

Karmaşık Hedeflerin Aktarımlı Öğrenme ile Sınıflandırmasında Yapay Sinyallerin Başarıma Etkisi

Tuğçe Toprak, M. Alper Selver*, Mustafa Seçmen**, E. Yeşim Zoral*

Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü
Elektrik ve Elektronik Mühendisliği Anabilim Dalı
İzmir
tugcetoprak.eee@gmail.com,

*Dokuz Eylül Üniversitesi, Mühendislik Fakültesi
Elektrik ve Elektronik Mühendisliği Bölümü
İzmir
alper.selver@deu.edu.tr, yesim.zoral@deu.edu.tr,

**Yaşar Üniversitesi
Elektrik ve Elektronik Mühendisliği Bölümü
İzmir
mustafa.secmen@yasar.edu.tr

Özet: Çekişmeli üretici ağların (Generative Adversarial Networks - GAN) görüntülerin üretilmesini konu alan uygulamalarda oldukça başarılı olduğu bilinmektedir. Son yıllarda üretici ağlar zaman serisi verilerini içeren problemlere de uygulanmaya başlamıştır. Bu çalışmada, saçılım sinyalleri kullanılarak hedef sınıflandırma uygulamalarında çekişmeli üretici ağlar ile aktarımlı öğrenmenin birlikte kullanımı incelenmiştir. Saçılım sinyalleri kullanılarak hedef sınıflandırmada en önemli problemlerden biri gerçek hedef ölçüm sinyallerinin derin ağ eğitimi için yeterli sayıda olmamasıdır. Bu problemi aşabilmek amacıyla, çekişmeli üretici ağlar kullanılarak üretilen yapay hedef sinyalleri ile eğitilmiş bir derin ağ modeline aktarımlı öğrenme uygulanarak gerçek hedef sinyallerinin sınıflandırılması sağlanmıştır.

Abstract: Generative adversarial networks (GANs) are highly successful in generative applications involving images. In recent years, GANs have begun to be applied to problems involving time series data. In this study, the use of GANs and transfer learning in target classification from scattering signals have been investigated. One of the most crucial problems in target classification using scatter signals is that the circumscribed real target measurement signals are not sufficient for deep network training. To overcome this problem, it is aimed to classify real target signals by applying transfer learning to a deep network trained with target signals generated using GANs.

1. Giriş

Makine öğrenmesi alanında yapılan çalışmaların büyük bir kısmı sınıflandırma uygulamalarında olduğu gibi gerçek verilerden gelen bilgiler ile ilgilenmektedir. Son yıllarda, bu tür gerçek verilerin örtük üretken modeller aracılığıyla nasıl üretilmesine dair yapılan çalışmalar da oldukça popülerdir. Yapay verilerin üretilmesinde hedeflenen, özgün veri setine dâhil edilmeyen doğal görünümlü örnekler üretmek, görünmeyen örneklerle eğitim verilerini yapay olarak artırma yoluyla veri setini büyütme'dir. Bunun dışında, belirli özelliklere sahip doğal görünümlü örnekler üretme imkânı ve bunları oluşturan modellerin incelenmesi, Çekişmeli Üretici Ağların (ÇÜA) eğitiminde kullanılan özgün veriyi anlamak adına yararlı bir araç olarak da kullanılabilir. ÇÜA'lar esas olarak yapay görüntülerin üretilmesinde uygulanmıştır ve zaman serilerini araştıran yalnızca birkaç çalışma yapılmıştır. Bu çalışmalardan [1] yapay ses üretimi ve [2] EEG sinyallerinin üretilmesi için umut verici sonuçlar elde etmişlerdir.

Son yıllarda, Evrişimli Sinir Ağları (ESA) kullanılarak, hedef sınıflandırma problemlerinde büyük gelişmeler elde edilmiştir [3-5]. Saçılım sinyalleri kullanılarak hedef sınıflandırma problemlerinde ESA'ların kullanılması, gerçek hedef veri kümesinin kısıtlı miktarda sinyal içermesinden dolayı ancak aktarımlı öğrenme aracılığıyla mümkün olmaktadır. Bu konuda yapılan çalışmada [6], aktarımlı öğrenme uygulanmadan önce eğitilen ESA'ların eğitim kümesini sentetik veriler oluşturmaktadır. Bu veriler matematiksel olarak elde edilmiş ve aktarımlı öğrenmeye katkı sağladıkları görülmüştür. Fakat aktarımlı öğrenme öncesinde eğitilen ESA'nın eğitim

kümesindeki sinyaller ile hedef sinyallerin benzerlik oranının probleme özgü performansı artıracakı öngörülebilir.

Bu çalışma kapsamında, gerçek hedef sinyalleri kullanılarak üretilen yapay hedef sinyallerinin aktarımlı öğrenmeye katkısı incelenmektedir. Gerçek hedef sinyallerine uygun şekilde üretilen yapay sinyallerden oluşturulacak farklı sayılarda veri içeren eğitim kümeleri ile veri sayısının eğitimdeki etkisi gözlemlenebilecektir.

2. Gerçek Hedef Veri Kümesi ve Yöntem

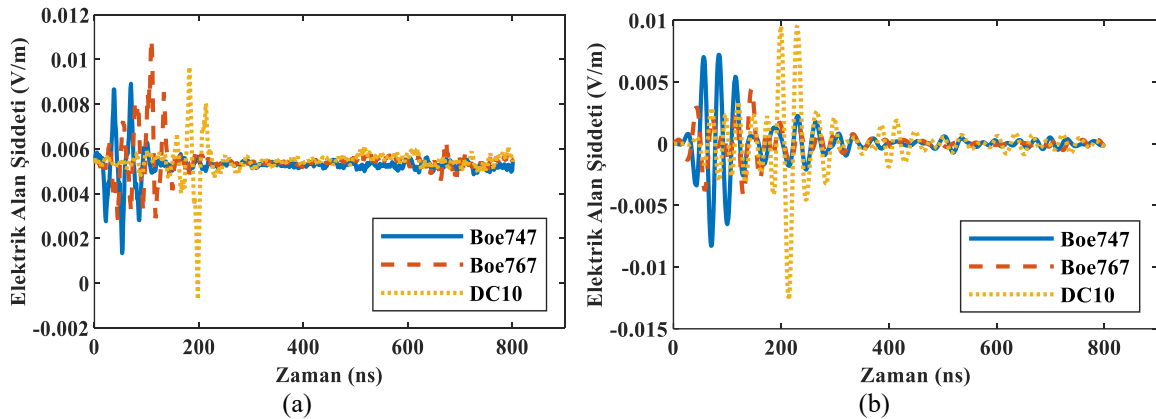
Veri Kümesi: Gerçek hedef veri kümesi, küçük ölçekli Boeing 747, Boeing 767 ve DC-10 modellerini içermektedir. Ölçeklendirmesi 1/500 olan modellerin, gövde, kanat ve kuyruk uzunlukları sırasıyla, Boeing 747 için 14.5 cm, 12.7 cm ve 4.8 cm; Boeing 767 için 12.48 cm, 12.54 cm ve 5 cm; DC-10 için ise 12.7 cm, 11.4 cm ve 5.25 cm'dir. VV polarizasyonda yapılan ölçümlerde modeller burun kısımları $\theta = 0^\circ$ de olacak şekilde z-ekseni boyunca konumlandırılmıştır [7].

Çekişmeli Üretici Ağlar: ÇÜA mimarisi, birbirini alt etmeye çalışan iki karşıt ağdan oluşur [8]. İlk ağ, ayırıcı, gerçek ve sahte giriş verilerini ayırt etmek için eğitilmiştir. İkinci ağ, üretici, girdi olarak gizli bir gürültü değişkenini alır ve ayırıcı tarafından sahte olarak tanımlanmayan sahte örnekler oluşturmaya çalışır. Bu, üreticinin ayırıcı tarafından daha iyi örnekler üretmeye zorlandığı bir minimum/maksimum oyunuyla sonuçlanır. Tablo 1 bu çalışma kapsamında eğitilen ÇÜA'nın mimarisini göstermektedir. Her iki evrişim katmanının arasında, normalleştirme katmanı ve doğrultucu katman da yer almaktadır.

Tablo 1. Yapay hedef sinyallerinin üretilmesinde kullanılan ÇÜA mimarisi.

(a) Üretici		(b) Ayırıcı	
Katman	Çıkış Boyutu	Katman	Çıkış Boyutu
Giriş	1x1000	Giriş	1024x1
Evrişim Katmanı 1	7x512	Evrişim Katmanı 1	505x512
Evrişim Katmanı 2	32x256	Evrişim Katmanı 2	123x256
Evrişim Katmanı 3	129x128	Evrişim Katmanı 3	28x128
Evrişim Katmanı 4	512x64	Evrişim Katmanı 4	6x64
Evrişim Katmanı 5	1024x1	Evrişim Katmanı 5	1x1

Tablo 1'de verilen ağ mimarisi, MATLAB 2020b'de oluşturulmuş ve eğitilmiştir. Eğitim toplam 1000 döngüden oluşmaktadır ve ADAM optimizasyon fonksiyonu kullanılmıştır. ADAM optimizasyon fonksiyonunun öğrenme hızı 0.0002 olarak belirlenmiştir. ÇÜA'nın eğitimi NVIDIA GTX1050Ti ekran kartı üzerinden gerçekleştirilmiştir. Eğitimde kullanılan gerçek hedef veri kümesi her bir sınıftan 19 adet olacak şekilde toplam 57 sinyalden oluşmaktadır. ÇÜA'nın eğitiminde kullanılan veri kümesindeki sinyal sayısı oldukça az olmasına karşın, Şekil 1'de görüldüğü gibi ürettiği yapay sinyaller gerçek hedef verisine oldukça yakın sinyallerdir.



Şekil 1. (a) ÇÜA ile üretilmiş yapay hedef sinyallerinden ve (b) ölçümü yapılmış gerçek hedef sinyallerinden alınan rastgele örnekler.

ÇÜA'dan üretilen sinyallerin her uygulamada farklı üretilmemesi ve sürekliliğin sağlanabilmesi için rastgele sayı üretimi sabitlenmiştir. ESA'ların eğitimi amacıyla, ÇÜA kullanılarak farklı miktarda yapay hedef sinyali içeren 3 farklı veri kümesi oluşturulmuştur. Veri kümeleri sırasıyla 2000, 5000 ve 8000 yapay sinyal

içermektedir. Sabitlenen rastgele sayı üretimi ile veri sayısı fazla olan kümeler daha az veriye sahip kümeleri de kapsamaktadır. ÇÜA'dan üretilen bu 3 veri kümesi kullanılarak mimarisi aynı 3 farklı ESA eğitilmiştir. Eğitilen sinir ağlarının her biri tek çıkışlı çapraz doğrulama yöntemi kullanılarak aktarımlı öğrenme ile gerçek hedef verisini sınıflandırmak üzere uyarlanmıştır.

3. Sonuçlar ve Tartışma

Uygulanan yöntem sonucunda elde edilen doğruluk (accuracy, CC), duyarlılık (sensitivity, SE) ve özgüllük (specificity, SP) değerleri Tablo 2'de verilmiştir. Benzer bir şekilde ESA ve aktarımlı öğrenme (AÖ) kullanan [6] çalışmasında uygulanan yöntem ve Tablo 2'de verilen literatürdeki sıklıkla kullanılan diğer sinyal işleme yöntemlerine göre daha yüksek performansa sahip olduğu görülmüştür. Bu durumun sebeplerinden birinin, ÇÜA'nın eğitim kümesindeki veri sayısının azlığı olabileceği öngörülmektedir. Daha fazla veri ile daha doğru sinyal üretimi sağlanabilir. Öte yandan, üretilen sinyaller probleme gereğinden fazla özelleştiğinden yapay sinyaller ile eğitilen ESA'ların genelleme yeteneğini kaybetmiş olması da mümkündür. Bu durumda tek çıkışlı çapraz doğrulama ile aktarımlı öğrenme uygulanırken test verisinde hata elde etme ihtimali artmaktadır.

Bu çalışma kapsamında elde edilen sonuçlara göre, veri kümesindeki yapay sinyal sayısının artması beklenildiği gibi performansı artırmaktadır. Fakat daha fazla sayıda yapay sinyal üretmek ve üretilen bu sinyaller ile uygun ESA'yı eğitmek aynı zamanda donanımsal gereksinimleri beraberinde getirmektedir. Çalışma sırasında kullanılan donanımın iyileştirilmesi ile performansın da artabileceği göz ardı edilmemelidir.

Tablo 2. Gerçek hedef sinyallerinde sınıflandırma sonuçları (%)

Hedef Model/Yöntem	Boeing 747			DC10			Boeing 767		
	CC	SE	SP	CC	SE	SP	CC	SE	SP
ESPRIT	88.2	88.5	90.9	90.6	91.4	93.5	89.9	92.4	95.5
Wigner-Wille	86.4	87.8	92.1	91.2	91.7	92.2	90.2	88.9	93.7
Min-Norm	88.1	88.7	91.3	91.4	90.3	90.6	92.2	90.9	92.6
MUSIC	89.1	88.9	91.6	92.3	92.5	94.1	91.0	93.1	96.9
WFC [7]	93.3	91.1	94.4	93.3	87.8	96.1	94.1	92.2	95.0
ESA-AÖ [6]	94.9	98.5	98.1	98.6	99.3	99.2	97.9	99.5	99.5
ESA(ÇÜA2k)-AÖ	91.2	87.1	93.3	93.9	91.3	95.4	91.7	87.9	93.7
ESA(ÇÜA5k)-AÖ	90.5	85.8	92.8	95.7	93.9	96.6	90.6	86.1	92.9
ESA(ÇÜA8k)-AÖ	94.1	91.3	95.6	96.1	92.2	96.9	92.1	88.2	94.1

Kaynaklar

- [1]. Donahue, C., McAuley, J., ve Puckette, M., "Adversarial audio synthesis", 2018. arXiv preprint arXiv:1802.04208.
- [2]. Hartmann, K. G., Schirrmester, R. T., ve Ball, T., "EEG-GAN: Generative adversarial networks for electroencephalographic (EEG) brain signals", 2018. arXiv preprint arXiv:1806.01875.
- [3]. Cheng, G., Li, Z., Han, J., Yao, X., ve Guo, L., "Exploring hierarchical convolutional features for hyperspectral image classification", IEEE Transactions on Geoscience and Remote Sensing, cilt.56, no.11, s.6712-6722, 2018.
- [4]. Fan, T. T., Liu, C., ve Cui, T. J., "Deep learning of raw radar echoes for target recognition", IEEE International Conference on Computational Electromagnetics (ICCEM), Çengdu, Çin, s.1-2, Mart 2018.
- [5]. De, S., Bruzzone, L., Bhattacharya, A., Bovolo, F., ve Chaudhuri, S., "A novel technique based on deep learning and a synthetic target database for classification of urban areas in PolSAR data", IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, cilt.11, no.1, s.154-170, 2017.
- [6]. Selver, M. A., Toprak, T., Seçmen, M., ve Zoral, E. Y., "Transferring Synthetic Elementary Learning Tasks to Classification of Complex Targets", IEEE Antennas and Wireless Propagation Letters, cilt.18, no.11, s.2267-2271, 2019.
- [7]. Selver, M. A., Taygur, M. M., Seçmen, M., ve Zoral, E. Y., "Hierarchical reconstruction and structural waveform analysis for target classification", IEEE Transactions on Antennas and Propagation, cilt.64, no.7, s.3120-3129, 2016.
- [8]. Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., ve Bengio, Y., "Generative Adversarial Networks", 2014. <http://arxiv.org/abs/1406.2661>.