

Elektronik Harp Sistemlerinde Derin Öğrenme: Otomatik Darbe İçi Kipleme Tanıma

Deep Learning in Electronic Warfare Systems: Automatic Intra-Pulse Modulation Recognition

Fatih Çağatay Akyön^{[1][2]}, Yaşar Kemal Alp^[1], Gökhan Gök^{[1][3]}, Orhan Arıkan^[2]

[1]Radar, Elektronik Harp ve İstihbarat Sistemleri, ASELSAN A.Ş., Ankara, Türkiye

[2]Elektrik ve Elektronik Mühendisliği Bölümü, Bilkent Üniversitesi, Ankara, Türkiye

Özetçe —Elektronik harp sistemlerinde tehdit radarların tespiti ve sınıflandırılması, önemli bir problemdir. Bu çalışmada radar sinyalleri üzerindeki istemli darbe içi kipleme tiplerini otomatik olarak tespit eden, derin öğrenme tabanlı yeni bir yöntem önerilmektedir. Uygulanan hibrit derin sinir ağı yapısında, ölçülen sinyalin YAKZFD'si (Yeniden Atanmış Kısa Zamanlı Fourier Dönüşümü) ve sinyalin anlık fazı üzerinde tespit edilen öznitelikler girdi olarak kullanılmıştır. Yapılan benzetimler sonucunda, önerilen yöntemin literatürdeki en yüksek başarımları gösteren yöntemin üzerinde bir başarımları sergilediği ve yüksek genelleme yeteneğine sahip olduğu gözlemlenmiştir.

Anahtar Kelimeler—elektronik harp, radar kipleme tipi tespiti, derin öğrenme, konvolüsyonel sinir ağları, zaman-frekans görünüşü, gürbüz, en küçük kareler

Abstract—Detection and classification of radars in electronic warfare systems is a major problem. In this work, we propose a novel deep learning based method that automatically recognizes intra-pulse modulation types of radar signals. We use reassigned short-time Fourier transforms of measured signals and detected outliers of the phase differences using robust least squares to train a hybrid structured convolutional neural network to distinguish frequency and phase modulated signals. Simulation results show that the developed method highly outperforms the current state-of-the-art methods in the literature.

Keywords—electronic warfare, radar modulation recognition, deep learning, convolutional neural networks, time-frequency image, robust least squares

I. GİRİŞ

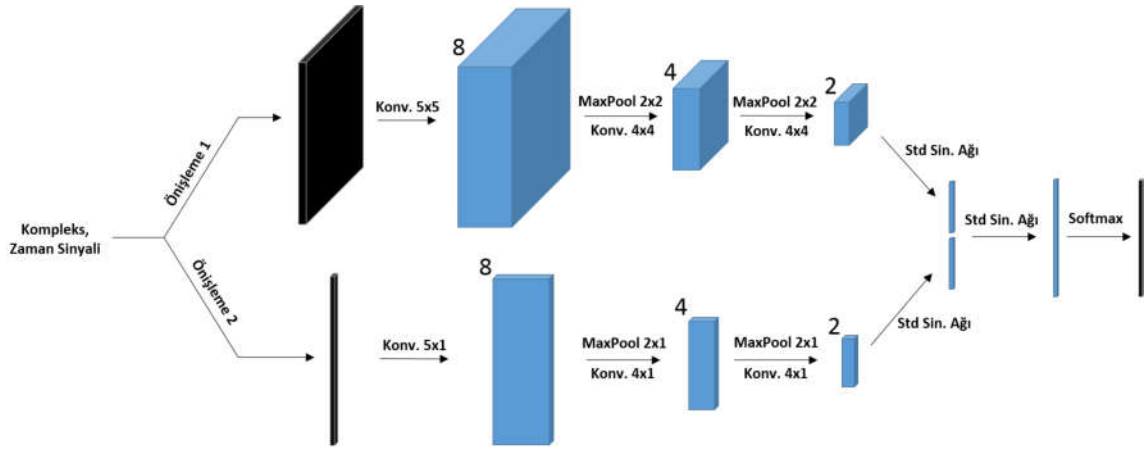
Otomatik darbe içi kipleme tespiti, EH (Elektronik Harp) sistemlerinde radar türü ve tehdit sınıflandırma alanlarında kullanılan önemli bir tekniktir [1]. Çeşitli modülasyon türlerini sınıflandırabilmek adına birçok yöntem önerilmiştir. Bu yöntemlerin çoğu öznitelik çıkarma ve sınıflandırma olmak üzere iki temel aşamadan oluşmaktadır. Sınıflandırıcı kısmı genelde çok değişiklik göstermezken, yöntemler arasındaki asıl fark öznitelik çıkarma aşamasından kaynaklanmaktadır.

Sınıflandırıcının farklı darbe içi kipleme tiplerini ayırt edebilmesini sağlayabilmek için öznitelik çıkarma aşamasında bir çok sinyal işleme yöntemine başvurulmuştur. [2] ve [3]'te zaman-frekans analizine dayalı öznitelikler türetilmiştir, [4]'de özilinti işlevinden faydalanarak öznitelikler çıkarılmıştır. Bu yöntemlerden farklı olarak, öznitelik çıkarma aşamasında [8]'de temel bileşenler analizi, [9]'de ise entropi metodu kullanılmıştır. Sınıflandırıcı aşamasında ise, çıkarılan öznitelikleri sınıflandırma amacıyla bilinen makine öğrenmesi metodları direkt olarak uygulanmıştır. Örnek olarak [8]'de kümeleme, [7]'de destek vektör makinesi, [1] ve [9]'de yapay sinir ağı, [4]'de ise olasılıksal grafiksel modeli kullanılmıştır.

Bahsedilen standart iki aşamalı sınıflandırma yöntemlerinin en zayıf yanı, sınıfları ayırt etmeyi kolaylaştıracak özniteliklerin çıkarılabilmemesinin zor olmasıdır. Bu zayıflıkların önüne geçebilmek adına [10]'de konvolüsyonel sinir ağı temelli bir yaklaşıma gidilmiştir. Şuana kadarki en yüksek başarımları ve genelleme yeteneğini gösteren bu yöntem ile öznitelik çıkarma ve sınıflandırma işlemi tek aşamaya yapılmaya başlanmıştır. Ancak yöntemin başarımları sadece frekans kipli sinyaller üzerinde değerlendirilmiş ve faz kipli darbeleri sınıflandırmadaki yetersizliği göz ardı edilmiştir.

Tüm bu yetersizliklerin önüne geçebilmek için bu çalışmada, derin öğrenme ile her türde frekans ve faz kiplemesine sahip darbelerden öznitelik çıkarılması ve sınıflandırılması aşamalarını otomatik olarak gerçekleştirebilen, hibrit şekilde modellenmiş bir konvolüsyonel sinir ağı öneriyoruz. Önerilen yöntem, ölçülen sinyale önce ön işleme uygulamakta, bu işlem sonucunda üretilen veriyi iki adet konvolüsyonel ağıdan oluşan hibrit bir derin ağ yapısına girdi olarak vermektedir. Bu tarz hibrit ağlarının başarılı uygulamasına [10] örnek olarak gösterilebilir. Derin ağın katmanları, insan beyninin katmanlarını taklit ederek, eğitim setindeki faz ve frekans kiplemelerindeki farkları öğrenerek, eğitim setinde görmediği sinyallerin başarılı şekilde sınıflandırılmasına olanak sağlamaktadır.

II. Bölümde, ön-işleme aşamalarının ve geliştirilen hibrit konvolüsyonel sinir ağı modelinin detaylarına yer verilmiştir. III. Bölümde benzetim sonuçları sunulmuş ve son bölüm ise değerlendirmelere ayrılmıştır.



Şekil 1: Önerilen hibrit konvolüsyonel sinir ağı modeli. İki işlenmiş girdiden paralel iki konvolüsyonel sinir ağı ile öznelilik çıkarma işlemi uygulandıktan sonra, iki ağıın sonuçlarını eş zamanlı olarak birleştirip 2 standart sinir ağı katmanından sonra softmax katmanını ile sınıf olasılıklarını vermektedir.

II. ÖNERİLEN YÖNTEM

Ölçülen gürültülü sinyal $x(t)$,

$$x(t) = a(t)e^{j\phi(t)} + z(t) \quad (1)$$

olarak modellenebilir. Burada $a(t)$ sinyal zarfını, $\phi(t)$ sinyal anlık fazını, $z(t)$ ise 0 ortalamalı dairesel simetriye sahip karmaşık Gauss gürültüsünü temsil etmektedir. Ölçülen sinyal $x(t)$ üzerindeki kiplemenin tipini otomatik olarak sınıflandırabilmek için Şekil 1'de görülen hibrit yapılı bir konvolüsyonel sinir ağıının kullanılmasını önermekteyiz. Bu ağı öncesinde ise, hem frekans hem de faz kiplemelerinin tanınmasını kolaylaştıran, iki farklı ön işleme tekniği uygulanmaktadır. Aşağıda, uygulanan ön işleme tekniği ve önerilen derin ağı yapısı detaylandırılmıştır.

A. Önişleme

Önerilen ilk önişleme bloğunda, sinyal üzerindeki frekans kiplemelerinin daha belirgi hale gelmesi amaçlanarak sinyalin, yüksek çözünürlükte ZFR'sini (Zaman-Frekans Resmi) oluşturabilen YAKZFD'si hesaplanmaktadır. Bunun için öncelikle ölçüm sinyali $x(t)$ 'nin $h(t)$ pencere fonksiyonu ile hesaplanan KZFD'si

$$F_x(t, w; h) = \int_{-\infty}^{\infty} x(s)h^*(s-t)e^{-jws}ds \quad (2)$$

ile hesaplanır. Ardından ölçüm sinyali $x(t)$ 'nin YAKZFD'si

$$S_x^y(t', w') = \int_{-\infty}^{\infty} S_x(t, w)\delta(t' - \hat{t}(x; t, w)) \times \delta(w' - \hat{w}(x; t, w))dtdw \quad (3)$$

ile elde edilir. Burada $\hat{t}_x(t, w)$, $\hat{w}_x(t, w)$ ve $S_x(t, w)$ ise


$$S_x(t, w) = |F_x(t, w; h)|^2 \quad (4)$$

$$\hat{t}_x(t, w) = t - \text{Re} \left\{ \frac{F_x(t, w; T_h)F_x^*(t, w; h)}{S_x(t, w)} \right\} \quad (5)$$

$$\hat{w}_x(t, w) = w + \text{Im} \left\{ \frac{F_x(t, w; D_h)F_x^*(t, w; h)}{S_x(t, w)} \right\} \quad (6)$$

ile tanımlıdır.

Şekil 2'de 10dB SGO'da ölçülen frekans kiplemeli yayının KZFD (2a) ve YAKZFD (2b) verilmiştir. Görüldüğü üzere




Şekil 2: 10dB SGO'da 100MHz örnekleme frekansında ölçülen Costas-10 kiplemeli darbenin (a) KZFD ile, (b) YAKZFD ile elde edilmiş ZFG'leri.

YAKZFD, KZFD'ye göre daha yüksek çözünürlüğe ZFR oluşturmuştur. İkinci önişleme bloğunda ise, sinyal üzerindeki faz modülasyonlarının belirginleşmesi için sinyalin çözülmesi anlık fazına *değişim tespitçisi* (*change detector*) uygulanmaktadır. Değişim tespitçisi, sinyalin çözülmesi anlık fazının, (7)'de verilen, en küçük faz/frekans atlama miktarına göre σ parametresi belirlenerek uygun şekilde ölçeklenmiş, $n = 1$ derece Hermit Gauss (HG) fonksiyonu ile konvolüsyonunu almakta ve daha sonra GEKK (Gürbüz En Küçük Kareler) [18] ile olası değişim noktalarını belirlemektedir.

$$h_n(t) = \frac{2^{5/4}}{\sigma} \sqrt{\pi} te^{-\frac{\pi t^2}{\sigma^2}} \quad (7)$$

Ölçülen sinyalin anlık fazının HG ile konvolüsyon işlemi, efektif olarak düzeltilmiş türev operasyonuna denk gelmekte ve Şekil 3'de görüldüğü gibi fazdaki atlamaların belirgin hale gelmesini sağlamaktadır. Sonrasında, konvolüsyonu alınan faza



Şekil 3: 5dB SNR’da ölçülen 16-PSK faz modülasyonlu darbe için ikinci ön işleme aşamaları. (a) Eşikten geçirilerek tespit edilen modülasyonlu darbenin fazı. (b) Darbenin fazının; HG ile konvolüsyonun sonucu (mavi), gürbüz en küçük kareler ile tespit edilen bölümü (kırmızı).

GEKK yöntemi [12] ile aykırılık tespiti yapılır ve Şekil 3b’de görüldüğü gibi fazda meydana gelen atlamaların olduğu yerler tespit edilmektedir. Bu işlem frekans kipli sinyallerin fazında meydana gelen değişikliklerde çıktı vermemektedir ve frekans ile faz modülasyonlu sinyallerin de birbirinden ayırt edilmesine katkıda bulunmaktadır. Ayrıca Şekil 3b’de görülen fazdaki atlama seviyeleri de ayrıştırılarak vektör formuna sokulur ve faz atlamalı sinyallerin sınıflandırılmasında da etkili olacak olan ikinci ön işleme girdisi oluşturulmuş olur.

B. Hibrit Konvolüsyonel Sinir Ağı Modeli

Önerilen hibrit konvolüsyonel sinir ağı modeli, sinyalin ön işlenmesiyle oluşturulan yeniden atanmış ZFR’sini ve fazın gürbüz en küçük kareler yöntemi ile kestirilmiş atlama miktarları vektörünü iki girdi olarak almakta, çıktı olarak da kipleme türünü vermektedir.

Zaman-frekans görüntüsüne dönüştürülen frekans modülasyonlu sinyaller, görüntü formatında olduğu için konvolüsyonel sinir ağlarıyla ayırt edilebilecek yapıya erişmiş olurlar. Şekil 1’de görüldüğü gibi, ilk önışlenmiş girdi için 3 konvolüsyonel katmandan oluşan derin sinir ağında öznetelik çıkarma işlemi gerçekleştirilmektedir. Bu katmanlarda sırasıyla 5x5, 4x4 ve 4x4’lük 8, 4 ve 2’şer filtre kullanılmaktadır. Her katmandan sonra işlem yükünü azaltmak adına 2x2’lik en büyük havuzlaması (max pooling) kullanılarak boyut düşürülmektedir.

İkinci ön işleme ile oluşturulan vektörlerden öznetelik çıkarılması aşamasında tek boyutlu 3 katmanlı konvolüsyonel sinir ağları kullanılmıştır. Bu katmanlarda sırasıyla 5x1, 4x1 ve 4x1’lük 8, 4 ve 2’şer filtre kullanılmaktadır. Her katmandan sonra işlem yükünü azaltmak adına 2x1’lik en büyük havuzlaması kullanılarak boyut düşürülmektedir. Son olarak bu iki ağın 5’er sinir hücrelerinden oluşan son katmanları birleştirilerek sınıflandırıcı görevi gören iki katmanlı standart sinir ağından geçirilerek çıktı olarak modülasyon sınıflarının olasılıklarını

TABLO I: Benzetim sonuçlarındaki kümelerde sınıf olarak kullanılan modülasyon türleri

7 Sınıflı Küme	14 Sınıflı Küme	
Tek Taşıyıcı Modülasyon (TTM)	TTM	Costas-5
Doğrusal FM	+ Rampa FM	Costas-7
Baker-13	- Rampa FM	Costas-10
Costas-10	Sinüsoidal FM	Barker-3
QPSK	Üçgen FM	Barker-7
8-PSK	QPSK	Barker-13
16-PSK	8-PSK	
	16PSK	

veren bir ağ kurulmuş olmaktadır. İki girdiyi frekans ve faza göre iki ayrı sinir ağı ile sınıflandırmak yerine bu ağlar birleştirip tek bir ağ olarak eğitildiğinde, ön işleme kaynaklı hatalara karşı daha gürbüz bir ağ modeli elde edilmektedir.

Son olarak; yaygın olarak konvolüsyonel sinir ağlarında, bilgi kaybı olmaması açısından ilerledikçe katmanların boyutu küçülürken kanal sayıları artmaktadır [14]. Ancak bu artan kanal sayısı hesap yükünü ve öğrenilmesi gereken parametre sayısının çok yüksek tutulmasını engellemek ve boyut küçültme işlemi de uygulamak amacıyla katmanlarda ilerledikçe boyut sayısı da kanal sayısı da azaltılmaktadır. Sonuç olarak küçük eğitim kümelerinde bile genelleme yapmayı öğrenebilen bir ağ yapısı oluşturulmuştur.


III. BENZETİM SONUÇLARI

Önerilen yöntemin mevcut yöntemlerle kıyaslamasının yapılabilmesi ve değişen gürültü miktarına göre genelleme başarısının ölçülmesi amacıyla 2 farklı küme göz önünde bulundurulmuştur. Bu senaryolarda [17]’deki tanımlamalara uygun olarak kullanılan sınıflar, Tablo I’de görülmektedir. Tüm modeller Python’da Tensorflow kütüphanesi kullanılarak oluşturulmuş, eğitilmiş ve test edilmiştir. Her durum için, eğitim kümesinde olmayan sınıf başı 100 örnek doğrulama, 500 örnek ise test için kullanılmıştır, her durum için eğitim 3 kere tekrarlanmış ve en iyi doğrulama performansını gösteren ağırlıklar test seti üzerinde kullanılmıştır. En iyileme metodu olarak diğer yöntemlerin birleşimi olarak kabul edilebilecek ADAM [15] en iyileme algoritması tercih edilmiştir.


Benzetim senaryosunda; kipleme içeren darbelerin 100 MHz örnekleme frekansına sahip olup uzunluğunun 2-25 μs arasında değiştiği, adımlı kiplemelerde kipleme süresinin en az 0.4 μs olduğu, periyodik kiplemelerin en az 1.5 periyot uzunluğunda olduğu, kipleme derinliklerinin ise 5-40 MHz arasında değiştiği varsayılmıştır. Ayrıca tipik bir EH ölçümünde ancak 10 dB SGO’da darbe tespiti yapılabildiğinden dolayı benzetim sonuçları da bu seviyedeki SGO değerlerine göre elde edilmiştir.

Geliştirdiğimiz yöntemi, mevcut en yüksek başarımlı yöntemlerle ([4] ACF-DGM, [10] TFI-CNN) karşılaştırma amaçlı 1. set kullanılmıştır. Bu set, [10]’de kullanılan sete mevcut yöntemlerin tanımlama yapmakta zorlandığını düşündüğümüz faz modülasyonlarının da eklenmiş halidir. Sonuçlar, değişen sınıf başı eğitim seti büyüklüğüne göre doğru sınıflandırma başarılarının hesaplanmasıyla elde edilmiştir. Şekil 4’de görüldüğü gibi; geliştirilen yöntem, mevcut en yüksek başarımlı yöntemin %10-15 üstünde başarımlı sergilemektedir.

Yöntemin farklı gürültü miktarına olan dayanıklılığını ve yüksek sınıf sayısında da genelleme yeteneğini kaybetmediğini gösterebilmek için 5 ve 10 dB SGO gürültü seviyelerinde Şekil 5’deki 14 sınıflı sınıflandırma sonuçları elde edilmiştir.



Şekil 4: Önerilen yöntemin başarımının, 10dB SGO'da ve 7 sınıflı durumda mevcut en yüksek başarımli iki yöntem ile karşılaştırılması



Şekil 5: Önerilen yöntemin 5 ve 10dB SGO'da, değişen eğitim seti büyüklüğüne göre 14 sınıflı sınıflandırılma başarısı.

Şekilden görüldüğü üzere, önerilen yöntem 5dB SGO kadar düşük seviyelerde bile genelleme yeteneğini kaybetmeden 14 sınıflı başarılı bir şekilde sınıflandırabilmektedir.

Tablo II'de ise önerilen metodun 14 sınıflı senaryo için süre analizine yer verilmiştir. Yöntemin ön işlemleri işlemcide, ağ eğitimi ve testi grafik işlemci biriminde gerçekleştirilmiştir. Kullanılan işlemci ve grafik işlemci birimi özellikleri ve modelleri sırasıyla 3.4 GHz hızda 4 çekirdekçe sahip Intel i5 4460 ve 1050 MHz hızda 1664 CUDA çekirdeğine sahip Nvidia GTX 970'dir. Çevrimdışı bir eğitimin ardından 43ms kadar kısa sınıflandırma süresiyle gerçek zamanlı kullanıma müsait bir metod olduğu görülmektedir.

IV. SONUÇLAR

Bu çalışmada; radar darbeleri üzerindeki frekans ve faz kipleme tiplerinin otomatik olarak sınıflandırılabilmesi için, darbelerin zaman-frekans görüntüsünü ve bu darbelerin fazlarındaki değişimin gürbüz en küçük kareler yöntemiyle işlenmiş halini girdi olarak kullanan hibrit yapıda bir konvolüsyonel sinir ağı önerilmiştir. Önerilen yöntemin, literatürdeki en yüksek başarımli yöntemin üzerinde bir başarımla sergilediği ve yüksek genelleme yeteneğine sahip olduğu, simülasyon sonuçlarıyla desteklenmiştir. Önerilen derin ağ modeli sentetik veri ile eğitilebildiğinden, istenilen büyüklükte eğitim seti ile eğitim sağlanarak EH uygulamalarında rahatlıkla kullanılabilir. Son olarak, ileriki çalışmalarda, çıktı olarak sınıf olasılıklarının

TABLO II: 14 sınıflı durum (sınıf başı 700 eğitim örneği) ve farklı SGO seviyeleri için süre analizleri.

	5dB SGO	10dB SGO
Ön-İşlem Süresi (Eğitim)	384 s	379 s
Yapay Sinir Ağı Süresi (Eğitim)	474 s	461 s
Ön-İşlem Süresi (Test)	36 ms	36 ms
Yapay Sinir Ağı Süresi (Test)	4 ms	4 ms
Performans	98.16%	99.79%

yanısıra parametre değerlerini de verebilecek sinir ağı yapıları incelenecektir.

KAYNAKLAR

- [1] J. Lunden and V. Koivunen, "Automatic Radar Waveform Recognition," in IEEE Journal of Selected Topics in Signal Processing, vol. 1, no. 1, pp. 124-136, June 2007.
- [2] D. Zeng, X. Zeng, H. Cheng and B. Tang, "Automatic modulation classification of radar signals using the Rihaczek distribution and hough transform," in IET Radar, Sonar & Navigation, vol. 6, no. 5, pp. 322-331, June 2012.
- [3] K. Konopko, Y. P. Grishin and D. Jańczak, "Radar signal recognition based on time-frequency representations and multidimensional probability density function estimator," Signal Processing Symposium (SPSymposium), 2015, Debe, 2015, pp. 1-6.
- [4] Chao Wang, Hao Gao and Xu-Dong Zhang, "Radar Signal Classification Based on Auto-correlation Function and Directed Graphical Model," 6th International Conference on Signal Processing, Communications and Computing (ICSPCC), Hong Kong, August 2016.
- [5] Y. Pu, W. Jin, M. Zhu and L. Hu, "Classification of Radar Emitter Signals Using Cascade Feature Extractions and Hierarchical Decision Technique," 2006 8th international Conference on Signal Processing, Beijing, 2006.
- [6] Hao Gao and Xu-Dong Zhang, "Automatic Radar Waveform Recognition Using SVM," Applied Mechanics and Materials 229 (2012): 2348-2351.
- [7] R. Mingqiu, C. Jinyan, Z. Yuanqing and H. Jun, "Radar signal feature extraction based on wavelet ridge and high order spectra analysis," Radar Conference, 2009 IET International, Guilin, 2009, pp. 1-5.
- [8] Z. Yu, C. Chen and W. Jin, "Radar Signal Automatic Classification Based on PCA," 2009 WRI Global Congress on Intelligent Systems, Xiamen, 2009, pp. 216-220.
- [9] J. Li and Y. Ying, "Radar signal recognition algorithm based on entropy theory," Systems and Informatics (ICSAI), 2014 2nd International Conference on, Shanghai, 2014, pp. 718-723.
- [10] Chao Wang, Jian Wang, and Xudong Zhang, "Automatic radar waveform recognition based on time-frequency analysis and convolutional neural network," 2017 International Conference on Acoustics, Speech and Signal Processing, New Orleans, 2017, pp. 2437-2441.
- [11] R. Girshick, "Fast R-CNN," 2015 IEEE International Conference on Computer Vision (ICCV), Santiago, 2015, pp. 1440-1448.
- [12] Chen, C, "Robust regression and outlier detection with the ROBUST-REG procedure," in Proceedings of the Proceedings of the Twenty-Seventh Annual SAS Users Group International Conference, Paper 265-27, 2002.
- [13] F. Auger, P. Flandrin "Improving the Readability of Time-Frequency and Time-Scale Representations by the Reassignment Method" IEEE Transactions on Signal Processing, Vol. 43, No. 5, pp. 1068-89, 1995.
- [14] K. Simonyan and A. Zisserman. Very deep convolutional networks for large-scale image recognition. In ICLR, 2015.
- [15] Ba, J., & Kingma, D.P. Adam: A Method for Stochastic Optimization. CoRR, abs/1412.6980, 2014.
- [16] M. A. Nuhoglu, Classification of Radar Signal Features in Electronic Warfare with Convolutional Long-Short Time Memory, SIU, 2018. (accepted)
- [17] P. E. Pace, Detecting and classifying low probability of intercept radar. Artech House, 2009.
- [18] Y. K. Alp, Elektronik İstihbarat Sistemlerinde Darbe İçerik Frekans Atlama Parametreleri Kestirimi, SIU, 2018. (accepted)