

# Radyo Sinyallerinin Derin Öğrenme Sinir Ağları ile Tanınması

## Recognition of Radio Signals with Deep Learning Neural Networks

Gültekin Işık<sup>1</sup>, Harun Artuner<sup>1</sup>

<sup>1</sup>Bilgisayar Mühendisliği Bölümü, Hacettepe Üniversitesi, Ankara, Türkiye  
[{gultekin, artuner}@cs.hacettepe.edu.tr](mailto:{gultekin, artuner}@cs.hacettepe.edu.tr)

**Özetçe—** Günümüzde Yapay Sinir Ağlarının çok farklı uygulamalarda kullanımı süreklilik göstermektedir. Özellikle işlem gücünün artması sonucu zamanında kullanımı pratik bulunmayan Derin Öğrenme türü yapay sinir ağlarının kullanımını gittikçe artmaktadır. Üzerindeki ilginin arttığı bir diğer konu da Yazılım Tanımlı Radyo (SDR) olarak adlandırılan sayısal radyo kavramıdır. Özellikle radyo amatörlerinin ilgisi ile gittikçe büyüyen bir ortam oluşmuştur. SDR ile sinyallerin analiz edilmesi ve anlamlandırılması ise birçok alanda kabul görmektedir. Bu çalışmada SDR üzerinden alınan radyo sinyallerinin derin öğrenme sinir ağları (DLNN) ile kimliklendirilmesine yönelik örnek bir çalışmanın tasarım ve gerçekleştirimi konu edilmiştir.

**Anahtar Kelimeler —** Derin Öğrenme Sinir Ağları, Yazılım Tanımlı Radyo, Radyo Sinyal Analizi

**Abstract—** Nowadays, the use of Artificial Neural Networks shows continuity in many different applications. In particular, the use of deep learning type neural networks, seen as impractical previously, is increasing by processing power growth. Software Defined Radio (SDR) is another hot topic called as Digital Radio concept. With a growing interest in the environment was formed especially by radio amateurs. Analyzing signals and making sense out of them by SDR is accepted in many areas. In this study, design and implementation of a sample work has been subjected for identification of received radio signals on SDR with deep learning neural networks. (DLNN).

**Keywords —** Deep Learning Neural Networks, Software Defined Radio, Radio Signal Analysis

### I. GİRİŞ

Yapay sinir ağları yeni bir hesaplama yöntemi değildir. Yaklaşık 60 yıldır [8][2] bilinen ve çeşitli sahalarda kullanılan bir yöntemdir. 1990'lara kadar kendine yer bulan yapay sinir ağları, lineer olmayan sistemlerde başarı sağlayamamıştır. Bunun sonucunda 2000'li yıllara kadar

herhangi bir çalışma yapılmamış, bir anlamda göz ardı edilmiştir.

2006 yılında Toronto Üniversitesi'nden Geoffrey Hinton ve arkadaşları [5] yapay sinir ağlarını konuşma tanıma problemlerinde kullanmayı başarmışlar ve bu sayede yapay sinir ağları tekrar bilim çevrelerinde gündeme gelmiştir.

Derin Öğrenme (Deep Learning) [1], derin mimariye dayanan, gizli katmanların sayısı artırılmış ve her katmanda probleme dair bir özniteliğin (feature) öğrenildiği yapay sinir ağlarından oluşan yöntemler bütündür. Bu mimaride her katmanda probleme ait bir öznitelik öğrenilir ve bu öğrenilen nitelik bir üst katmana bir girdi oluşturur. Böylelikle en alt katmandan en üst katmana doğru en basitten en karmaşık nitelikin öğrenildiği bir yapı kurulmuş olur.

Derin Öğrenme son yılların en önemli konuları arasındadır. Görüntü işleme, ses tanıma ve doğal dil işleme gibi alanlarda kendine yer bulmuştur. Google [7], Facebook [12], Baidu [4], Microsoft [1] gibi firmalar bu konu üzerinde çalışmalar yürütmeaktadır.

Bu çalışmanın ikinci bileşeni olan Yazılım Tanımlı Radyo (Software Defined Radio - SDR) [3] ilk kez 1970'te DoD Laboratuvarlarında (Department of Defense Laboratories) MIDAS (Missile Defense Alarm System) adıyla anılan proje kapsamında sayısal radyo sistemi olarak ortaya çıkmıştır. Bu amaçla GNURadio adıyla bilinen [15] açık kaynak kodlu, yazılım tanımlı radyo geliştirilmiştir. Söz konusu bu ortamda, gereklili olan her tür sinyal işleme bileşeni, yazılım kütüphanesi biçiminde sunulmaktadır. Kısaca yazılımla bir radyo alıcısının gerçekleştirimi yapılmaktadır.

Bu çalışmada Yazılım Tanımlı Radyo'dan elde edilmiş sinyallerin üzerine Hızlı Fourier Dönüşümü (Fast Fourier Transform-FFT) uygulanmış zaman eksenindeki akan

görüntüleri (*Waterfall*), derin öğrenme yöntemleri kullanılarak sınıflandırılmıştır. Deneyel olarak 11 sinyal kaynağına ait görüntü kullanılmış ve bu görüntülerin sınır ağının tarafından tanınması sağlanmıştır. Tanımada oldukça yüksek bir başarı elde edilmiştir.

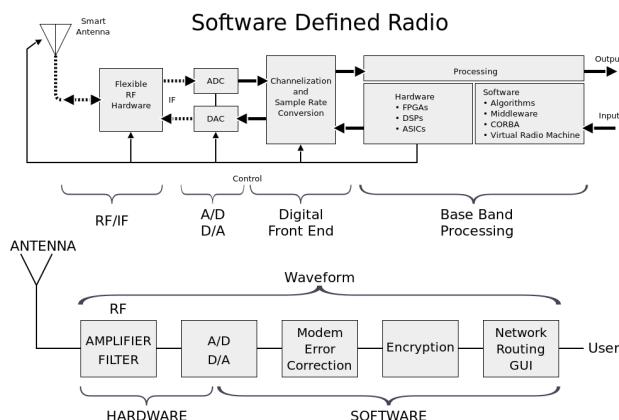
Bu çalışmada derin öğrenme yöntemlerinden Konvolüsyonel Sinir Ağları (Convolutional Neural Networks - CNN) [10][11][13] yöntemi kullanılmıştır.

Çalışmanın; ikinci bölümünde Yazılım Tanımlı Radyo (SDR) tanıtılmış, üçüncü bölümünde CNN yapısı anlatılmıştır. Dördüncü bölümde kullanılan veri seti tanıtılmış, ardından beşinci bölümde yapılan çalışma, altıncı bölümde ise çalışmaya ilişkin sonuçlar açıklanmıştır.

## II. YAZILIM TANIMLI RADYO (SOFTWARE DEFINED RADIO - SDR)

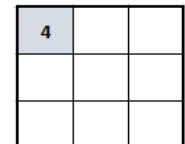
Sabit donanım yerine yazılım ile kimi sinyal işleme fonksiyonlarının geliştirilmesi üzerine son yıllarda oldukça fazla çalışma bulunmaktadır [14]. Genelde eğilim sabit donanımla gerçekleştirilen donanımların yerine, istediği zaman özelliklerin değiştirilebileceği esnek ortamların geliştirilmesi, öteden beri her alanda istenilen bir tasarım yaklaşımı olmuştur. Özellikle yapılan hataların düzeltilmesi ya da sistemin donanım değişikliği gerektirmeden yazılımla özelliklerinin değiştirilmesi, tasarım ve geliştirme maliyetlerini azaltmaktadır. Bu tür yaklaşımlar günlük hayatımızda çokça kullandığımız cep telefonları ve bilgisayarlar için vazgeçilmez bir özelliktir. SDR olarak tanımlanan sistemler bilgisayar ortamında radyo gerçekleştirmenin mümkün olmasını sağlamaktadır.

SDR üzerinde, bir radyo için gereken hemen hemen tüm bileşenlerin yazılım ile sağlandığı görülmektedir. Donanım olarak sadece uygun bir anten, RF alıcı ve örnekselden sayısala dönüştürücü (Analog Digital Converter) bulunmaktadır. Şekil 1'de de görüldüğü gibi klasik radyo tanımındaki modüller yerlerini yazılım ile çözümlemeye bırakmaktadır.

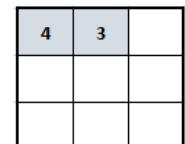


Şekil 1. Sofware Defined Radio için ilke şeması [18]

|   |    |   |    |   |    |   |   |
|---|----|---|----|---|----|---|---|
| 1 | x1 | 1 | x0 | 1 | x1 | 0 | 0 |
| 0 | x0 | 1 | x1 | 1 | x0 | 1 | 0 |
| 0 | x1 | 0 | x0 | 1 | x1 | 1 | 1 |
| 0 | 0  | 1 | 1  | 1 | 0  | 0 | 0 |
| 0 | 1  | 1 | 0  | 0 | 0  | 0 | 0 |



|   |   |    |   |    |   |    |   |
|---|---|----|---|----|---|----|---|
| 1 | 1 | x1 | 1 | x0 | 0 | x1 | 0 |
| 0 | 1 | x0 | 1 | x1 | 1 | x0 | 0 |
| 0 | 0 | x1 | 1 | x0 | 1 | x1 | 1 |
| 0 | 0 | 1  | 1 | 0  | 0 | 0  | 0 |
| 0 | 1 | 1  | 0 | 0  | 0 | 0  | 0 |



Şekil 2. Filtrenin iki kere kaydırılmasıyla oluşan öznitelikler

## III. DERİN ÖĞRENME SİNİR AĞLARI

Derin Öğrenmeye ilişkin aşamalar ise aşağıda özetlenmektedir.

### A. Konvolüsyon

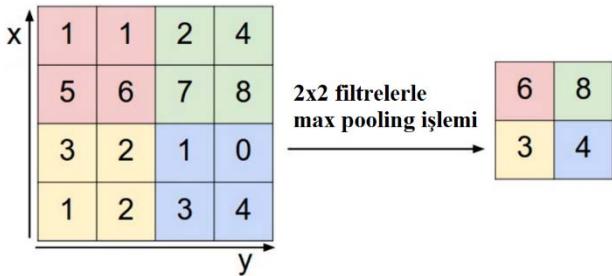
Konvolüsyon, genel tanımıyla matris üzerine kayan bir pencere fonksiyonun uygulanmasıdır. Şekil 2'de, soldaki matris siyah – beyaz bir resmi göstermektedir. 0 ve 1 ile gösterilenler sırasıyla siyah ve beyaz piksellere karşılık gelmektedir. Alt alta gösterilen iki resim ise, bir matris üzerinde iki kere konvolüsyon işlemi yapıldığını göstermektedir. Kayan pencereye genelde kernel ya da filtre denilmektedir. Burada kullanılan 3x3 boyutlu滤re değerleri, üzerinde bulunduğu matris ile eleman elemana çarpılır ve toplamı alınır. Bu işlem matrisin sonuna gelene kadar kaydırılarak devam eder. Şekil 2'deki resim üzerinde filtre iki kere kaydırılmıştır.

### B. Pooling

Konvolüsyonel Sinir Ağlarında *pooling* katmanları konvolüsyon katmanlarından sonra gelmektedir. *Pooling* katmanları girdi olarak verilen resmin alt örneklemeye işlemini yapar. *Pooling* katmanında herfiltrenin sonucuna *max* işlemi uygulanır. Şekil 3'te 2x2 boyutlu pencere için *max pooling* (filtrelerde oluşan değerlerin en yüksekinin alınması) yapılmıştır. *Pooling* işleminin sonucunda sabit boyutlu bir matris elde edilmekte ve çıkış boyutu önemli ölçüde düşürülmektedir.

### C. Konvolüsyonel Derin Öğrenme Sinir Ağları (CNN)

CNN birden fazla konvolüsyon katmanından oluşan ve bu katmanlarda lineer olmayan fonksiyonların bulunduğu yapılardır. Geleneksel ileri beslemeli sinir



Şekil 3. Pooling işlemi [17]

ağlarında bir katmandaki bütün nöronlar bir sonraki katmanın bütün nöronlarına bağlıdır. Bu tür bağlı katmanlara tam bağlı katman denir. CNN'de tam bağlı katmanlara ek olarak, çıkışı üretmesi için giriş katmanına konvolüsyon uygulanır. Bu, giriş katmanındaki bütün bölgelerin bir sonraki katmanda bulunan nöronlara bağlı olduğu, lokal bağlantılara neden olur. Her katman farklı filtreler uygular ve sonunda bunların sonuçlarını birleştirir. Eğitim boyunca CNN, filtrelerin içeriğini (öz nitelikleri), gerçekleştirmesi istenen işleme göre kendisi otomatik olarak öğrenir. Böylece baştan sona doğru her katmanda görüntüye ilişkin, basitten karmaşağa, öz nitelikler öğrenilmiş olur (Şekil 4).

#### IV. VERİ SETİ

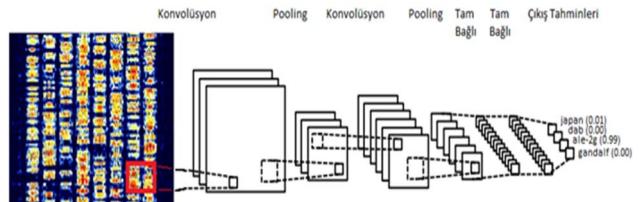
Çeşitli vericilere ait sinyalleri içeren bir veritabanı [16]'da bulunmuş ve kullanılmıştır. Bu veritabanı örnek radyo sinyallerinden ve bu sinyallerin waterfall çıktılarından (her sinyal için bir adet) oluşan bir veritabanıdır. Bu sinyaller Yazılım Tanımlı Radyo (SDR) kullanılarak alınmıştır. Aynı zamanda sinyallerin kimlikleri, frekans aralıkları, ses örnekleri de mevcuttur. Görüntüler RGB özellikli ve çoğu 300x600 piksel ebadındadır.

#### V. DENEYSEL ÇALIŞMA

Signal Identification Wiki [16]'de bulunan veritabanında Yazılım Tanımlı Radyolardan elde edilen görüntüler ve bu görüntülere ait açıklamalar bulunmaktadır.

Derin öğrenme yöntemleri, ağın eğitilmesi için çok fazla sayıda örneğe ihtiyaç duyduğundan bir adet görüntü ismine yaramaz. Ancak bu görüntülerin web ortamında bulunması o kadar kolay değildir. Bu yüzden eldeki görüntülerini yatay olarak (300x100 piksel) parçalara ayıra ve bir görüntüden birden fazla görüntü elde etme yoluna gidilmiştir. Bu durumda da yatay olarak kesilebilecek, görüntüsü dikeyde tekrar eden görüntüler kullanılmalıdır. Aksi durumda kesilerek elde edilen görüntülerin sınıflandırılması ya da doğru olarak sınıflanması mümkün olmayacağından.

Böylece 11 ayrı kategoriye ait (Şekil 5'te 7 tanesi), her bir kategoride yaklaşık 12 görüntü olacak şekilde, toplamda 137 örnek görüntü oluşturulmuştur. Bunlardan 82 adedi eğitim, 22 adedi doğrulama ve geri kalan 33 adedi ise test



Şekil 4. Görüntü sınıflandırma işlem sırası

amaçlı kullanılmıştır.

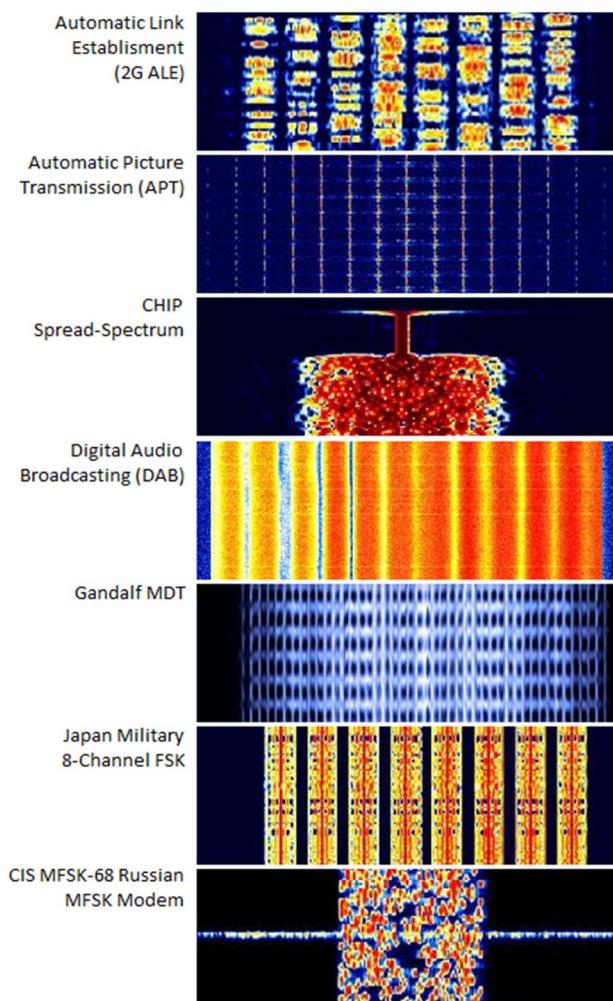
Oluşturulmuş görüntüler DLNN için, [6]'da tanıtılan Caffe platformu kullanılarak eğitilmiştir. Caffe açık kaynak kodlu, konvolüsyonel sinir ağları yöntemi kullanılarak öz nitelik çıkarma ve tanıma için geliştirilmiş bir platformdur. Sinir ağının; hangi katmanlardan oluşacağı, her katmanın girdi ve çıktılarının ne olacağı, katmanlarda kullanılacak parametreler, konvolüsyon çerçeve boyutu, bu çerçeveden ne kadar kaydırılacağı, öğrenme oranı, etiketler, etiket isimleri gibi özellikleri belirtilerek platform kurulmuş olur.

Bu kısıtlı deneysel çalışmada, sinir ağına verilen 82 eğitim ve 22 doğrulama verisiyle eğitilen ağın kendisine test için verilen bir görüntüye verdiği sonuçlar ise Şekil 6'da gösterilmiştir. Şekilden de görüleceği gibi sinir ağ, test için verilen görüntüyü (daha önce hiç görümediği 300x250 piksel) 0.99 olasılıkla doğru olarak sınıflandırmıştır.

#### VI. SONUÇ ve YORUMLAR

Oluşturulan yaklaşık 12 görüntüden yaklaşık 8 adedi eğitim için, diğerleri doğrulama ve test için kullanılmıştır. 11 ayrı sinyal kaynağından alınmış bu görüntüler, sinir ağ tarafından %82 başarıyla tanınmıştır. Uluslararası görüntü tanıma yarışmalarında [9] kullanılan değerlendirme ölçütlerinden yararlanılmıştır. Burada, Top-1 (tanınanların ilki) ve Top-5 (tanınanların ilk beşi) hata oranlarına göre de eğitilen ağın hata oranı düşüktür. Top-1 hata oranı, test aşamasında ağ tarafından ilk sırada gösterilen hatalı tahmin sonuçlarının, toplam test örnek sayısına bölünmesiyle oluşur. Top-5 hata oranı ise, doğru sonucun test aşamasında ağ tarafından sunulan ilk 5 sonuç arasında bulunmamasıyla oluşturulan bir orandır. Bu durumda, eğitilen ağ %3 Top-5 hata oranına, %18 Top-1 hata oranına sahiptir.

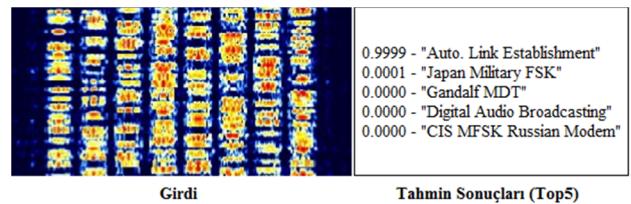
Burada az sayıda örnek ve yine az sayıda bu örneklerin ait olduğu kategoriyle çalışılmıştır. Örnek ve kategori sayılarının artırılmasıyla sonuçları kullanılabilir uygulamalar yapılabilir. Top-1 hata oranının %18 seviyelerinden daha düşük seviyelere çekilmesinin mümkün olduğu düşünülmektedir. Ayrıca, oluşturulan sinir ağ modelinin parametrelerinin değiştirilmesiyle de daha iyi sonuçlara varılabilir.



**Şekil 5.** Kategorilere ait örnekler

Buradaki basit örnek sayısıyla oluşturulan sinir ağını eğitmek için harcanan süre yaklaşık 3 saatdir. İşlemler 4 çekirdekli, 2.6 GHz frekanslı bir işlemci ve 1 GB boyutlu belleğe sahip bir bilgisayar üzerinde yapılmıştır. Daha fazla kategori ve bunlara ait daha büyük veri seti kullanılması durumunda eğitim için harcanan süre artacaktır. Bu süre sorununun üstesinden gelebilmek için üzerinde çalışılan bilgisayarın hesaplama ve saklama kapasitesinin artırılması gereklidir. Daha ayrıntılı uygulamalar ve sonuçları için ise grafik işlemci kullanılması söz konusudur.

Çalışmada GNURadio üzerinden alınan sinyaller işlenmiştir. Bundan sonraki aşamada, istenilen frekanstaki radyo sinyallerinin GNURadio'ya yapılan bir eklenti ile gerçek zamanda kimliklendirilmesinin ya da tanınmasının sağlanması amaçlanmaktadır.



**Şekil 6.** Sinir ağının test edilmesi. Sinir ağ test için verilen resmi (ALE-2g) 0.99 olasılıkla doğru (Şekil 5) tanımlmaktadır.

#### KAYNAKÇA

- [1] Deng, L. and Yu, D., “Deep Learning: Methods and Applications”, Foundation and Trends in Signal Processing Vol. 7, pages 197-387, 2014
- [2] Farley, B. G. and Clark, W. A., “Simulation of Self-Organizing Systems by Digital Computer”, IRE Transactions on Information Theory 4, pages 76-84, 1954
- [3] Grayver, E., “Implementing Software Defined Radio”, ISBN: 978-1-4419-9331-1, 2013
- [4] Hannun, A., et al., “Deep Speech 2: End-to-End Speech Recognition in English and Mandarin”, arXiv:1512.02595, 2015
- [5] Hinton, G. E., et al., “A Fast Learning Algorithm for Deep Belief Nets”, Neural Computation 18, pages 1527-1554, 2006
- [6] Jia, Y., et al., “Caffe: Convolutional Architecture for Fast Feature Embedding”, arXiv:1408.5093, 2014
- [7] Le, Q.V, et al., “Building High-Level Features Using Large Scale Unsupervised Learning”, In Proceedings of the 29th International Conference on Machine Learning, Edinburgh, 2012
- [8] Rosenblatt, F., “The Perceptron: A Probabilistic Model For Information Storage and Organization in the Brain”, Psychological Review 65, pages 386-408, 1958
- [9] Russakovsky, O., et al., “ImageNet Large Scale Visual Recognition Challenge”, arXiv:1409.0575, 2015
- [10] Sánchez, J. And Perronnin, F., “High-dimensional signature compression for large-scale image classification.” In Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference on, pages 1665–1672. IEEE, 2011.
- [11] Simard, P.Y., et al., “Best practices for convolutional neural networks applied to visual document analysis.” In Proceedings of the Seventh International Conference on Document Analysis and Recognition, volume 2, pages 958–962, 2003.
- [12] Taigman, Y., et al., “DeepFace: Closing the Gap to Human-Level Performance in Face Verification”, Conference on Computer Vision and Pattern Recognition (CVPR), 2014
- [13] Turaga, S.C., et al., “Convolutional networks can learn to generate affinity graphs for image segmentation”, Neural Computation, 22(2):511–538, 2010.
- [14] Vasudevan, S., et al., “Software Defined Radio Implementation”, Int. Journal of Computer Applications Vol. 4, 2010
- [15] GNURadio, <http://gnuradio.org/redmine/projects/gnuradio/wiki>, 21 Mart 2016 tarihinde erişildi.
- [16] Sigidwiki Veritabanı, <http://www.sigidwiki.com>, 21 Mart 2016
- [17] [http://deeplearning.stanford.edu/wiki/index.php/Feature\\_extraction\\_using\\_convolution](http://deeplearning.stanford.edu/wiki/index.php/Feature_extraction_using_convolution), 21 Mart 2016
- [18] [http://en.wikipedia.org/wiki/Software-defined\\_radio](http://en.wikipedia.org/wiki/Software-defined_radio), 21 Mart 2016