

DERİN ÖĞRENME TABANLI MODÜLASYON TANIMA

Merih LEBLEBİCİ * 

Ali ÇALHAN † 

Murtaza CİCİOĞLU ** 

Alınma: 12.08.2022; düzeltme: 11.12.2022; kabul: 02.01.2023

Öz: Haberleşme teknolojilerinde her geçen gün artan sinyal çeşitliliği, bu sinyallerin tanımlanması ve sınıflandırılması gerekliliğini ortaya çıkarmıştır. Beşinci nesil (fifth generation, 5G) ve ötesi kablosuz haberleşme teknolojileri, birçok uygulama için vazgeçilmez iletişim araçları haline gelmiştir. Otomatik modülasyon tanıma (automatic modulation recognition, AMR) tekniği, özellikle yeni nesil nesnelerin interneti, akıllı şehirler, otonom araçlar ve bilişsel radyo gibi birçok uygulama için temel bileşen haline gelmiştir. Bu çalışmada sekiz farklı modülasyon türü kullanılarak bir veri seti oluşturulmuş ve derin öğrenme (deep learning, DL) algoritmalarından olan evrişimli sinir ağları (convolutional neural network, CNN) kullanılarak farklı sinyal-gürültü oranlarında (signal-to-noise ratio, SNR) modülasyon türü sınıflandırılması yapılmıştır. Sonuç olarak SNR değerleri 10 dB, 20 dB ve 30 dB iken CNN ile sınıflandırma işleminde sırasıyla %80,76, %99,89 ve %100 doğruluk sağlanmıştır.

Anahtar Kelimeler: Otomatik Modülasyon Tanıma, Evrişimli Sinir Ağları, Derin Öğrenme, 5G ve Ötesi Haberleşme Teknolojileri

Deep Learning Based Modulation Recognition

Abstract: The increasing signal diversity of communication technologies has revealed the need that these signals to be defined and classified. Fifth-generation (5G) and beyond wireless communication technologies have become indispensable communication tools for many applications. The automatic modulation recognition (AMR) technique has become a key component for many applications, especially the next-generation internet of things, smart cities, autonomous vehicles, and cognitive radio. In this study, a data set was created using eight different modulation types and modulation classification was made at different signal-to-noise ratios (SNR) using convolutional neural networks (CNN) from deep learning (DL) algorithms. As a result, while the SNR values were 10 dB, 20 dB, and 30 dB, CNN provided 80.76%, 99.89%, and 100% accuracy in the classification process, respectively.

Keywords: Automatic Modulation Recognition, Convolutional Neural Networks, Deep Learning, 5G and Beyond Communication Technologies

1. GİRİŞ

Modülasyon tanıma, alınan sinyalin bazı özelliklerine bakarak modülasyon türüne karar verme işlemidir. Bu işlem haberleşme ağlarında sinyal algılama işlemi ile demodülasyon işlemi arasında gerçekleştirilmektedir. Otomatik modülasyon tanıma (automatic modulation recognition, AMR), özellikle askeri ve güvenlik sektörlerindeki birçok uygulamada önemli bir rol oynamaktadır (Ansari ve diğ., 2022). Ayrıca yazılım tanımlı radyo, frekans yönetimi, bilişsel radyo ve ağ trafiği düzenleme gibi konularda da AMR işleminden faydalanılmaktadır.

* Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi, Düzce Üniversitesi, Düzce, Türkiye, 81620

† Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Düzce Üniversitesi, Düzce, Türkiye, 81620

** Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Bursa Uludağ Üniversitesi, Bursa, Türkiye, 16059

İletişim Yazarı: Merih Leblebici (merihleblebici@duzce.edu.tr)

Beşinci nesil (fifth generation, 5G) ve ötesi kablosuz haberleşme teknolojileriyle beraber yüksek taşıyıcı frekansları kullanılmaya başlanmakta ve yeni kablosuz uygulamalar ortaya çıktıkça da kullanılan frekans çeşitliliği artmaktadır. Bu durumda kablosuz ortamlarda farklı sinyallerin tanımlanması problemi ortaya çıkmaktadır. Otomatik modülasyon tanıma, sinyal işleme için gerekli olan modülasyon türünü ön bir bilgiye ihtiyaç duymadan algılamak ve bu tür bilgilerin eksik olduğu durumlarda çok önemli bir işlevi yerine getirmektedir (Zhang ve diğ., 2022). Haberleşme esnasında, verici tarafından üretilen sinyaller gürültü, çok yollu sönmüleme, gölge sönmülemesi, merkez frekans kayması ve örnekleme hızı kayması gibi olumsuz faktörlere maruz kalmaktadır (O'Shea ve diğ., 2016). Bozulan bu sinyallerin alıcıda tanımlanması için otomatik modülasyon tanıma işlemi devreye girmektedir. Literatürde AMR için çeşitli yöntemler önerilmektedir. Son yıllarda bu çözümlerin en etkili derin öğrenme (deep learning, DL) tabanlı modülasyon sınıflandırma işlemidir.


AMR işlemi, olasılık teorisine dayalı ve özellik tabanlı olmak üzere iki ana başlık altında ele alınmaktadır (Dulek, 2017) (Wang ve diğ., 2020). Olasılık teorisine dayalı AMR, genellikle Bayes kuralına göre yapılmakta ve yüksek hesaplama karmaşıklığına sahiptir. Özellik tabanlı AMR ise temel olarak eğitim örneklerinden temsili özellikleri öğrenip eğitilmiş modelleri kullanarak gelen sinyalleri sınıflandırmaktadır. Makine öğrenmesi ve derin öğrenme algoritmaları da son yıllarda AMR işleminde kullanılmaktadır. Makine öğrenmesi, insanların öğrenme şeklini taklit etmek için veriyle algoritmaları kullanan ve doğruluğunu aşamalı olarak artıran bir yapay zeka dalıdır. Derin öğrenme ise, temelde üç veya daha fazla katmana sahip bir sinir ağı olan makine öğreniminin bir alt dalıdır. Geleneksel yöntemlere göre derin öğrenme ile doğal dil işleme ve görüntü işleme gibi alanlarda son derece iyi sonuçlar elde edilmektedir. Çok katmanlı yapay sinir ağları ve güçlü özellik çıkarma özelliği sayesinde derin öğrenme, modülasyon tanıma işleminde de yüksek doğrulukta sonuçlar vermektedir.

Literatürdeki modülasyon tanıma üzerine yapılan güncel çalışmalar incelendiğinde çeşitli modülasyon türleri için hazırlanan veri setlerinde makine öğrenmesi ve derin öğrenme algoritmalarının uygulandığı görülmektedir. Wang ve diğ. (2019) derin öğrenme (DL) tabanlı bir AMR yöntemi önermişlerdir. Bu yöntemde doğruluk oranını artırmak için farklı veri setlerinde eğitilmiş iki adet evrişimli sinir ağı (convolutional neural network, CNN) kullanılmıştır. Zeng ve diğ. (2019) ise çalışmalarında radyo sinyallerinden kısa zamanlı Fourier dönüşümü (short time Fourier transform, STFT) yardımıyla spektrogram görüntüleri elde etmişlerdir. Sonrasında bu görüntüler radyo sinyallerinin tespiti için CNN tabanlı bir modülasyon tanımlama yönteminde kullanılmıştır. Zhang ve diğ. (2022) literatürdeki derin öğrenme tabanlı modülasyon tanıma çalışmaları ve bu konudaki veri setleri üzerine bir inceleme çalışması yapmışlardır. Zhou ve diğ. (2020) ise çalışmasında kablosuz sinyallerin tanımlanıp sınıflandırılmasında son zamanlarda en çok kullanılan DL teknikleri üzerinde durmuşlardır. Bunu yaparken ilgili tekniklerin avantaj ve dezavantajları vurgulanıp gelecekte karşılaşılabilecek zorluklar hakkında bilgi verilmiştir. Aynı zamanda çeşitli yazılım tabanlı cihazlar kullanılarak gerçek zamanlı bir simülasyon ile CNN modelinin kablosuz sinyalleri tanımlama ve sınıflandırma performansı gösterilmiştir. Shi ve diğ. (2022a) RadioML2018.01A veri seti üzerinde çalışmışlar ve CNN kullanmışlardır. Lin ve diğ. (2022) CNN tabanlı otomatik modülasyon tanıma işlemi için bir zaman-frekans dikkat (time-frequency attention, TFA) mekanizması önermişlerdir. Çalışmalarında RadioML2016.10A ve RadioML2016.10B setlerini kullanmışlardır. Shi ve diğ. (2022b) DeepSig ve Hisarmod veri setleri üzerinde karmaşıklığı düşük bir ağ tasarlamışlardır. Son yıllardaki derin öğrenme tabanlı modülasyon tanıma çalışmalarının başlıca olanları bu şekilde özetlenebilir.

Bu çalışmamızda, yapılan çalışmalardan farklı olarak Şekil 1'de görülen 8 adet modülasyon türünü içeren sentetik (kendi ürettiğimiz) bir veri seti kullanılmıştır. Bu modülasyon türleri, dördün genlik modülasyonu (quadrature amplitude modulation, QAM) ailesinden 4-QAM, 16-QAM, 64-QAM ve 256-QAM ile faz kaydırmalı anahtarlama (phase shift keying, PSK) ailesinden ikili PSK (binary PSK, BPSK), 8-PSK, 16-PSK ve 32-PSK'yı içermektedir. Veri

setinin derin öğrenme ile analizi gerçekleştirilmiş ve modülasyon tanıma işlemi yapılmıştır. Yine literatürden farklı olarak düşük, orta ve yüksek sinyal-gürültü oranı (signal-to-noise ratio, SNR) değerlerinde derin öğrenme algoritması çalıştırılmıştır. SNR değeri olarak 10 dB, 20 dB ve 30 dB ele alınmış ve başarımlar analizleri gerçekleştirilmiştir.

Çalışmanın diğer kısımlarında ise veri seti ve bileşenleri incelenmiştir. Ardından evrişimli sinir ağları ile oluşturulan ağ yapısı açıklanmıştır. Son olarak da başarımlar analizinin sonuçları verilmiştir.



Şekil 1:
Veri setimizdeki modülasyon türleri

2. VERİ SETİ VE BİLEŞENLERİ

Her modülasyon türü için 10000 adet .mat dosyası olmak üzere toplam 80000 adet .mat dosyası CNN yapısında işleme sokulmuştur. Bu işlemde veri seti, %80'i eğitim, %10'u doğrulama ve %10'u test verisi olmak üzere ayrılmıştır. Benzetim MATLAB 2022a programında gerçekleştirilmiştir.


Veri setinin oluşturulması için öncelikle ilgili yıldız diyagramına ait sembol dizileri üretilmiş, ardından modüle edilen sembol dizileri tek taşıyıcılı olacak şekilde toplamsal beyaz Gauss gürültüsü (additive white Gaussian noise, AWGN) kanaldan geçirilmiştir. Son olarak veriler, eş fazlı (in-phase, I) ve dördün (quadrature, Q) bileşenler olacak şekilde .mat dosyalarına kaydedilmiştir. AWGN kanaldan geçirilen verilere tasarlanan algoritma ile modülasyon tanıma işlemi uygulanmıştır. Şekil 2'de I/Q yapısı ve veri setindeki I/Q bileşenleri örneği verilmiştir.

Veri setimizi oluştururken her modülasyon türüne ait .mat dosyaları, Şekil 2'de gösterildiği gibi I/Q bileşenleri karmaşık sayılar olacak şekilde kaydedilmiştir. Her sinyal için 1024 adet

örnek alınmıştır ve mat dosyasında bulunan alanlardan, çerçeve (frame) alanında 1024x1 boyutunda matris şeklinde I/Q bileşenleri ile etiket (label) alanında modülasyon türü bilgisi tutulmaktadır.


3. EVRİŞİMLİ SİNİR AĞLARI İLE OLUŞTURULAN AĞ YAPISI

CNN, piksel verilerini işlemek için özel olarak tasarlanmış, görüntü tanıma ve işlemede kullanılan bir tür yapay sinir ağıdır. Bir CNN yapısı, bir giriş katmanı, bir çıkış katmanı ile çoklu evrişim katmanlarını, havuz katmanlarını, tam bağlantılı katmanları ve normalleştirme katmanlarını içeren bir gizli katmandan oluşmaktadır. Evrişim katmanında girdi ile bir dizi ağır-



Şekil 2:
I/Q yapısı ve veri setimizdeki I/Q bileşenleri

lığın çarpılmasını içeren doğrusal bir işlem olan evrişim gerçekleşmektedir. İki boyutlu girdi için düşünüldüğünde, çarpma işlemi bir dizi girdi verisi ile filtre veya çekirdek adı verilen iki boyutlu ağırlık dizisi arasında gerçekleştirilmektedir. Şekil 3'te örnek bir CNN yapısı gösterilmektedir.




Şekil 3:
Evrişimli sinir ağı bileşenleri

Çalışmamızda kullanılan CNN modeli, giriş olarak her sinyale ait 1024 örneği I/Q bileşenler şeklinde almaktadır. Şekil 3'te belirtilen katmanlardan geçtikten sonra her frame için

modülasyon türü tahmin edilmektedir. Kullanılan CNN modeli, 6 adet evrişim katmanından (convolutional layer, CL) ve 1 adet tamamen bağlı katmandan (fully connected layer, FCL) oluşmaktadır. Sonuncu evrişim katmanı hariç her evrişim katmanı 1 adet toplu normalleştirme katmanı (batch normalization layer, BNL), 1 adet düzeltilmiş doğrusal birim (rectified linear unit, ReLU), 1 adet etkinleştirme katmanı (activation layer, AL) ve 1 adet maksimum havuzlama katmanı (max pooling layer, MPL) sırasıyla yerleştirilmiştir. Sondaki evrişim katmanında, MPL yerine ortalama havuzlama katmanı (average pooling layer, APL) bulunmaktadır. Çıkış katmanı (output layer, OL), softmax aktivasyonuna (softmax activation, SMA) sahiptir. Şekil 4'te tasarlanan CNN yapısı gösterilirken Tablo 1'de tasarlanan CNN yapısındaki katmanlar ve temel özellikleri verilmiştir.

4. MODÜLASYON TANIMA İŞLEMİNDE EVRİŞİMLİ SİNİR AĞININ BAŞARIM ANALİZİ

SNR değeri haberleşme kanalının iletim kalitesini belirleyen en önemli parametredir. İletim ortamındaki gürültü arttıkça SNR değeri düşecek ve iletilen sinyalin şeklinde bozulmalar olacaktır. Yüksek SNR değerlerinde sinyal kalitesindeki azalma fazla olmayacağından iletilen sinyaller alıcıda hatasız ya da en az hata ile geri elde edilecektir. Bu durumda modülasyon tanıma işlemi için sinyal özelliklerine bakıldığında modülasyon sınıflandırması kolaylaşacaktır.



Şekil 4:
Tasarlanan CNN yapısı

Tablo 1. Tasarlanan CNN yapısındaki katmanlar ve özellikleri


Sıra No	Katman İsimleri	Özellikleri	Sıra No	Katman İsimleri	Özellikleri
1	Giriş Katmanı	1x1024x2	8	Evrişim Katmanı 4	FilterSize:1x8, NumFilters:48
2	Evrişim Katmanı-1	FilterSize:1x8, NumFilters:16	9	Maksimum Havuzlama Katmanı-4	PoolSize:1x2, Stride:1x2
3	Maksimum Havuzlama Katmanı-1	PoolSize:1x2, Stride:1x2	10	Evrişim Katmanı-5	FilterSize:1x8, NumFilters:64
4	Evrişim Katmanı-2	FilterSize:1x8, NumFilters:24	11	Maksimum Havuzlama Katmanı-5	PoolSize:1x2, Stride:1x2
5	Maksimum Havuzlama Katmanı-2	PoolSize:1x2, Stride:1x2	12	Evrişim Katmanı-6	FilterSize:1x8, NumFilters:96
6	Evrişim Katmanı-3	FilterSize:1x8, NumFilters:32	13	Ortalama Havuzlama Katmanı	PoolSize:1x32, Stride:1x1
7	Maksimum Havuzlama Katmanı-3	PoolSize:1x2, Stride:1x2	14	Tamamen Bağlı Katman	OutputSize:8

Tasarladığımız evrişimli sinir ağının başarımını incelemek için çeşitli SNR değerlerinde oluşturulmuş veriler kullanılmıştır. Genel olarak, veri ağları için 20 dB ve üzeri SNR değerleri önerilirken ses uygulamaları kullanan ağlar için 25 dB ve üzeri SNR değerleri önerilmektedir (Hu ve diğ., 2021). Bu nedenle veri setleri oluşturulurken SNR değerleri 10 dB, 20 dB ve 30 dB olarak alınmış ve sırasıyla Şekil 5, Şekil 6 ve Şekil 7’de doğrulama sonuçları ve karışıklık (confusion) matrisleri gösterilmiştir.


Şekil 5’te SNR değeri 10 dB alındığında elde edilen sonuçlar gösterilmiştir. Bu SNR değeri kablosuz ortam için düşük bir değer olduğundan dolayı sinyaller oldukça bozulmuş bir şekilde alınmıştır. Tasarlanan CNN yapısı bu durumdaki modülasyon türü sınıflandırmasını %80,76 doğruluk oranında yapmıştır. Ayrıca karışıklık matrisi yardımıyla yapılan sınıflandırmada hangi modülasyon türlerinin birbiriyle karıştırıldığı görülebilir.

Şekil 6’daki sonuçlar SNR değerinin 20 dB olduğu durumda elde edilmiştir. Önceki duruma göre SNR değeri iki kat artırıldığı için alınan sinyaller daha az bozulmaya uğramıştır. Sonuç olarak CNN yapısı modülasyon türü sınıflandırmasını %99,89 doğruluk oranında yapmıştır. Karışıklık matrisinde belirtildiği üzere SNR değeriyle beraber ortalama doğruluk oranı artmış olmasına rağmen az da olsa yüksek dereceli QAM modülasyon türleri tam doğrulukta sınıflandırılmamıştır.

Şekil 7’deki 30 dB’lik SNR değerinde CNN yapısı modülasyon türü sınıflandırmasını %100 doğruluk oranında gerçekleştirmiştir. Şekil 6’daki karışıklık matrisinde bulunan küçük sınıflandırma hatalarının bu SNR değerinde tamamen ortadan kalktığı görülmektedir.




a.




b.

Şekil 5:

a. SNR=10 dB için doğrulama sonuçları b. SNR=10 dB için karışıklık matrisi




a.




b.

Şekil 6:

a. SNR=20 dB için doğrulama sonuçları b. SNR=20 dB için karışıklık matrisi




a.




b.

Şekil 7:


a. SNR=30 dB için doğrulama sonuçları b. SNR=30 dB için karışıklık matrisi



a.



b.




c.


Şekil 8:
a. SNR=10 dB, CL=3 b. SNR=10 dB, CL=4 c. SNR=10 dB, CL=5



a.




b.




c.

Şekil 9:


a. SNR=20 dB, CL=3 b. SNR=20 dB, CL=4 c. SNR=20 dB, CL=5



a.



b.



c.

Şekil 10:

a. SNR=30 dB, CL=3 b. SNR=30 dB, CL=4 c. SNR=30 dB, CL=5

16-PSK						%100	
16-QAM						%100	
256-QAM						%100	
BPSK			%100				
32-PSK						%100	
4-QAM						%100	
64-QAM						%100	
8-PSK						%100	
	16-PSK	16-QAM	256-QAM	BPSK	32-PSK	4-QAM	64-QAM

Tahmin Edilen Sınıf

a.

16-PSK	%69,5				%22,2		%8,3
16-QAM		%98,3					%1,7
256-QAM		%0,3	%73,8				%25,9
BPSK				%100			
32-PSK	%69,8				%20,8		%9,4
4-QAM					%100		
64-QAM		%62,3	%42,9				%54,8
8-PSK	%5,0				%1,3		%93,7
	16-PSK	16-QAM	256-QAM	BPSK	32-PSK	4-QAM	64-QAM

Tahmin Edilen Sınıf

b.

16-PSK	%87,8				%10,7		%1,5
16-QAM		%98,7					%1,3
256-QAM		%0,1	%65,7				%34,2
BPSK				%100			
32-PSK	%80,2				%18,1		%1,7
4-QAM					%100		
64-QAM		%63,3	%33,1				%63,6
8-PSK	%1,4						%98,6
	16-PSK	16-QAM	256-QAM	BPSK	32-PSK	4-QAM	64-QAM

Tahmin Edilen Sınıf

c.

Şekil 11:

a. SNR=10 dB, CL=3 b. SNR=10 dB, CL=4 c. SNR=10 dB, CL=5

16-PSK			%98,9					%1,1
16-QAM			%99,6					%0,4
256-QAM			%99,4					%0,6
BPSK				%100				
32-PSK			%98,4					%1,6
4-QAM			%100					
64-QAM			%99,7					%0,3
8-PSK			%99,1					%0,9
	16-PSK	16-QAM	256-QAM	BPSK	32-PSK	4-QAM	64-QAM	8-PSK

Tahmin Edilen Sınıf

a.

16-PSK	%100							
16-QAM		%100						
256-QAM			%92,9				%7,1	
BPSK				%100				
32-PSK	%0,2				%99,8			
4-QAM						%100		
64-QAM		%0,2	%2,1				%97,7	
8-PSK								%100
	16-PSK	16-QAM	256-QAM	BPSK	32-PSK	4-QAM	64-QAM	8-PSK

Tahmin Edilen Sınıf

b.

16-PSK	%100							
16-QAM		%100						
256-QAM			%99,9				%0,1	
BPSK				%100				
32-PSK					%100			
4-QAM						%100		
64-QAM							%100	
8-PSK								%100
	16-PSK	16-QAM	256-QAM	BPSK	32-PSK	4-QAM	64-QAM	8-PSK

Tahmin Edilen Sınıf

c.

Şekil 12:

a. SNR=20 dB, CL=3 b. SNR=20 dB, CL=4 c. SNR=20 dB, CL=5

16-PSK	%82,8				%13,9			%3,3
16-QAM		%93,3			%0,2		%6,5	
256-QAM		%4,4	%1,4				%94,2	
BPSK				%100				
32-PSK	%68,0	%1,3			%29,3			%1,4
4-QAM						%100		
64-QAM		%6,4	%1,0				%92,6	
8-PSK	%0,1					%1,2		%98,7
	16-PSK	16-QAM	256-QAM	BPSK	32-PSK	4-QAM	64-QAM	8-PSK

Tahmin Edilen Sınıf

a.

16-PSK	%100							
16-QAM		%100						
256-QAM			%99,6				%0,4	
BPSK				%100				
32-PSK					%100			
4-QAM						%100		
64-QAM			%0,4				%99,6	
8-PSK								%100
	16-PSK	16-QAM	256-QAM	BPSK	32-PSK	4-QAM	64-QAM	8-PSK

Tahmin Edilen Sınıf

b.

16-PSK	%100							
16-QAM		%100						
256-QAM			%100					
BPSK				%100				
32-PSK					%100			
4-QAM						%100		
64-QAM							%100	
8-PSK								%100
	16-PSK	16-QAM	256-QAM	BPSK	32-PSK	4-QAM	64-QAM	8-PSK

Tahmin Edilen Sınıf

c.

Şekil 13:

a. SNR=30 dB, CL=3 b. SNR=30 dB, CL=4 c. SNR=30 dB, CL=5

Şekil 8, Şekil 9 ve Şekil 10’da sırasıyla 10 dB, 20 dB ve 30 dB SNR değerleri için modülasyon tanımlama işleminin doğruluk oranları verilmiştir. Her bir şekilde ayrıca CNN yapısındaki CL sayısının 3, 4 ve 5 olma durumlarında doğruluk oranı üzerindeki etkisi gösterilmeye çalışılmıştır. Genel olarak CL sayısı artıkça doğruluk oranının yükseldiği görülmüştür. 10 dB SNR değeri için hedeflediğimiz %80 ve üzerindeki doğruluk oranı CL sayısı 6 olarak ayarlandığında elde edilmiştir.

Şekil 11, Şekil 12 ve Şekil 13’te ise SNR değerleri ile CL sayısı değişimlerinin karışıklık matrisleri üzerindeki etkisi gösterilmiştir. Haberleşme için oldukça iyi bir SNR değeri olan 30 dB için karışıklık matrislerine bakılacak olursa CL sayısının 3 olduğu durumda sınıflandırma işleminin sağlıklı bir şekilde yapılamadığı görülebilir.

Tablo 2. Farklı SNR ve CL değerleri için doğruluk oranının değişimi

	SNR=10 dB	SNR=20 dB	SNR=30 dB
CL=3	%25	%25,04	%74,76
CL=4	%76,36	%98,80	%99,90
CL=5	%79,06	%99,99	%100
CL=6 (tasarlanan)	%80,76	%99,89	%100

Son olarak Tablo 2’de tüm SNR ve CL değerleri için doğruluk oranlarının değişimi verilmiştir.

5. SONUÇ

Yeni nesil haberleşme sistemlerinin hayatımızda yer almaya hızla devam etmesi haberleşme sistemlerinde kullanılan sinyal çeşitliliğini artırmaktadır. Çalışmamızda çeşitli modülasyon türleriyle modüle edilmiş sinyallerin sınıflandırılması amaçlanmıştır. Farklı SNR değerlerinde sentetik (kendi ürettiğimiz) veri seti üzerinde derin öğrenme tabanlı modülasyon tanımlama işlemi gerçekleştirilmiş ve günümüz uygulamaları için yüksek doğruluk elde edilmiştir. Ayrıca 10 dB SNR değerinde hedeflenen doğruluk oranını yakalamak için tasarlanan CNN yapısı diğer CNN yapıları ile karşılaştırılıp karışıklık matrisleri verilmiştir. Gelecek çalışmalarımızda farklı modülasyon tekniklerinin de içinde olacağı yeni veri setleri oluşturulacak ve özellikle düşük ve orta seviyedeki SNR değerleri için yüksek doğrulukta sınıflandırma yapılması amaçlanacaktır.

ÇIKAR ÇATIŞMASI

Yazarlar, bilinen herhangi bir çıkar çatışması veya herhangi bir kurum/kuruluş ya da kişi ile ortak çıkar bulunmadığını onaylamaktadırlar.

YAZAR KATKISI

Merih Leblebici, Ali Çalhan ve Murtaza Cicioğlu çalışmanın kavramsal ve tasarım süreçlerinin belirlenmesi ve yönetimi, veri toplama, veri analizi ve yorumlama, makale taslağının oluşturulması, fikirsel içeriğin eleştirel incelenmesi, son onay ve tam sorumluluk alanlarına katkı sağlamışlardır.

KAYNAKLAR

1. Ansari, S., Alnajjar, K. A., Saad, M., Abdallah, S. ve El-Moursy, A. A. (2022) Automatic Digital Modulation Recognition Based on Genetic-Algorithm-Optimized Machine Learning Models, *IEEE Access*, 10, 50265–50277. doi:10.1109/ACCESS.2022.3171909
2. Dulek, B. (2017) Online Hybrid Likelihood Based Modulation Classification Using Multiple Sensors, *IEEE Transactions on Wireless Communications*, 16(8), 4984–5000. doi:10.1109/TWC.2017.2704124
3. Hu, L., Jiang, H., Lu, R. ve Liu, C. (2021) Signal Classification in Real-time Based on SDR using Convolutional Neural Network, *Proceedings of 2021 IEEE 2nd International Conference on Information Technology, Big Data and Artificial Intelligence, ICIBA2021*, (Iciba), 893–898. doi:10.1109/ICIBA52610.2021.9687958
4. Lin, S., Zeng, Y., ve Gong, Y. (2022) Learning of Time-Frequency Attention Mechanism for Automatic Modulation Recognition, *IEEE Wireless Communications Letters*, 11(4), 707–711. doi:10.1109/LWC.2022.3140828
5. O'Shea T. J., Corgan, J., ve Clancy, T. C. (2016) Convolutional radio modulation recognition networks, *Communications in Computer and Information Science*, 629, 213–216. doi:10.1007/978-3-319-44188-7_16
6. Shi F. Y., Hu, Z. M., Yue, C. S. ve Chen, Z. C. (2022a) Combining neural networks for modulation recognition, *Digital Signal Processing*, 120, 103264. doi:10.1016/J.DSP.2021.103264
7. Shi F. Y., Yue, C. S. ve Han, C. (2022b) A lightweight and efficient neural network for modulation recognition, *Digital Signal Processing*, 123, 103444. doi:10.1016/J.DSP.2022.103444
8. Wang, Y., Liu, M., Yang, J. ve Gui, G. (2019) Data-Driven Deep Learning for Automatic Modulation Recognition in Cognitive Radios, *IEEE Transactions on Vehicular Technology*, 68(4), 4074–4077. doi:10.1109/TVT.2019.2900460
9. Wang, Y., Gui, J., Yin, Y., Wang, J., Sun, J., Gui, G., Gacanin, H., Sari, H. ve Adachi, F. (2020) Automatic Modulation Classification for MIMO Systems via Deep Learning and Zero-Forcing Equalization, *IEEE Transactions on Vehicular Technology*, 69(5), 5688–5692. doi:10.1109/TVT.2020.2981995
10. Zeng, Y., Zhang, M., Han, F., Gong, Y. ve Zhang, J. (2019) Spectrum Analysis and Convolutional Neural Network for Automatic Modulation Recognition, *IEEE Wireless Communications Letters*, 8(3), 929–932. doi:10.1109/LWC.2019.2900247
11. Zhang, F., Luo, C., Xu, J., Luo, Y. ve Zheng, F. (2022) Deep learning based automatic modulation recognition: Models, datasets, and challenges, *Digital Signal Processing*, 129, 103650. doi:10.1016/J.DSP.2022.103650
12. Zhou, R., Liu, F. ve Gravelle, C. W. (2020) Deep Learning for Modulation Recognition: A Survey with a Demonstration *IEEE Access*, 8, 67366–67376. doi:10.1109/ACCESS.2020.2986330

