

Hiperspektral Görüntü ile LiDAR Verisinin Tümleştirilmesi ve Derin Evrişimsel Sinir Ağları İle Sınıflandırılması

Fusion of Hyperspectral Image and LiDAR Data and Classification using Deep Convolutional Neural Networks

Mesut Salman, Seniha Esen Yüksel

Elektrik ve Elektronik Mühendisliği Bölümü, Hacettepe Üniversitesi, Ankara, 06800, Türkiye
mesalman@aselsan.com.tr, eyuksel@ee.hacettepe.edu.tr

Özetçe— Gelişen uzaktan algılama teknolojisi ile birlikte, elektromanyetik spektrumda yüzlerce farklı dalga boyunda hiperspektral görüntüler elde edilmektedir. Bu görüntülere ek olarak elde edilen yükseklik bilgilerini içeren LiDAR verileri, görüntüsü alınan bölgeye yönelik ek bilgiler sağlamaktadır. Bu veri kümelerinden faydalananak anlamsal bölütme probleminin çözümünün iki aşaması bulunmaktadır. Öncelikle farklı kaynaklardan elde edilen bilgilerin tümleştirilmesi ardından sınıflandırılması temel aşamalıdır. Bu çalışma kapsamında öncelikle Houston veri kümesindeki hiperspektral görüntülerden ve LiDAR verilerinden biçimsel profil haritaları üretilmiş ardından bu spektral veriler ve biçimsel profiller boyutsal olarak tümleştirilmiştir. Bu veri imge sınıflandırulmasında oldukça etkili bir derin evrişim mimarisine sahip AlexNet'in ilk evrişim katmanında yer alan filtreler ile filtrelenmiştir. Daha sonra da, bu veriye özel olarak modellenmiş bir derin evrişimli sinir ağının (DESA) mimarisine ile sınıflandırılması gerçekleştirilmiştir. Sınıflandırma sonuçları son yıllarda önerilmiş beş yöntem ile karşılaştırılmış, ve önerilen yöntemin karşılaştırılan yöntemler arasında en iyi sonuçları verdiği görülmüştür.

Anahtar Kelimeler — hiperspektral veri sınıflandırma, derin evrişimsel sinir ağları, hiperspektral ve LiDAR veri tümleştirme, biçimsel profil çıkarımı

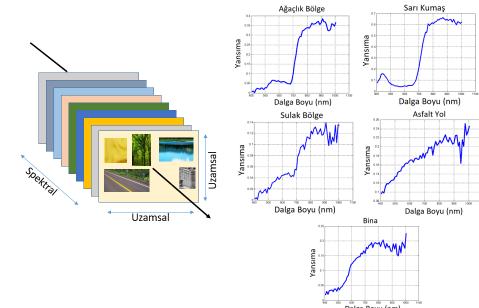
Abstract— With the developing remote sensing technology, hundreds of different wavelengths of hyperspectral images are obtained in the electromagnetic spectrum. LiDAR data, which gives altitude information, provides additional information for the area being imaged. In this study, there are two stages of solving the problem of semantic segmentation using these datasets, namely the information fusion and classification. In this study, firstly, morphological profile maps were produced from the hyperspectral LiDAR images in the Houston dataset, then these spectral data and morphological profiles were integrated through concatenation. Then, this data was filtered by the filters in the first convolution layer of AlexNet, which has a highly efficient deep convolutional architecture in image classification. Finally, this data was classified with a proposed deep convolutional neural network. Classification results are compared with the five methods proposed in the recent years, and it has been shown that our

proposed method gives the best results among the competing methods.

Keywords — *hyperspectral image classification, deep convolutional neural networks, fusion of hyperspectral and LiDAR, extended morphological profiles*

I. GİRİŞ

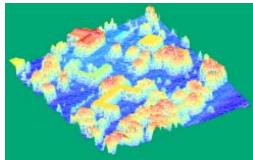
'Hiper' ve 'spektral' kelimelerinden oluşan 'hiperspektral' çok sayıda spektral banttan oluşan anlamına gelmektedir. Hiperspektral kameralar ile alınan ölçümlerde, her bir materyalin farklı dalga boylarında ışığı farklı şekilde yansımmasına bağlı olarak, o materyallere ait spektral imzalar çıkartılır ve görüntü içerisinde yer alan her bir pikselin hangi materyali içerdığı tespit edilir. Hiperspektral görüntüleme; maden ve mineral tespiti, besinlerin kalitesinin tespiti, zirai ürünlerin sınıflandırılması; mayın tespiti gibi birçok alanda kullanılmaktadır ([1] [2] [3]). Hiperspektral görüntüler "hiperküp" olarak adlandırılan yapılarında tutulmaktadır. Temsili bir hiperküp ve görüntüde yer alan pikselin içeriği materyal ve materyalin spektral izması Şekil 1 ile verilmektedir.



Şekil 1: Temsili bir Hiperspektral Veri Kübü ve Farklı Piksellerde Yer Alan Farklı Nesnelerin Spektral İzmazı

Hiperspektral görüntülere ek bilgi sağlama nedeniyle LiDAR verilerinin anlamlandırılması büyük önem taşımaktadır. Örneğin beton yol ve t çatı malzemelerinin spektral veri bilgisi

materyal yapitaşlarının benzerliğinden dolayı büyük benzerlik göstermektedir. Ancak iki farklı sınıfta yer alan bu nesnelerin LiDAR verileri incelendiğinde, bu nesnelerin varyanzında bulundukları konum itibariyle LiDAR verileri farklılık göstermeye ve hiperspektral verilere ek bir girdi sağlamaktadır. Şekil 2 ile örnek bir LiDAR yükseklik haritası görseli sağlanmıştır.



Şekil 2: LiDAR Yükseklik Haritası Örneği

Hiperspektral görüntülerin denetimli bölütlemesinde kullanılmak üzere birçok yöntem önerilmiştir. Yalnızca spektral bilgiyi kullanan k-en yakın komşu, maksimum olasılık, minimum mesafe ve lojistik regresyon gibi algoritmalar, "yüksek boyutluluk" problemine karşı etkin bir çözüm sunamamaktadır [3]. Oysa ki, iyi bir sınıflandırma işlemi en temelde türeltilmiş iyi öznitelikler ile mümkündür. Son yıllarda uzamsal bilgi, hiperspektral veri sınıflandırması için gittikçe daha fazla önem kazanmaktadır. Bunun sonucu olarak Hiperspektral verilerden spektral özniteliklere ek olarak uzamsal özniteliklerin de çıkarılması ile birlikte çevre piksellerin etkisi öznitelik olarak sınıflandırıcılarla verilmeye başlanmıştır [4]. Bu gelişmelere ek olarak son yıllarda görüntü işleme alanında çığır açan derin öğrenme tabanlı sınıflandırma ve öznitelik çıkarma yöntemleri hiperspektral veri kümelerine de uygulanmaya başlanmıştır ([5] [11]).

Bu çalışmada bıçimsel profil haritaların çıkarımı, derin evrişimsel sınır ağları kurulumu, hiperspektral ve LiDAR verilerinin tümleştirilmesi ve sonuç olarak sınıflandırma sonuçlarının diğer güncel çalışmalar ile karşılaştırılması sırasıyla alt başlıklarda detaylandırılmıştır.

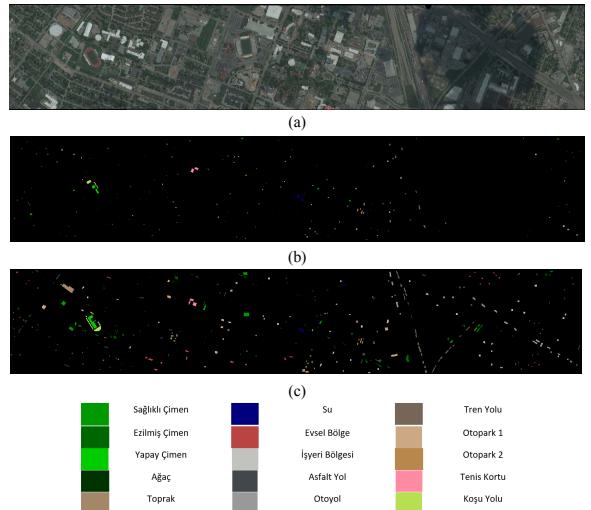
II. VERİ KÜMESİ

IEEE (Institute of Electrical and Electronics Engineers) Yer Bilimleri ve Uzaktan Algılama Topluluğunun 2013 yılında düzenlediği bir yarışmada sağlanan bu veri kümesi ABD'nin Houston Üniversitesi bölgesinin çevresinden elde edilmiştir. 349x1905 uzamsal çözünürlüğe sahip hiperspektral görüntüde 380 nm ile 1050 nm dalga boyu aralığında 144 farklı spektral bant bulunmaktadır. Verilerin uzamsal çözünürlüğü ise 2.5m'dir. Hiperspektral verilere ek olarak LiDAR yükseklik ve yoğunluk verileri de bu veri kümesi içerisinde sağlanmıştır. Veri kümesinde yer alan ve araştırmacılara eğitim ve test veri kümesi başlığı altında sunulan 15 farklı sınıfa ait eğitim ve test verileri örnek sayıları ve sınıf bilgileri Tablo 1 ile verilmektedir.

Houston veri kümesine yönelik olarak bölgeye ait KYM(Kırmızı-Yeşil-Mavi) gösterimi, eğitim ve test örneklerinin HSG (Hiperspektral Görüntü) üzerindeki konumları Şekil 3 ile verilmektedir. İlgili şekil incelendiğinde imgenin sağ tarafında şehir içi bölgenin bir kısmı buluttan kaynaklanan gölge sebebiyle karartı altında kaldığı görülmektedir. Ayrıca gölgelik alana dair oldukça kısıtlı sayıda eğitim verisi örneği bulunmakla birlikte yüksek miktarda test verisi bu bölgeden alınmıştır.

Tablo 1: Houston Üniversitesi Veri Kümesi İçeriği

Sınıf Numarası	Sınıf Adı	Eğitim Verisi Miktarı	Test Verisi Miktarı
1	Sağlıklı Çimen	198	1053
2	Ezilmiş Çimen	190	1064
3	Yapay Çimen	192	505
4	Ağaç	188	1056
5	Toprak	186	1056
6	Su	182	143
7	Evsel Bölge	196	1072
8	İşyeri Bölgesi	191	1053
9	Asfalt Yol	193	1059
10	Otoyol	191	1036
11	Tren Yolu	181	1054
12	Otopark 1	192	1041
13	Otopark 2	184	285
14	Tenis Kortu	181	247
15	Koşu Yolu	187	473



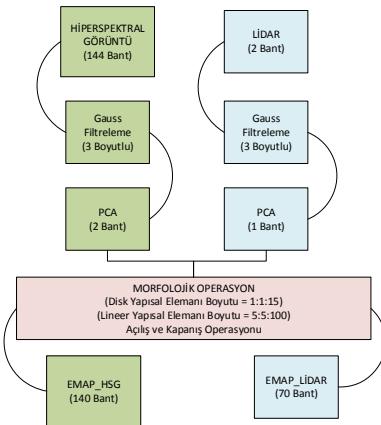
Şekil 3: (a) Houston verisinin sahte KYM ile gösterimi (b) Eğitim Veri Kümesi Noktaları ve Sınıf-Renk İlişkisi. (c) Test Veri Kümesi Noktaları ve Sınıf – Renk İlişkisi.

III. EMAP YÖNTEMİ İLE BİÇİMSEL PROFİL HARİTALARININ OLUSTURULMASI

Bu çalışma kapsamında veri kümelerine öncelikle Gauss filtreleri ile yumusatma uygulanmıştır. Spektral boyutun tamamını kapsayan Gaussfiltrelemesi ile spektral ve uzamsal eksende gürültünün azaltılması sağlanmıştır. Bu işlemin ardından HSG'lere PCA uygulanmış veri kümelerinin boyutu düşürülmüştür. Hiperspektral verilere uygulanan PCA sonucu oluşan ilk iki temel bileşenin kümülatif varyansın %99'undan fazlasını temsil ettiği görülmüştür.

Hem LiDAR hem de ilk iki temel bileşen ile yeniden yapılandırılmış HSG üzerinden morfolojik profillerin çıkarımı gerçekleştirilmiştir. Farklı boyutlarda ve şekillerde yapısal elemanlar kullanılarak açılış ve kapanış işlemleri gerçekleştirilmiştir [6]. Öncelikle disk şecline sahip yapısal eleman ile hem LiDAR hem de HSG için 15'er adet açma ve kapama işlemi uygulanmıştır. Disk şekilli yapısal elemanın yarıçapı 1'den 1'er kademeli artış ile 15'e kadar artırılarak biribirinden farklı morfolojik profiller oluşturulmuştur. Ardından aynı veri kümelerine lineer yapısal elemanın boyutu 5'den başlayarak 5'er kademeli artış ile 100'e kadar 20 adet açma ve kapama işlemi uygulanmıştır. Bu işlemler sonucu HSG'lere her bir temel bileşene özgü 70'er adet morfolojik profil oluşturulmuştur. İlgili işlemler Şekil 4 ile verilmektedir. Sonuç

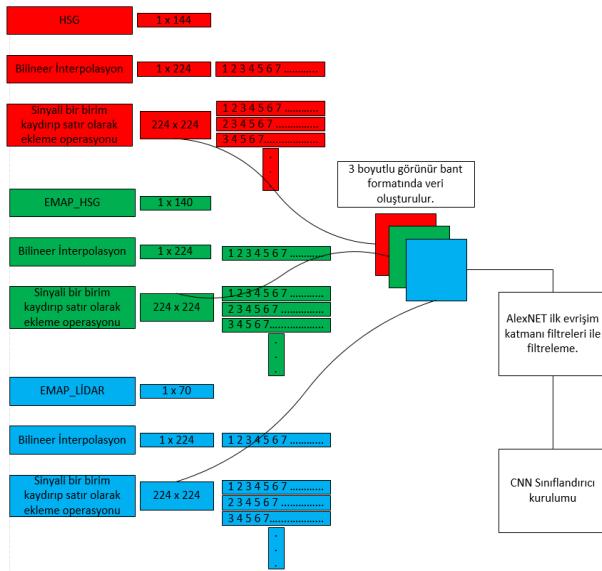
olarak EMAP'leri içeren Houston veri kümesi HSG'leri verisinin boyutu 349x1905x140, EMAP'leri içeren Houston veri kümesi LiDAR verisinin boyutu ise 349x1905x70 olmuştur. Burada üretilen biçimsel özelliklerini içeren haritaları içeren veriler EMAP_HSG ve EMAP_LiDAR olarak adlandırılmıştır.



Şekil 4: Morfolojik Profil Oluşturma Basamakları – Houston Veri Kümesi

IV. HİPERSPETRAL VE LİDAR VERİ KÜMELERİNİN TÜMLEŞTİRİLMESİ

AlexNet ([12]) ağının ilk evrişim katmanında yer alan filtrelerin kullanılarak öznitelikler üretme amacıyla sırasıyla piksel seviyesinde spektral ve biçimsel veriler interpolasyon yöntemiyle boyutları 1×224 'e getirilmiştir. Herbir veri kümesi birer basamak kaydırılmış ve alt alta yerleştirmiştir. Sonuç olarak $224 \times 224 \times 3$ 'luk bir veri oluşturulmuştur. Ardından AlexNet tarafından öğrenilen ilk katmandaki filtreler kullanılarak eğitim kümesi oluşturulmuş buna ek olarak spektral ve uzamsal haritaların tümleştirilmesi sağlanmıştır. Şekil 5 ile tümleştirme ve iyileştirilmiş AlexNet'in ilk evrişim katmanının çıktıları blok diyagramlar halinde verilmektedir.



Şekil 5: AlexNet Girdisi Oluşturacak Şekilde Hiperspektral ve LIDAR özniteliklerin Tümleştirilmesi

HSG ve LiDAR verilerinin $224 \times 224 \times 3$ boyutununa getirilmesinin ardından; AlexNet'in ilk katmanında yer alan; evrişim katmanı, normalizasyon ve aktivasyon işlemi ve son olarak da havuzlama katmanı ile verinin boyutu $24 \times 24 \times 64$ 'e dönüştürülmüştür. Ardından önerilen DESA (Derin Evrişimli Sinir Ağları) ile sınıflandırma işlemi gerçekleştirilmiştir.

V. ÖNERİLEN SINIFLANDIRMA MODELİ

Bu bölümde kaynaştırılması gerçekleştirilmiş ve AlexNET ([12]) sinir ağı modelinde yer alan ilk evrişim katmanından geçirilmiş veri kümesine yönelik olarak yeni bir derin evrişimsel sinir ağı modeli oluşturulmuştur. Önerilen sınıflandırıcıda temel olarak 2 evrişim katmanı, 1 havuzlama katmanı ve 1 adet tam bağlı katman yer almaktadır. Aktivasyon fonksiyonu olarak RELU kullanılmıştır. Soft-max sınıflandırıcı ile ağ sonlandırılmıştır. İlgili DESA modelinde yer alan detaylı bilgiler Tablo 2 ile verilmektedir. Bu ağın sonuçlarının çok başarılı olduğu görülmüştür.

Tablo 2: Spektral-EMAP_HSG-EMAP_LiDAR Boyutsal Tümleştirilmiş ve AlexNet İlk Evrişim katmanı Filtreleri ile Oluşturulmuş Veri Kümelerine Özel DESA Detaylı Model

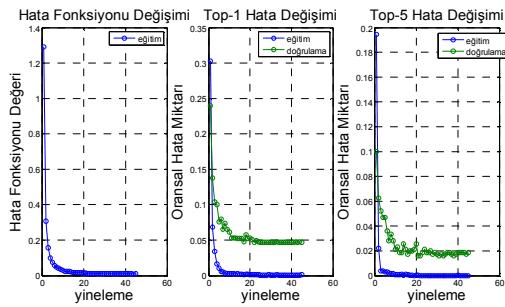
GIRDİ	[27x27x64]
EVİRİŞİM_1 Aktivasyon Fonksiyonu : RELU	Çekirdek Boyutu : $6 \times 6 \times 64$ Çekirdek Sayısı # 64 Kayma Miktarı : 3
Özellik Haritası	[8 x 8 x 64]
EVİRİŞİM_2 Aktivasyon Fonksiyonu : RELU	Çekirdek Boyutu: $5 \times 5 \times 64$ Çekirdek Sayısı # 128 Kayma Miktarı : 3
Özellik Haritası	[2 x 2 x 128]
Havuzlama_1 (Max)	Havuzlama Boyutu : [2 x 2]
Özellik Haritası	[1 x 1 x 128]
Tam Bağlı Katman	$1 \times 1 \times 15$
SoftMax Kayıp Fonksiyonu	
Çıktı	Olasılık Vektörü [1 x 15]

VI. DENEYSEL SONUÇLAR

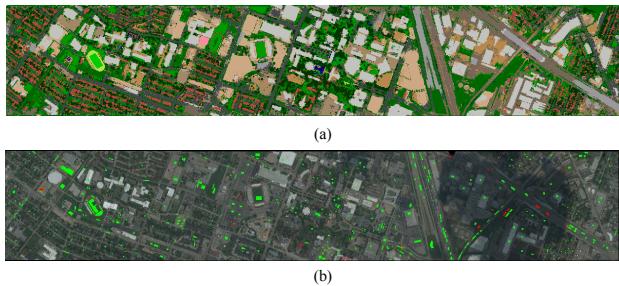
Eğitim esnasında oluşan sınıflandırıcı sonuçlarını içeren grafikler Şekil 6 ile verilmiştir. Grafikte yer alan Top-1 hata değişimi eğitim ve doğrulama kümelerinin her bir yinelemde oluşan hata oranını, Top-5 hata değişimi ise ağ tarafından oluşturulan sonuçların en yüksek 5 olasılıklı değerinin doğru sınıfta bulunmama durumunu gösteren hata durumunu göstermektedir. Eğitim grafikleri incelemişinde eğitim esnasında verilerin eğitim kümesinin eğitiminin sağlandığı ve doğrulama kümesi üzerinde de iyi başarımlar elde edildiği görülmektedir. Sınıflandırma başarılarının raporlanması sadece test pikselleri üzerinden (Şekil 7-b) yapılmakla birlikte, tüm görüntüde de makul bir sınıflandırma yapılabildiği görülmektedir (Şekil 7-a).

DESA ile sınıflandırma sonucu oluşan karışıklık matrisi Tablo 3 ile verilmektedir. Burada özellikle sağlıklı çimen ile ezilmiş çimen sınıflarının birbirlerine karışabildiği görülmektedir. Spektral imzaları çok yüksek oranda benzerlik gösteren bu iki sınıfın çevresinde yer alan sınıflarda benzerlik gösterebilmesi durumundan dolayı ayrıca diğer çalışmalar da birbirine en çok karışan sınıflar olduğu için toplam başarımı etkileyen önemli unsur olduğu görülmektedir. Benzer şekilde

otoyol ile tren yolu sınıflarının da birbirlerine karışabildiği görülmüştür. Bu bilgilere ek olarak özellikle gölgelik alanda bulunan test verilerinin de sınıflandırma başarısının toplam başarımı düşüren etkiye sebep olduğu görülmektedir.



Şekil 6: Houston EMAP_LiDAR ve EMAP_HSG piksel seviyesinde tümleştirilmiş veri kümelerine özel DESA Eğitim Grafikleri – Hata Fonksiyonu Değişimi – Top-1 Hatalı Sınıflandırma Oranı Değişimi (Toplam Oransal Hata) – Top-5 Hatalı Sınıflandırma Oranı Değişimi (Olasılıksal olarak en yüksek 5 değerin doğru sınıfla eşleşmemesi durumu)



Şekil 7: Sınıflandırma Sonuçları – (a) tüm görüntünün sınıflandırılması sonuçları –(b) Sadece ilgili test piksellerin sınıflandırılması sonuçları (Kırmızı: Hatalı sınıflandırma, Yeşil: Doğru Sınıflandırma)

Tablo 3: Sınıflandırıcı Karışıklık Matrisi

	#1	#2	#3	#4	#5	#6	#7	#8	#9	#10	#11	#12	#13	#14	#15
#1	84.40	14.6	-	0.95	-	-	-	-	-	-	-	-	-	-	-
#2	0.66	98.9	-	0.38	-	-	-	-	-	-	-	-	-	-	-
#3	-	-	100	-	-	-	-	-	-	-	-	-	-	-	-
#4	1.04	1.04	97.82	-	-	0.09	-	-	-	-	-	-	-	-	-
#5	-	-	-	99.90	-	-	-	-	-	-	-	-	-	0.09	-
#6	-	-	-	-	99.30	-	-	-	-	-	-	-	-	0.69	-
#7	0.18	0.37	-	0.09	0.56	92.44	4.38	0.09	-	1.21	0.09	0.56	-	-	-
#8	-	-	-	-	-	1.71	96.86	-	-	-	-	1.42	-	-	-
#9	-	-	-	-	-	1.42	-	-	90.93	0.66	3.49	3.49	-	-	-
#10	-	-	-	-	-	-	3.18	0.09	82.34	14.38	-	-	-	-	-
#11	-	-	-	-	-	-	-	-	0.28	95.43	-	0.28	-	-	-
#12	-	-	-	-	-	-	-	-	9.03	-	0.38	90.49	0.09	-	-
#13	-	-	-	-	-	-	-	-	-	5.61	4.91	2.46	87.02	-	-
#14	-	-	-	-	-	-	-	-	-	-	-	-	100	-	-
#15	-	-	-	-	-	-	-	-	-	-	-	-	-	-	100

Bu çalışmanın, derin evrişimsel sınır ağlarının yer aldığı diğer çalışmalar ile karşılaştırıldığında oluşan sonuçlar Tablo 4 ile verilmektedir. Özellikle gölge bölgeye yönelik ekstra bir önlem alınmayan çalışmalar içerisinde bu çalışma sonucu en iyi sınıflandırıcı sonucunun yakalandığı görülmektedir. Ancak gölgeden kaynaklı alana özel önlem alan sınıflandırıcı sonuçlarından bir miktar düşük sınıflandırma sonuçları elde edilmiştir [10].

Bu çalışma sonucunda hiperspektral verilerin sınıflandırılmasında derin evrişimsel sınır ağlarının rekabetçi sonuçlar verebildiği görülmüştür. Özellikle eğitim veri kümelerinde bulunan veri miktarının artırılması DESA'nın başarısını daha da üst seviyelere taşımamasını sağlayacaktır. Bütün bunlara ek olarak LiDAR verisinin çok önemli tamamlayıcı bilgiler sağladığı ancak bu bilgilerin doğru

tümleştirme yöntemiyle ortaya çıkabileceği görülmüştür. AlexNet ile önerilen filtrelerin ise genel özellik bilgilerini kullanmak için oldukça kullanışlı bilgiler sunduğu ve bu filtrelerin HSG'lere uygulanabilirliği bu çalışmada doğrulanmış ve gösterilmiştir.

Tablo 4 Önerilen Yöntem Mevcut Yöntemlerle Karşılaştırılması

Sınıf	GBFF CNN [11]	MLRsub MRF [8]	OTCVA RF [9]	GGF-SVM [7]	MFC SVM [10]	Onerilen Yöntem
#1	78.73	83.1	80.6	82.9	97.3	84.42
#2	94.92	83.1	99.6	99.3	97.0	98.97
#3	100	100	100	100	100	100
#4	99.34	95.9	96	99.3	97.4	97.82
#5	99.62	100	99.4	100	99.8	99.90
#6	95.80	98.8	95.8	95.1	95.8	99.30
#7	87.87	84.8	86.0	90.9	97.4	92.44
#8	95.25	83.6	93.5	95.6	91.5	96.87
#9	89.71	96.5	97.1	89.3	93.9	90.93
#10	81.18	86.8	68.5	92.8	90.1	82.33
#11	86.34	99.7	98.9	96.6	98.6	99.43
#12	92.70	99.8	100	91.9	97.7	90.49
#13	87.02	85.3	74.7	74.4	82.5	87.02
#14	99.19	100	100	100	100	100
#15	89.64	98.7	100	98.7	98.7	100
Genel Test Başarımı	91.8	92.9	92.7	93.8	95.6	93.97
Ortalama Test Başarımı	91.0	92.0	92.4	94.0	95.9	94.66
kappa	0.90	0.91	0.92	0.93	0.96	0.9346

TEŞEKKÜR

Bu çalışma TÜBİTAK tarafından 115E318 numaralı proje kapsamında desteklenmiştir.

KAYNAKLAR

- [1] Kim, M.S., Chen, Y.R., Mehl, P.M., (2001), "Hyperspectral Reflectance and Fluorescence Imaging System for Food Quality and Safety", Transactions of ASAE, vol.44, no.3,721-729.
- [2] Cathcart, J.M., Bock, R.D. ve Campbell, R., (2004), "Analysis of Soil and Environmental Processes on Hyperspectral Infrared Signatures of Landmines", Technical Report, Georgia Inst. of Tech.-Electro-Optics Enviroment and Materials Lab. Avaiable at: <http://handle.dtic.mil/100.2/ADA432578>.
- [3] G. Foody and A. Mathur, "A relative evaluation of multiclass image classification by support vector machines," in IEEE Transactions on Geoscience and Remote Sensing, vol. 42, no. 6, pp. 1335-1343, June 2004.
- [4] B. Song et al., "Remotely Sensed Image Classification Using Sparse Representations of Morphological Attribute Profiles," in IEEE Transactions on Geoscience and Remote Sensing, vol. 52, no. 8, pp. 5122-5136, Aug. 2014.
- [5] M. Salman and S. E. Üysel, "Hyperspectral data classification using deep convolutional neural networks," in 2016 24th Signal Processing and Communication Application Conference (SIU), Zonguldak, Turkey, 2016, pp. 2129-2132.
- [6] W. Liao, R. Bellens, A. Pižurica, W. Philips, and Y. Pi, "Classification of hyperspectral data over urban areas using directional morphological profiles and semi-supervised feature extraction," IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens., vol. 5, no. 4, pp. 1177-1190, Aug. 2012.
- [7] W. Liao, A. Pižurica, R. Bellens, S. Gautama and W. Philips, "Generalized Graph-Based Fusion of Hyperspectral and LiDAR Data Using Morphological Features," in IEEE Geoscience and Remote Sensing Letters, vol. 12, no. 3, pp. 552-556, March 2015.
- [8] M. Khodadadzadeh, J. Li, S. Prasad and A. Plaza, "Fusion of Hyperspectral and LiDAR Remote Sensing Data Using Multiple Feature Learning," in IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 8, no. 6, pp. 2971-2983, June 2015.
- [9] B. Rasti, P. Ghamisi, J. Plaza and A. Plaza, "Fusion of Hyperspectral and LiDAR Data Using Sparse and Low-Rank Component Analysis," in IEEE Transactions on Geoscience and Remote Sensing, vol. 55, no. 11, pp. 6354-6365, Nov. 2017.
- [10] R. Luo et al., "Fusion of Hyperspectral and LiDAR Data for Classification of Cloud-Shadow Mixed Remote Sensed Scene," in IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 10, no. 8, pp. 3768-3781, Aug. 2017.
- [11] P. Ghamisi, B. Höfle and X. X. Zhu, "Hyperspectral and LiDAR Data Fusion Using Extinction Profiles and Deep Convolutional Neural Network," in IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 10, no. 6, pp. 3011-3024, June 2017.
- [12] Krizhevsky, Alex & Sutskever, Ilya & Hinton, Geoffrey. (2012). ImageNet Classification with Deep Convolutional Neural Networks. Neural Information Processing Systems. 25. . 10.1145/3065386.