

## Radyo Haberleşmesinde Evrişimli Sinir Ağı Kullanılarak Yapılan Modülasyon Sınıflandırması

Bircan ÇALIŞIR<sup>1\*</sup>

<sup>1</sup>Firat Üniversitesi, Elazığ, Türkiye

\*<sup>1</sup> bkamislioglu@firat.edu.tr

(Geliş/Received: 06/07/2022;

Kabul/Accepted: 12/09/2022)

**Öz:** Bu çalışmada, radyo iletişim sinyalleri için modülasyon tipi sınıflandırması amaçlanmış ve derin öğrenmenin sınıflandırma performansı üzerindeki etkisi incelenmiştir. Ayrıca bu çalışmada, modülasyon sınıflandırmasında bir evrişimsel sinir ağının (Convolutional Neural Network-CNN) nasıl kullanılacağı araştırılmaktadır. İlk olarak, sentetik, kanal-bozulmuş dalga biçimleri oluşturulur. Üretilen dalga formlarını veri olarak kullanan bir CNN eğitilir, ardından modülasyon sınıflandırması yapılır. Sonunda, CNN'yi test etmek için Yazılım Tanımlı Radyo (SDR) donanımı ve havadan alınan sinyaller (kablosuz) kullanılır. Simülasyonda taşıyıcı frekans kayması, sembol hızı, çok yönlü sönümleme, gecikme yayılımı ve termal gürültünün farklı etkileri göz önünde bulundurulmaktadır. Tüm bu etkiler tam olarak uygun bir şekilde modellenilebilir ve ayrıca burada çalışmamızın kapsamı dışında sentetik olarak modellenilebilecek birçok ek yayılma etkisi vardır. Bu çalışmada eğitilen CNN; İkili faz kaydırmalı anahtarlama (BPSK), dörtlü faz kaydırmalı anahtarlama (QPSK), (8-PSK), 16 dörtlü genlik modülasyonu (QAM), 64 QAM, 4 darbeleri genlik modülasyonu (PAM4), gauss frekans kaydırmalı anahtarlama (GFSK), sürekli faz frekans kaydırmalı anahtarlama (CPFSK), yayın FM (B-FM), çift yan bant genlik modülasyonu (DSB-AM), tek yan bant genlik modülasyonu (SSB-AM) şeklindeki modülasyon tiplerini tanımlamak için kullanılır. Eğitilmiş CNN, 1024 ve 512 örnek için her bir çerçevenin modülasyon tipi hakkında tahminde bulunur ve karşılaştırmalar yapar. Bu çalışmada gösterilen performans ödüneşimleri, veri sembolleri ve eğitim sembolleri üretimindeki temel parametreleri dikkate alır, algılamayı geliştirir ve bu tür sistemlerin optimizasyonu üzerine gelecekteki çalışmalara odaklanır.

**Anahtar kelimeler:** CNN, DL, Modülasyon.

### Modulation Classification Using A Conventional Neural Network in Radio Communications

**Abstract:** Modulation type classification for radio communications signals is purposed and examined the effect of deep learning on the classification performance in this paper. In this work, search how to use a convolutional neural network (CNN) in modulation classification is searched. Firstly, synthetic, channel-impaired waveforms are generated. A CNN is trained that used the generated waveforms as data, then, modulation classification is realized. In the end, Software-defined radio (SDR) hardware and over-the-air signals are utilized to test the CNN. Different effects of carrier frequency offset, symbol rate, multipath fading, delay spread, and thermal noise in the simulation are considered. All of these impacts can be fully modeled decently and also, there are many additional dispersion influences that can be modeled synthetically beyond the scope of our work here. The CNN that is trained in this paper identifies such as; Binary phase-shift keying (BPSK), Quadrature phase-shift keying (QPSK), (8-PSK), 16-quadrature amplitude modulation (QAM), 64 QAM, 4-pulse amplitude modulation (PAM4), Gaussian frequency-shift keying (GFSK), Continuous phase frequency shift keying (CPFSK), Broadcast FM (B-FM), Double sideband amplitude modulation (DSB-AM), Single sideband amplitude modulation (SSB-AM). The trained CNN predicts and makes comparisons about the modulation type of each frame for 1024 and 512 channel-impaired samples in this paper. Trade-offs of the performance shown in this paper consider key parameters in data symbols and training symbols generation, enhance sensing and focus future workings on the optimization of such systems.

**Key words:** CNN, DL, Modulation.

### 1. Giriş

Kablosuz haberleşme sistemlerinde önemli işlemlerden biri sinyallerin modülasyonudur. Modülasyon tanıma işlemi genellikle hem sinyal algılama hem de demodülasyon için kullanılır. İletilen sinyalin alıcı tarafında doğru bir şekilde demodüle edilmesi halinde, sinyal iletimi sorunsuz bir şekilde gerçekleştirilebilir. Ancak, daha üst düzey ve karmaşık gereksinimlerin artması ve kablosuz iletişim tekniklerinin gelişmesiyle birlikte, kablosuz

\* Sorumlu yazar: bkamislioglu@firat.edu.tr. Yazarların ORCID Numarası: <sup>1</sup> 0000-0002-2838-1357

iletişim sistemlerinde kullanılan modülasyon yöntemlerinin ve parametrelerin sayısında hızlı bir artış gözlemlenmektedir. Bu artış nedeniyle modülasyon yöntemlerinin tam olarak nasıl belirleneceği daha zor hale gelmektedir. Geleneksel modülasyon tanımlama teknikleri genellikle, yumuşak koşullar altında yanlış olabilen ve ayrı bir kontrol kanalı kullanılarak iletebilen sinyal ve kanal parametreleri hakkında önceden bilgiye sahiptir. Kablosuz sistemlerde iletilen bilginin geçtiği ortam değişikçe modülasyon şemalarının sıklıkla değişmesi beklendiğinden, otonom modülasyon tanıma tekniklerinin gerekliliği ortaya çıkmıştır. Bu durum sinir ağıları kullanılarak yeni modülasyon tanımlama tekniklerinin düşünülmesine yol açmıştır [1].

Evrişimsel Sinir Ağı (CNN), son zamanlarda görüntülerin sınıflandırılmasında ve ses sinyallerinin işleminde sağlam ve etkili bir yöntem olarak kabul edilmiştir. Literatürde bu yöntemle ilgili doğal dil işleme ve video algılama gibi alanlarda da başarılı uygulamalar bulunmaktadır [2]. Spektrumdaki parazit takibi, radyo arızasının tespiti, dinamik spektruma erişim ve birçok düzenleyici ve savunma uygulaması için, radyo spektrumunu hızlı bir şekilde anlama ve etiketleme yeteneği önemli bir etkinleştirme faktörüdür. Çok sayıda radyo iletişim sisteminde, üzerinde işlem yapılabilen ve kompakt bir şekilde taşınabilen hassas ve doğru etiketler için karmaşık bir yüksek veri hızlı RF bilgi akışıyla işbirliği yapmak kritik bir öneme sahiptir [3].

Son on yılda, derin öğrenme (Deep Learning-DL) olarak bilinen algoritmalar ve optimizasyon teknikleri ile geliştirilen sinir ağı yapılarında hızlı bozulmalar yaşanmaktadır [4-6]. DL'nin son zamanlarda bilgisayarlı görme (Computer Vision-CV), ses ve doğal dil işlemede son teknoloji makine öğrenmesinin (Machine Learning-ML) yerini aldığı görülmektedir. DL, yüksek sayıda serbest parametreye sahip çok büyük sinir ağı modellerinin öğrenilmesi için yeni kurulmuş kapasitesi nedeniyle, yüksek düzeyde kontrol edilebilen hedeflere dayanan ham yüksek boyutlu girdi verileri üzerinde doğrudan öğrenme özelliklerini mükemmel bir şekilde geliştirmiştir [7-10].

Bu çalışmada, radyo sinyal türlerinin geniş veri kümesi, kablosuz yayılma ortamının gerçekçi bir şekilde simülasyonu, yeni veri kümesinin havadan (OTA) ölçülmesi (yani gerçek yayılma etkileri) amaçlanmıştır. Eşzamanlı olarak kablosuz veri talebi, gelişmiş radyo verimliliğine duyulan ihtiyacı artırıyor. Spektral tahsisi ve parazit azaltmayı iyileştirmek için yüksek kaliteli spektrum algılama ve uyarılma, bunu başarabileceğimiz önemli bir yoldur. Amerika Birleşik Devletleri'ndeki FCC ve Avrupa'daki muadilleri ciddiye almakta ve bu fikirlerin bazılarında yararlanan spektrum politikası izlemektedir. Hava Radyo iletişimi, makine öğrenimi topluluğu için bir dizi ilginç zorluk ve fırsatla benzersiz bir sinyal işleme alanı sunar. Bu alanda uzman özellikleri ve karar kriterleri kapsamlı bir şekilde geliştirilmiş ve uzun yıllardır belirli kriterler altında optimalite için analiz edilmiştir. Bununla birlikte, son birkaç yılda, görüntü işleme ve ses tanıma uygulamaları için makine öğrenimindeki eğilim, etkin bir şekilde, uzman özelliklerin işlenmesinden ziyade verilerden özellik öğrenme yönündedir ve bu, bu alanda benzer bir değişimi değerlendirmemiz gerektiğini düşündürmektedir.

## 2. Sinyallerin Sınıflandırılması

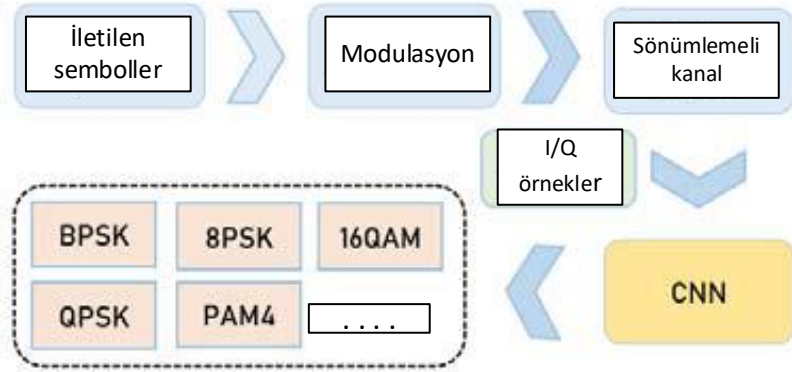
Bu bölümde, bu makalenin geri kalanında kullanılacak radyo sinyali sınıflandırma yöntemleri incelenmiştir.

### I. Temel Yöntem

Temel yöntem, daha yüksek dereceli sinyallerin listesini ve diğer toplam sinyal davranışı istatistiklerini içerir. Burada, önemli ölçüde tek bir karar ağacı veya destek vektör makinesinden (SVM) daha iyi performans gösteren modülasyonları sınıflandırmak için gradyan destekli ağaçların (XGBoost) [11] topluluk modeli kullanılır.


### II. Evrişimli Sinir Ağı (CNN)

CV'de (Bilgisayar Görüşü) yaygın olarak kullanılan evrişimli sinir ağı (CNN) mimarisi, sınıflandırıcılarda [12,13] tam bağlı (Fully Connected-FC) katmanlar tarafından izlenen bir dizi evrişimsel katman içerir. Oxford Üniversitesi'nde [14] Görsel Geometri Grubu (VGG), bu tür ağların nasıl yapılandırılacağı sorusu araştırılmış ve ağ mimarileri için birkaç temel tasarım ilkesi geliştirilmiştir. Bu CNN'deki özellikler, normleştirme değeri birim varyans olan her bir iletişim sinyali örneğinin ham I/Q (In-Phase and Quadrature) örnekleri olarak tanımlanır. Ham radyo sinyaline herhangi bir özellik çıkarma veya diğer ön işleme uygulanmaz, ağı doğrudan yüksek boyutlu veriler üzerinde ham zaman serisi özelliklerini öğrenmesine izin verilir. Karmaşık değerli otomatik farklılaşma pratik kullanım için henüz yeterince gelişmediğinden, gerçek değerli ağlar kullanılır.



Şekil 1. Önerilen CNN destekli sinyal modülasyon tanımlama sisteminin mimarisi.

Bu bölümde, farklı modülasyon modlarına sahip sinyalleri tanımak için CNN'yi benimsiyoruz ve nihai hedefimiz yukarıdaki onbir modülasyon modunu doğru bir şekilde tanımlamaktır. Şekil 1'de gösterildiği gibi, iletim sembolleri modülasyon ile dijital sinyallere değiştirilir. Ardından sayısaldan analoğa dönüştürme ve analog sinyalleri sönümlenme kanalına gönderme yoluyla modüleli sinyaller elde edilir. IQ örneklerini elde etmek için veriler önceden işlendikten sonra, CNN destekli sinyal modülasyon tanımlama sistemi sinyallerinin modülasyonunu doğru bir şekilde tanımlayabilir [15].



Şekil 2. CNN'nin temel yapısı evrişim (Convolution) katmanı, havuzlama (pool) katmanı ve FC katmanını içerir.

CNN, ileri beslemeli bir sinir ağıdır ve çok katmanlı algılayıcının bir çeşididir. Şekil 2'de gösterildiği gibi, CNN, evrişim katmanı ve havuzlama katmanının genellikle değiştiği bir model kullanır, böylece çıkarılan öznitelikler daha açıklayıcı öznitelikler oluşturmak üzere birleştirilir. Son tam bağlı (FC) katman, verimli tanıma elde etmek için kullanılır. CNN, yerel algı ve ağırlık paylaşımı olmak üzere iki avantajı olduğu için birçok alanda yaygın olarak kullanılmaktadır. Yerel algı, ağırlık kısmen bağlı olduğu ve her nöronun sadece bir önceki katmandaki bazı nöronlara bağlı olduğu anlamına gelir. Bu şekilde, yerel bilgi, küresel bilgi elde etmek için daha yüksek bir düzeyde bütünleştirilir. Ağırlık paylaşımı, ağırlık sayısını azaltabilen ve ağırlık optimize edilmesini kolaylaştırabilen konvolüsyon sürecindeki konvolüsyon çekirdeği aracılığıyla gerçekleştirilir. Dahası, aşırı uydurma riski de büyük ölçüde azalır.

Giriş katmanının ileriye doğru yayılması, CNN ileri yayılma algoritmasının ilk adımınıdır. Burada aktivasyon fonksiyonu  $\sigma(n)$  olarak seçilir ve gizli ve çıktı katmanlarının çıktı değerleri  $a$ 'dır. Bu durumda,  $l$ 'inci katmanın çıktısı şu şekilde ifade edilebilir:

$$\begin{aligned} a^l &= \sigma(z^l) \\ &= \sigma(a^{l-1} \otimes W^l + b^l) \end{aligned} \quad (1)$$

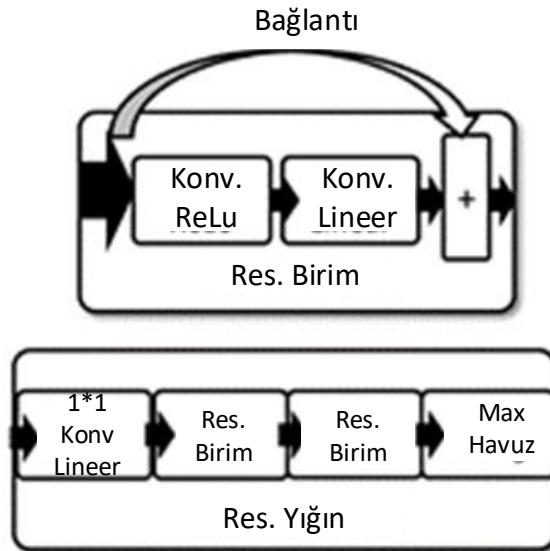
Denklem 1’de  $a^{l-1}$ , (l-1).nci katmanın çıktısının vektörünü temsil eder.  $W^l$ , l.nci katmanın lineer katsayılarının ağırlık matrisini gösterir.  $b^l$ , l’inci katmanın önyargı vektörünü gösterir ve  $\otimes$ , konvolüsyon hesaplamasını temsil eder. M alt matrisleri şeklinde de yazılabilir.

$$\begin{aligned} a^l &= \sigma(z^l) \\ &= \sigma\left(\sum_{k=1}^M z_k^l\right) \\ &= \sigma\left(\sum_{k=1}^M a_k^{l-1} \otimes W_k^l + b^l\right) \end{aligned} \quad (2)$$

Denklem 2’de  $a_k^{l-1}$ , k’inci alt matrisin çıktısının vektörünü temsil eder (l-1).nci katmanın,  $W_k^l$  l-inci katmanın lineer katsayılarının k.nci alt matrisinin ağırlık matrisini gösterir. Toplu normalleştirme (Batch Normalization-BN) katmanı, giriş değerlerini standartlaştırmak için ağ yapısı boyunca tanıtılır. Bir yandan, eğitimde gradyan kaybolması sorununu etkili bir şekilde hafifletebilir, öte yandan, modun eğitimini hızlandırabilir [16-20].

### III. Artık Sinir Ağı (RN)

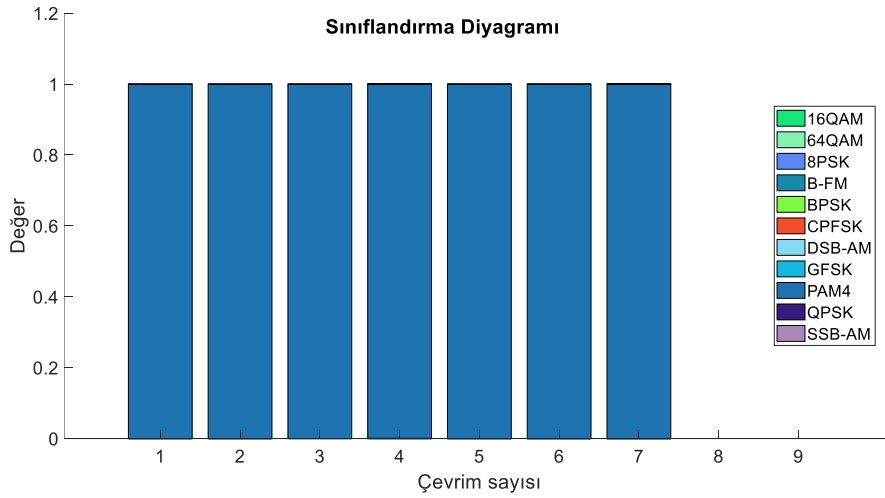
Geleneksel CNN’de sadece birkaç katmana sahip küçük bir evrişimsel sinir ağı kullanılır. Bununla birlikte, derin artık ağlar (RN’ler) görüşü CV alanında etkileyici bir şekilde gelişim göstermiştir [21-23]. Şekil 3’te gösterilen RN şemasında, özelliklerin ağ üzerinden çoklu ölçeklerde ve derinliklerde çalışmasına izin veren atlama veya baypas bağlantılarının görünümü güçlü bir şekilde kullanılmaktadır. RN’ler zaman serisi radyo sınıflandırması için araştırılır ve daha az dönem eğittiği, ancak doğruluk açısından önemli performans geliştirmeleri sağlamadığı kabul edilir.



Şekil 3. RN ağ katmanları gösterimi.

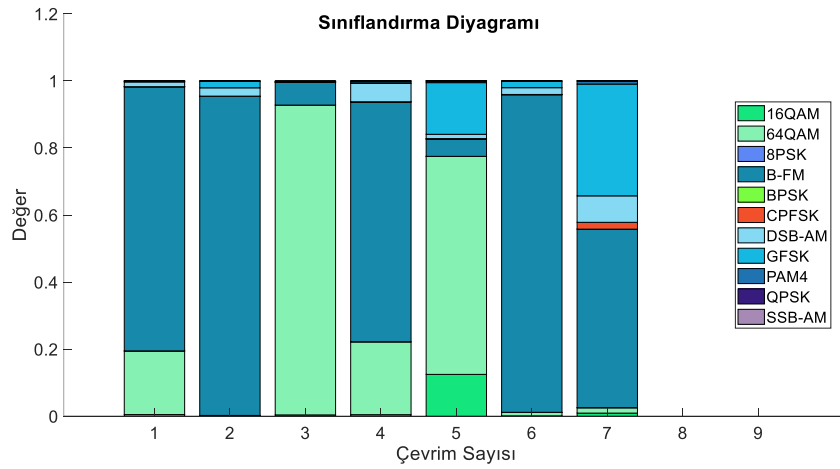
### 3. Veri Seti Üretim Yaklaşımı ve Uygulamalar

Pratikte yaygın olarak kullanılan modülasyonlar olan ayırık ikili semboller (dijital modülasyonlar) ve sürekli semboller (analog modülasyonlar), iyi tanımlanmış bir veri seti oluşturmak için üretilirler. Bu makale, çok çeşitli tek taşıyıcılı modülasyon düzenlerini içeren 11 farklı analog ve dijital modülatörü araştırmaktadır. Çalışmamızda, eğitilmiş olan CNN, 1024 ve 512 kanal-bozulmuş kalıpları kullanır ve her döngüde modülasyon tipini tahmin eder. Merkez frekansı ve örnekleme zamanı kayması ile bozulmuş Rician çok yollu sönümlenme kanalı ve AWGN, CNN'yi test etmek için sentetik sinyaller üretir ve CNN, döngülerdeki modülasyon tipini tahmin etmek için kullanılır [24-28].




**Şekil 4.** Farklı modülasyon yöntemlerinin sınıflandırma sonuçları  $f_s=200$  kHz ve çevrim başına örnek sayısı 1024.

Önerilen CNN modelini eğitmek için IQ örnekleri kullanılır. Faz içi bileşen ve kareleme bileşeni, vektörün yön problemleridir. Eş fazlı bileşen, vektör yönü ile aynı sinyal bileşeniyken, kareleme bileşeni vektör sinyaline diktir.

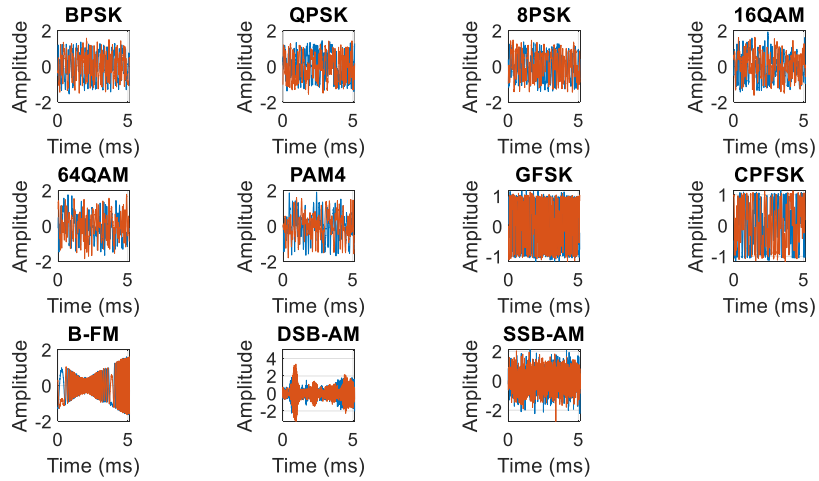


**Şekil 5.** Farklı modülasyon yöntemlerinin sınıflandırma sonuçları  $f_s=200$  Hz ve çevrim başına örnek sayısı 1024.

Çerçeve başına 1024 örnek için, farklı modülasyon yöntemlerinin sınıflandırma sonuçları  $f_s=200$  kHz Şekil 4'de,  $f_s=200$  Hz için farklı modülasyon yöntemlerinin sınıflandırma puanları Şekil 5'te gösterilmiştir,  $f_s=200$  MHz farklı modülasyon yöntemlerinin sınıflandırma sonuçları Şekil 6'da gösterilmiştir.

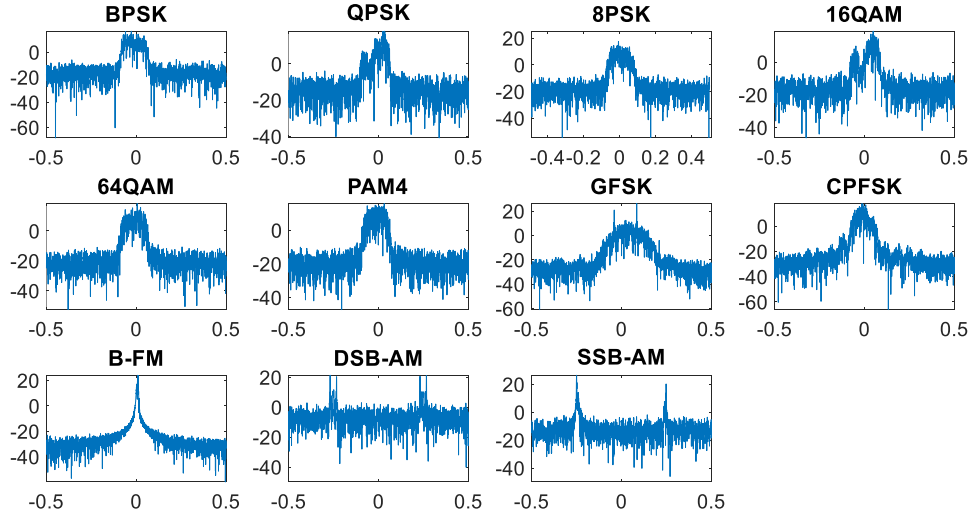


Şekil 6. Farklı modülasyon yöntemlerinin sınıflandırma sonuçları  $f_s=200$  MHz ve çevrim başına örnek sayısı 1024.



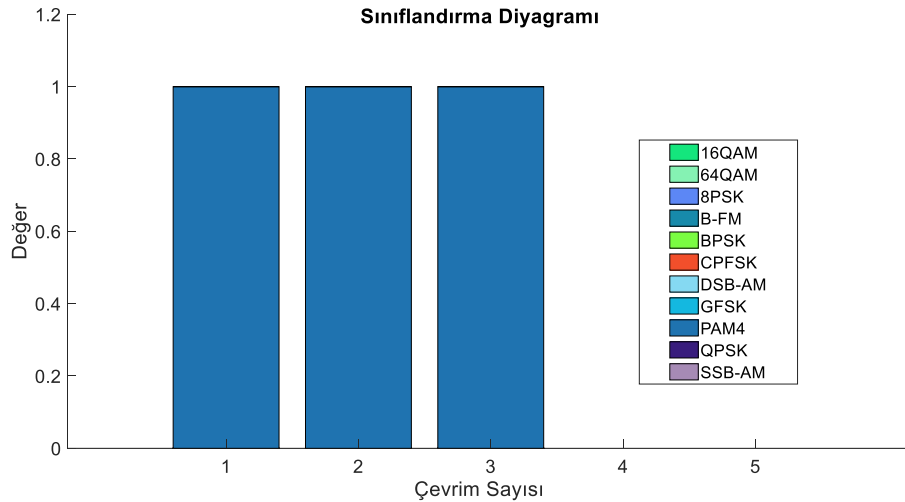
Şekil 7. Farklı modülasyon yöntemlerinin zaman düzlemi yanıtı.

30 dB SNR değeri için farklı modülasyon yöntemlerinin zaman alanı yanıtı genlik ve zaman ekseninde Şekil 7'de verilmiştir.



Şekil 8. Farklı modülasyon yöntemlerine ait güç spektral yoğunluğu.


Şekil 8, bu yazıda kullanılan modülasyon yöntemlerinin güç spektral yoğunluğunu normalize frekans ve dB cinsinden genlik eksenlerinde vermektedir.



Şekil 9. Farklı modülasyon yöntemlerinin sınıflandırma sonuçları  $f_s=200$  kHz ve çevrim başına örnek sayısı 512.

Çevrim başına 512 örnek için, farklı modülasyon yöntemlerinin sınıflandırma sonuçları  $f_s=200$  kHz Şekil 9'da gösterilmiştir. Bu makale, 6 konvolüsyon katmanından ve 1 tam bağlantı (FC) katmandan oluşan bir CNN sunmaktadır. Bir toplu normalleştirme (BN) katmanı, doğrusal birim (ReLU) etkinleştirme katmanını düzeltir ve her konvolüsyon katmanını bir maksimum havuzlama (pool) katmanı takip eder. Maksimum havuzlama katmanı, son konvolüsyon katmanındaki ortalama havuzlama katmanının yerini alır. Ardından, 256 mini batch size boyutuna sahip bir SGDM çözücü kullanmak için trainingOptions'ı yapılandırılır. Daha fazla çevrim sayısı daha fazla eğitim avantajı sağlamadığından, maksimum çevrim sayısını 12'ye ayarlanır. Varsayılan olarak, 'ExecutionEnvironment' özelliği 'auto' olarak ayarlanmıştır; burada trainNetwork işlevi, varsa bir GPU kullanır veya yoksa CPU kullanır. GPU'yu kullanmak için Parallel Computing Toolbox lisansına sahip olmanız gerekir. Bir NVIDIA Titan Xp GPU'da ağı eğitilmesi yaklaşık 25 dakika sürer. Test çerçeveleri için sınıflandırma

doğruluğunu elde ederek eğitilmiş ağ değerlendirilir. Sonuçlar, ağın bu dalga formu grubu için yaklaşık %98 doğruluk elde ettiğini göstermektedir [29-30].



Şekil 10. Öngörülen modülasyonun eğitim ilerleme diyagramı.

Şekil 10'da öngörülen modülasyonun eğitim ilerleme diyagramı gösterilmektedir. Yineleme doğruluğu %98.70, tahminde geçen süre sonu 14 saniye olarak elde edilmiştir.



**Test Verileri için Karışıklık Matrisi**

Gerçek Sınıf	16QAM	64QAM	8PSK	B-FM	BPSK	CPFSK	DSB-AM	GFSK	PAM4	QPSK	SSB-AM		
16QAM	42	8										84.0%	16.0%
64QAM	10	40										80.0%	20.0%
8PSK	2		46							2		92.0%	8.0%
B-FM				50								100.0%	
BPSK					50							100.0%	
CPFSK						50						100.0%	
DSB-AM							49				1	98.0%	2.0%
GFSK								50				100.0%	
PAM4									50			100.0%	
QPSK	1		1							48		96.0%	4.0%
SSB-AM											50	100.0%	

Tahmin Edilen Sınıf

**Şekil 11.** Test verileri için karışıklık matrisi: Tahmin edilen modülasyon sınıfı ve gerçek modülasyon sınıfı ilişkisi.

Karışıklık matrisi, alıcı işlem karakteristiği (Receiver Operating Characteristic-ROC) eğrisi çiziminin temelidir ve aynı zamanda tanıma modelinin doğruluğunu ölçmek için en temel, en sezgisel ve en basit yöntemdir. Doğruluk değerlendirmesi için standart bir formattır. Kappa katsayısı  $\kappa$  tutarlılık testi için kullanılır ve tanıma doğruluğunu ölçmek için de kullanılabilir. Aynı zamanda, karışıklık matrisine dayalı olarak kappa katsayısı hesaplanır ve Denklem 3 ile verilen şekilde ifade edilebilir.

$$\kappa = \frac{P_0 - P_e}{1 - p_e} \quad (3)$$

Denklem 3'te  $p_0$  gerçek tutarlılık oranını temsil eder ve  $p_e$  teorik tutarlılık oranını belirtir.

Test verileri için karışıklık matrisi: Tahmin edilen modülasyon sınıfı ve gerçek modülasyon sınıfı ilişkisi SNR oranı 30 dB için Şekil 11'de verilmiştir. Matrisin gösterdiği gibi, ağ 16-QAM ve 64-QAM çerçevelerini karıştırır. Her çerçeve yalnızca 128 sembol taşıdığından ve 16-QAM, 64-QAM'ın bir alt kümesi olduğundan bu sorun beklenmektedir. Ağ ayrıca QPSK ve 8-PSK çerçevelerini karıştırır, çünkü bu modülasyon türlerinin takımyıldızları, sönmüleme kanalı ve frekans kayması nedeniyle faz döndürüldüğünde benzer görünür.

Bu makale, uygulanabilir ve oldukça iyi çalışan radyo sinyali verilerinin zaman serileri üzerinde evrişimli ağların bir uygulamasını sunar. İlk olarak, çevrim başına 1024 örnek için, farklı modülasyon yöntemlerinin sınıflandırma sonuçları sırasıyla 200 Hz, 200 kHz ve 200 MHz için grafiklerle gösterilmektedir. Örneklem frekansı değiştiğinde sınıflandırma değerleri de farklı değerler almaktadır. Daha sonra kullanılan modülatörlerin zaman düzlemi alanı tepkileri Şekil 7 ile kullanılan modülatörlerin güç spektral yoğunluğu Şekil 8 ile verilmiştir. Ek olarak çevrim başına örnek sayısı 512 olması durumunda 200 kHz için farklı modülasyon yöntemlerinin sınıflandırma sonuçları Şekil 9'da verilmiştir. Şekil 9'da çevrim sayısı azaldığından, sınıflandırma sonuçları Şekil 4'e göre daha azalmıştır. Çalışmanın sonunda, sınıflandırma performansını test etmek için doğruluk ve kayıp eğrileri aracılığıyla eğitim ilerleme diyagramı elde edilir. Şekil 10'daki eğitim ilerleme diyagramı, eğitimin doğruluğu %98.70, tahminin geçen süresi 14 saniye olarak ölçülen modülasyon sınıflandırmasına yönelik güçlü ve muhtemelen son teknoloji bir doğruluk yaklaşımını temsil eder.

#### 4. Sonuçlar

DL yöntemleri, özellikle kısa süreli gözlemler için radyo sinyali tanıma duyarlılığının ve doğruluğunun iyileştirilmesi için etkili yöntemlerdir. CNN ağ mimarisi, performans geliştirme için etkili bir yöntemdir ve performans, daha büyük filtrelerden, farklı yapılardan ve havuzlama katmanlarından önemli ölçüde etkilenebilir, ancak bu çalışmada uygunluk tam olarak araştırılmamıştır. Bu sınıflandırma alanı, kablosuz sinyal işleme ve

bişsel radyo etki alanlarının son teknolojiden önemli ölçüde etkileneceği, onları daha çok makine öğrenimi ve veri güdümlü girişimlerle ilgilendireceği geniş bir araştırma ve uygulama dizisi için olgunlaşmıştır. Ayrıca, bu yaklaşım ek modülasyon sınıflarını kolayca ölçeklendirir ve radyo iletiminde sağlam ve düşük SNR sınıflandırmasına dayalı güçlü bir aday olarak kabul edilebilir. Bu sınıf sistemler için hala mevcut olan en doğru veri kümelerinin ve eğitim rejimlerinin nasıl öğrenileceği hakkında öğrenilecek çok şey olduğu gerçeği göz önüne alındığında, bu belgede, veri oluşturma ve eğitimde belirtilen performans ödünleşimleri, anlayışı geliştirir ve bu tür sistemleri optimize etmek için gelecekteki çabaları merkeze alır. Bu konuda, gerçekçi sistemlerin tasarımında hala çözülmesi gereken birçok açık soru olduğu görülmektedir. Gelecekte, pratik uygulamaları dikkate almak için örneğin OFDM sistemlerinde farklı alt taşıyıcılar için farklı modülasyon modları tespiti gerçekleştirilebilir.

## Kaynaklar

- [1] Timothy J. O, Pemula L, Batra D, Charles C. T. Radio transformer networks: Attention models for learning to synchronize in wireless systems. In Signals, Systems and Computers, 2016; IEEE 50th Asilomar Conference on; pp. 662-666.
- [2] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. CoRR, abs/1512.03385, 2015.
- [3] Goodfellow I, Bengio Y, and Courville A, Deep Learning. Cambridge, MA, USA: MIT Press, 2016.
- [4] Lowe D. G, Distinctive image features from scale-invariant keypoints, International Journal Computer Vision, vol. 60, no. 2, pp. 91–110, 2004.
- [5] Vidal-Naquet M, Ullman S. Object recognition with informative features and linear classification, in Proc. Int. Conf. Comput. Vis., 2003, vol. 3, pp. 281–288.
- [6] Imai S. Cepstral analysis synthesis on the mel frequency scale. Proc. IEEE Int. Conf. Acoust., Speech, Signal Process., 1983, vol. 8, pp. 93–96.
- [7] O'Shea T. J, Corgan J, Clancy T. C. Convolutional radio modulation recognition networks. Proc. Int. Conf. Eng. Appl. Neural Netw., 2016, pp. 213–226.
- [8] O'Shea T, Hoydis J. An introduction to deep learning for the physical layer. IEEE Trans. Cogn. Commun. Netw., vol. 3, no. 4, pp. 563–575, 2017.
- [9] Razavian A. S, Azizpour H, Sullivan J, Carlsson S. CNN features off-the-shelf: An astounding baseline for recognition. Proc. IEEE Conf. Comput. Vis. Pattern Recognit. Workshops, 2014, pp. 806–813.
- [10] O'Shea, T. J, Roy T, Clancy T. C. Over-the-Air Deep Learning Based Radio Signal Classification. IEEE Journal of Selected Topics in Signal Processing. Vol. 12, Number 1, 2018, pp. 168–179.
- [11] Chen T, Guestrin C. Xgboost: A scalable tree boosting system. Proc. 22nd ACM SIGKDD Int. Conf. Knowl. Discovery Data Mining, 2016, pp. 785–794.
- [12] Spooner, C. M, Mody A. N, Chuang J, Petersen J. Modulation recognition using second-and higher-order cyclostationarity. Proc. 2017 IEEE Int. Symp. Dyn. Spectr. Access Netw., 2017, pp. 1–3.
- [13] Abdelmutalab A, Assaleh K, El-Tarhuni M. Automatic modulation classification based on high order cumulants and hierarchical polynomial classifiers. Phys. Commun., vol. 21, pp. 10–18, 2016.
- [14] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. arXiv:1409.1556, 2014.
- [15] Gui G, et al. Flight delay prediction based on aviation big data and machine learning. IEEE Trans. Veh. Technol., vol. 69, no. 1, pp. 1065–1069, 2020.
- [16] Mao B, Fadlullah Z. Md, Tang F, Kato N, Akashi O, Inoue T, Mizutani K. Routing or computing? The paradigm shift towards intelligent computer network packet transmission based on deep learning. IEEE Trans. Comput., vol. 66, no. 11, pp. 1946–1960, Nov. 2017.
- [17] Tang F, Fadlullah Z. M, Mao B, Kato N. An intelligent traffic load prediction-based adaptive channel assignment algorithm in SDNIoT: A deep learning approach. IEEE Internet Things Journal, vol. 5, no. 6, pp. 5141–5154, 2018.
- [18] Gacanin H. Autonomous wireless systems with artificial intelligence: A knowledge management perspective. IEEE Veh. Technology Magazine, vol. 14, no. 1, pp. 51–59, 2019.
- [19] Sun J, Shi W, Han Z, Yang J, Gui G. Behavioral modeling and linearization of wideband RF power amplifiers using BiLSTM networks for 5G wireless systems. IEEE Trans. Veh. Technol., vol. 68, no. 11, pp. 10348–10356, 2019.
- [20] Gui G, Huang H, Song Y, Sari H. Deep learning for an effective nonorthogonal multiple access scheme. IEEE Trans. Veh. Technol., vol. 67, no. 9, pp. 8440–8450, 2018.
- [21] Huang H., et al. Deep learning for super-resolution channel estimation and DOA estimation based massive MIMO system. IEEE Trans. Veh. Technol., vol. 67, no. 9, pp. 8549–8560, Sept. 2018.
- [22] Huang H, Song Y, Yang J, Gui G. Deep-learning-based millimeterwave massive MIMO for hybrid precoding. IEEE Trans. Veh. Technol. vol. 68, no. 3, pp. 3027–3032, Mar. 2019.

- [23] Huang H. et al. Deep learning for physical-layer 5G wireless techniques: Opportunities, challenges and solutions. *IEEE Wirel. Commun.*, in press, doi: 10.1109/MWC.2019.1900027.
- [24] Huang H, Peng Y, Yang J, Xia W, Gui G. Fast beamforming design via deep learning. *IEEE Trans. Veh. Technol.*, vol. 69, no. 1, pp. 1065–1069, 2020.
- [25] Sun X, Gui G, Liu R, Li Y, An Y. ResInNet: A novel deep neural network with feature reuse for internet of things. *IEEE Internet of Things J.*, vol. 6, no. 1, pp. 679–691, 2019.
- [26] Sun X, Li Y, Gui G, Sari H. Echo-state restricted Boltzmann machines: A perspective on information compensation. *IEEE Access*, vol. 7, no. 1, pp. 16281–16290, 2019.
- [27] Xie W, Hu S, Yu C, Zhu P, Peng X, Ouyang J. Deep learning in digital modulation recognition using high order cumulants. *IEEE Access*, vol. 7, pp. 63760–63766, 2019.
- [28] Wang D., et al. Modulation format recognition and osnr estimation using cnn-based deep learning. *IEEE Photon. Technol. Lett.*, vol. 29, no. 19, pp. 1667–1670, 2017.
- [29] Wang Y, Liu M, Yang J, Gui G. Data-driven deep learning for automatic modulation recognition in cognitive radios. *IEEE Trans. Veh. Technol.*, vol. 68, no. 4, pp. 4074–4077, 2019.
- [30] Wang W. et al. LightAMC: Lightweight automatic modulation classification using deep learning and compressive sensing. *IEEE Trans. Veh. Technol.*, in press, doi: 10.1109/TVT.2020.2971001