



**T.C. İSTANBUL T CARET
 NİVERSİTESİ**

FEN B LİMLERİ ENSTİT S 

**SAYISAL MOD LASYONLU İ ARETLERİN RADYOMETRE VE
DERİN   RENME Y NTEMLERİ İLE TESPİTİ VE BA ARIMI**

Gamze K RMAN TOKG Z

**Dan şman
Do . Dr. Serhan YARKAN**

**Y KSEK LİSANS TEZİ
ELEKTRONİK VE HABERLE ME M HENDİSLİ İ ANABİLİM DALI
İSTANBUL - 2020**

KABUL VE ONAY SAYFASI

Gamze KİRMAN TOKGÖZ tarafından hazırlanan "**Sayısal Modülasyonlu İşaretlerin Radyometre Ve Derin Öğrenme Yöntemleri İle Tespiti Ve Başarımı**" adlı tez çalışması 17.07.2020 tarihinde aşağıdaki jüri üyeleri önünde başarı ile savunularak, İstanbul Ticaret Üniversitesi Fen Bilimleri Enstitüsü **Elektronik ve Haberleşme Mühendisliği Anabilim Dalı'nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman **Doç. Dr. Serhan YARKAN**
İstanbul Ticaret Üniversitesi

Jüri Üyesi **Dr. Öğr. Üyesi Ali BOYACI**
İstanbul Ticaret Üniversitesi

Jüri Üyesi **Dr. Öğr. Üyesi Ali Rıza EKTİ**
Balıkesir Üniversitesi

Onay Tarihi : 24.07.2020

İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsünün 24.07.2020 tarih ve 2020/288 numaralı Yönetim Kurulu Kararının 1. maddesi gereğince, ders yüklerini ve tez yükümlülüğünü yerine getirdiği belirlenen "Gamze KİRMAN TOKGÖZ" (TC: 31108847990) adlı öğrencinin mezun olmasına oy birliği ile karar verilmiştir.

Prof. Dr. Necip ŞİMŞEK
Enstitü Müdürü

AKADEMİK VE ETİK KURALLARA UYGUNLUK BEYANI

İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada,

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversitede veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

24.07.2020

Gamze KİRMAN TOKGÖZ



İÇİNDEKİLER

	Sayfa
İÇİNDEKİLER.....	i
ÖZET	ii
ABSTRACT	iii
TEŞEKKÜR.....	iv
ŞEKİLLER.....	v
ÇİZELGELER.....	vi
SİMGELER VE KISALTMALAR.....	vii
1. GİRİŞ.....	1
2. LİTERATÜR ÖZETİ.....	6
3. SPEKTRUM SEZİMİ.....	12
3.1. Spektrum Sezim Teknikleri.....	13
4. GELENEKSEL YÖNTEMLER	14
4.1. Enerji Sezici	14
4.2. Uyumlu Filtreleme.....	16
4.3. Çevrimsel Durağan Sinyal Analizi.....	17
5. YAPAY ZEKA YÖNTEMLERİ	19
5.1. Makine Öğrenmesi.....	20
5.1.1. Denetimli öğrenme.....	20
5.1.2. Yarı denetimli öğrenme	21
5.1.3. Denetimsiz öğrenme.....	21
5.1.4. Takviyeli öğrenme	22
5.2. Derin Öğrenme.....	22
5.2.1. Evrişimsel sinir ağları (CNN).....	22
5.2.1.1. Evrişimsel sinir ağı katmanları.....	23
5.2.1.1.1. Evrişim katmanı (Convolutional layer).....	24
5.2.1.1.2. Havuzlama katmanı (Pooling layer)	24
5.2.1.1.3. Seyreltme katmanı (Dropout layer)	25
5.2.1.1.4. Düzleme katmanı (Flatten layer).....	26
5.2.1.1.5. Yoğun katman (Fully connected layer)	26
5.2.1.1.6. Aktivasyon fonksiyonları (Activation functions).....	27
5.2.2. Derin sinir ağları için bilgi işlem kütüphanesi (CLDNN) mimarisi ...	27
5.2.3. LSTM mimarisi	27
5.2.4. ResNet mimarisi	29
6. SİSTEM MODELİ	30
6.1. Spektrum Seziminde Derin Öğrenme Metotlarının Karşılaştırılması	30
6.1.1. Test sonuçları	35
6.2. Spektrum Seziminde Enerji Sezici ve Evrişimsel Sinir Ağının (CNN) Karşılaştırılması	37
6.2.1. Test sonuçları	40
6.3. Enerji Sezici ve CNN'in Gerçek Veriler Kullanılarak Karşılaştırılması	43
7. SONUÇ VE ÖNERİLER.....	48
KAYNAKLAR	49
ÖZGEÇMİŞ.....	53

ÖZET

Yüksek Lisans Tezi

SAYISAL MODÜLASYONLU İŞARETLERİN RADYOMETRE VE DERİN ÖĞRENME YÖNTEMLERİ İLE TESPİTİ VE BAŞARIMI

Gamze KİRMAN TOKGÖZ

İstanbul Ticaret Üniversitesi
Fen Bilimleri Enstitüsü
Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Serhan YARKAN

2020, 54 sayfa

Yeni nesil kablosuz iletişim hizmetlerinin ve uygulamalarının hızla büyümesi nedeniyle, frekans spektrumu kaynaklarına çok dikkat edilmiştir. Sınırlı radyo spektrumu göz önüne alındığında, daha yüksek kapasite ve daha yüksek veri hızları için talebi desteklemek, mevcut radyo spektrumundan yararlanmanın yeni yollarını sunabilecek yenilikçi teknolojiler gerektiren zorlu bir görevdir.

Bilişsel radyoların spektral boşlukları tanımlamasını sağlayan spektrum algılama konsepti, yeni nesil kablosuz iletişim teknolojileri ve sistemlerinde kritik bir rol oynamaktadır. Ayrıca, spektrum algılama ve dinamik spektrum erişimi ile radyo spektrumu kullanımının verimliliğini artırmak, ortaya çıkan trendlerden biridir.

Bu çalışmada, sayısal modülasyonlu işaretler için derin öğrenme algoritmalarından olan CNN, CLDNN, LSTM ve ResNet mimarileri arasında spektrum sezimi verimliliği karşılaştırılması yapıldıktan sonra en iyi sonucu veren performansı gösteren algoritmanın CNN olduğu sonuçlar çerçevesinde gösterilmiştir. Daha sonra, düşük maliyeti ve düşük karmaşıklık seviyesinden dolayı spektrum sezimi uygulamaları için hâlihazırda en çok kullanılan geleneksel enerji sezici yöntemi, en iyi performansı gösteren derin öğrenme CNN yöntemi ile verimlilik analizi yapılarak karşılaştırılmıştır.

Önerilen CNN mimarisinin, geleneksel enerji dedektörü yönteminden daha iyi algılama performansı sağladığı sonuçlar ışığında gösterilmiştir. Sonuç olarak, bu tezdeki araştırmalar, gürültü belirsizliğinin zorluğunu aşmak için CNN tabanlı spektrum algılama tekniklerinin geleneksel enerji sezici tekniği ile karşılaştırılmasını sunmaktadır.

Anahtar Kelimeler: Artık ağ mimarisi (ResNet), bilgi işlem kütüphanesi (CLDNN), enerji sezici, evrimsel sinir ağı (CNN), spektrum sezimi, uzun-kısa süreli bellek (LSTM).

ABSTRACT

M.Sc. Thesis

EMPIRICAL ANALYSIS OF THE PERFORMANCE OF RADIOMETER AND DEEP LEARNING METHODS FOR DIGITALLY MODULATED SIGNALS

Gamze KIRMAN TOKGOZ

**İstanbul Commerce University
Graduate School of Applied and Natural Sciences
Department of Electronics and Communication Engineering**

Supervisor: Assoc. Prof. Dr. Serhan YARKAN

2020, 54 pages

Due to the ever-increasing growth of next-generation wireless communication services and applications, nowadays, the need for frequency spectrum sources is greater than ever. Considering the scarcity in limited radio spectrum, satisfying the demand for high capacity and data rates is a challenging task that requires innovative technologies that can pave new ways to utilize the existing spectrum.

Spectrum sensing concept, which enables cognitive radios to identify spectral holes, plays a critical role in next-generation wireless communication technologies and systems. Moreover, enhancing the efficiency of radio spectrum allocation with the use of spectrum sensing and dynamic spectrum access is one of the very emerging trends.

In this study, a comparison of deep learning algorithms, CNN, CLDNN, LSTM and ResNet architectures, are demonstrated for spectrum sensing of digitally modulated signals in terms of the accuracy and efficiency. In the light of results, it is shown that CNN is the best performing algorithm among others. Furthermore, due to its low cost and low complexity, the most commonly used traditional energy detector method is compared with CNN method for spectrum sensing applications within the framework of efficiency analysis.

The results show that the proposed CNN architecture provides better detection performance than the traditional energy detector method. In conclusion, the investigations in this thesis provide a comparison of CNN based spectrum sensing techniques with traditional energy detector techniques to overcome the challenge of noise uncertainty.

Keywords: Compute library for deep neural networks (CLDNN), convolutional neural network (CNN), energy detector, long short term memory (LSTM), residual network (ResNet), spectrum sensing.

TEŞEKKÜR

Bu araştırmanın gerçekleştirilmesinde, iki yıl boyunca değerli bilgilerini ve zamanını benimle paylaşan, desteğini esirgemeyen, beni yönlendiren ve karşılaştığım bütün zorlukları bilgisi, tecrübesi ve tüm samimiyeti ile aşmamda yardımcı olan değerli Danışman Hocam Doç. Dr. Serhan YARKAN'a teşekkürü bir borç bilir ve sonsuz şükranlarımı sunarım.

Yine araştırmalarımda konu, kaynak ve yöntem açısından bana sürekli yardımda bulunarak yol gösteren değerli Hocalarım Dr. Öğr. Üyesi Ali Rıza EKTİ ve Dr. Öğr. Üyesi Ali BOYACI'ya teşekkürlerimi iletmek isterim.

Ayrıca, araştırmamın yürütülmesinde teknik tartışmaları ve motivasyon desteğiyle bana sürekli yardımcı olan Kürşat TEKBIYIK, Nihan ÇAYDAŞ, İpek BAZ ve TÜBİTAK BİLGEM'deki bütün çalışma arkadaşlarıma teşekkür ederim.

Son olarak, tezimin her aşamasında beni yalnız bırakmayıp destek olan eşim Sezer Can TOKGÖZ'e ve aileme sonsuz sevgi ve saygılarımı sunarım.

Gamze KİRMAN TOKGÖZ
İSTANBUL, 2020

ŞEKİLLER

	Sayfa
Şekil 1.1. Kablosuz iletişim için ayrılan radyo spektrumu.....	1
Şekil 3.1. Spektrum sezme yöntemleri	13
Şekil 5.1. Yapay zeka, makine öğrenmesi ve derin öğrenme ilişkisi.....	19
Şekil 5.2. Makine öğrenmesi alt kümeleri	20
Şekil 5.3. Sırasıyla regresyon ve sınıflandırma	21
Şekil 5.4. Evrişimsel sinir ağı genel blok diyagramı	23
Şekil 5.5. Maksimum ve ortalama havuzlama katmanı.....	25
Şekil 5.6. Seyreltme oranı 0.5 olan bir seyreltme katmanı örneği.....	26
Şekil 5.7. CLDNN mimarisi	27
Şekil 5.8. LSTM mimarisi	28
Şekil 6.1. CLDNN tabanlı sezicinin değişen işaret uzunluklarında sezim ve yanlış alarm olasılıkları	30
Şekil 6.2. LSTM tabanlı sezicinin değişen işaret uzunluklarında sezim ve yanlış alarm olasılıkları	31
Şekil 6.3. ResNet tabanlı sezicinin değişen işaret uzunluklarında sezim ve yanlış alarm olasılıkları	32
Şekil 6.4. Farklı öz niteliklerinin kullanımının model başarımına etkisi	33
Şekil 6.5. CNN tabanlı sezicinin değişen işaret uzunluklarında sezim ve yanlış alarm olasılıkları	34
Şekil 6.6. 1024 uzunluklu işaretler için CNN, CLDNN, LSTM ve ResNet sezicilerinin sezim olasılıklarının karşılaştırılması.....	35
Şekil 6.7. 1024 uzunluklu işaretler için CNN, CLDNN, LSTM ve ResNet sezicilerinin yanlış alarm olasılıklarının karşılaştırılması.....	36
Şekil 6.8. Derin öğrenme yöntemlerinin zaman tüketimi, bellek kullanımı, sezim olasılığı ve yanlış alarm olasılığı açısından karşılaştırılması.....	37
Şekil 6.9. CNN modelinin mimarisi	39
Şekil 6.10. Değişen işaret uzunluğuna göre enerji sezicinin performansı ($P_{fa} = 10^{-2}$)	41
Şekil 6.11. CNN sezicinin sahip olduğu yanlış alarm olasılıklarında enerji sezicinin sezim performansı.....	42
Şekil 6.12. CNN sezicinin sahip olduğu yanlış alarm olasılığında 1024 uzunluklu işaretler için her iki sezicinin sezim olasılıklarının karşılaştırılması.....	42
Şekil 6.13. Rohde&Schwarz SMC100A sinyal üretici	44
Şekil 6.14. Rohde&Schwarz FSW26 sinyal ve spektrum analizörü	44
Şekil 6.15. Değişen işaret uzunluğuna göre enerji sezicinin gerçek veriler ile yapılan ölçüm sonuçlarının performansı	45
Şekil 6.16. Hata histogramı	46
Şekil 6.17. 1024 uzunluklu ED ve CNN için gerçek ve sentetik veriler ile alınan sonuçların karşılaştırılması.....	46

ÇİZELGELER


	Sayfa
Çizelge 5.1. ResNet mimarisi.....	29
Çizelge 6.1. Kullanılan CNN modelinin katmanlarının çıkışında gözlenen veri boyutları.....	40

SİMGELER VE KISALTMALAR

ADAM	Uyarlanabilir Moment Tahmini (Adaptive Moment Estimation)
AI	Yapay Zeka (Artificial Intelligence)
AWGN	Toplamsal Beyaz Gauss Gürültüsü (Additive White Gaussian Noise)
BPSK	İkili Faz Kaydırma Anahtarlama (Binary Phase Shift Keying)
CFAR	Sabit Yanlış Alarm Oranı (Constant False Alarm Rate)
CFO	Taşıyıcı Frekans Ofseti (Carrier Frequency Offset)
CLDNN	Derin Sinir Ağları için Bilgi İşlem Kütüphanesi (Compute Library for Deep Neural Networks)
CNN	Evrimsel Sinir Ağı (Convolutional Neural Network)
CSS	İşbirlikçi Spektrum Sezimi (Cooperative Spectrum Sensing)
DCS	Derin İşbirlikçi Sezimi (Deep Cooperative Sensing)
DNN	Derin Sinir Ağı (Deep Neural Network)
DSA	Dinamik Spektrum Erişimi (Dynamic Spectrum Allocation)
E	Kullanıcı İşaretinin Enerjisi
EL	Topluluk Öğrenme (Ensemble Learning)
FCC	Federal İletişim Komisyonu (Federal Communications Commission)
GPU	Grafik İşlem Birimi (Graphic Processing Unit)
H_0	Hipotez 0
H_1	Hipotez 1
I/Q	In-quadrature/Quadrature (Çeyrek Evreici/Evre Farkı)
LSTM	Uzun Kısa Süreli Bellek (Long Short-Term Memory)
LTE	Uzun Süreli Evrim (Long Time Evolution)
MIMO	Çok Girişli Çok Çıkışlı (Multiple Input Multiple Output)
MLP	Çok Katmanlı Algılayıcı (Multilayer Perceptron)
MUSIC	Multiple Signal Classification (Birden Fazla İşaret Sınıflandırması)
OFDM	Orthogonal Frequency-Division Multiplexing (Dik Frekans Bölmeli Çoğullama)
P_d	Saptama Olasılığı
P_{fa}	Yanlış Alarm Olasılığı
PU	Birincil Kullanıcı (Primary User)
ResNet	Artık Ağ Mimarisi (Residual Network)
RF	Radio Frekansı (Radio Frequency)
RNN	Tekrarlayan Sinir Ağları (Recursive Neural Network)
SAE-SS	Yığın Otoenkoder Tabanlı Spektrum Algılama (Stacked Autoencoder Based Spectrum Sensing)
SNR	Sinyalin Gürültüye olan Oranı (Signal-to-Noise Ratio)
SU	İkincil Kullanıcı (Secondary User)
WLAN	Kablosuz Yerel Alan Ağı (Wireless Local Area Network)
$x(n)$	Kullanıcı İşareti
$y(n)$	Alınan İşareti
λ_E	Karar Eşiği
σ_w^2	Gürültü Varyansı

1. GİRİŞ

Son yıllarda, kablosuz cihazlar ve ağılar pazarı benzeri görülmemiş bir büyüme sağladı. Bu büyüme sayısız kablosuz servis ve uygulamaya yol açtı. Sonuç olarak, farklı ülkelerdeki düzenleyici kurumlar lisanslı spektrum bant aralıklarını farklı kablosuz hizmetlere tahsis etmektedir. Örneğin, farklı uygulamalar için tahsis edilen radyo spektrumu Şekil 1.1’de gösterilmektedir (David vd., 2020).



Şekil 1.1. Kablosuz iletişim için ayrılan radyo spektrumu

Kablosuz ağların bu gelişmekte olan amansız büyümesi spektrum talebini artırmıştır. Artan talebi karşılamak ve spektrumun etkin kullanımı için aşağıda tanımlanan teknolojiler geliştirilmiştir:

Çok Girişli Çok Çıkışlı (multiple input and multiple output, MIMO) İletişim: MIMO sistemleri, aynı toplam iletim gücünü antenler üzerine yayar ve spektral verimliliği artırarak ek spektrum kullanımı olmadan daha yüksek veri çıkışına izin verir. Örneğin, IEEE 802.11n (Wi-Fi) 2,4 GHz'de 600 Mbps'ye kadar maksimum veri hızına ulaşmak için MIMO kullanır. Öte yandan farklı MIMO sistemleri arasında tek kullanıcı ve çok kullanıcı MIMO bulunur. Ek olarak, büyük ölçekli anten dizileri kullanan devasa MIMO, hücre boyutunu küçültebilir ve kanal eğitimi için iletim gücünü ve ek yükü azaltabilir (kanal karşılıklılığı kullanılırsa) (Larsson vd., 2014).

İşbirlikçi İletişim: İşbirlikçi radyo yayınları, çok kullanıcıli bir ortamda dağıtılmış uzamsal çeşitliliği kullanarak hem güvenilirliği hem de veri hızını artırır (Nosratinia vd., 2004). Kooperatif teknikleri arasında röle, kooperatif MIMO ve çok hücreli MIMO bulunur. Tek kullanıcıli veya çok kullanıcıli röle, daha az güç kullanarak kaynak ve hedef arasındaki sinyal iletimini kolaylaştırır. Farklı kullanıcıların antenlerini kullanan dağıtılmış bir anten sistemi oluşturan kooperatif MIMO, görüş açısı yayılımı ve hücre kenarı kullanıcıları için etkilidir. Kooperatif MIMO, hem MIMO hem de kooperatif iletişim tekniklerinin avantajlarını kullanır. Ayrıca, MIMO ağlarındaki daha fazla sayıda kullanıcı / anten ve evrensel frekansın yeniden kullanımı (örneğin, uzun vadeli evrimde (LTE) gelişmiş) yüksek seviyelerde ortak kanal parazitine neden olur. Bu tür bir girişim, çok hücreli MIMO olarak adlandırılan, işbirliği yapan birden fazla hücre tarafından hafifletilebilir.

Heterojen ağlar: Bu ağlar, birim ağ başına spektral verimliliği artırmak için mobil ağlarda artan düğüm yoğunluğunu ve hücre trafiğini desteklemek için gerekli olan farklı hücrelerdeki çeşitli baz istasyonları kullanır (Lei vd., 2013). Bununla birlikte, geleneksel hücresel ağlar gelecekteki büyümeyi karşılamak için neredeyse en yüksek kapasitelerinde bulunduğundan, heterojen tasarımlar öngörülmüştür. Bunlar arasında baz istasyonların ve piko-hücrelerde (250mW – 2W) düşük frekanslı baz istasyonları ve femtocells (100mW veya daha az) ve yüksek hızlı kablosuz yerel alan ağları (wireless local area network, WLAN) gibi hücrelerin ayrı bir karışımı bulunur. Bir kullanıcı makro hücreler, piko-hücreler, femto-hücreler ve WLAN'lar arasında geçiş yapabilir.

Bu ileri teknolojilere rağmen, spektrum kıtlığı ABD'deki Federal İletişim Komisyonu (federal communications commission, FCC) ve diğer ülkelerdeki düzenleyici kurumlar için zorluklar yaratmaya devam etmektedir. Gelecek vaat eden bir çözüm bilişsel radyo teknolojisidir.

Bilişsel Radyo (cognitive radio, CR): Kablosuz erişimde ortaya çıkan yeni bir kavram olan bilişsel radyo teknolojisi, görünür spektrumun yetersiz kullanımıdır. FCC'nin deneyleri, herhangi bir zamanda ve yerde, lisanslı

spektrumun çoğunun (%80 ila %90 arasında) yetersiz kullanıldığını göstermektedir. Bu gibi geçici olarak kullanılmayan spektrum yuvalarına spektrum delikleri denir ve bu da spektral verimsizlik ile sonuçlanır. Dolayısıyla, sadece bazı lisanslı bantlarda spektrum kullanımı düşük olmakla kalmaz, aynı zamanda radyo spektrumunun gerçek kıtlığı da sorunu bir araya getirir. Sonuç olarak, kablosuz uygulamaların büyümesi engellenebilir. Bilişsel bir radyo alıcı-vericisinin temel özellikleri radyo çevre bilinci ve spektrum zekasını içerir. İkincisi, spektrum ortamını öğrenme ve iletim parametrelerini uyarlama yeteneğini ifade eder (Yücek ve Arslan, 2009).

Öte yandan, dinamik spektrum erişimi (dynamic spectrum allocation, DSA), bir radyo ağının çalışma spektrumunun, mevcut spektrumdan dinamik olarak seçilebildiği bir teknik olarak tanımlanır (Srinivasa vd., 2007). DSA, lisanslı kullanıcılar ve lisanssız kullanıcılar ile hiyerarşik erişim yapısına sahip bilişsel radyo ağlarına uygulanabilir. DSA'nın temel fikri, birincil kullanıcılar tarafından algılanan paraziti sınırlarken ikincil kullanıcılara lisanslı spektrum açmaktır. DSA, iki strateji ile uygulanan fırsatçı spektrum paylaşımını gerektirir (Maldonado vd., 2005).

1. Spektrum kaplaması, ikincil kullanıcıların iletim gücü üzerinde değil, iletim süreleri üzerinde ciddi kısıtlamalar getirebilir. Sonuç olarak, ikincil bir kullanıcı DSA aracılığıyla atanan bir spektrum deliğine erişir.
2. Spektrum altlığı, ikincil kullanıcıların iletim gücü üzerinde katı kısıtlamalar getirir. Bu nedenle iletim güçleri birincil kullanıcılar tarafından gürültü olarak kabul edilecek kadar düşüktür. Hem birincil hem de ikincil kullanıcılar böylece aynı spektrum bandında eşzamanlı olarak iletim yapabilir.

İkincil bindirme kullanıcıları spektrum deliklerine fırsatçı bir şekilde erişirken, birincil kullanıcılar gönderme ve alma yoluyla aktif hale gelirse, ikincil kullanıcılar bu iletimleri güvenilir bir şekilde tespit etmeli, kanalı hemen

boşaltmalı ve sürekli iletişim için diğer spektrum deliklerini bulmalıdır. Bu nedenle en önemli görevlerden biri spektrum deliklerini tanımlamaktır.

Yukarıda da anlatıldığı gibi bilişsel radyoların spektral boşlukları tanımlamasını sağlayan spektrum algılama konsepti, yeni nesil kablosuz iletişim teknolojileri, sistemleri ve çözümlerinde, sınırlı radyo spektrumundaki kıtlık ve sürekli artan daha yüksek kapasite ve daha yüksek veri hızları gereklilikleri göz önünde bulundurulduğunda, kritik bir rol oynamaktadır. Ayrıca, spektrum algılama ve dinamik spektrum erişimi ile radyo spektrumu kullanımının verimliliğini artırmak, ortaya çıkan trendlerden biridir.

Günümüz kablosuz iletişiminde, farklı teknolojilerin gelişmesi, artan kullanıcı talepleri, mevcut sınırlı spektrumun verimsiz olarak kullanımı yeni bir iletişim teknolojisi kavramının ortaya çıkmasına ve bu teknolojinin hızla gelişmesine neden olmuştur. Yeni nesil ağlar olarak da adlandırılan bilişsel radyo teknolojisi ile spektrumun verimli ve dinamik kullanılması sonucu iletişimin kesintisiz ve daha hızlı olarak yapılması amaçlanmaktadır. Bu nedenle, bu problemin üstesinden gelebilecek bir yöntem ihtiyacı var. Bilişsel radyoların işlem kapasite gücü düşüktür. Bu sistemlerin ucuz olmasını istediğimiz için, çok enerji harcamayan bir metot önerildi.

Yapılan bu çalışmada spektrumun verimli kullanılması için farklı yöntemler arasında verim analizi yapılarak bu problemin üstesinden gelebilecek bir yöntem önerilmektedir.

Bu motivasyon ile bu çalışmada, sayısal modülasyonlu işaretler için en güçlü ve dirençli derin öğrenme algoritmalarından olan CNN, CLDNN, LSTM ve ResNet mimarileri arasında spektrum sezimi verimliliği karşılaştırılması yapıldıktan sonra en iyi sezim performansını gösteren algoritmanın CNN olduğu sonuçlar çerçevesinde gösterilmiştir. Daha sonrada ise, düşük maliyetleri ve düşük karmaşıklık seviyelerinden dolayı spektrum sezimi uygulamaları için hâlihazırda en çok kullanılan geleneksel enerji sezici yöntemi, en iyi performansı gösteren derin öğrenme CNN yöntemi ile verimlilik analizi

yapılarak karşılaştırılmıştır. Elde edilen sonuçlar ışığında CNN tabanlı sezim algoritmasının enerji sezicisinden daha iyi performans sergilediği gözlenmiştir. Elde edilen sonuçlar hakkındaki ayrıntılı tartışmalar ilgili bölümlerde sunulmuştur.

Burada yapılan çalışmaların bir kısmı SIU 2020’de (28. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı) sunuma hak kazanan “Enerji Sezici ve CNN Tabanlı Sezici Üzerine Bir Karşılaştırma” isimli makalede yer almaktadır.

2. LİTERATÜR ÖZETİ

Spektrumda işaretlerin varlığının kestirilmesi birçok amaca hizmet etmektedir. Bilişsel radyolar olarak bilinen spektrumun daha verimli kullanılması amacıyla ortaya konulan sistemlerin temelinde spektrum kestirimi yatmaktadır. Ayrıca, sinyal istihbarat uygulamalarında spektrumda işaret varlığının belirlenmesi önemli bir husustur. Bu amaçla kullanılan birçok yöntem mevcuttur fakat bunlar içerisinde en çok kullanılanı Urkowitz tarafından temel yaklaşımı verilen enerji sezicilerdir (Urkowitz, 1967). Son zamanlarda makine öğrenmesi tekniklerinin de bu alanda uygulamalarına rastlanmaktadır (Cui vd., 2015), (Paisana vd., 2017).

Literatürde enerji sezicilerin performansını artırmak için çeşitli yöntemler ele alınmaktadır. Enerji seziciler için eşik seçimi süreci, sabit yanlış alarm oranı (constant false alarm rate, CFAR, P_{fa}) tabanlı ele alınır ve mevcut gürültü seviyesi koşulları göz önüne alınarak seçim yapılır. Sezim işlemi sırasında mevcut gürültü seviyesine göre algılama eşiği dinamik olarak ayarlanırsa tespit olasılığının sabit bir eşik değeri düşünüldüğünde elde edilen değerden daha yüksek olacağı gösterilmektedir.

Atapattu vd. (2015), sabit bir optimum eşik değeri kapalı formda çıkarımı yapılan ortalama tespit olasılığına göre belirlenen bir araştırma yapmışlardır. Düşük SNR seviyelerinde konvansiyonel enerji sezici için farklı kanallarda performans analizi yapılmaktadır. Ayrıca donanım kaynaklı bozucu etkiler enerji sezicinin performansını etkilemektedir. Örneğin, bozucu etmenler işaretle I/Q dengesizliğine sebep olabilmektedir.

I/Q dengesizliği altında enerji sezicinin başarımı Gokceoglu vd. (2014)'nin araştırmasında incelenmektedir. I/Q dengesizliğinin klasik enerji sezici performansını düşürdüğü gözlemlenmektedir. Burada önerilen sezici klasik sezicilere göre pratik kusurlu RF devrelerinde daha iyi başarımlar sağlamaktadır.

Klasik enerji sezicilere bir başka yaklaşım Chen (2010), alışlagelmiş enerji sezicilerin aksine işaret genliğinin karesini almak yerine yanlış alarm olasılığı ve SNR değerine bağlı olarak belirlenen herhangi bir pozitif üst değerinin alınmasını önermektedir.

Gezgin ve kısa mesafe senaryoları için, kablosuz bağlantılar zaman ve frekans seçici olma eğiliminde olabilir, yani bu durumda zamanla değişen sönümleme katsayılarına sahip çok yollu yayılımlar kaçınılmaz olmaktadır. Bu durumda geleneksel enerji seziciler düşük performans sergilemektedir. Li vd. (2015)'de zaman ve frekans seçici kanallarla baş edebilecek bir yöntem önerilmektedir. İlk olarak, algılama sürecini karakterize etmek için dinamik ayrık bir durum-uzay modeli oluşturulur. Burada birincil bant doluluk durumu ve zamanla değişen çok kanallı kanal iki gizli durum olarak ele alınırken toplanan enerji gözlenen çıktı olarak kabul edilir.

Enerji seziciler düşük hesaplama maliyetine ve basit donanım isterlerine sahip olmasına rağmen gürültü varyansının önceden bilinmesini gerektirmektedir. Bu ön bilginin belirlenmiş olması sezim probleminin zaten sonuçlandırılması anlamına gelmektedir ki güç seviyesinin bilindiği durumda işaretin varlığı gücünden tespit edilebilir. Bu durum tavuk yumurta ikilemini hatırlatmaktadır. Ayrıca jammer ve girişim kaynaklarının varlığında sezim işlemi daha çetrefilli bir hal almaktadır. Böylesi bir durumda gürültü tabanını kestirmek hesaplama maliyeti yüksek işaret işleme algoritmaları (ör. MUSIC) gerektirmektedir.

Evrişimsel sinir ağı (convolutional neural network, CNN) tabanlı sezici, gürültü varyansının bilinmesi gerekliliğine ihtiyaç duymayan, onun yerine geniş SNR aralığında işaret ve gürültü örnekleri barındıran bir veri setine bağımlılığı olan bir sezicidir. Örneğin, Lee vd. (2019)'daki yazarlar, bilişsel radyo ağlarında kooperatif spektrum algılamayı (cooperative spectrum sensing, CSS) araştırır, bu senaryoda birden fazla ikincil kullanıcı (secondary user, SU), aynı anda birden fazla bantı kaplayan bir birincil kullanıcıyı tespit etmek için işbirliği yapar. CNN'e dayanan ilk CSS çerçevesini oluşturan derin kooperatif algılama (deep cooperative sensing, DCS) önerilmektedir. DCS'de, CSS'nin açık

matematiksel modellemesi yerine, SU'ların bireysel algılama sonuçlarını birleştirme stratejisi, bireysel algılama sonuçlarının nicelikli olup olmadığına bakılmaksızın eğitim algılama örnekleri kullanılarak bir CNN ile özerk olarak öğrenilir. Ayrıca, bireysel algılama sonuçlarının hem spektral hem de uzamsal korelasyonu, DCS'de ortama özgü bir CSS'nin etkinleştirileceği şekilde dikkate alınır. Lees vd. (2019)'nin çalışmalarında, yakın tarihli bir ölçüm kampanyası tarafından toplanan 14.000'den fazla 3.5 GHz bant spektrogramından oluşan bir kütüphane kullanarak, SPN-43 radar tespiti için 13 yöntemin performansını araştırılır. Yani, yazarlar sinyal algılama teorisi ve makine öğrenmesinden klasik derin öğrenme mimarilerine kadar klasik yöntemleri karşılaştırmaktadır. Makine öğrenme algoritmalarının klasik sinyal algılama yöntemlerinden önemli ölçüde daha iyi performans sergilediklerini gösterirler. Özellikle, üç katmanlı evrişimli sinir ağının doğruluk ve hesaplama karmaşıklığı arasında üstün bir denge sağladığını görülür.

Xie vd. (2019) araştırmasındaki yazarlar spektrum algılaması için evrişimli sinir ağlarına dayalı derin öğrenme algoritması önermektedir. Model tabanlı spektrum algılama algoritmalarıyla karşılaştırıldığında, önerilen derin öğrenme yaklaşımı veriye dayalıdır ve ne sinyal-gürültü olasılığı modeli ne de birincil kullanıcı (primary user, PU) aktivite modeli modeli gerektirmez. Önerilen algoritma, aynı zamanda, mevcut PU algılama modelini ve geçmiş algılama verilerini içerir; burada, PU aktivitesinin saptanmasına fayda sağlamak için doğal PU aktivite paterni öğrenilebilir.

Öte yandan, literatürdeki çeşitli çabalara rağmen, geleneksel OFDM algılama yöntemlerinin çoğu, algılama doğruluğunu önemli ölçüde azaltan gürültü belirsizliği, zamanlama gecikmesi ve taşıyıcı frekans ofsetinden (carrier frequency offset, CFO) muzdariptir. Bu zorlukları aşmak için, Cheng vd. (2019)'nin çalışmasında derin öğrenme ağlarından destek alan iki yeni OFDM algılama çerçevesi geliştirmektedir. Özellikle, ilk olarak, yığılmış bir otoenkoder ağının OFDM sinyallerinin gizli özelliklerini çıkarmak için tasarlandığı bir yığın otoenkoder tabanlı spektrum algılama (stacked autoencoder based spectrum sensing, SAE-SS) yöntemi önerilir. OFDM kullanıcısının faaliyetlerini

sınıflandırmak için bu özellikleri kullanan SAE-SS, gürültü belirsizliği, zamanlama gecikmesi ve CFO için geleneksel OFDM algılama yöntemlerinden çok daha sağlamdır. Ayrıca, SAE-SS, geleneksel özellik tabanlı OFDM algılama yöntemleri için gerekli olan herhangi bir önceden sinyal bilgisi (örn., sinyal yapısı, pilot tonlar, döngüsel önek) gerektirmez. SAE-SS'nin, özellikle düşük SNR koşullarında algılama doğruluğunu daha da iyileştirmek için, zaman frekansı alan sinyalleri kullanarak yığılmış otomatik kodlayıcı tabanlı spektrum algılama yöntemi önerilir. Bu yöntem, daha yüksek hesaplama karmaşıklığı pahasına SAE-SS'den daha yüksek algılama doğruluğu sağlar.

He ve Jiang (2019)'ın çalışmasında, yazarlar dağıtılmış CSS için enerji verimliliği optimizasyonuna odaklanan kablosuz iletişim sistemleri için derin öğrenme tekniklerinin uygulanmasını araştırmaktadır. Günümüz teknolojilerinin ve kullanıcı taleplerinin sürekli gelişmesiyle, kablosuz iletişim sistemleri her zamankinden daha büyük ve daha karmaşık hale gelmektedir, bu da geleneksel yaklaşımların artık üstesinden gelemeyeceği birçok kritik zorluğu beraberinde getirmektedir. Bu sebeple yazarlar, derin öğrenme temelli yaklaşımların, yeni nesil kablosuz iletişim sistemlerinde bu tür zorlukların üstesinden gelinmesinde önemli bir rol oynayacağını öngörmektedir. Ayrıca, yazarlar spektrum verimliliğini artırmak ve spektrum algılama sürecini optimize etmek için derin öğrenme teknikleri geliştirmek için umut verici bir teknoloji olan bilişsel radyoya odaklanmaktadır. Özellikle, eğitilmiş kooperatif algılamanın enerji verimliliğini bir tümleşik optimizasyon problemi olarak formüle ederek araştırmaktadır. Bu formülasyona dayanarak, genel sistem enerji verimliliğini artırmak için grafik sinir ağını ve takviyeli öğrenmeyi entegre ederek derin bir öğrenme çerçevesi geliştirirler.

Yu vd. (2017)'nin çalışmalarında, spektrum kullanılabilirliğini tahmin etmek için uzun kısa süreli bellek (long short-term memory, LSTM) ağı adı verilen derin bir öğrenme tekniği önerilir. Bu tekniğin ana fikri, geçmiş spektrum kullanılabilirlik verilerinden öğrenmek ve gelecekteki spektrum kullanılabilirliğini tahmin etmek için aralarındaki gerçek spektral-temporal korelasyondan yararlanmaktır. Yapay sinir ağları ile spektrumu tahmin etmeye

alışan bazı alışmalarda yalnızca tarihsel veriler arasındaki zamansal korelasyonlara dayalı tahminler yapabilirken, önerilen sistemde spektral zamansal alandaki korelasyonu keşfedebilir ve bu nedenle daha etkilidir.

Yu vd. (2018)'nin alışmasında, iki farklı spektrum veri setinde derin öğrenme yaklaşımına sahip bir spektrum tahmin çerçevesi geliştirilir. Kanal doluluk durumlarını tahmin etmek için ilk veri kümesinde, öncelikle belirli spektrum noktası için sinir ağıının en iyi şekilde oluşturulmuş yapılandırmasını belirlemek ve ardından her bir tasarım hiper parametresinin etkisini analiz etmek için Taguchi yöntemini kullanılır. Daha sonra, spektrum tahmini için iki regresyon ve sınıflandırma perspektifi ile LSTM sinir ağıları inşa edilir. İkinci veri kümesinin kanal kalitesini tahmin etmesi için LSTM sinir ağıının ve geleneksel çok katmanlı algılayıcı (multilayer perceptron, MLP) sinir ağıının tahmin performansını karşılaştırılır. Her iki veri seti için de sonuçlar, tahmin performansının frekans bantlarına göre değiştiğini göstermektedir. İstatistikler açısından, LSTM sinir ağı MLP sinir ağıından daha iyi tahmin performansına sahiptir ve aynı zamanda daha kararlıdır. Ayrıca, sınıflandırma perspektifine sahip LSTM sinir ağıının performansının ilk veri setimizde regresyon perspektifinden biraz daha iyi olduğunu bulunmuştur.

Yang vd. (2019)'nin alışmasındaki yazarlar, üç farklı çeşitte sinir ağını, yani evrişimli sinir ağılarını, uzun kısa süreli belleği ve tamamen bağı sinir ağılarını kullanan derin öğrenmeye dayanan kör spektrum algılama yöntemi önermiştir. Deneyler ışığında, önerilen yöntemin, özellikle sinyal/gürültü oranı düşük olduğunda, bir enerji detektöründen daha iyi bir performansa sahip olduğunu gösterilir. Aynı zamanda, bu alışmada farklı uzun kısa süreli bellek katmanlarının algılama performansı üzerindeki etkisini analiz etmekte ve derin öğrenme tabanlı dedektörün neden daha iyi performans elde edebileceğini araştırılmaktadır.

Liu vd. (2018)'nin alışmasındaki yazarlar, bir OFDM sinyaline dayalı bilişsel radyo sisteminde CSS için bir topluluk öğrenme (ensemble learning, EL) çerçevesi benimsemiştir. Buna göre her SU, temel spektrum algılamasının,

PU'nin inaktif veya aktif olma olasılığını arařtırmak için bir temel öğrenici olarak kabul edilir. Basit mimariye sahip olan evriřim sinir ağıları, görüntü tanımadaki gücü göz önüne alındığında, her bir SU'nun sınırlı hesaplama kabiliyetine uygulanır, bu arada, girdi verileri olarak döngüsel spektral korelasyon özelliğı tanıtılır. Burada, denetimli öğrenmeye gelince, torbalama stratejisinin eğitim veri tabanının oluřturulmasına yardımcı olunur. Küresel karar için füzyon merkezi, PU durumunun sınıflandırma ön tahmininin SU çıktısını öğrenmek için daha fazla kombinasyon için yığılmıř genelleme kullanır. Önerilen yöntem, algılama olasılığı veya yanlış alarm olasılığı performansı açısından geleneksel CSS yöntemlerine göre önemli avantajlar göstermektedir.

Liu vd. (2019), veri odaklı test istatistiklerini akıllıca keřfetmek için derin bir sinir ağı (DNN) kullanırlar. İlk olarak, yazarlar, tasarlanan test istatistiğinin optimumluğunu garanti etmek için DNN tabanlı bir olasılık oranı testinin türetildiğı bir DNN tabanlı algılama çerçevesi sunarlar. Geliřtirilmiř DNN tabanlı çerçevenin bir gerçekteřtirmesi olarak, örnek kovaryans matrisini, bir CNN ağının giriři olarak kullanırlar ve kovaryans matrisine duyarlı CNN tabanlı performansı artıran spektrum algılama algoritması önerirler. Ayrıca, yazarlar önerilen yöntemin teorik analizini de sağırlarlar. Sonuç olarak, yazarlar, simülasyon sonuçları ışığında, önerilen yöntemin performansının, optimal detektörün (Bayesian detektörü) performansına yakın olduğunu göstermektedir.

3. SPEKTRUM SEZİMİ

Spektrum delikleri, yani mevcut kanallar, fırsatçı spektrum erişimi için algılanmalıdır. Başarılı algılamaları, yer paylaşımli kullanıcı erişimine izin verir. Spektrum delikleri birincil kullanıcıların boşa olma durumundan (yani sinyal iletimi olmadığından) dolayı, spektrum deliklerini tanımlamak için ikincil kullanıcılar belirli bir frekans yuvasında birincil sinyallerin olmadığını tespit etmelidir. Bu görev, Hipotez 0 (H_0) ve Hipotez 1 (H_1)'in sırasıyla birincil sinyal yokluğu ve birincil sinyal varlığı olduğu ikili bir hipotez test problemi olarak görülebilir. Spektrum delikleri böylece H_0 doğru olduğunda tanımlanır.

Sinyal algılama geleneksel ağlarda yaygın olmakla birlikte, bilişsel radyo spektrum algılaması için kullanımında aşağıdaki zorluklar ortaya çıkmaktadır.

Kaçırılan herhangi bir algılama, tespit edilmemiş aktif birincil kullanıcılara müdahale edecek ikincil aktarımlarla sonuçlandığından, çok daha güvenilir bir dedektör (geleneksel ağlardakinden daha fazla) gereklidir. Bu nedenle, IEEE 802.22 standardı %90 doğru algılama kabiliyeti belirler.


Mümkün olduğunca çok spektrum deliği tanımlamak için çok daha geniş bir spektrum bant genişliğinin algılanması gerekir; örneğin, bir TV kanalı bant genişliği (6-7MHz) 20MHz bant genişliğinden daha büyük bant genişliği kullanan 4G/5G mobil iletişim uygulamaları için yeterli değildir. Ayrıca, farklı frekans bantları farklı sinyal yayılım karakteristikleri yaşadığından, tespit algoritmalarının tasarımı ve performans analizleri zordur.

Çok çeşitli iletim ortamlarında, birden fazla lisanslı kablosuz düğümden sinyal iletimi algılanmalıdır. Farklı uygulamaların farklı kullanıcı popülasyonları olabilir, bunlar farklı mobilite kalıpları ile sinyal tespiti üzerinde büyük etkiye sahiptir. Ayrıca, sinyal tespiti geleneksel kablosuz ağlar için iyi araştırılmış olsa da, aynı teknikler bilişsel radyo ağlarında başarısız olabilir, çünkü ikincil kullanıcılarda birincil ağ parametrelerinin mevcut bilgisi sınırlıdır ve hesaplama karmaşıklığı ve uygulama maliyeti de ana faktörlerdir.

3.1. Spektrum Sezim Teknikleri

Farklı spektrum algılama teknikleri aşağıda Şekil 3.1’de gösterilmiştir. Spektrum algılama esas olarak üç gruba ayrılır. İşbirlikçi olmayan algılama, işbirlikçi algılama ve girişime dayalı algılama. İşbirlikçi olmayan algılama için diğer isim verici tespitidir.

İşbirlikçi spektrum seziciler ve girişime dayalı spektrum sezicilerde birden fazla sezici bulunup, birbirlerine haber verme yöntemi ile algılama yapılmaktadır. Bu nedenle bu çözümler daha maliyetli olmaktadır. Bundan dolayı işbirlikçi olmayan çözümler daha yaygın olarak kullanılmaktadır. Bu çalışmada da işbirlikçi olmayan yöntemler kullanılarak kıyaslamalar yapılmıştır. İlerdeki bölümlerde işbirlikçi olmayan spektrum sezme yöntemleri detaylıca açıklanacaktır.



Şekil 3.1. Spektrum sezme yöntemleri

4. GELENEKSEL YÖNTEMLER

4.1. Enerji Sezici

Radyometre veya periodogram olarak da bilinen enerji sezici tabanlı yaklaşım, düşük hesaplama ve uygulama karmaşıklıkları nedeniyle spektrum algılamanın en yaygın yoludur. Buna ek olarak, alıcılar birincil kullanıcıların sinyali hakkında herhangi bir bilgiye ihtiyaç duymamaktadır. Sinyal, enerji sezicinin çıkışında görülen değer ile gürültü tabanına bağlı bir eşik ile karşılaştırılarak tespit edilir. Eşik seviyesinin belirlenmesi için gürültü seviyesinin tahmin edilmesine ihtiyaç duyulmaktadır. Enerji sezici tabanlı algılama ile ilgili zorluklardan bazıları, birincil kullanıcıları tespit etmek için eşik seçimi, birincil kullanıcılar ve gürültüden ayırt edilememe ve düşük sinyal/gürültü oranı (signal-to-noise ratio, SNR) değerleri altında düşük performans göstermesidir. Enerji seviyesi eşik seviyesinden ne kadar yüksek olursa tespit olasılığı da o ölçüde yüksek olacaktır. Enerji sezici, yayılı spektrum sinyallerini tespit etmek için verimli çalışmaz.

Alınan sinyal, aşağıdaki basit formül ile matematiksel olarak ifade edilebilir.

$$y(n) = s(n) + w(n) \quad (4.1)$$

burada $s(n)$ tespit edilmesi beklenen sinyal, $w(n)$ toplamsal beyaz Gauss gürültüsü (additive White Gaussian noise, AWGN) örneğidir ve n örnek endeksidir. Birincil kullanıcı tarafından iletim olmadığında $s(n) = 0$ olmaktadır. Enerji sezici için karar parametresi Denklem (4.2)'deki şekilde ifade edilebilir.

$$M = \sum_{n=0}^N |y(n)|^2 \quad (4.2)$$

Denklemdaki N , gözlem vektörünün boyutudur. Bir spektrum bandının doluluk durumuna ilişkin karar; karar metriği olan M 'nin, sabit bir eşik seviyesi olan λ_E

ile karşılaştırılmasıyla elde edilebilir. Denklem (4.3) ve (4.4)'te yer alan hipotezler, sırasıyla işaretin spektrumda bulunmadığı ve bulunduğu durumları göstermektedir.

$$H_0 : y(n) = w(n), \quad (4.3)$$

$$H_1 : y(n) = s(n) + w(n). \quad (4.4)$$

Algılama algoritmasının performansı iki olasılıkla özetlenebilir. Saptama olasılığı P_d ile yanlış alarm olasılığı P_{fa} ile ifade edilmiştir. P_d , spektrumda işaret gerçekte mevcut olduğunda, enerji sezicinin dikkate alınan frekans üzerinde bir sinyal tespit etme olasılığıdır. Bu nedenle, P_d olasılığının yüksek olması istenir. Denklem (4.5)'de gösterildiği şekilde formüle edilebilir.

$$P_d = \Pr (M > \lambda_E | H_1). \quad (4.5)$$

Öteki taraftan, yanlış alarm olasılığını ifade eden P_{fa} , spektrumda işaretin gerçekte bulunmadığı durumda, enerji sezicinin spektrumda işaretin mevcut olduğuna karar vermesi olasılığıdır. (4.6)'da gösterildiği şekilde formüle edilebilir.

$$P_{fa} = \Pr (M > \lambda_E | H_0). \quad (4.6)$$

İletim fırsatlarının yetersiz kullanımını önlemek için P_{fa} mümkün olduğunca küçük tutulmalıdır. Karar eşiği olan λ_E , P_d ve P_{fa} arasında optimum bir denge gözetilerek seçilir. Ancak, bu seçimin yapılabilmesi için gürültü gücü ve algılanan sinyal güçleri hakkında bilgi sahibi olunması gerekir. Gürültü gücü tahmin edilebilir, ancak sinyal gücü devam eden iletim özelliklerine ve bilişsel radyo ile birincil kullanıcı arasındaki mesafeye bağlı olarak değiştiği için tahmin edilmesi zordur. Uygulamada eşik değeri, belirli bir yanlış alarm oranı elde etmek için seçilir. Bu nedenle, bir eşik değerinin belirlenmesi için gürültü varyansı bilgisi yeterlidir.

Gürültünün varyansı alınan işaretin öz ilişkisinin en küçük öz değerinden elde edilir. Gürültü sıfır ortalamalı ve σ_w^2 varyanslı Gauss dağılımı ile modellenenabilir. Eşik seviyesi gürültü varyansına bağlı olarak belirlendiği için gürültü gücü tahminindeki küçük yanlışlar sezicinin performansında önemli kayıplara sebep olur. Eşik seviyesi genelde P_{fa} 'ya göre belirlenmektedir. N gözlenen örnek sayısı ve σ_w^2 gürültü varyansı olmak üzere, eşik değeri

$$\lambda_E = (\sqrt{2}\text{erfc}^{-1}(2 P_{fa}) + \sqrt{N})\sqrt{N}\sigma_w^2 \quad (4.7)$$

olarak bulunur.

4.2. Uyumlu Filtreleme

Uyumlu filtreleme, haberleşme teorisinde alınan işaretin sinyal gürültü oranını (SNR) en üst düzeye çıkaran en uygun filtreleme yöntemi olarak bilinmektedir (Cabric vd., 2004). Düşük SNR seviyelerinde iyi sezim başarımı gösterdiğinden enerji sezicileri desteklemek için kullanılabilir. Uyumlu filtreleme birincil kullanıcının varlığını sezer, ayrıca birincil kullanıcının işaret güç seviyesini de belirleyebilir. Bunun yanında, eşzamanlı bir filtreleme yöntemi olduğundan dolayı, birincil kullanıcının işareti hakkında ön bilgiye ve tespit edilmesi beklenen sinyalin demodülasyonunu gerektirir. Yani bu da işaretin modülasyon tipi, bant genişliği, taşıyıcı frekansı gibi bazı parametlerin bilinmesi gerektiği anlamına gelmektedir. Bütün sinyal tipleri için bahsedilen verilerin tutulup, sinyal tespiti için işlenmesi beraberinde yüksek maliyetleri getirmektedir. Bilişsel radyonun her birincil kullanıcı sınıfı için özel bir alıcıya ihtiyaç duyması bu filtreleme yönteminin en önemli dezavantajları arasındadır. Ayrıca işaret hakkında edinilen bilginin eksikliği de başarımı düşürmektedir. Uyumlu filtrelemenin hesaplama karmaşıklığı yüksek olduğundan enerji tüketimi de yüksektir. Denklem (4.8)'de verilen karar testi ile işaretin spektrumdaki varlığı tespit edilebilir. $y(n)$ alınan işareti, $x(n)$ ise kullanıcı işaretini göstermektedir.

$$\begin{cases} H_0, & \text{eğer } \sum_{n=1}^N y(n) * x(n) \leq \lambda_E. \\ H_1, & \text{dışında} \end{cases} \quad (4.8)$$

Neyman – Pearson kriteri (Paysarvi-Hoseini ve Beaulieu, 2011) temel alınarak sezim ve yanlış alarm olasılıkları aşağıdaki verilen Denklem (4.9) ve Denklem (4.10)’da sırasıyla ifade edilmiştir.

$$P_d = Q\left(\frac{\lambda_E - E}{\sqrt{E\sigma_w^2}}\right). \quad (4.9)$$

$$P_{fa} = Q\left(\frac{\lambda_E}{\sqrt{E\sigma_w^2}}\right). \quad (4.10)$$

Denklemden kullanılan E kullanıcı işaretinin enerjisini, λ_E sezim eşikini ve σ_w^2 ise gürültü varyansını ifade etmektedir. Yanlış alarm olasılığına bağlı sezim eşikliği Denklem (4.11)’de verilmektedir.

$$\lambda_E = Q^{-1}(P_{fa})\sqrt{E\sigma_w^2}. \quad (4.11)$$


4.3. Çevrimsel Durağan Sinyal Analizi

Hayatımızdaki sinyallerin çoğu durağan değildir ancak sinyaller durağanmış gibi istatistiksel sinyal işleme yöntemleri uygulanır. Bu nedenden dolayı sinyalleri karakterize eden bu periyodiklikler göz ardı edilebilir. Çevrimsel durağan sinyal algılama, alınan sinyallerin periyodik özelliklerinden yararlanarak birincil kullanıcı iletimini tespit etmek için kullanılan bir yöntemdir (Kim vd., 2007). Çevrimsel durağan model, sinyal işlemcilerin performansını arttırmak için rastgele sinyalin, periyodik olarak zaman alanında değişen istatistiksel parametreler kullanılarak modellenir. Modelin bir sonucu olarak işlemci, altta yatan sinyal periyodikliklerini tespit etmeyi mümkün kılar. Çevrimsel durağan sinyal işlemeyi kullanarak iletişim teorisindeki sinyallerin veya darbelerin modülasyonu, sabit rastgele dalga üzerinde Doppler etkisi ve

mevsimsel etkileri gösteren atmosferik veri kümeleri daha iyi analiz edilebilir (Akyıldız vd., 2006). Çevrimsel durağan sinyal analizi, sinyallerin ve bunların modülasyon tiplerinin gürültü veya girişim varlığında algılanmasını sağlar. Ayrıca çevrimsel durağan yaklaşımlar taşıyıcı fazı, varış yönünü, rastgele sinyalin gelecekteki değerini kestirmeye imkan tanımaktadır (Yücek ve Arslan, 2009).

5. YAPAY ZEKA YÖNTEMLERİ

Yapay zeka (artificial intelligence, AI), bir makineye bilişsel bir yetenek kazandırmak olarak tanımlanmaktadır. YZ konseptinin amaçları öğrenme, akıl yürütme ve algılamayı içerir. Günümüzde YZ, birçok farklı sektöre fayda sağlamak için sürekli olarak geliştirilmektedir. YZ, makine öğrenmesi ve derin öğrenme konseptleri aşağıdaki şekilde (Şekil 5.1) gibi ilişkilendirilebilir.



Şekil 5.1. Yapay zeka, makine öğrenmesi ve derin öğrenme ilişkisi


YZ genellikle herhangi bir bilgisayar sisteminde bir simülasyon parçası olarak taklit edebileceği bir süreci takip eder (Mueller ve Massaron, 2018):

1. İhtiyaçlara veya isteklere göre bir hedefin belirlenmesi.
2. Hedefi desteklemek için bilinen herhangi bir bilginin değerlendirilmesi.
3. Hedefi destekleyebilecek ek bilgiler toplayın.
4. Verilerin mevcut bilgilerle tutarlı bir forma ulaşacak şekilde ayarlanması.
5. Mevcut ve yeni bilgiler arasındaki ilişkilerin ve doğruluk değerlerinin tanımlanması.
6. Hedefe ulaşıp ulaşılmadığının belirlenmesi.
7. Hedefin, yeni veriler ve başarı olasılığı üzerindeki etkisi ışığında ayarlanması.

Hedefe ulaşılan (doğru olarak bulunana) veya başarıma olasılıkları tükenene (yanlış olarak bulunana) kadar adım 2 ila 7'nin tekrarlanması.

5.1. Makine Öğrenmesi

Makine öğrenmesi, istatistiksel yöntemler kullanarak kendisine sunulan veri setleri ve parametreler ile benzetimler yaparak tespitlerde bulunan, kendi kendini eğitebilen yapay zekanın alt kümesi olarak bilinen sistemlerdir (Alpaydin, 2020). Makine öğrenmesi eğitimi mevcut verilere dayalı olarak tahmin yapmaya odaklanır. Dört alt bölüme ayrılmaktadır. Bu alt bölümler altında makine öğrenimi hedeflerine ulaşmak için kullanılan çeşitli algoritmalar bulunmaktadır. Şekil 5.2'de makine öğrenmesinin alt kümeleri gösterilmektedir.




Şekil 5.2. Makine öğrenmesi alt kümeleri

5.1.1. Denetimli öğrenme

Denetimli öğrenme, verilerin zaten doğru cevaplarla etiketlendiği kategorilerde sınıflandırıldığı bir öğrenme türü olarak tanımlanır. Denetimli öğrenme aynı zamanda tahmini öğrenme hedefi olarak girdi ve çıktı arasındaki ilişkiyi anlamaktır, böylece yeni gelen verileri tahmin veya kategorize edebilir (Caruana ve Niculescu-Mizil, 2006). Denetimli öğrenme problemleri veya algoritmaları iki ana kategoriye ayrılır.

Regresyon: Doğrusal ilişki içindeki veriler ve etiketleri arasındaki sürekli değişkenlerin değerlerini tahmin etme sürecidir.

Sınıflandırma: Verileri iki ya da daha fazla belirli etikete ayırma ya da tahmin etme sürecidir. En çok kullanılan makine öğrenmesi tekniği olarak düşünülmektedir.



Şekil 5.3. Sırasıyla regresyon ve sınıflandırma

5.1.2. Yarı denetimli öğrenme

Yarı Denetimli öğrenme, bazı verilerin kategorize edildiği ve etiketlendiği, geri kalanının etiketsiz olduğu bir öğrenme türü olarak tanımlanır. Bu, algoritmaların etiketli verilerden öğrenebildiği ve bilgileri etiketlenmemiş verilere uygulayabildiği denetimli öğrenme ve denetimsiz öğrenme arasında bir bağlantıdır (Zhu ve Goldberg, 2009).

5.1.3. Denetimsiz öğrenme

Denetimsiz öğrenme, verilerin etiketlenmediği veya sınıflandırılmadığı, algoritmaların veya öğrenen kimsenin veriler üzerinde rehberlik olmadan hareket ettiği bir öğrenme türü olarak tanımlanır (Fritzke, 1994). Açıklayıcı bir öğrenme hedefi olarak bilinen denetimsiz öğrenme, daha önce herhangi bir eğitim almadan verilerdeki yeni modelleri veya ilişkileri bulmak veya tasarlamaktır.

Denetimsiz öğrenme problemleri/algorithmaları iki ana alanda tanımlanmaktadır:

Kümeleme: Verileri yeni alt gruplardaki verilerin birbirine benzediği ve diğer gruplardaki verilerden farklı olduğu alt gruplara gruplama veya bölme işlemidir.

Birliktelik: Veri kümesindeki birlikteliği açıklayan bir kural bulmak için kullanılan bir algoritmadır.

5.1.4. Takviyeli öğrenme

Takviyeli öğrenme, ajanı bir dizi operasyona koymaya, gözlemlemeye, ödüllendirmeye ve politika olarak da bilinen uygun bir yol veya öngörüye sahip olana kadar doğru yolu tahmin etmeye çalışan bir makine öğrenmesi yöntemidir (Kaelbling vd., 1996).


5.2. Derin Öğrenme

Derin öğrenme; yapay sinir ağlarına dayanan makine öğrenmesinin bir alt kümesidir. Verilen bir veri kümesi ile birçok katmanda makine öğrenmesinde kullanılan hesapları yapabilen, tanımlanması gereken verileri kendi kendine öğrenerek çıktıları tahmin edebilen sistemlerdir (LeCun vd., 2015).

5.2.1. Evrişimsel sinir ağları (CNN)

Evrişimli sinir ağı, bir girdi görüntüsünde yer alan, görüntüdeki çeşitli yönlerde/nesnelere önem (öğrenilebilir ağırlıklar ve sapmalar) atayabilen ve birini diğerinden ayırt edebilen bir derin öğrenme algoritmasıdır. Yani; evrişimli sinir ağları görüntü kümeleri için sınıflandırma ve tanıma amaçlı kullanılmaktadır. Özellik çıkarma ve sınıflandırma olmak üzere iki aşamadan oluşmaktadır. Evrişimsel sinir ağları, görüntüyü çeşitli katmanlar ile işler. Özellik çıkarımında, bir evrişimsel katmanı bir havuzlama katmanı takip eder.

Sınıflandırma aşaması tamamen bağlı bir katman ile sonlandırılır. Evrişim katmanında özellik haritasının çıkarılması için, matris olarak temsil edilen girdi üzerinde farklı filtreler ile evrişim işlemi gerçekleştirilir. Bu iki boyutlu evrişim işleminden sonra, evrişim tabakasını havuzlama tabakası izler. Havuzlama tabakasında, işlemsel karmaşıklık ve eğitim süresi azaltılır. Ayrıca aktivasyonları özellik konumlarına daha az duyarlı hale getirilerek ezberlemenin (overfitting) önüne geçilir. Sonrasında, havuzlama katmanının çıktısının düzleştirilmesi için veriler düzleştirme katmanına gönderilir. Düzleştirme katmanı verileri tek boyutlu matris haline getirerek bağlı katman için hazırlar. Sınıflandırma işlemi tamamen bağlı katmanda gerçekleştirilir. Ayırt edici özelliklerin çıkarılması için genelde evrişim katmanından sonra bir aktivasyon fonksiyonu kullanılmaktadır. Yoğun katman çıkışında softmax aktivasyon işlemi ile test girdisinin her bir sınıfa benzerliği için sınıfa ait ardıl olasılık değeri hesaplanır. Böylelikle bu ardıl olasılıklar kullanılarak alınan işaretin sınıfına karar verilir (Lawrence vd., 1997).



Şekil 5.4. Evrişimsel sinir ağı genel blok diyagramı

5.2.1.1. Evrişimsel sinir ağı katmanları

Evrişimsel Sinir Ağı, görüntü tanıma ve görüntü sınıflandırma konusunda birçok alanda önemli atılımlar sağlayan yapay sinir ağının bir alt türü olarak kabul edilir. Evrişimsel sinir ağı, beyin mimarisini görüntü bulma ve keşfetme davranışında simüle eden bir algoritmadır. Evrişimsel sinir ağı, bu hedefe ulaşmak için bir dizi farklı katman ve bileşen içerir. Bu katmanlar ve özellikleri aşağıda açıklanmıştır.


5.2.1.1.1. Evriřim katmanı (Convolutional layer)

Evriřim katmanı, evriřim ağı yapısının ana bloęu olarak temsil edilir. İleri beslemeli bir sinir ağıdır ve bu katman ağıdaki ana hesaplamalardan sorumludur. Evriřim katmanı giriş görüntüsünden özellik çıkarımı için kullanılır. Temel bileřeni olarak öğrenilebilir çekirdeklere dayanır. Ařağıdaki örnek evriřim katmanı çalışma kriterlerini açıklamaktadır.

Öncelikle belirli bir filtre tanımlanır. Bu filtre, filtre ve girişte verilen görüntünün parçaları arasında nokta çarpımı kullanılarak yeni bir filtre oluşturmak için tüm görüntünün üzerinde kaydırılır. Böylelikle özellik çıkarımı yapılır. Birden çok özellik için birden çok filtre kullanılır. Çıktı, yeni bir skaler görüntüdür. Filtreyi tüm resme uyguladıktan sonra ortaya çıkan çıktı, özellik haritası olarak adlandırılır.

5.2.1.1.2. Havuzlama katmanı (Pooling layer)


Evriřimsel sinir ağı genel mimarisinde bir sonraki adım havuzlama katmanıdır. Bu katman boyutsallığın azaltılması, hesaplama karmařıklığı ve modeldeki parametrelerin toplam sayısının en aza indirilmesinden sorumludur. Genel olarak, ortalama havuzlama ve maksimum havuzlama katmanları popüler ve kullanım açısından kabul edilen iki temel yaygın katmandır. Ortalama havuzlama, özellik sayısının bir dikdörtgen řekline ařağı örneklenmesi ve belirli bir piksel miktarı için orijinal formun deęerlerinin ortalaması alınarak yapılır. Öte yandan, maksimum havuzlama, dikdörtgen řeklindeki maksimum deęeri kullanarak hacmi ařağı örnekleyerek özelliklerin sayısını ve boyutunu azaltır.



Şekil 5.5. Maksimum ve ortalama havuzlama katmanı

5.2.1.1.3. Seyreltme katmanı (Dropout layer)

Ağ gittikçe derinleşirken, parametre miktarı da artmaktadır. Bu muazzam parametre sayısı modele fazla takılma şansı verir. Genel olarak bakıldığında ezberleme (overfitting) aşırı uyum, yani modelin hatırlaması, verilerden öğrenmediği anlamına gelmektedir. Seyreltme katmanı, ezberlemenin azaltılmasına yardımcı olan katman olarak düşünülmektedir. Adı üzerinde eğitim aşamasında belirli sayıda düğümü keserek, öğrenme aşamasında ağın her seferinde aynı yolları izlemesini önlemeye yaramaktadır. Seyreltme katmanı düğümü seyreltme oranına göre rastgele düşürmektedir. Seyreltme oranı değeri, eğitim aşamasında belirli sayıdaki düğümü kesmek için kullanılan 0-1 arasındaki bir değerdir.



Şekil 5.6. Seyreltme oranı 0.5 olan bir seyreltme katmanı örneği

5.2.1.1.4. Düzleme katmanı (Flatten layer)

Bu katmanın görevi, önceki katmanlardan gelen çok boyutlu verileri yoğun katman için tek boyutlu olarak hazırlamaktır. Çünkü yoğun katman verileri tek katmandan alıp işleyebilmektedir.

5.2.1.1.5. Yoğun katman (Fully connected layer)


Evrişimli sinir ağındaki son katman yoğun katman olarak da adlandırılan tam bağlantılı katmandır. Yoğun katman, modelden yüksek seviye özellikler çıkarılarak girdinin farklı kategorilere sınıflandırılmasından sorumludur. Yoğun katman, düzleme katmanından gelen tek sıralı verileri, ağdan gerçekleştirilen göreve göre göre belirlenen bir aktivasyon fonksiyonu kullanarak etiketlemekten sorumludur.

5.2.1.1.6. Aktivasyon fonksiyonları (Activation functions)

Aktivasyon fonksiyonları, girdinin toplam ve sapma hesaplamasını yaparak buna karşılık üretilecek olan çıkış bilgisinin belirlenmesini sağlayan fonksiyondur. Aktivasyon fonksiyonları doğrusal ve doğrusal olmayan fonksiyonlar olarak sınıflandırılır.

5.2.2. Derin sinir ağları için bilgi işlem kütüphanesi (CLDNN) mimarisi

Tekrarlayan Sinir Ağlarının (RNN), önceki durum bilgilerini mevcut göreve bağlayabilmeleri nedeniyle zaman alanlı veri işleme görevleri için güçlü bir araç sağladığı kanıtlanmıştır. CLDNN mimarisinde çalışma (Sainant vd., 2015)'den esinlenerek, CNN mimarisine bir LSTM katmanı eklenmektedir. CLDNN için düşünülen ayrıntılı mimari Şekil 5.7'de gösterilmektedir. Ekstra LSTM katmanı, CNN katmanları ile yoğun katmanlar arasına yerleştirilmektedir.




Şekil 5.7. CLDNN mimarisi

5.2.3. LSTM mimarisi

Rajendran vd. (2018)'nin çalışmasındaki yazarlar tamamı ile LSTM mimarisine dayanan bir sınıflandırma modeli önermişlerdir. Bu ağın tasarımı, CLDNN'deki

benzer sezgilere dayanmaktadır, yani LSTM, zaman serisi veri işleme görevlerindeki uzun vadeli bağımlılıkları öğrenmede etkilidir. Bununla birlikte, CLDNN'den farklı olarak, LSTM evrişimli katmanlara sahip değildir. Bu mimari, diğer tüm mimariler için kullanılan dikdörtgen form yerine, girdi örneklerini polar formda alır. Polar form gösterimi, her bir örnekleme zamanı adımında giriş I/Q numunesinin genliği ve fazının hesaplanmasıyla elde edilir. Daha sonra, farklı modülasyon şemalarının genlik ve faz özelliklerinin zamansal bağımlılıklarını çıkarmak için her biri 128 hücreli iki LSTM katmanı kullanır. İkinci LSTM katmanının çıktısını son olasılık çıktı alanına yansıtmak için son gizli katman olarak Softmax aktivasyon fonksiyonlu yoğun bir katman kullanır.



Şekil 5.8. LSTM mimarisi

5.2.4. ResNet mimarisi

Sinir ağıları derinleştikçe, öğrenme performansları, degrade ve patlatma ve aşırı sığdırma gibi problemlerle karşı karşıya kalmıştır ve bu nedenle, ağ belirli bir derinliğe ulaştıktan sonra derin bir sinir ağı için hem eğitim hem de test doğruluğu azalmaya başlar. Test doğruluğunun bozulması, derin bir sinir ağındaki ekstra karmaşıklık nedeniyle aşırı sığdırma sorunundan kaynaklanır. Ve eğitim doğruluğunun bozulması, optimize ediciyi maliyet işlevinin yeterince iyi bir yerel minimum değerine yaklaşmak için daha az uygulanabilir hale getiren degrade kaybindan kaynaklanmaktadır.

ResNet mimarisi ilk olarak ImageNet ve COCO 2015 yarışmalarında tanıtılmıştır (He vd., 2016). ResNet daha derin sinir ağlarındaki doğruluk bozulması sorunlarını çözer ve çok çeşitli makine öğrenimi görevleri için sağlam bir seçim olduğu gösterilmiştir.


Çizelge 5.1. ResNet mimarisi

Katman	Çıkış Boyutları
Giriş	2 x 128
Artık (Residual) Katman	32 x 64
Artık (Residual) Katman	32 x 32
Artık (Residual) Katman	32 x 16
Yoğun Katman (FC) / ReLU	128
Yoğun Katman (FC) / ReLU	128
Yoğun Katman (FC) / Softmax	10

6. SİSTEM MODELİ

6.1. Spektrum Seziminde Derin Öğrenme Metotlarının Karşılaştırılması


Bu çalışmada CLDNN, LSTM, ResNet ve CNN tabanlı sezicilerin değişen işaret uzunluklarında sezim ve yanlış alarm olasılıkları bulunarak, 1024 işaret uzunluklarındaki bulunan sonuçlar karşılaştırılmıştır. Eğitim sırasında kullanılan veri seti her gözlem uzunluğu için ve her SNR değeri için 1000 gürültü ve 1000 BPSK işareti içermektedir. Eğitim sırasında -10dB ile 5dB SNR değerleri arasında 0.5dB adımlarla oluşturulmuş işaretler kullanılmıştır. Mümkün olduğunca P_{fa} 'ya ait kestiriminin hassas olması için her bir SNR değerinde 10000 gürültü ve 10000 BPSK işareti kullanılmıştır.



Şekil 6.1. CLDNN tabanlı sezicinin değişen işaret uzunluklarında sezim ve yanlış alarm olasılıkları

Şekil 6.1'deki CLDNN tabanlı seziciye bakıldığında artan SNR değerinde tüm uzunluktaki işaretler için sezim olasılığı da artmaktadır. En iyi sonuç, 1024 gözlem uzunluğundaki işarete görülmüştür.

Yanlış alarm olasılığı ise yine artan SNR değerinde azalmaktadır. İşaret uzunluklarının yanlış alarm olasılık değerlerini karşılaştırdığımızda ise, 512 ve 1024 uzunluktakilerin birbirine yakın olup en iyi sonucu verdiği şekilden görülebilmektedir.




Şekil 6.2. LSTM tabanlı sezicinin değişen işaret uzunluklarında sezim ve yanlış alarm olasılıkları

Şekil 6.2'deki LTSM tabanlı seziciye baktığımızda artan SNR değerinde tüm uzunluktaki işaretler için sezim olasılığı önce biraz azalıp sonra artmaktadır. Şekilden de görüleceği üzere 128 uzunluktaki işaret en iyi sonucu vermektedir.

Yanlış alarm olasılığına bakılacak olursa, artan SNR'da tüm gözlem uzunluğundaki işaretler yaklaşık aynı oranda başlayıp azalarak 0 olasılığına


ulaşmıştır. Ancak yine şekilden görüldüğü üzere en iyi sonucu 128 gözlem uzunluklu işaretle gözlenmiştir.



Şekil 6.3. ResNet tabanlı sezicinin değişen işaret uzunluklarında sezim ve yanlış alarm olasılıkları


Şekil 6.3'teki ResNet tabanlı seziciye baktığımızda artan SNR değerinde farklı uzunluktaki işaretler için sezim olasılıkları değişimi birbirinden farklı değişim göstermektedir. En düşük sezim olasılığı 1024 uzunluktaki işaretle gözlenirken, 128 ve 256 uzunluktaki işaretler birbirine çok yakın sonuçlar vermiş olup, çok az bir fark ile 128 uzunluktaki işaretin sezim olasılığı daha yüksektir.

Yanlış alarm olasılığı şekilden de görüldüğü üzere, artan SNR'da azalan bir eğilim göstermiştir. 128 ve 256 uzunlukta işaretler birbirinize yakın bir grafik çizerken, en iyi sonuç 1024 uzunluktaki işaretle gözlenmiştir.



Şekil 6.4. Farklı özniteliklerinin kullanımının model başarımına etkisi


CNN tabanlı seziciye ait sezim ve yanlış alarm performansını incelemek için Bölüm 5.2.1’de detayları verildiği üzere bir test prosedürü ele alınmıştır. Dört farklı öznitelik olan otokorelasyon, genlik-faz, FFT ve I/Q kullanılarak test edilen model başarımının sonucunda, Şekil 6.4’te görüldüğü üzere I/Q en iyi sonucu verdiği için daha sonra verilecek olan çalışmalarda CNN sonuçları alınırken bu öznitelik kullanılmıştır. Otokorelasyon ve FFT öznitelikleri herhangi bir SNR değerinde işaret ile gürültüyü ayıramaktadır. Bu nedenle Şekil 6.4’te görüldüğü üzere CNN modelinin iki sınıflı bir sınıflandırma işleminde gösterebileceği minimum performans olan %50’yi aşamamaktadır. Öte yandan genlik-faz matrisi girdi olarak kullanıldığında ancak 4 dB SNR değerinden sonra %90 başarıma ulaşabilmektedir. Alınan işaretler herhangi bir ön işleme tabi tutulmadan girdi olarak kullanıldığında model başarımının yüksek olduğu görülmektedir. Bu durumda ön sinyal işleme metodları uygulanmamaktadır. Böylece hesaplama maliyeti diğer özniteliklere göre daha düşük olmaktadır. Bunun yanı sıra sezim başarımı diğerlerine kıyasla ciddi ölçüde yüksektir.



Şekil 6.5. CNN tabanlı sezicinin değişen işaret uzunluklarında sezim ve yanlış alarm olasılıkları


CNN tabanlı seziciye ait sezim ve yanlış alarm performansını incelemek için Bölüm 5.2.1’de detayları verildiği üzere bir test prosedürü ele alınmıştır. Enerji sezicilerin aksine gözlem uzunluğunun artışıyla birlikte sezim performansı hakkında doğrudan yorum yapılması pek mümkün olmamaktadır. Çünkü gözlem uzunluğu ve SNR değerinin değişimiyle beraber P_{fa} ’da da değişiklik olmaktadır. Bu durum, Şekil 6.5’te açıkça görülmektedir. Ama şu söylenebilir ki gözlem uzunluğunun artmasıyla birlikte P_{fa} daha kabul edilebilir bir seviyeye inmekte ve sezici, alınan işaretin karakteristiği hakkında daha çok bilgi üretebilmektedir. Böylece, sezim performansı enerji sezicilerde görüldüğü gibi gözlem uzunluğuna bağlı olarak sezim olasılığının doğrudan değişimi, belli bir gözlem uzunluğundan sonraki artışlarda görülebilir. Gözlem uzunluğu ve SNR arttıkça sezicinin yanlış alarm üretme olasılığı düşmektedir. 1024 gözlem uzunluğu için bu olasılık tüm SNR değerlerinde sıfıra yakınsamaktadır.

6.1.1. Test sonuçları




Şekil 6.6. 1024 uzunluklu işaretler için CNN, CLDNN, LSTM ve ResNet sezicilerinin sezim olasılıklarının karşılaştırılması

Şekil 6.6’da 1024 uzunluklu CNN, CLDNN, LSTM ve ResNet sezicilerinin sezim olasılıkları karşılaştırılmıştır. LSTM yükselen SNR değerinde önce azalan sonra artan bir grafik çizerek en yüksek sezim olasılığı yaklaşık olarak 0.85’tir. ResNet’e bakılacak olursa 0.7 sezim olasılığından başlayıp, LSTM’e benzer olarak 0.85’lere kadar çıkabilmiştir. CLDNN sezici diğer sezicilere kıyasla -10dB SNR’da yaklaşık 0.6 olasılık ile en düşük performansı göstermiştir. Ancak -3dB’de sezim olasılığı 1’e ulaşmıştır. CNN ise grafikten de görüleceği üzere, 0.7’lerde başlayıp, yaklaşık -7dB SNR’da sezim olasılığı 1’e ulaşip bu seziciler arasındaki en iyi performansı göstermiştir.



Şekil 6.7. 1024 uzunluklu işaretler için CNN, CLDNN, LSTM ve ResNet sezicilerinin yanlış alarm olasılıklarının karşılaştırılması

Şekil 6.7'de 1024 uzunluklu CNN, CLDNN, LSTM ve ResNet sezicilerinin yanlış alarm olasılıkları karşılaştırılmıştır. Grafikten de görüleceği üzere LSTM ve ResNet sezicileri, CNN ve CLDNN sezilere kıyasla düşük SNR seviyelerinde daha yüksek yanlış alarm (P_{fa}) değerine sahiptirler. LSTM ve ResNet sezicilerde 1-2dB SNR arasında bu değer 0'a yaklaşmaktadır. CNN ve CLDNN sezicilere bakılacak olduğunda ise, bu iki sezicinin yanlış alarm değerlerinin birbirine çok yakın olduğu görülmektedir. Ancak grafiğe daha yakından bakıldığında, CLDNN sezicinin yanlış alarm oranının, CNN'e göre biraz daha düşük olduğu görülmektedir.



Şekil 6.8. Derin öğrenme yöntemlerinin zaman tüketimi, bellek kullanımı, sezim olasılığı ve yanlış alarm olasılığı açısından karşılaştırılması

Şekil 6.8’de görüldüğü üzere eğitim sırasında normalize edilen epok sayısı ve bellek kullanımı sonuçları ile testte görülen ortalama sezim olasılığı ve ortalama yanlış alarm oranları verilmiştir. Burada normalize değerler verilerek donanım bağımsız karşılatırılma yapılması amaçlanmaktadır. Sonuçlardan da görüleceği üzere, bu tez çalışmasında tasarımı yapılp önerilen CNN sezici, düşük epok sayısı ve bellek kullanımı oranı, yüksek ortalama sezim olasılığı ve düşük ortalama yanlış alarm olasılığı sonuçları ile derin öğrenme yöntemleri arasında en iyi sonucu veren model olmuştur.

6.2. Spektrum Seziminde Enerji Sezici ve Evrişimsel Sinir Ağının (CNN) Karşılaştırılması

Bu çalışmada kullanılan CNN modeli daha önceki çalışmalarımızda modülasyon sınıflandırma amaçlı tasarlanan modelin Tekbıyık vd. (2019)’nin çalışmalarının bir benzeridir. Model, açık kaynak kodlu makine öğrenmesi kütüphanesi olan Keras kullanılarak oluşturulmuştur. Önerilen CNN modeli iki yoğun katman ile sonlandırılmakta ve ayrıca dört adet evrişim ve havuzlama katmanı

içermektedir. (6.1)'de ifade edilen doğrultulmuş doğrusal birim (rectified linear unit, ReLU) aktivasyon fonksiyonu,

$$x_{out} = \max(0, wx_{in} + b), \quad (6.1)$$

her evrişim katmanında kullanılır. (6.1)'de bulunan x_{in} , x_{out} , w ve b sırasıyla denklemin girdi ve çıktıları, ağırlık ve bias değişkenlerini ifade etmektedir. Bu model, her evrişim katmanındaki filtre sayısı açısından, model çıkarma kısmının sonuna kadar daralacak şekilde seçildi. Birçok farklı konfigürasyonla ilgili deneyimlerim, aşağıdaki her bir evrişimli katmanda daralan modellerin, sınıflandırma ve eğitme süresinin azalması açısından daha iyi sonuçlar verdiğini gösterdi. Aslında, ideal performans için, son katman 64 adet filtreye sahipken, birinci katmanda 256 adet filtre kullanıldı. İlk yoğun katman, 128 nöron ve ReLU aktivasyon katmanı tarafından oluşturuldu. Yoğun katmanı, her sınıf için olasılıkları, (6.2) ile hesaplayan bir softmax aktivasyon katmanı takip eder:

$$S(y_i) = \frac{e^{y_i}}{\sum_j e^{y_j}}, i, j = 1, 2, \dots, L, \quad (6.2)$$

y_i ve L sırasıyla sınıfların herhangi bir elemanını ve sınıf sayısını göstermektedir. Dahası, uyarlanabilir moment tahmini (adaptive moment estimation, ADAM) iyileştiricisi, model parametrelerini öğrenme oranı ile tahmin etmek için kullanılır. CNN model mimarisi, Şekil 6.9'da gösterilmiştir. Ayrıca, önerilen CNN modeli için yapılan tasarım Çizelge 6.1'de verilmiştir. Eğitim süreci boyunca, eğer validasyon kaybı yeterli seviyeye yaklaşırsa, süreci sonlandırmak için erken sonlandırma kullanılmaktadır. Sonuç olarak model, uyum göstermesi için korunur. Eğitim ve test adımlarında, NVIDIA GTX 1070 grafik işlem birimi (graphic processing unit, GPU) kullanılmıştır.


Alınan işaret vektörünü, y , kendisinin dikgen bileşenleri cinsinden ifade etmek mümkündür:

$$y = I + jQ. \quad (6.3)$$

Dikgen bileşenlerin ayrıştırılması ile elde edilen

$$X_{in} = \begin{bmatrix} I \\ Q \end{bmatrix} \quad (6.4)$$

matrisi CNN modeline giriş olarak beslenir. N uzunluklu gözlem için X_{in} matrisi $2 * N$ boyutludur. Eğitim sırasında kullanılan veri seti her gözlem uzunluğu için ve her SNR değeri için 1000 gürültü ve 1000 BPSK işareti içermektedir. Eğitim sırasında -10dB ile 5dB SNR değerleri arasında 0.5dB adımlarla oluşturulmuş işaretler kullanılmıştır. Test sırasında ise her bir SNR değeri (toplamda 31 farklı değer) için eğitilen model üzerinden ayrı ayrı test işlemi gerçekleştirilmiştir. Mümkün olduğunca P_{fa} 'ya ait kestiriminin hassas olması için her bir SNR değerinde 10000 gürültü ve 10000 BPSK işareti kullanılmıştır. Bu durumda ölçülebilecek en küçük P_{fa} değerinin 10^{-4} olacağı aşıkardır.



Şekil 6.9. CNN modelinin mimarisi

Çizelge 6.1. Kullanılan CNN modelinin katmanlarının çıkışında gözlenen veri boyutları.


Katmanlar	Çıkış Boyutları
Evrişim Katmanı1	$2 * N * 256$
Maks. Havuzlama Katmanı1	$2 * (N / 2) * 256$
Seyreltme	$2 * (N / 2) * 256$
Evrişim Katmanı2	$2 * (N / 2) * 128$
Maks. Havuzlama Katmanı2	$2 * (N / 4) * 128$
Seyreltme	$2 * (N / 4) * 128$
Evrişim Katmanı3	$2 * (N / 4) * 64$
Maks. Havuzlama Katmanı3	$2 * (N / 8) * 64$
Seyreltme	$2 * (N / 8) * 64$
Evrişim Katmanı4	$2 * (N / 8) * 64$
Maks. Havuzlama Katmanı4	$2 * (N / 16) * 64$
Seyreltme	$2 * (N / 16) * 64$
Düzleştirme	$1 * (2 * (N / 16) * 64)$
Yoğun Katman1	$1 * 128$
Yoğun Katman2	$1 * 2$

*N işaret uzunluğudur.

6.2.1. Test sonuçları


Öncelikle geleneksel enerji sezicilere ait sezim performansını incelemek yerinde olacaktır. Bu bölümde işaret olarak BPSK kullanılmaktadır. Bölüm 4.1’de detaylandırıldığı gibi belirlenen bir eşik yardımıyla spektrumda işaret varlığı kestirilmektedir. Gözlem uzunluğu arttıkça işaret gücü ve gürültü varyansı daha yüksek hassasiyetle kestirilebilmektedir. Bu nedenle işaret uzunluğu arttıkça sezim olasılığının artması beklenmektedir meğerki SNR duvarına ulaşılmamış olsun (Tandra ve Sahai, 2018). Farklı gözlem uzunluklarında enerji seziciye ait sezim olasılıkları, Şekil 6.10’da verilmektedir. Beklendiği üzere gözlem uzunluğu arttıkça sezim performansı iyileşmektedir. Burada CFAR sezici tasarımı kullanılmış olup seziciye ait P_{fa} , 10^{-2} olarak belirlenmiştir. Gürültü varyansının

hatasız kestirildiği varsayılmış olup, bu sonuçlar verilen gözlem uzunluklarında enerji seziciler için optimumdur.




Şekil 6.10. Değişen işaret uzunluğuna göre enerji sezicinin performansı ($P_{fa} = 10^{-2}$)

Adil bir karşılaştırma yapabilmek için CNN seziciye ait P_{fa} değerlerinin enerji sezicide kullanılması sonucu sezim performansı incelenmiştir. Bu duruma ait sonuçlar Şekil 6.11'de verilmektedir. Artık burada CFAR sezici kullanılmamakta Şekil 6.5'te görülen P_{fa} değerleri ile eşik hesaplanmaktadır. P_{fa} 'daki artış sezim olasılığının artmasına sebep olmaktadır.



Şekil 6.11. CNN sezicinin sahip olduğu yanlış alarm olasılıklarında enerji sezicinin sezim performansı



Şekil 6.12. CNN sezicinin sahip olduğu yanlış alarm olasılığında 1024 uzunluklu işaretler için her iki sezicinin sezim olasılıklarının karşılaştırılması

Örneğin, gözlem uzunluğunun 256 olduğu durum için P_{fa} 'nın 10^{-2} olduğu CFAR seziciye kıyasla P_{fa} 'nın 0.2 olduğu -10dB SNR'da sezim olasılığı daha yüksektir. Şekil 6.12'de enerji sezici ile CNN tabanlı sezicinin aynı yanlış alarm olasılıklarında sezim başarımlarına ilişkin sonuçlar verilmektedir. Sonuçlar CNN tabanlı sezicilerin enerji tabanlı sezicilere kıyasla bir miktar daha iyi performans gösterdiğini ortaya koymaktadır. Fakat daha düşük P_{fa} istenilirse bu durumda gürültü varyansının hatasız kestirilmesi şartıyla enerji sezicilerin performansı daha yüksek olmaktadır. Gürültü varyansının hatalı kestirildiği durumlarda enerji sezicinin performansı düşmektedir.

CNN tabanlı sezici gürültü varyansının kestirilmesine olan bağımlılığı ortadan kaldırıp bir işaret kümesi üzerine bağımlılık oluşturmaktadır. İşaret seti bu çalışmada -10dB ile 5dB arasında belirlenmiş olup adım aralığı 0.5dB'dir. Böylece, CNN sezici alınan işaret için gürültü varyansının kestirilmesine olan ihtiyacı ortadan kaldırmakta ve özellikle Gauss dağılımlı işaret üreten jammer veya girişim kaynakları varlığında sezim performansında ciddi kayıplar yaşanmasının önüne geçilmesine olanak sağlamaktadır. Unutulmamalıdır ki, jammer veya girişim kaynakları birincil ve ikincil kullanıcılar tarafından gürültü olarak düşünülebilir. Bu açıdan bakıldığında hareketli (veya çıkış gücünün zamanla değiştiği bir durumda) bir jammer veya girişim kaynağı nedeniyle gürültü tabanı zamanla değişmektedir. Böyle bir durumda daha önceden kestirilen gürültü varyansının kullanılması durumunda enerji seziciler ciddi anlamda performans kaybı yaşayabilmektedir. Fakat CNN sezici gürültü varyansı yerine farklı SNR'lara ve dolayısıyla gürültü varyanslarına duyarlı bir işaret setine bağımlılık oluşturduğu için bu tip durumlardan daha az etkilenmesi beklenmektedir.

6.3. Enerji Sezici ve CNN'in Gerçek Veriler Kullanılarak Karşılaştırılması

Tez çalışmasının bu bölümüne kadar sentetik veriler kullanılarak ölçüm yapılmıştır. Ancak bu bölümde gerçek veriler kullanılarak ölçüm alınmış ve sentetik veriler ile alınan ölçüm sonuçları ile karşılaştırılmıştır. Ölçüm alınırken verici olarak Şekil 6.13'te gösterilen Rohde Schwarz SMC100A, alıcı olarak ise


Şekil 6.14'te gösterilen Rohde Schwarz FSW26 cihazları kullanılmıştır. Ölçüm sonuçları laboratuvar ortamında kablo ile adaptif olarak SNR değiştirilerek alınmıştır.



Şekil 6.13. Rohde&Schwarz SMC100A sinyal üreteci




Şekil 6.14. Rohde&Schwarz FSW26 sinyal ve spektrum analizörü




Şekil 6.15. Değişen işaret uzunluğuna göre enerji sezicinin gerçek veriler ile yapılan ölçüm sonuçlarının performansı

Şekil 6.15'te görüldüğü üzere, enerji sezici için gerçek verilerle alınan ölçüm sonuçlarına bakılırsa; 128, 256 ve 512 uzunluklu işaretler için gerçek verilerle alınan sonuçların daha iyi olduğu görülmektedir. 1024 uzunluklu işaretle ise sentetik verilerle alınan ölçüm sonuçları düşük SNR'da gerçek veri sonuçlarına göre daha yüksek sezim performansı göstermiştir. Bu test sırasında enerji sezici gürültü varyansını kestirmektedir. Kestirime ilişkin hata Şekil 6.16'da gösterilmektedir. Yapılan çalışma göstermektedir ki sezicinin varyans kestirimindeki hatası normal dağılıma yakınsamaktadır. Buna ilişkin histogram ve en büyük olasılıklı kestirim sonucu Şekil 6.16'da verilmektedir. Burada hata kestirimine ilişkin histogram, hatanın varyansa göre normalize edilmiş olduğu durum için verilmektedir.



Şekil 6.16. Hata histogramı



Şekil 6.17. 1024 uzunluklu ED ve CNN için gerçek ve sentetik veriler ile alınan sonuçların karşılaştırılması

CNN tabanlı sezici gürültü varyansının kestirilmesine olan bağımlılığı ortadan kaldırıp bir işaret kümesi üzerine bağımlılık oluşturmaktadır. Şekil 6.17’de görüldüğü üzere, 1024 işaret uzunluklu CNN tabanlı sezici için gerçek veriler ile ölçüm alındığında yanlış alarm olasılığının az miktarda arttığı gözlemlenmektedir. Yanlış alarm olasılığındaki artışa bağlı olarak sezim olasılığının da bir miktar arttığı görülmektedir. Fakat sezicinin başarımının çok düşük düzeyde azaldığı söylenebilir. Enerji sezici için ise, düşük SNR’da sentetik verilerle alınan ölçüm sonuçları daha iyi sezim performansı göstermiştir. Varyans kestiriminde ortalama %1’lik hata enerji sezicinin performansını ciddi ölçüde düşürmektedir.

7. SONUÇ VE ÖNERİLER

Bu çalışmada, spektrum sezimi için geleneksel enerji sezicinin ve derin öğrenme metotlarından CNN, CLDNN, LSTM ve ResNet sezicilerinin performansları kıyaslanmaktadır. Derin öğrenme metotlarının kendi aralarında kıyaslandığı test sonuçlarına bakıldığında CNN'nin diğer sezicilere göre artan SNR değerinde sezim olasılığının daha yüksek olduğu görülmüştür. Sonrasında CNN ve geleneksel enerji sezici arasında yapılan kıyaslamaların test sonuçlarına göre, CNN tabanlı seziciler düşük SNR seviyelerinde daha yüksek P_{fa} değerine sahip olmalarına rağmen artan SNR değerinde bu olasılık sıfıra yakınsarken sezim olasılığı bire yakınsamaktadır. CNN tabanlı sezicinin en önemli avantajı değişen gürültü varyansına karşı daha dayanıklı olmasıdır. Farklı kanal ve koşullarda CNN tabanlı sezicilerin performanslarının incelenmesi gerekmektedir.

KAYNAKLAR

- Akyildiz, I.F., Lee, W.Y., Vuran, M.C., Mohanty, S., 2006. Next Generation/Dynamic Spectrum Access/Cognitive Radio Wireless Networks: A survey. *Computer Networks*, 50(13), 2127-2159.
- Alpaydin, E., 2020. *Introduction to Machine Learning*. MIT Press.
- Atapattu, S., Tellambura, C., Jiang, H., Rajatheva, N., 2014. Unified Analysis of Low-SNR Energy Detection and Threshold Selection. *IEEE Transactions on Vehicular Technology*, 64(11), 5006-5019.
- Cabric, D., Mishra, S.M., Brodersen, R.W., 2004. Implementation Issues in Spectrum Sensing for Cognitive Radios. *Conference Record of the Thirty-Eighth Asilomar Conference on Signals, Systems and Computers*, 1, 772-776. Pacific Grove, CA, USA.
- Caruana, R., Niculescu-Mizil, A., 2006. An Empirical Comparison of Supervised Learning Algorithms. *Proceedings of the 23rd International Conference on Machine Learning*, 161-168. Pennsylvania.
- Cheng, Q., Shi, Z., Nguyen, D.N., Dutkiewicz, E., 2018. Deep Learning Network Based Spectrum Sensing Methods for OFDM Systems. *arXiv preprint arXiv:1807.09414*.
- Cui, Y., jun Jing, X., Sun, S., Wang, X., Cheng, D., Huang, H., 2015. Deep Learning Based Primary User Classification in Cognitive Radios. *15th International Symposium on Communications and Information Technologies (ISCIT)*, 165-168.
- David, K., Dixit, D., Jefferies, N., 2010. 2020 Vision. *IEEE Vehicular Technology Magazine*, 5(3), 22-29.
- Gokceoglu, A., Dikmese, S., Valkama, M., Renfors, M., 2014. Energy Detection Under IQ Imbalance with Single-and Multi-Channel Direct-Conversion Receiver: Analysis and Mitigation. *IEEE Journal on Selected Areas in Communications*, 32(3), 411-424.
- He, H., Jiang, H., 2019. Deep Learning Based Energy Efficiency Optimization for Distributed Cooperative Spectrum Sensing. *IEEE Wireless Communications*, 26(3), 32-39.

- He, K., Zhang, X., Ren, S., Sun, J., 2016. Deep Residual Learning for Image Recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 770-778. Las Vegas, NV, USA.
- Kaelbling, L.P., Littman, M.L., Moore, A.W., 1996. Reinforcement Learning: A Survey. Journal of Artificial Intelligence Research, 4, 237-285.
- Kim, K., Akbar, I.A., Bae, K.K., Um, J.S., Spooner, C.M., Reed, J.H., 2007. Cyclostationary Approaches to Signal Detection and Classification in Cognitive Radio. 2nd IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks, 212-215.
- Larsson, E.G., Edfors, O., Tufvesson, F., Marzetta, T.L., 2014. Massive MIMO for Next Generation Wireless Systems. IEEE Communications Magazine, 52(2), 186-195.
- Lawrence, S., Giles, C.L., Tsoi, A.C., Back, A.D., 1997. Face Recognition: A Convolutional Neural-Network Approach. IEEE Transactions on Neural Networks, 8(1), 98-113.
- LeCun, Y., Bengio, Y., Hinton, G., 2015. Deep Learning. Nature, 521(7553), 436-444.
- Lee, W., Kim, M., Cho, D.H., 2019. Deep Cooperative Sensing: Cooperative Spectrum Sensing Based on Convolutional Neural Networks. IEEE Transactions on Vehicular Technology, 68(3), 3005-3009.
- Lees, W.M., Wunderlich, A., Jeavons, P.J., Hale, P.D., Souryal, M.R., 2019. Deep Learning Classification of 3.5-GHz Band Spectrograms with Applications to Spectrum Sensing. IEEE Transactions on Cognitive Communications and Networking, 5(2), 224-236.
- Lei, L., Zhong, Z., Zheng, K., Chen, J., Meng, H., 2013. Challenges on Wireless Heterogeneous Networks for Mobile Cloud Computing. IEEE Wireless Communications, 20(3), 34-44.
- Li, B., Sun, M., Li, X., Nallanathan, A., Zhao, C., 2015. Energy Detection Based Spectrum Sensing for Cognitive Radios Over Time-Frequency Doubly Selective Fading Channels. IEEE Transactions on Signal Processing, 63(2), 402-417.

- Liu, C., Wang, J., Liu, X., Liang, Y.C., 2019. Deep CM-CNN for Spectrum Sensing in Cognitive Radio. *IEEE Journal on Selected Areas in Communications*, 37(10), 2306-2321.
- Liu, H., Zhu, X., Fujii, T., 2019. Ensemble Deep Learning Based Cooperative Spectrum Sensing with Semi-soft Stacking Fusion Center. *IEEE Wireless Communications and Networking Conference (WCNC)*, 1-6. Marrakech, Morocco.
- Maldonado, D., Le, B., Hugine, A., Rondeau, T.W., Bostian, C.W., 2005. Cognitive Radio Applications to Dynamic Spectrum Allocation: A Discussion and an Illustrative Example. *First IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks*, 597-600.
- Mueller, J.P., Massaron, L., 2018. *Artificial Intelligence for Dummies*. John Wiley & Sons.
- Nosratinia, A., Hunter, T.E., Hedayat, A., 2004. Cooperative Communication in Wireless Networks. *IEEE Communications Magazine*, 42(10), 74-80.
- Paisana, F., Selim, A., Kist, M., Alvarez, P., Tallon, J., Bluemm, C., Puschmann, A., DaSilva, L., 2017. Context-Aware Cognitive Radio Using Deep Learning. *IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN)*, 1-2.
- Rajendran, S., Meert, W., Giustiniano, D., Lenders, V., Pollin, S., 2018. Deep Learning Models for Wireless Signal Classification with Distributed Low-Cost Spectrum Sensors. *IEEE Transactions on Cognitive Communications and Networking*, 4(3), 433-445.
- Sainath, T.N., Vinyals, O., Senior, A., Sak, H., 2015. Convolutional, Long Short-Term Memory, Fully Connected Deep Neural Networks. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 4580-4584. Brisbane, Australia.
- Srinivasa, S., Jafar, S.A., 2007. Cognitive Radios for Dynamic Spectrum Access-The Throughput Potential of Cognitive Radio: A Theoretical Perspective. *IEEE Communications Magazine*, 45(5), 73-79.
- Tandra, R., Sahai, A., 2008. SNR Walls for Signal Detection. *IEEE Journal of Selected Topics in Signal Processing*, 2(1), 4-17.

- Tekbıyık, K., Ekti, A.R., Görçin, A., Kurt, G.K., Keçeci, C., 2019. Robust and Fast Automatic Modulation Classification with CNN Under Multipath Fading Channels. arXiv preprint arXiv:1911.04970.
- Urkowitz, H., 1967. Energy Detection of Unknown Deterministic Signals. *Proceedings of the IEEE*, 55(4), 523-531.
- Xie, J., Liu, C., Liang, Y.C., Fang, J., 2019. Activity Pattern Aware Spectrum Sensing: A CNN-Based Deep Learning Approach. *IEEE Communications Letters*, 23(6), 1025-1028.
- Yang, K., Huang, Z., Wang, X., Li, X., 2019. A Blind Spectrum Sensing Method Based on Deep Learning. *Sensors*, 19(10), 2270.
- Yu, L., Chen, J., Ding, G., Tu, Y., Yang, J., Sun, J., 2018. Spectrum Prediction Based on Taguchi Method in Deep Learning with Long Short-Term Memory. *IEEE Access*, 6, 45923-45933.
- Yu, L., Wang, Q., Guo, Y., Li, P., 2017. Spectrum Availability Prediction in Cognitive Aerospace Communications: A Deep Learning Perspective. *Cognitive Communications for Aerospace Applications Workshop (CCAA)*, 1-4.
- Yucek, T., Arslan, H., 2009. A Survey of Spectrum Sensing Algorithms for Cognitive Radio Applications. *IEEE Communications Surveys & Tutorials*, 11(1), 116-130.
- Zhu, X., Goldberg, A.B., 2009. Introduction to Semi-Supervised Learning. *Synthesis Lectures on Artificial Intelligence and Machine Learning*, 3(1), 1-130.

ÖZGEÇMİŞ

Adı Soyadı : Gamze KİRMAN TOKGÖZ
Doğum Yeri ve Yılı : İSTANBUL, 17/07/1994
Medeni Hali : Evli
Yabancı Dili : İngilizce
E-posta : gamze.kirman@istanbulticaret.edu.tr



Eğitim Durumu

Lise : Adile Mermerci Anadolu Lisesi, 2012
Lisans : İstanbul Ticaret Üniversitesi, Mühendislik Fakültesi,
Elektrik – Elektronik Mühendisliği Bölümü, 2017
: İstanbul Ticaret Üniversitesi, Mühendislik Fakültesi,
Endüstri Mühendisliği Bölümü (Çift Anadal), 2018
Yüksek Lisans : İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü,
Elektronik ve Haberleşme Mühendisliği Anabilim Dalı,
2020

Mesleki Deneyim

İstanbul Ticaret Üniversitesi,
Elektrik- Elektronik Mühendisliği Bölümü 2018-2019
TÜBİTAK,
Test ve Değerlendirme Başkan Yardımcılığı 2019-devam ediyor

Yayınları

Alaca, Ö., Kirman, G., Boyacı, A., Yarkan, S., 2018. Empirical Analysis of The Performance of Radiometer for Digitally Modulated Signals. Computational Methods and Telecommunication in Electrical Engineering and Finance, 44-45.
Tekbıyık, K., Tokgöz, G.K., Ekti, A.R., Yarkan, S., Kurt, G.K., 2020. Terahertz Haberleşme için Ölçüm Sonuçları Tabanlı LOS/NLOS Sinyal Tanıma: Enerji Sezici Yöntemi. 28. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (Kabul edildi.). Gaziantep, Türkiye.

Tokgöz, G.K., Tekbıyık, K., Kurt, G.K., Yarkan, S., 2020. Enerji Sezici ve CNN Tabanlı Sezici Üzerine Bir Karşılaştırma. 28. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (Kabul edildi.). Gaziantep, Türkiye.