

Hiperspektral Verilerin Derin Konvolüsyonel Sinir Ağlarıyla Sınıflandırılması

Hyperspectral Data Classification using Deep Convolutional Neural Networks

Mesut Salman¹, Seniha Esen Yüksel²

¹Tübitak Bilgem İLTAREN, Ankara, Türkiye

²Elektrik ve Elektronik Mühendisliği Bölümü, Hacettepe Üniversitesi, Ankara, Türkiye
mesut.salman@tubitak.gov.tr, eyuksel@hacettepe.edu.tr

Özetçe—Bilgisayarlı görü alanında, öznelik çıkarımı ve sınıflandırılması, iki temel problemi teşkil etmektedir. Son beş yılda bu alanlarda çığır açan derin öğrenme yöntemi, hem öznelikleri hem de sınıflandırıcıları otomatik olarak öğrenebilmesiyle öne çıkmaktadır. Fakat, hiperspektral görüntülerin sınıflandırılmasında derin öğrenmeyi inceleyen çok az sayıda çalışma bulunmaktadır. Bu çalışmada, hiperspektral görüntüler için derin öğrenme kullanılmış ve hiperspektral veriye uygun bir derin öğrenme yapısı önerilmiştir. Sonuçlar literatürde yayınlanmış ve aynı veri üzerinde çalışılmış destek vektör makineleri ve K-en yakın komşuluk algoritmaları ile karşılaştırılmış, derin öğrenmenin ve önerilen mimarinin sınıflandırmada çok daha başarılı olduğu görülmüştür.

Anahtar Kelimeler — derin öğrenme, hiperspektral veri sınıflandırma, öznelik çıkarımı, segmentasyon.


Abstract—In the last five years, deep learning has been gaining a large amount of interest in the computer vision community due to its capability to perform feature learning and classification at the same time. However, the studies using deep learning for hyperspectral imaging are still very few. In this paper, a deep convolutional neural network structure to classify hyperspectral data is proposed. The results are compared to the support vector machine and K-nearest neighbourhood algorithms and it has been shown that deep learning with the proposed architecture is much more successful in hyperspectral data classification.

Keywords — deep learning, hyperspectral image classification, feature extraction, classification.

I. GİRİŞ

İnsan gözü kırmızı-yeşil-mavi renk filtrelerine duyarlılık göstermekte ve yaygın olarak kullanılan kameralar da bu bantlarda veri toplamakta, diğer bantlardan gelebilecek ortama ait birçok detay kaybedilememektedir. Buna karşılık, son yıllarda yaygınlaşan hiperspektral görüntüleme elektromanyetik spektrumun onlarca ya da yüzlerce farklı bandından veri alınabilmektedir [1]. Bu özelliğiyle, hiperspektral

görüntüleme madencilikten yer bilimlerine, tarımdan astronomiye ve askeri alanlara kadar uzanan ve her geçen gün kullanım alanı artan bir teknoloji haline gelmiştir [2][3][4]. Hiperspektral görüntüler Şekil 1(a)'da gösterildiği gibi hiperküpler halinde saklanmaktadır. Burada iki boyut uzamsal üçüncü boyut ise spektral değişimi ifade etmektedir. Hiperspektral görüntülemenin bir önemli özelliği de, ışığı yansıtma özelliklerine göre nesnelerin kendilerine özgü birer spektral imzasının bulunmasıdır. Şekil 1(b)'de, örnek bir imza gösterilmiştir. Bu imzalar veri sınıflandırma ve obje tespiti gibi uygulamalarda kullanılmakta, tipik olarak da öncelikle öznelik çıkarımı daha sonra da sınıflandırma gibi işlemlerden geçmektedir [6]. Günümüzde hiperspektral verilerin sınıflandırılmasında destek vektör makineleri, en yakın K komşuluğu, spektral sınıflandırma gibi algoritmalar kullanılmaktadır [5] [7].



Şekil 1: (a) Hiperspektral görüntülerin oluşturduğu hiperküp. (b) Hiperspektral görüntüdeki tek bir pikselden elde edilen spektral imza örneği.

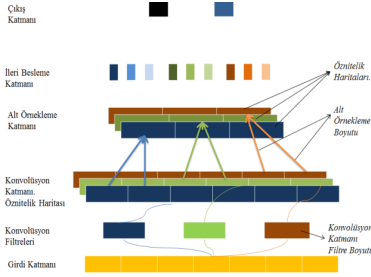
Bu çalışmada, son beş yılda bilgisayarlı görüde çığır açan ve birçok sınıflandırıcının ciddi derecede önüne geçen, fakat henüz hiperspektral görüntüleme yeterince yer bulamamış derin öğrenme yönteminin hiperspektral verilere uygulanması incelenmiştir. Bunun için veriye uygun bir yapı önerilmiş ve filtre boyutları veriye uygun olacak şekilde ayarlanmıştır. Derin öğrenme metodunun kullanılmasıyla birlikte öznelik çıkarımı ve sınıflandırıcıdan oluşan sınıflandırma basamakları tek

adıma indirilmiştir. Benzer bazı çalışmalarda, öznetelik çıkarımı için derin öğrenmenin kullanıldığı görülmüş, sınıflandırma çalışmalarında ise literatürde çok fazla çalışma bulunmadığı görülmüştür [8] [9].

II. DERİN KONVOLÜSYONEL SİNİR AĞLARI

Derin konvolüsyonel sinir ağları ileri beslemeli sinir ağları modelinin en gelişmiş yapısına sahiptir. Tipik bir derin konvolüsyonel sinir ağında bir ya da birden fazla sayıda konvolüsyon, alt örnekleme ve ileri besleme katmanı bulunmaktadır [9]. Şekil 2’de tipik bir derin konvolüsyonel sinir ağı modeli verilmiştir. Öncelikle girdi katmanı üzerinden veri alınmış, daha sonra ise üç farklı konvolüsyon filtresi girdi katmanı verisine uygulanmış ve konvolüsyon katmanında 3 adet öznetelik haritası oluşturulmuştur. Sonrasında ise alt örnekleme katmanında konvolüsyon katmanındaki verinin boyutu indirgenmiştir. Alt örnekleme katmanının çıktısı, ileri besleme katmanının girdisini oluşturmakta ve ağ son olarak ileri besleme katmanı ile sonlandırılmaktadır. Çıktı katmanı ise iki sınıf verecek şekilde modellenmiştir [10].

Derin konvolüsyonel sinir ağlarında temel amaç problem çözen öznetelikleri öğrenmektir. Önerilen yöntemde de konvolüsyon katmanındaki filtreler eğitim sonucunda öznetelikleri de öğrenmiş olmaktadır [11].



Şekil 2 : Tipik bir Derin Konvolüsyonel Sinir Ağı Modeli

Önerilen model klasik olarak ileri besleme ile hata tespiti ve bulunan hatanın geri besleme ile ağı düzeltmesi temeliyle çalışmaktadır. İleri beslemede gerçekleştirilen denklemsel ifadeler (1) ve (2) numaralı denklemler ile verilmiştir. Burada ℓ katman numarasını, W ilgili katmandaki eğitim ağırlık vektörünü ifade etmektedir. $(\ell - 1)$. katmanın çıktısı olan $x^{\ell-1}$, ℓ . katmanın girdisini oluşturmakta ve bu katmanın ağırlık vektörü W^ℓ ile çarpılarak, bu katmandaki sapma değeri olan b^ℓ ile toplanmaktadır. Bu işlemlerden sonra oluşan sonuç ise u^ℓ ile gösterilmektedir. Bu değer ise aktivasyon fonksiyonundan geçirilerek ($f(\cdot) = \tanh(\cdot)$) ℓ . katmanın çıktısı hesaplanmıştır. Genel olarak aktivasyon fonksiyonu olarak $f(x) = 1.7159 * \tanh\left(\frac{2}{3}x\right)$ kullanılmıştır. Burada önerilen parametreler Lecun tarafından önerilmiştir [12].

$$u^\ell = W^\ell x^{\ell-1} + b^\ell \quad (1)$$

$$x^\ell = f(u^\ell) \quad (2)$$

Bütün katmanlardaki ileri besleme adımı gerçekleştirildikten sonra son katman olan L . katmanda hata hesabı gerçekleştirilir. Bu katmanda gerçekleştirilen hata hesabı ise (3) ile verilmiştir. E^n , n . örnekteki hata miktarını, c son katmanda bulunan toplan çıktı nöron sayısını göstermekte ve t_k^n ile n . örnekteki k . nöron verisinin beklenen çıktısını y_k^n ise n . örnekte k . nöron verisinin ağda gerçekleşen sonucunu göstermektedir.

$$E^n = \sum_{k=1}^c \frac{1}{2} (t_k^n - y_k^n)^2 = \frac{1}{2} \|t_k - y_k\|_2^2 \quad (3)$$

İleri besleme sonucu hesaplanan hatanın katmanlara yayılımı geri yayılım ile yapılmaktadır. Sapma hatasının katmanlara yayılımı (4) ile verilmiştir. Denklemden görüldüğü üzere hatanın sapma değerine bağlı gradyanı δ ile verilmiş ve hata yayılımının sapmaya bağlı türevinin sabit bir değer olduğu görülmüştür.

$$\frac{\partial E}{\partial b} = \frac{\partial E}{\partial u} \frac{\partial u}{\partial b} = \delta \quad (4)$$

İndisi büyük katmandan indisi küçük katmanlara aktarım yapılırken hatanın türevinin dağılımı (5) ile verilmiştir. Denklemden $\delta^{\ell+1}$ ile öndeki katmandaki hatanın türevinin $W^{\ell+1}$ ile çarpılarak, gerideki katmanın çıktısı olan u^ℓ 'nin aktivasyon fonksiyonunun türevinden geçirilerek eleman eleman çarpımı ile δ^ℓ hesaplanmaktadır.

$$\delta^\ell = (W^{\ell+1})^T \delta^{\ell+1} o f'(u^\ell) \quad (5)$$

Çıkış katmanı olan L indisli katman için hatanın türevinin matematiksel hesabı (6) ile verilmiştir. Ağın çıktısı olan y^n ile olması gereken t^n çıktısının farkı ile hata miktarı bulunmuş ve aktivasyon fonksiyonunun türevinden L . katmanın çıktısının geçirilmesiyle elde edilen değerler eleman eleman çarpımıyla elde edilmiştir.

$$\delta^L = f'(u^L) o (y^n - t^n) \quad (6)$$

Delta kuralı ile ağırlık parametre güncellemeleri (8) ile verilmiştir. Hatanın ağırlık vektörüne bağlı türevinin hesabı ise (7) ile verilmiştir. $x^{\ell-1}$ ile $(\ell - 1)$. katmanın çıktısı ile ℓ . katmandaki hatanın türevinin transpozu ile çarpılmasıyla ℓ . katmandaki hatanın öğrenme parametresine bağlı türevi bulunmuştur. Bu değer öğrenme parametresi ile çarpılması sonucu ℓ . katmandaki ağırlık güncelleme miktarları hesaplanmıştır.

$$\frac{\partial E}{\partial W^\ell} = -x^{\ell-1} (\delta^\ell)^T \quad (7)$$

$$\Delta W^\ell = -\eta \frac{\partial E}{\partial W^\ell} \quad (8)$$

Konvolüsyon ve alt örnekleme katmanında gerçekleşen işlemler burada gerçekleşen işlemler ile paralellik göstermektedir. Konvolüsyon katmanında gerçekleşen ileri besleme (9) numaralı denklem ile verilmiştir. $(\ell - 1)$. katmanın çıktısı olan $x_j^{\ell-1}$ ile konvolüsyon katmanında

bulunan k_{ij}^ℓ filtreleri ile konvolüsyon işlemi gerçekleştirilir ve daha sonra bu konvolüsyon sonuçlarının kendi içerisinde toplanması ve sapma değerlerinin eklenmesi işlemi yapılır. Son olarak ise bulunan bu değer aktivasyon fonksiyonundan geçirilerek ℓ . konvolüsyon katmanının ileri beslemedeki sonuç değeri bulunur.

$$x_j^\ell = f\left(\sum_{i \in M_j} x_j^{\ell-1} * k_{ij}^\ell + b_j^\ell\right) \quad (9)$$

Konvolüsyon katmanında gerçekleşen geri öğrenme işlemi ise hatanın türevinin gradyentinin (δ_j^ℓ) bu katmandaki hesabı (10) ile verilmiştir. $\beta_j^{\ell+1}$ alt örnekleme katmanındaki parametreleri içeren ℓ . katmandaki verinin boyutunun eşitlenmesini sağlayan sabit bir parametredir. ($\ell + 1$). katmandaki hatanın alt katmana aktarılması için öncelikle üst örneklemeden geçirilip ardından klasik olarak aktivasyon fonksiyonunun türevinden geçirilip ℓ . katmanın çıkışının eleman çarpımının gerçekleştirilmesi gerekmektedir. Sapma değerinin aktarımının ise sabit değerlerin toplamı olduğu (11) numaralı denklem ile verilmiştir.

$$\delta_j^\ell = \beta_j^{\ell+1} (f'(u_j^\ell) \circ up(\delta_j^{\ell+1})) \quad (10)$$

$$\frac{\partial E}{\partial b_j} = \sum \delta_j^\ell \quad (11)$$

Hatanın konvolüsyon filtresine göre türevi ise hatanın gradyanlarının ($(\delta_j^\ell)_{uv}$), $(p_i^{\ell-1})_{uv}$ ile çarpımının toplamıyla bulunmaktadır. $(p_i^{\ell-1})_{uv}$ ise $x^{\ell-1}$ ile k_{ij}^ℓ değerlerinin eleman çarpımı ile bulunmaktadır. (12) ile denklemsel ifade hatanın filtreleri bağlı türevinin matematiksel bağıntısı verilmiştir.

$$\frac{\partial E}{\partial k_{ij}^\ell} = \sum (\delta_j^\ell)_{uv} (p_i^{\ell-1})_{uv} \quad (12)$$


Alt örnekleme katmanında ise herhangi bir eğitim parametresi bulunmamaktadır. Geri beslemede hesaplanan hatanın gradyanın üst örneklenecek aktarımı gerçekleştirilmekte, ileri beslemede ise (13) numaralı denklem ile gösterilen; ($\ell - 1$). katmanın çıkışı alt örneklenecek, daha sonra bu sonuç aktivasyon fonksiyonundan geçirilerek alt örnekleme katmanının çıkışı hesaplanmaktadır.

$$x_j^\ell = down(x_j^{\ell-1}) \quad (13)$$

III. ÖNERİLEN SİNİR AĞI MODELİ

A. Veri Kümesi

Bu çalışmada Pavia Üniversitesi'ne ait hiperspektral veri kümesi kullanılmıştır. İlgili veriler 103 farklı bantta, 0.43-0.86 μm arasında değişen dalga boylarında, 610 x 340 piksel uzamsal kapsamına sahiptir. Veri kümesinin 9 sınıfa ait mutlak doğrusu (ground truth) bulunmaktadır.. Bu sınıflara ait spektral veriler Şekil 3'te gösterilmiştir.




Şekil 3 : Pavia Verisine Ait Sınıfların Spektral Bilgileri

Veri kümesi önerilen sisteme verilmeden önce normalize edilmektedir. Normalizasyon işlemi kapsamında girdi olan piksel ortalama değerinden çıkarılarak standart sapmasına bölünmektedir. Kurulan ağın eğitimi aşamasında her bir sınıftan 200 adet eğitim verisi, doğrulama kümesi olarak da her bir sınıftan 50 adet veri kurulan ağa verilmiştir. Daha sonra işaretlenmiş bütün veriler ağa test girdi kümesi olarak verilip sistemin başarımlı ölçülmüştür.

B. Önerilen Sinir Ağı Modeli


Bu çalışmada önerilen ağ modeli Şekil 4 ile verilmiştir. Piksel girdisi olarak 1 x 103 'lük veri girdi katmanına verilmiştir. Bu katmanın bağlı olduğu birinci konvolüsyon katmanında toplamda 10 adet birbirinden farklı başlangıçta değerleri rastgele atanmış 1x5 boyutunda filtreler bulunmaktadır. Birinci konvolüsyon katmanının çıkışında ise 10 adet birbirinden farklı 1x99 boyutunda öznetelik haritası bulunmaktadır. Daha sonra gelen alt örnekleme katmanında ise verinin boyutu 1x33'e düşürülmüş 10 adet öznetelik haritası bulunmaktadır. İkinci konvolüsyon katmanında ise toplamda 20 adet birbirinden farklı başlangıçta değerleri rastgele atanmış 1x6 boyutunda filtreler bulunmaktadır. İkinci konvolüsyon katmanının çıkışında ise 10 adet birbirinden farklı 1x28 boyutunda 20 adet öznetelik haritası bulunmaktadır. Takip eden alt örnekleme katmanında ise verinin boyutu 1x14'e döndürülmüş ardından ise üçüncü konvolüsyon katmanında bulunan 1x14 boyutundaki filtrelerden geçirilerek 100 adet tek boyutlu veriye döndürülmüştür. Artık verinin boyutu 100 x 1'e getirilmiş 9 sınıflı sonuç için ise ileri besleme katmanı ile ağ sonlandırılmıştır.



Şekil 4 : Önerilen Ağ Modeli

IV. SONUÇLAR VE DEĞERLENDİRME

Çalışmanın sonucunda eğitim setinin sınıflandırma başarımları Şekil 5 ile verilmiştir. Analiz sonucunda eğitim kümesine ait yanlış sınıflandırma oranı ve doğrulama kümesi üzerindeki başarımları gösterilmiştir. Grafiklerde görüldüğü üzere başarımın değişiminin yakınsadığı değerde iterasyon durdurulmuş, buradaki ağ modeli sınıflandırıcı olarak belirlenmiştir.



Şekil 5 : DNN başarımının iterasyon sayısına bağlı değişimi

	Asfalt	Çayırık	Çakıl	Ağaçlık	B. Metal Tabaka	Toprak	Zift	Tuğla	Gölge
Asfalt	5148	43	207	25	15	165	394	227	107
Çayırık	216	16179	13	1041	0	1148	52	0	0
Çakıl	82	3	1852	0	1	1	33	125	2
Ağaçlık	2	175	1	2874	0	7	4	0	1
B. Metal Tabaka	1	1	0	0	1341	0	1	0	1
Toprak	387	1109	200	48	2	2926	36	142	3
Zift	85	1	39	0	0	3	1069	131	2
Tuğla	109	11	676	0	0	67	188	2729	2
Gölge	4	4	1	27	1	0	0	0	910

Tablo 1 : Test Kümesinde Verilerin Atandığı Sınıflar

Sınıf	Başarım Yüzdesi (%) (Önerilen Method)	Başarım Yüzdesi (%) (En Yakın K Komşuluğu)	Başarım Yüzdesi (%) (SVM)
Asfalt	81.31	81.5	84.30
Çayırık	86	79.3	67.01
Çakıl	88.23	0	68.43
Ağaçlık	93	47.8	97.8
Boyanmış Metal Tabaka	99.7	97.3	99.37
Toprak	60.03	89.1	92.45
Zift	80	27.1	89.91
Tuğla	72	52.9	92.42
Gölge	98.70	99.9	97.23

Tablo 2 : Farklı Sınıflandırıcılarda Sınıfların Başarım Oranları

Bütün test kümesine uygulanmış sonuçlar karar matrisi olarak Tablo 1 ile verilmiştir. Tablo 2 ile ise sınıfların başarımları özet halinde verilmiştir. İlgili tablodaki sonuçlarda; aynı verinin en yakın K komşuluğu yöntemiyle ve SVM ile sınıflandırılmasına bağlı sonuçları da verilmiş; önerilen yöntemin en yakın K-komşuluğundan daha başarılı sonuçlar verdiği; SVM ile ise yakın başarımlarda sonuçlar verdiği gözlenmiştir [13][14]. Toplam başarımları da ise SVM ile sınıflandırma sonucu başarımın %79 olduğu, önerilen yöntemdeki

başarımın ise %83.75 olduğu görülmüştür [14]. Önerilen method da gözle ayrılabilen verilerin imzalarının başarıyla doğru bir şekilde sınıflandırılabilirdiği, ayrıca eğitim aşamasında aynı sınıfa ait ancak farklılık gösterebilen imzaların eğitim aşamasına dahil edilmesi durumunda başarımın daha da yükseleceği görülmüştür. Yapılan çalışmada, derin konvolüsyonel sinir ağı modelinin, doğru parametrik değerlerin seçilip iyi bir ağ kurulması durumunda hiperspektral verilerin sınıflandırılmasında başarılı bir yöntem olarak kullanılabileceği gösterilmiştir.

V. TEŞEKKÜRLER

Bu çalışma TÜBİTAK tarafından 115E318 numaralı proje kapsamında desteklenmiştir.

KAYNAKÇA

- [1] D. Landgrebe, "Hyperspectral image data analysis", IEEE Signal Process. Mag., vol. 19, no. 1, pp.17-28, 2002.
- [2] F.M. Lacar, M. M. Lewis and I.T. Grierson, "Use of hyperspectral imagery for mapping grape varieties in the Barossa Valley, South Australia", Proc. IEEE Int. Geosci. Remote Sens. Symp. (IGARSS), vol. 6, pp.2875-2877, 2001
- [3] P.W. Yuen and M. Richardson, "An introduction to hyperspectral imaging and its application for security, surveillance and target acquisition", Imaging Sci. J., vol. 58, no. 5, pp.241-253, 2010
- [4] J. Bioucas-Dias, "Hyperspectral remote sensing data analysis and future challenges", Geosci. Remote Sens. Mag., vol. 1, no. 2, pp.6-36, 2013.
- [5] Li Ma, M.M. Crawford, and Jinwen Tian. Local manifold learning based k-nearest-neighbor for hyperspectral image classification. Geoscience and Remote Sensing, IEEE Transactions on, 48(11), Nov 2010.
- [6] X. Jia, B. Kuo and M.M Crawford, "Feature mining for Hyperspectral image classification", in Proc. IEEE, vol. 101, no 3, pp 676-679, Mar. 2013
- [7] F. Melgani and B.Lorenzo, "Classification of hyperspectral remote sensing images with support vector machines", IEEE Trans. Geosci. Remote Sens., vol. 42, no. 8, pp, 1778-1790, Aug.2004.
- [8] Y. Chen, X. Zhao, X. Jia, "Spectral-Spatial Classification of Hyperspectral Data Based on Deep Belief Network", vol.8, no 6, 2015.
- [9] W.Hu, Y.Huang, L.Wei, F.Zhang, H.Li "Deep Convolutional Neural Networks for Hyperspectral Image Classification", Research Article. 2015.
- [10] Oquab, Maxime, et al. "Learning and transferring mid-level image representations using convolutional neural networks." Proceedings of the IEEE Conf. on Computer Vision and Pattern Recog., 2014.
- [11] P.Y. Simard, D. Steinkraus, and J.C. Platt. Best practices for convolutional neural networks applied to visual document analysis. In Proceedings of the Seventh International Conference on Document Analysis and Recognition, vol. 2, pages 958-962, 2003.
- [12] LeCun, Yann, et al. "Gradient-based learning applied to document recognition." Proceedings of the IEEE 86.11 (1998): 2278-2324.
- [13] Alizade Naeini, A.; Jamshidzadeh, A.; Saadatesherst, M.; Homayouni, S., "An Efficient Initialization Method for K-Means Clustering of Hyperspectral Data" ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XL-2/W3, 2014, pp.35-39.
- [14] Chen, Yi, Nasser M. Nasrabadi, and Trac D. Tran. "Hyperspectral image classification using dictionary-based sparse representation." Geoscience and Remote Sensing, IEEE Transactions on 49.10 (2011): 3973-3985.