Sensing*, <https://doi.org/10.3390/rs10081271>.
- Ghasrodashti, E., K., Helfroush, M., S. & Danyali, H. (2017). A wavelet-based classification of hyperspectral images using Schroedinger eigenmaps. *International Journal of Remote Sensing*, <https://doi.org/10.1080/01431161.2017.1302108>.
- GIC-Grupo De Inteligencia Computacional. (2021, 12 Temmuz). https://www.ehu.es/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes
- Gurram, P. & Kwon, H.: Support-vector-based hyperspectral anomaly detection using optimized kernel parameters. *IEEE Geosci. Remote Sens. Lett.* 8(6), 1060–1064 (2011). <https://doi.org/10.1109/LGRS.2011.2155030>.
- He, L., J. Li, C. Liu & S. Li, Recent advances on spectral–spatial hyperspectral image classification: an overview and new guidelines, *IEEE Transactions on Geoscience and Remote Sensing*, <https://doi.org/10.1109/TGRS.2017.2765364>.
- Jia, S., Zhang, Z., Zhang, M., Xu, M., Huang, Q., Zhou, J. & Jia, X. (2021) Multiple feature-based superpixel-level decision fusion for hyperspectral and LiDAR data classification, *IEEE Transactions on Geoscience and Remote Sensing*, 2021, <https://doi.org/10.1109/TGRS.2020.2996599>.
- Kennedy, S., M., W. Williamson, J. D. Roth & J. W. Scrofani (2020). Cluster-Based spectral-spatial segmentation of hyperspectral imagery, *IEEE Access*, <https://doi.org/10.1109/ACCESS.2020.3011668>.
- Kim, D.H. & L.H. Finkel, Hyperspectral image processing using locally linear embedding, in: *Neural Engineering, 2003. Conference Proceedings. First International IEEE EMBS Conference on, IEEE, 2003*, pp. 316–319.
- Özdemir, A. & Polat K. (2020). Deep learning applications for hyperspectral imaging: a systematic review. *Journal of the Institute of Electronics and Computer*, <https://doi.org/10.33969/JIEC.2020.21004>.
- Özer, F. & Özkaya, U. (2017). Süperpiksel algoritmalarının gürültülü imgeler için bölütleme performansının incelenmesi, *Akıllı Sistemlerde Yenilikler ve Uygulamaları Konferansı 2017*, Antalya, Turkey.
- Suresh, S. & Lal, S. (2019). A metaheuristic framework based automated spatial-spectral graph for land cover classification from multispectral and hyperspectral satellite images. *Infrared Physics & Technology*, <https://doi.org/10.1016/j.infrared.2019.103172>.
- Verdoja, F. & Grangetto, M. (2020). Graph Laplacian for image anomaly detection. *Machine Vision and Applications*, <https://doi.org/10.1007/s00138-020-01059-4>.
- Üstüner, M. (2023). Çekirdek tabanlı aşırı öğrenme makinesi ile hiperspektral görüntü sınıflandırma. *Turkish Journal of Remote Sensing and GIS*, 4(2), 198–212. <https://doi.org/10.48123/rsgis.1237772>.
- Wang, L., Peng, J. & Sun, W. Spatial–Spectral squeeze-and-excitation residual network for hyperspectral image classification. *Remote Sens.* 2019, 11, 884.

- Zhang, X., Selene, E., Chew, Zhenlin, Xu & Nathan D. Cahill, SLIC superpixels for efficient graph-based dimensionality reduction of hyperspectral imagery, *Proc. SPIE 9472, Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XXI, 947209 (21 May 2015)*, <https://doi.org/10.1117/12.2176911>.
- Zhang, X., Y. Liang & N. Cahill, Using superpixels to improve the efficiency of Laplacian Eigenmap based methods for target detection in hyperspectral imagery, *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Beijing, China, 2016*, pp. 5876-5879, <https://doi: 10.1109/IGARSS.2016.7730535>.
- Zhao, Y. & Yan, F. (2021). Hyperspectral image classification based on sparse superpixel graph. *Remote Sensing*, <https://doi.org/10.3390/rs13183592>.