



**DERİN ÖĞRENME TABANLI FREKANS ATLAMALI İLETİŞİM
SİSTEMLERİNDE PARAZİT ÖNLEME VE FREKANS SEÇİMİ**

Gökhan KAYA

**YÜKSEK LİSANS TEZİ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ARALIK 2024

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

Bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Gökhan KAYA

23/12/2024

DERİN ÖĞRENME TABANLI FREKANS ATLAMALI İLETİŞİM SİSTEMLERİNDE PARAZİT ÖNLEME VE FREKANS SEÇİMİ

(Yüksek Lisans Tezi)

Gökhan KAYA

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Aralık 2024

ÖZET

Bu tez çalışmasında, Türkiye genelinde GPS destekli, frekans atlamalı ve konuma dayalı bir iletişim sistemi geliştirilmiştir. Yazılım Tanımlı Radyo (SDR) teknolojisine dayanan bu sistem, özellikle frekans parazitini minimize etmek ve kesintisiz iletişim sağlamak amacıyla tasarlanmıştır. Türkiye, coğrafi olarak 8 ve 16 bölgeye ayrılmış ve her bölgeye farklı başlangıç frekansları atanmıştır. Her bölge, aynı 50 MHz bant genişliğini kullanmakla birlikte, frekans atlama sırasında başlangıç frekansları bölgeye özgü olarak belirlenmiştir. Sistem, HackRF cihazları ve GNU Radio platformu kullanılarak iki radyo platformu arasında iletişim sağlamak üzere geliştirilmiştir. Bu sistem, GPS zaman verilerini kullanarak, frekans atlama işlemini konuma dayalı olarak dinamik bir şekilde gerçekleştirir. Ek olarak, her bölge için ayrı çalışan derin öğrenme algoritması, bölgesel radyo frekansı kullanımını öğrenerek yoğun kullanılan veya parazitli frekanslardan kaçınma yeteneği kazandırılmıştır. Özellikle, 136 MHz gibi yüksek kullanım oranına sahip frekanslar derin öğrenme modeli tarafından tanınarak, sistemin bu frekanslara atlamaması sağlanır. Geliştirilen sistem, askeri ve sivil uygulamalarda güvenilir, yüksek kaliteli ve verimli bir iletişim altyapısı sunar. Bu çalışma, özellikle yoğun radyo frekansı trafiği ve yüksek parazit oranlarına sahip bölgelerde frekans spektrumunun daha verimli kullanımını sağlamak amacıyla önemli katkılar sunmaktadır. Sistem, spektrum yönetiminde etkin bir yaklaşım sunarak, iletişim kalitesini artırmayı ve parazitlenmeyi en aza indirmeyi hedeflemektedir.

Bilim Kodu : 93420
Anahtar Kelimeler : GPS destekli iletişim sistemleri, frekans atlama, derin öğrenme, Yazılım Tanımlı Radyo (SDR), parazit önleme, spektrum yönetimi, HackRF
Sayfa Adedi : 50
Danışman : Prof. Dr. Özgür ERTUĞ

INTERFERENCE MITIGATION AND FREQUENCY SELECTION IN DEEP LEARNING-BASED FREQUENCY HOPPING COMMUNICATION SYSTEMS

(M. Sc. Thesis)

Gökhan KAYA

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

December 2024

ABSTRACT

This thesis presents the development of a GPS-supported, frequency-hopping, location-based communication system designed for use across Turkey. Based on Software Defined Radio (SDR) technology, the system is specifically aimed at minimizing frequency interference and ensuring uninterrupted communication. Turkey is divided into 8 and 16 geographical regions, with each region assigned different starting frequencies. While each region operates within the same 50 MHz bandwidth, the starting frequency for frequency hopping is determined uniquely for each region. The system was developed using HackRF devices and the GNU Radio platform to establish communication between two radio platforms. By utilizing GPS time data, the system dynamically adjusts the frequency hopping process based on the geographic location. Furthermore, a deep learning algorithm operates separately for each region, learning the local radio frequency usage and enabling the system to avoid heavily used or interference-prone frequencies. In particular, frequencies like 136 MHz, which are heavily used, are recognized by the deep learning model, preventing the system from hopping to these frequencies. The system offers a reliable, high-quality, and efficient communication infrastructure for both military and civilian applications. This study makes significant contributions to optimizing spectrum usage, particularly in regions with high radio traffic and heavy interference. By presenting an effective approach to spectrum management, the system aims to enhance communication quality and minimize interference.

Science Code : 93420
Key Words : GPS-supported communication systems, frequency hopping, deep learning, Software Defined Radio (SDR), interference avoidance, spectrum management, HackRF
Page Number : 50
Supervisor : Prof. Dr. Özgür ERTUĞ

TEŐEKKÜR

Öncelikle Tez sürecinde değerli bilgileri ile bana destek olan danışman Hocam Prof.Dr. Özgür ERTUĐ hocama teşekkür ediyorum. Ayrıca, manevi desteđiyle her zaman yanımda olan ve bana inanan eşime ve çocuđuma şükranlarımı sunuyorum. Onların sevgisi ve teşviki bu süreçte en büyük motivasyon kaynađım olmuştur. Son olarak, çalışmalarımı yaparken hali hazırda çalıştığım ve laboratuvarını kullandığım Türk Havacılık ve Uzay Sanayi (TUSAŐ) 'a teşekkür ederim. Bu destek, çalışmalarımı başarıyla tamamlamama büyük katkı sağlamıştır. Bu tez, yukarıda adı geçen herkesin katkılarının bir ürünüdür ve hepsine sonsuz teşekkür ederim.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ŞEKİLLERİN LİSTESİ.....	ix
RESİMLERİN LİSTESİ.....	x
HARİTALARIN LİSTESİ.....	xi
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ	1
2. DERİN ÖĞRENME İLE FREKANS ATLAMA MİMARİSİ	21
2.1. Frekans Modülasyon ve Demodülasyonu	23
2.2. Frekans Atlamalı Sistem ve Uygulaması	23
2.3. Derin Öğrenme Tabanlı Frekans Seçimi	24
2.3.1. CNN (Convolutional Neural Network) tabanlı frekans seçimi	24
2.3.2. RNN (Recurrent Neural Network) Tabanlı Frekans Seçimi	25
2.3.3. Derin öğrenme modelinin eğitimi	25
3. FREKANS ATLAMA VE DERİN ÖĞRENME YÖNEMLERİ	27
3.1. Frekans Kullanım Verimliliği	27
3.2. Bölgesel Frekans Atlama	28
3.3. Parazite Karşı Koruma	28
3.4. Serbest Uzay Kayıpları (Free Space Path Loss)	29
3.5. Derin Öğrenme Yöntemlerinin Entegrasyonu	29
3.5.1. CNN Modeli ve Frekans seçimi	29

Sayfa

3.5.2. RNN Modeli ve Frekans seçimi	31
4. TEST ADIMLARI VE SOUÇLAR	33
4.1. Frekans kullanım verimliliği	33
4.2. Bölgesel Frekans Atlama	34
4.3. Parazite Karşı Koruma	36
4.4. Serbest Uzay Kayıpları	37
4.5. Derin Öğrenme Yöntemleriyle Frekans Yönetimi	39
5. SONUÇ VE ÖNERİLER	43
KAYNAKLAR	45
EKLER	47
EK-1. 1.Gözlem RINEX Dosyası	48
EK-2. 2.Gözlem RINEX Dosyası	49
ÖZGEÇMİŞ	50

ÇİZELGELERİN LİSTESİ

Şekil	Sayfa
Çizelge 4.1. Frekanslar ve yoğunluk oranları	40



ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. GNU Radio frekans modülasyon blokları	3
Şekil 1.2. GNU Radio frekans demodülasyon blokları	4
Şekil 1.3. GNU Radio	5
Şekil 1.4. USRP, GNU Radio blok şeması	6
Şekil 1.5. Frekans atlama grafiğinde Frekans ve Zaman	10
Şekil 1.6. Tipik bir Frekans atlama periyod örneği	10
Şekil 1.7. Sınıflandırılmış DNN model	14
Şekil 1.8. DNN model	15
Şekil 1.9. CNN model	17
Şekil 1.10. RNN model	18
Şekil 4.1. Frekans kullanım verimliliği bölmesiz ve 16 bölmeli system	33
Şekil 4.2. Bölgesel frekans atlama	35
Şekil 4.3. Cihaz sayısına göre bölmeli ve bölmesiz sistemlerde parazitlenme oranı	36
Şekil 4.4. Bölmeli ve bölmesiz sistemlerde serbest uzay kayıpları	38
Şekil 4.5. CNN eğitim ve doğrulaması	39

HARİTALARIN LİSTESİ

Harita	Sayfa
Harita 4.1. Türkiye Haritasının bölgelere ayrılması.....	37



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

KHz

Kilo Hertz

MHz

Mega Hertz

Kısaltmalar

Açıklamalar

ADC

Analog-Sayısal Dönüştürücü

CNN

Evrişimli Sinir Ağı

DAC

Sayısal-Analog Dönüştürücü

DNN

Derin Sinir Ağı

FHSS

Frekans Atlamalı Yayılı Spektrum

FM

Frekans Modülasyonu

GPS

Küresel Konumlama Sistemi

GRC

GNU Radio Companion

LSTM

Uzun Kısa Süreli Bellek

RF

Radyo Frekansı

RNN

Tekrarlayan Sinir Ağı

SDR

Yazılım Tanımlı Radyo

USRP

Evrensel Yazılım Tanımlı Radyo Birimi

1. GİRİŞ

Kablosuz iletişim sistemleri, insanlık tarihindeki en önemli teknolojik atılımlardan biri olarak görülmektedir. İlk olarak 19. yüzyılın sonlarında radyo dalgalarının keşfiyle ortaya çıkan bu teknoloji, günümüzde modern iletişim altyapısının temelini oluşturmaktadır. Radyo dalgalarının keşfiyle başlayan bu süreç, 20. yüzyıl boyunca gelişerek radyo yayıncılığından uydu iletişimine kadar geniş bir alanda uygulanmaya başlanmıştır. Kablosuz iletişim, artık günlük yaşamın vazgeçilmez bir unsuru haline gelmiş ve cep telefonlarından Wi-Fi bağlantılarına, Bluetooth cihazlarından uydu sistemlerine kadar çok çeşitli alanlarda kullanılmaktadır.

Bu teknolojinin hızlı ilerlemesi ve yaygınlaşması, özellikle frekans spektrumunun etkin yönetimi sorununu gündeme getirmiştir. Kablosuz iletişim sistemlerinde sınırlı bir kaynak olan frekans spektrumu, doğru ve verimli bir şekilde yönetilmesi gereken kritik bir unsurdur. Radyo frekans spektrumunun kısıtlı yapısı, aynı anda birçok kullanıcının aynı frekans bandını paylaşmasını zorunlu kılar. Bu durum, parazitlenme (interference) ve sinyal karışması gibi sorunların ortaya çıkmasına neden olabilir. Parazitlenme, birden fazla kullanıcının aynı frekans bandında çalıştığı durumlarda meydana gelerek iletişim kalitesinde düşüşe yol açar.

Bu tür sorunlara çözüm sunmak amacıyla geliştirilen yöntemlerden biri, frekans atlamalı sistemlerdir (Frequency Hopping Spread Spectrum - FHSS). Bu sistemlerde, belirli bir frekans bandı içinde sürekli olarak frekans değiştirilerek sinyalin parazitlenme ihtimali azaltılır ve daha güvenilir bir veri iletimi sağlanır. Frekans atlamalı sistemler, hem askeri hem de sivil haberleşme uygulamalarında yaygın bir kullanım alanına sahiptir. Bu sistemlerin en önemli avantajlarından biri, sinyalin sabit bir frekansta kalmaması sayesinde parazitlenme riskinin minimuma indirilmesidir.

FM modülasyon ve demodülasyon

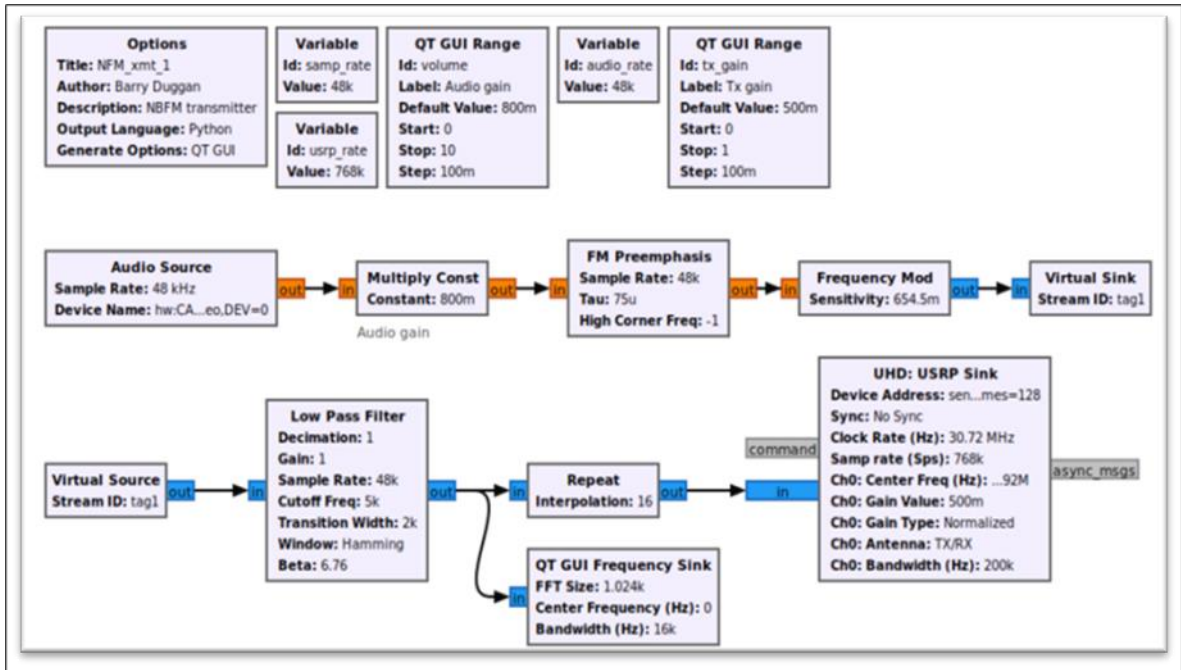
Kablosuz iletişimde verilerin modülasyon yöntemiyle iletilmesi, iletişim kalitesini artırmanın en temel yollarından biridir. FM modülasyonu (Frekans Modülasyonu), taşıyıcı dalganın frekansının iletilen sinyalin genliğine bağlı olarak değiştirilmesi prensibine

dayanır. Bu yöntem, özellikle radyo yayıncılığında yaygın bir kullanım alanı bulur ve yüksek ses kalitesi ile parazitlere karşı dayanıklılığı nedeniyle tercih edilir.

FM yayını, geleneksel bir analog iletişim yöntemidir. Düşük maliyetli ekipman gereksinimi ve ses iletiminin yüksek kalitede gerçekleşmesi, analog FM yayınlarının günümüzde dünya genelinde yaygın olarak kullanılmasını sağlamaktadır. Bu yayınlar, 88–108 MHz frekans aralığında, 150 kHz'lik kanal bant genişliği ile gerçekleştirilir. FM modülasyonuna ek olarak, HackRF modülasyonu frekans kaydırmalı anahtarlama (FSK) için de kullanılabilir. HackRF One kullanarak SDR'yi uygulamak için Frekans Kaydırmalı Anahtarlama Şeması" başlıklı bir araştırma, dijital sinyallerin bu yöntemle başarıyla iletilip alınabileceğini ve üretilen güç değerlerinin değişkenlik gösterdiğini ortaya koymuştur [7]. FM modülasyonu, taşıyıcı dalganın genliğini sabit tutarak frekansını değiştirme prensibine dayanır. FM demodülasyonu ise, modüle edilmiş bir sinyalin alıcı tarafından geri çözülmesi işlemidir. Demodülasyon sürecinde, taşıyıcı sinyalin frekansındaki değişimler algılanarak orijinal bilgi yeniden elde edilir. FM modülasyonu ve demodülasyonu, özellikle frekans atlamalı sistemlerde parazitlenmeyi önlemek amacıyla sıkça kullanılan yöntemler arasında yer alır.

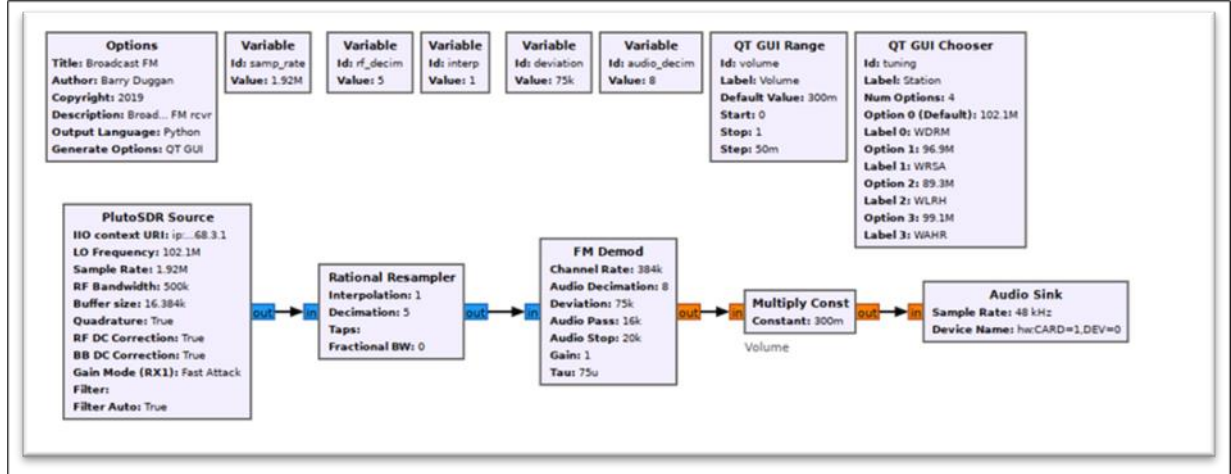
Frekans modülasyonu, taşıyıcı sinyalin frekansının, iletilen bilgi sinyaline bağlı olarak sürekli değiştiği bir modülasyon tekniğidir. Bu yöntemde, bilgi sinyalinin genliği sabit tutulurken, taşıyıcı sinyalin frekansında meydana gelen değişiklikler, bilginin iletilmesini sağlar. Frekans modülasyonu, taşıyıcı sinyalin anlık frekansının, modüle edici sinyalin anlık genliğine göre değişmesi esasına dayanır. Taşıyıcı sinyal genellikle bir sinüs dalgası olarak kullanılırken, modüle edici sinyal ise sinüs, kare, üçgen veya ses sinyali gibi çeşitli dalga türlerinde olabilir. Frekans modülasyonunda, taşıyıcı sinyalin genliği sabit kalır, ancak frekansı, modüle edici sinyalin genliğine göre farklılık gösterir [7]. FM modülasyonu, özellikle ses sinyallerinin iletiminde tercih edilen bir yöntemdir; çünkü frekanstaki değişiklikler, genlik modülasyonuna kıyasla parazitlere karşı daha dirençli bir yapı sunar. Çalışmada, frekans atlamalı bir iletişim sisteminde FM modülasyonu kullanılmakta olup, belirli zaman aralıklarında sinyalin frekansı değiştirilerek güvenli ve girişimsiz bir iletişim sağlanmaktadır. GNU Radio platformu, FM modülasyonunun dijital ortamda yazılım tabanlı bir şekilde gerçekleştirilmesine olanak tanımaktadır. Bu platformda, modülasyon sırasında sinyalin frekansı dinamik olarak ayarlanabilmekte ve çeşitli işlem blokları kullanılarak sinyal işleme süreci özelleştirilebilmektedir. Şekil 1.1'de gösterildiği gibi, modülasyon ve

demodülasyon işlemleri sırasında sinyalin frekans bileşenleri ve zamanlama unsurları yazılım üzerinden yönetilmektedir. FM modülasyonu sırasında, sinyalin belirli frekans aralıklarında atlaması, hem verici hem de alıcı tarafında GPS zaman bilgisi ile senkronize edilmekte ve bu sayede iletişimde tam bir uyum sağlanmaktadır. Bu süreç, sinyalin doğru bir şekilde modüle edilip iletilmesini ve ardından güvenilir bir şekilde demodüle edilmesini sağlamaktadır. Böylece, frekans atlamalı sistemin parazitlerden arındırılmış ve güvenli bir iletişim ortamı sunması mümkün hale gelmektedir.



Şekil 1.1. GNU Radio frekans modülasyon blokları [1]

FM demodülasyonu, modüle edilmiş taşıyıcı sinyalin frekansındaki değişimlerin çözümlenmesiyle bilgi sinyalinin geri kazanılması işlemidir. Şekil 1.2'de görüldüğü üzere, GNU Radio platformunda FM demodülasyonu sürecinde sinyal, PlutoSDR gibi bir SDR kaynağından alınarak işlenir. İlk olarak, sinyal bir Rational Resampler yardımıyla yeniden örneklenir; bu adım, sinyalin daha iyi işlenmesini sağlar. Daha sonra, FM Demodülasyon bloğu kullanılarak sinyalin frekans değişimleri çözümlenir ve modüle edilen sinyal tekrar orijinal bilgi sinyaline dönüştürülür. Elde edilen bilgi sinyali, Audio Sink bloğuna iletilerek ses olarak dinlenebilir hale gelir. FM demodülasyonu, modüle edilmiş sinyalin frekansındaki değişiklikleri çözerek bilgi sinyalini geri kazanan bir süreçtir ve bu işlem radyo iletişiminin temel bir bileşenidir.

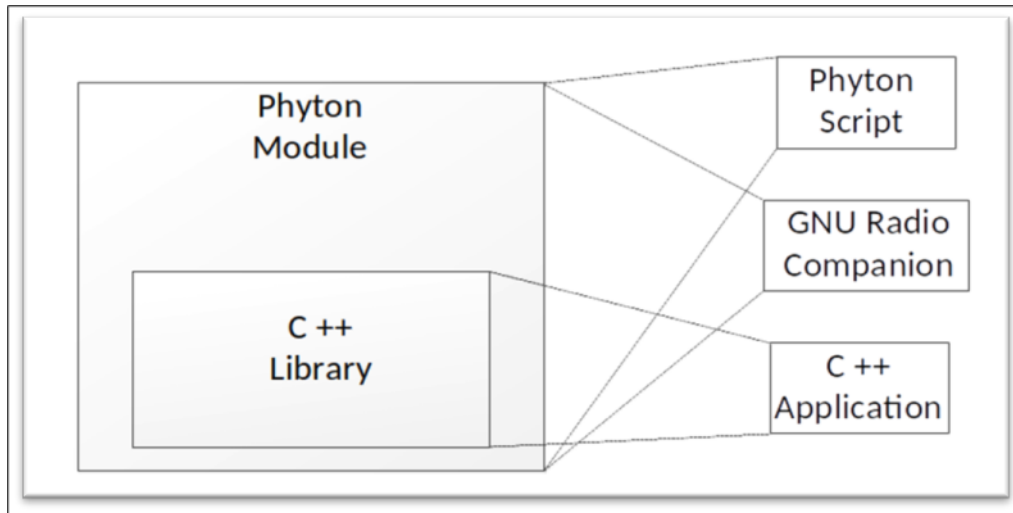


Şekil 1.2. GNU Radio frekans demodülasyon blokları [2]

Bu tez çalışmasında, FM modülasyonu kullanılarak veri iletimi gerçekleştirilmiştir. Frekans atlamalı bir sistemde verinin iletilmesi sırasında, sinyalin önce modüle edilmesi ve ardından demodüle edilerek alınması, veri kaybını önlerken parazitlere karşı dayanıklılığı artırmaktadır. FM modülasyonu, yalnızca radyo yayıncılığı değil, aynı zamanda askeri haberleşme, uzaktan algılama ve uydu iletişimi gibi birçok farklı alanda da yaygın bir şekilde kullanılmaktadır.

GNU radio ile yazılım tabanlı radyo iletişimi

GNU Radio, açık kaynaklı bir yazılım platformudur ve yazılım tabanlı radyo (SDR) uygulamaları geliştirmek için kullanılan bir araçtır. GNU Radio, harici RF donanımında yazılım tabanlı radyo sistemlerini hayata geçirmek için kullanılan sinyal işleme blokları ile çalışır [11]. Şekil 1.3'de GNU Radio'nun yazılım yapısının Python ve C++ dilleriyle nasıl entegre çalıştığını göstermektedir. C++ kütüphaneleri, sinyal işleme işlevlerini yerine getirirken, Python modülleri bu işlevlerin kullanıcı dostu bir arayüz üzerinden yönetilmesini sağlar. Kullanıcılar, Python betikleri veya GNU Radio Companion (GRC) adlı grafiksel arayüz aracılığıyla sinyal işleme görevlerini tanımlayabilir ve C++ işlevlerini kontrol edebilirler. GNU Radio, bir kişisel bilgisayar üzerinde gerçekleştirilen sinyal işleme yöntemlerini kullanarak çeşitli sinyal işleme görevlerini yerine getirebilir. Bu sayede dijital veri içeren bilgileri alabilir, veri gönderimi yapabilir ve bu veriler RTL adı verilen bir donanım cihazı aracılığıyla iletilebilir.



Şekil 1.3. GNU Radio [7]

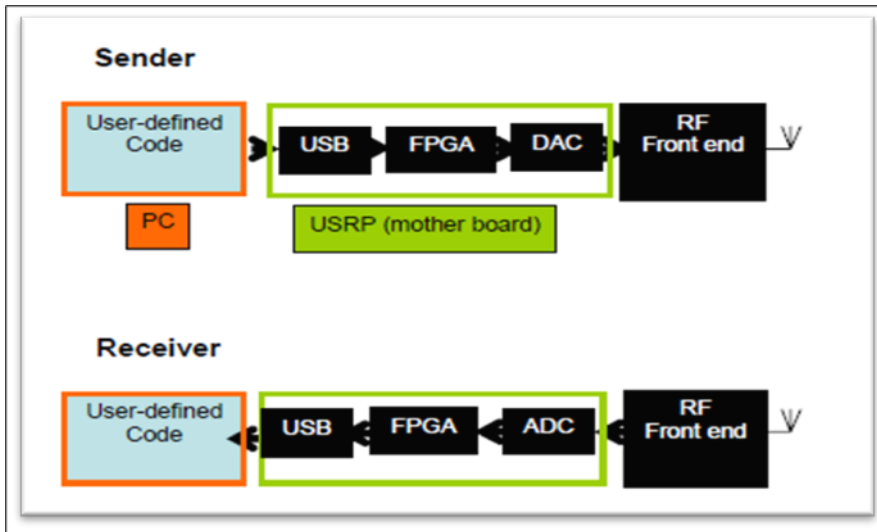
GNU Radio, filtreler, kod akışı, senkronizasyon, demodülasyon, kodlama ve kod çözme gibi çeşitli bileşenlere sahiptir. Bu bileşenler, sistemin "blok entegrasyonu" adı verilen yapısı içinde çalışır. GNU Radio'nun en önemli işlevlerinden biri, bloklar arasındaki bağlantıyı sağlamak ve kullanılan modülasyonu kontrol etmektir [8]. GNU Radio, özellikle sinyal işleme ve radyo iletişimi alanında çalışan araştırmacılar ve mühendisler için büyük bir esneklik sunmaktadır. Donanımdan bağımsız olarak çalışabilen bu yazılım, radyo sinyallerini işlemek, analiz etmek ve iletmek için gerekli olan çeşitli bloklar ve araçlar sağlar. GNU Radio, özellikle radyo frekansı spektrumu üzerinde çalışan uygulamalarda yaygın olarak tercih edilmekte ve frekans atlamalı sistemlerin geliştirilmesinde kullanılmaktadır.

SDR (Software Defined Radio), radyo iletişim sistemlerinin esnek ve yazılım tabanlı bir şekilde tasarlanmasına olanak tanıyan bir teknolojidir. Yazılım Tanımlı Radyo (SDR), radyo sinyallerinin dijital hale getirilerek yazılım yardımıyla işlenmesini sağlayan bir platformdur. SDR'nin temel hedefi, alıcı sistemlerinde donanımın getirdiği zorlukları yazılımla çözerek daha esnek ve erişilebilir bir çalışma ortamı sunmaktır [6]. Geleneksel radyo sistemlerinin donanım bağımlılığının aksine, SDR ile radyo frekansları yazılım yoluyla tanımlanır ve yönetilir. Bu, frekans atlama gibi dinamik işlemlerin kolayca uygulanmasını sağlar. Yazılım Tanımlı Radyo (SDR), radyo iletişim sistemlerinde donanım bileşenlerinin yazılımla yönetildiği bir yaklaşımdır. SDR, donanım tarafından yakalanan sinyali verici ya da alıcı olarak işler ve bu sinyal daha sonra bilgisayarda çözülerek işlenir [9]. SDR, frekans yönetimi, modülasyon ve demodülasyon gibi geniş bir yelpazede işlemleri gerçekleştirdiği

için frekans atlamalı iletişim sistemlerinde kritik bir role sahiptir. SDR teknolojisi, farklı protokoller ve standartlar arasında geçiş yapmayı oldukça kolaylaştırmaktadır.

Şekil 1.3, USRP (Universal Software Radio Peripheral) donanımının temel çalışma prensibini ve GNU Radio ile entegrasyonunu göstermektedir. USRP, Yazılım Tanımlı Radyo (SDR) sistemlerinde kullanılan bir donanım olarak dijital sinyallerin analog sinyallere (ve tam tersi) dönüştürülmesini sağlar. Bu donanım, radyo sinyallerinin dijital işlenmesinde kritik bir rol oynar ve GNU Radio ile birlikte çalışarak kullanıcı tanımlı radyo uygulamalarının esnek bir şekilde oluşturulmasına olanak tanır.

Verici tarafında, kullanıcı tanımlı kod bilgisayardan USB aracılığıyla FPGA'ya (Field Programmable Gate Array) aktarılır. FPGA, dijital sinyalleri işleyerek bir DAC (Digital to Analog Converter) yardımıyla analog sinyale dönüştürür. Daha sonra, RF (Radyo Frekansı) ön uç bileşeni ile sinyal istenen frekans bandına taşınır ve iletilir. Alıcı tarafında ise, RF ön uçtan alınan analog sinyal bir ADC (Analog to Digital Converter) yardımıyla dijital hale getirilir. Bu dijital sinyal FPGA'da işlenir ve USB üzerinden bilgisayara aktarılır, burada kullanıcının tanımladığı işlem adımları uygulanır. Bu yapı, SDR sistemlerinde radyo frekanslarıyla çalışan sinyallerin esnek ve programlanabilir bir yapıda işlenmesini sağlar. USRP, taşıyıcı sinyalin modüle edilmesi ve demodüle edilmesi süreçlerinde, ayrıca frekans atlamalı sistemler gibi uygulamalarda kullanılan bir araç olarak radyo iletişim sistemlerinin verimliliğini artırmaktadır.



Şekil 1.4. USRP, GNU Radio blok şeması [3]

USRP, bağımsız bir Yazılım Tanımlı Radyo (SDR) değildir; bu nedenle, USRP'nin mimarisi sinyal işleme işlevlerinin başka bir ana cihazda gerçekleştirilmesini gerektirir. Ana cihaz genellikle en az bir USB 2.0 bağlantısına sahip bir bilgisayar olarak düşünülse de, sinyal işleme işlevlerini yerine getirebilen ve USB 2.0 bağlantısı aracılığıyla bağlanabilen herhangi bir cihaz da olabilir. Bu cihazlar, Genel Amaçlı İşlemciler (GPP), Dijital Sinyal İşlemciler (DSP), Alan Programlanabilir Kapı Dizileri (FPGA) veya Uygulamaya Özel Entegre Devreler (ASIC) gibi bileşenleri içerebilir [4].

GNU Radio, radyo sistemleri için açık kaynaklı bir yazılım çözümü olarak, açık yazılım geliştirme topluluğunun ve kaynaklarının desteğinden büyük ölçüde yararlanmaktadır. GNU/Linux işletim sistemini tanıyan kullanıcılar için, GNU Radio'nun yapısı, diğer birçok açık kaynak projesinde kullanılan yazılım yönetim araçları, derleyiciler ve iş akışları ile aynı şekilde organize edilmiştir. Bu nedenle, GNU Radio ile geliştirme yapmak isteyen kişilerin temel düzeyde GNU/Linux bilgisine sahip olması önerilmektedir. Windows ve Mac işletim sistemlerinde GNU Radio'yu çalıştırmak için bazı ayarlamalar yapılmış olsa da, bu proje esas olarak GNU/Linux üzerinde geliştirilmektedir ve en fazla destek ile güncellemeler bu platformda gerçekleştirilmektedir. Bunun yanı sıra, USRP2 donanımı yalnızca GNU/Linux platformunda tam desteklenmekte olup, diğer platformlardaki geliştirme ortamları Linux tabanlı yazılımın uyarlanmış sürümleri olarak sunulmaktadır [5].

GNU radio'nun yapısı ve özellikleri

GNU Radio, kullanıcılara kendi yazılım tabanlı radyo sistemlerini geliştirme imkanı sağlayan bir dizi sinyal işleme yazılım aracıdır. Bu yazılım, düşük maliyetli harici RF donanımı ile çeşitli radyo uygulamalarını gerçekleştirmek için geniş bir işleme bloğu kütüphanesi sunar [6]. GNU Radio, radyo iletişimini yazılım tabanlı bloklar aracılığıyla yönetir. Bu bloklar, sinyal işleme işlemlerini gerçekleştiren modüller olarak işlev görür. Örneğin, bir blok taşıyıcı dalgayı oluştururken, başka bir blok modülasyon işlemini gerçekleştirir. Bu blokların bir araya getirilmesiyle kullanıcılar, radyo iletişim sürecini simüle edebilir veya gerçek zamanlı olarak radyo sinyalleri iletebilir. GNU Radio'nun en büyük avantajı, esnekliği ve kullanıcıların donanım tabanlı kısıtlamalar olmaksızın çeşitli radyo uygulamaları geliştirebilmelerine olanak sağlamasıdır.

GNU Radio'nun grafik kullanıcı arayüzü (GUI), sinyal işleme bloklarının bir araya getirilmesini oldukça kolaylaştırır. Kullanıcılar, bu blokları sürükleyip bırakarak radyo iletişim sistemlerini tasarlayabilirler. Örneğin, FM modülasyon ve demodülasyon bloklarının eklenmesiyle bir radyo vericisi ve alıcısı kolayca oluşturulabilir. Ayrıca, GNU Radio'nun esnek yapısı, kullanıcıların kendi özel sinyal işleme bloklarını geliştirebilmesine de olanak tanımaktadır.

GNU radio ve frekans atlamalı sistemler

Bu çalışmada kullanılan frekans atlamalı sistemin temel yapı taşlarından biri olan GNU Radio, frekans atlama işlemlerinin gerçekleştirilmesinde kritik bir rol oynar. GNU Radio, farklı uygulamalar için özel olarak geliştirilmiş birçok bloğun bulunduğu aktif bir topluluğa sahiptir. Bu bloklar arasında Frekans Atlamalı Yayılma Spektrumu (FHSS) için iki farklı uygulama da yer almakta ve ilgili uygulama bağlamında ele alınmaktadır [10]. Frekans atlamalı sistemler, belirli bir frekans aralığında sürekli olarak frekans değiştiren sistemlerdir ve bu sistemlerde dinamik spektrum yönetimi büyük bir öneme sahiptir. GNU Radio, bu dinamik spektrum yönetimini sağlamak için gerekli sinyal işleme araçlarını sunar. Frekans atlamalı sistemler, özellikle dış müdahalelere karşı dayanıklılığı artırmak ve parazitlenmeyi önlemek amacıyla yaygın olarak kullanılmaktadır.

Bu çalışmada, GNU Radio kullanılarak bir frekans atlamalı sistemin simülasyonu gerçekleştirilmiş ve sistem, Türkiye'nin farklı coğrafi bölgelerinde uygulanmak üzere tasarlanmıştır. Türkiye'nin 8 ve 16 coğrafi bölgeye ayrılması ile her bölge için farklı bir başlangıç frekansı atanmış, bu frekans atlama işlemi GNU Radio üzerinde tasarlanan bloklar yardımıyla uygulanmıştır. Her bölgenin başlangıç frekansı, sistemin bulunduğu GPS konumuna göre belirlenmiş ve GNU Radio kullanılarak bu frekansların dinamik olarak değiştirilmesi sağlanmıştır.

GNU radio ve HackRF entegrasyonu

HackRF, GNU Radio ile birlikte kullanılan bir donanım platformudur. HackRF One, internette en yaygın bulunan SDR cihazlarından biridir. Bu cihaz, 1 MHz'den 6 GHz'e kadar radyo sinyallerini alabilen veya iletebilen bir Yazılım Tanımlı Radyo (SDR) donanımdır [7]. HackRF, geniş bir frekans aralığında çalışabilen ve radyo sinyallerini iletmek veya

almak için kullanılan bir SDR donanımdır. Bu çalışmada HackRF cihazları, hem verici hem de alıcı olarak kullanılmıştır. HackRF'nin GNU Radio ile entegrasyonu, yazılım tabanlı radyo uygulamalarının gerçek dünya senaryolarında uygulanabilmesini mümkün kılmaktadır. HackRF cihazları sayesinde frekans atlamalı sistemin gerçek zamanlı olarak test edilmesi sağlanmıştır.

GNU Radio ile HackRF'nin birlikte kullanımı, özellikle gerçek zamanlı sinyal işleme ve frekans atlama işlemlerinin senkronize edilmesi açısından önemli avantajlar sunmaktadır. Bu çalışmada, frekans atlamalı sistemin GPS verileri ile entegre bir şekilde HackRF cihazlarıyla çalışması sağlanmış ve her bölge için farklı başlangıç frekansları dinamik olarak atanmıştır. Bu yapı, Türkiye'nin farklı bölgelerinde parazitlenmeden etkilenmeden güvenilir bir iletişim kurulmasına olanak tanımaktadır.

SDR ile frekans atlamalı iletişim

HackRF, SDR sistemleri için kullanılan donanım cihazlarından biridir. HackRF, geniş bir frekans aralığında (1 MHz ila 6 GHz) çalışabilir ve radyo sinyallerini alıp iletme yeteneğine sahiptir. Bu cihaz, özellikle SDR tabanlı frekans atlamalı sistemlerin gerçek zamanlı test edilmesi ve geliştirilmesi için idealdir. Frekans senkronizasyonu işlemi iki aşamaya ayrılabilir. İlk aşamada, doğru frekans atlama sırasını elde etmek için kullanılan kanalların sıralanması gerekir. Bu sıralama tamamlandıktan sonra, ikinci aşama frekans atlama işleminin gerçekleştirilmesidir [10]. HackRF, GNU Radio ile entegre çalışarak, yazılım tabanlı radyo uygulamalarının donanım seviyesinde test edilmesine olanak tanımaktadır.

Şekil 1.5'de frekans atlamalı bir sistemde sinyalin zaman içerisindeki davranışını göstermektedir. Bu şekilde, taşıyıcı frekansın belirli bir zaman aralığında farklı frekanslara sıçradığı gözlemlenmektedir. Bu frekans değişiklikleri, belirli bir atlama dizisi ile önceden belirlenmiş olup, girişimden kaçınmak ve sinyal güvenliğini artırmak amacıyla uygulanmaktadır. Frekansların bu şekilde dinamik olarak değişmesi, geniş spektrumlu bir yayılım sağlar ve sistemin parazitlerden etkilenmesini önler. Frekans atlama, sinyalin farklı frekans kanalları arasında periyodik olarak geçiş yapmasını sağlayan bir yayılma spektrum tekniğidir. Bu yöntem, sinyalin dar bant girişimlerine karşı daha dayanıklı olmasını sağlayarak, girişimden kaçınma ve iletişim kalitesini artırma amacı taşır [3].

güvenilir bir veri iletimi sağlanmaktadır. Temel bant mesajı, her atlama periyodunun sadece orta kısmında iletilmektedir. Bu durum, temel bant sinyalinin sürekli olmaması nedeniyle, frekans atlama ile en etkili şekilde yalnızca dijital modülasyon şemalarının iletilebileceğini göstermektedir. Ayrıca, yazılım tabanlı sistemlerde frekans atlamalı modülasyonların uygulanması, boşluk periyodundaki hassas zamanlama gereksinimleri nedeniyle önemli bir zorluk yaratmaktadır. Yazılım sistemleri bu sıkı zamanlama gereksinimlerini karşılamakta zorlanabilir [3].

Frekans atlamalı sistemlerde GNU Radio'nun avantajları

GNU Radio'nun frekans atlamalı sistemlerde sunduğu en büyük avantaj, esneklik ve hızlı prototipleme yeteneğidir. Geleneksel donanım tabanlı radyo sistemlerinde frekans değişiklikleri donanımsal olarak gerçekleştirilirken, GNU Radio ile bu işlemler yazılım yoluyla yapılabilmektedir. Bu, sistemin daha hızlı ve verimli bir şekilde geliştirilmesine olanak tanımaktadır. Ayrıca, GNU Radio'nun açık kaynaklı olması, kullanıcıların kendi ihtiyaçlarına uygun özel sinyal işleme blokları geliştirebilmelerine imkan tanımaktadır.

Bu çalışmada geliştirilen sistemde, GNU Radio'nun sunduğu bu esneklik sayesinde frekans atlamalı sistem, GPS verilerine dayalı olarak dinamik bir şekilde çalıştırılmıştır. Her coğrafi bölge için ayrı bir frekans atlama izgenin oluşturulması, GNU Radio'nun esnek yapısı sayesinde hızlı ve etkili bir şekilde gerçekleştirilmiştir. Ayrıca, GNU Radio'nun grafik arayüzü, sistemin görsel olarak simüle edilmesini ve izlenmesini kolaylaştırmıştır.

Frekans atlamalı sistemler ve konuma dayalı frekans seçimi

Kablosuz iletişim sistemlerinin en büyük zorluklarından biri, aynı frekans bandını birden fazla kullanıcının paylaşması durumunda yaşanan parazitlenme sorunlarıdır. Frekans atlamalı sistemler, bu sorunu çözmek amacıyla geliştirilmiş etkili yöntemlerden biridir. Bu sistemlerde, belirli bir frekans bandı içinde sürekli olarak frekans değiştirilir. Bu değişim, belirli bir izge veya algoritma doğrultusunda gerçekleştirilir ve bu sayede sinyalin dışarıdan izlenmesi ve parazitlenmesi zorlaşır.

Frekans atlamalı sistemler, özellikle askeri haberleşme ve güvenlik gerektiren diğer iletişim sistemlerinde yaygın olarak kullanılmaktadır. Bu sistemlerin en büyük avantajı, sinyalin

sabit bir frekansta kalmaması ve sürekli olarak farklı frekanslara atlamasıdır. Bu durum, dışarıdan gelen parazitler veya sinyal bozucuların (jammers) iletişimi kesmesini zorlaştırır. Ayrıca, frekans atlamalı sistemler, frekans spektrumunun daha verimli kullanılmasını sağlamaktadır. Farklı kullanıcılar aynı frekans bandını paylaşabilir, ancak sinyaller farklı zaman dilimlerinde farklı frekanslara atladığından parazitlenme riski minimuma indirilir.

Bu çalışmada, Türkiye'nin 8 ve 16 coğrafi bölgeye ayrıldığı bir yapı oluşturulmuştur. Her bölgeye farklı bir başlangıç frekansı atanmış ve frekans atlama işlemi GPS verilerine dayalı olarak gerçekleştirilmiştir. Sistem, her bölgenin aynı 50 MHz bant genişliğini kullanmasına rağmen başlangıç frekanslarının farklı olmasıyla frekans çakışmalarının önüne geçilmesini sağlamaktadır. Örneğin, 1. bölge frekans atlamasına 125 MHz'den başlarken, 2. bölge 135 MHz'den başlamaktadır. Bu yapı, aynı bant genişliğini paylaşan bölgeler arasında çakışmayı önlemektedir. Sistem, GPS verileriyle sürekli güncellenen bir frekans atlama izgelerine sahiptir.

Konuma dayalı frekans seçimi, bu çalışmanın en önemli yeniliklerinden biridir. Her coğrafi bölge için farklı bir başlangıç frekansı belirlenmiş ve bu frekans, o bölgedeki radyo frekansı yoğunluğuna göre optimize edilmiştir. Örneğin, İstanbul gibi yoğun radyo frekansı trafiğine sahip bir bölgede, 136 MHz gibi sıkça kullanılan frekanslar, derin öğrenme algoritmaları tarafından tanınmakta ve sistem bu frekanslara atlamaktan kaçınmaktadır. Bu yaklaşım, frekans spektrumunun daha verimli kullanılmasını ve parazitlenme riskinin minimize edilmesini sağlamaktadır.

GPS ve SDR teknolojilerinin entegrasyonu

Günümüzde uydu temelli navigasyon sistemleri, modern toplumun birçok alanında kritik bir role sahip hale gelmiştir. GPS'in sunduğu navigasyon, konumlandırma ve zamanlama hizmetleri ise yaygın bir şekilde kullanılmaktadır [12]. GPS (Global Positioning System), dünya genelinde konum belirleme hizmeti sunan bir uydu sistemidir. GPS, özellikle konuma dayalı frekans yönetimi gerektiren kablosuz iletişim sistemlerinde büyük avantaj sağlar. GPS alıcısı, GPS uydularından gelen efemeris verilerini kullanarak uydunun konumunu belirler ve alıcının konumunu sahte mesafe (pseudorange) ölçümleriyle hesaplar. Uydular, aynı veriyi senkronize bir şekilde iletir, ancak uyduların alıcıya olan mesafeleri farklı olduğu için her bir uydu için farklı sahte mesafe değerleri elde edilir [13]. GPS verileri,

kullanıcıların konumuna göre frekans atlama izgelerini dinamik olarak belirleyebilmektedir. Bu sayede, her coğrafi bölge için en uygun frekans seçilir ve aynı frekans bandının farklı bölgelerde kullanımı sırasında çakışmalar önlenir.

Bu tez çalışmasında, GPS destekli frekans atlamalı bir sistem geliştirilmiştir. Türkiye'nin farklı bölgeleri için başlangıç frekansları GPS verilerine dayalı olarak atanmış ve sistem, her bölge için farklı bir frekans izgelerine sahip olacak şekilde tasarlanmıştır. GPS verileri sürekli olarak güncellenmekte ve sistem, bulunduğu bölgeye göre frekans seçimini dinamik olarak gerçekleştirmektedir. Bu yapı sayesinde, özellikle büyük şehirlerde ve frekans kullanımının yoğun olduğu bölgelerde parazitlenme riski en aza indirilmektedir. SDR (Software Defined Radio), radyo iletişim sistemlerinin yazılım yoluyla yapılandırılmasını sağlayan bir teknolojidir. Geleneksel radyo sistemlerinde frekanslar donanımsal olarak belirlenirken, SDR teknolojisi ile frekanslar yazılım aracılığıyla dinamik bir şekilde değiştirilebilmektedir. SDR, bu esnekliği sayesinde farklı frekans bantlarında hızlı geçiş yapabilme kabiliyeti sunmakta ve frekans atlamalı sistemler için büyük bir avantaj sağlamaktadır.

Bu çalışmada, GNU Radio yazılımı ve HackRF cihazları kullanılarak SDR tabanlı bir iletişim sistemi geliştirilmiştir. HackRF cihazları, geniş bir frekans aralığında çalışabilen SDR donanımlarıdır ve bu cihazlar sayesinde Türkiye genelindeki farklı bölgelerde dinamik frekans atlama işlemleri gerçekleştirilmiştir.

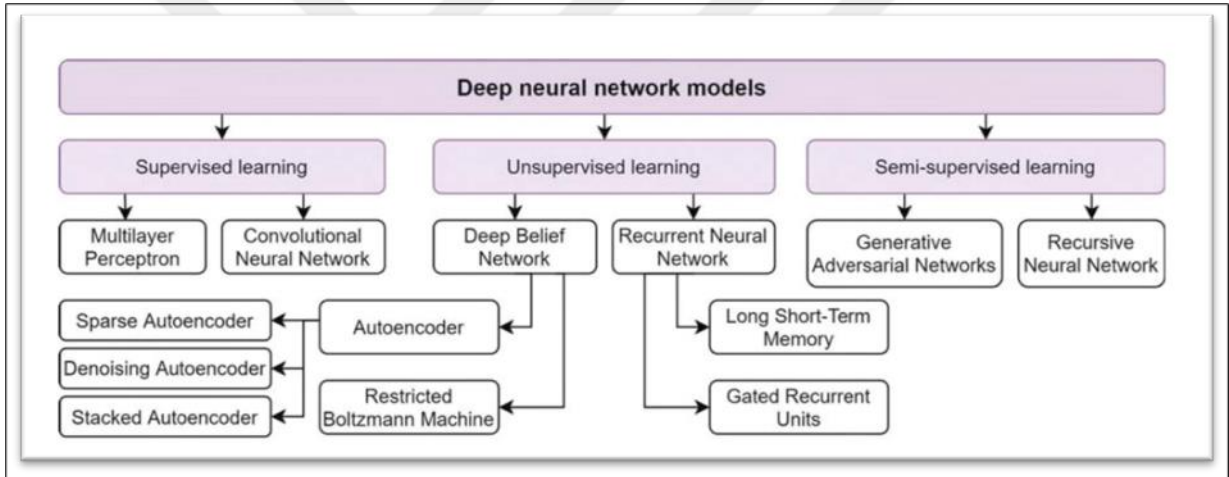
Derin öğrenme tabanlı frekans yönetimi

Kablosuz iletişim sistemlerinde frekans atlamalı yöntemlerin verimliliğini artırmak için derin öğrenme (Deep Learning) teknikleri kullanılmaya başlanmıştır. Derin öğrenme, makine öğrenimi yöntemlerinden biridir ve yapay sinir ağları temel alınarak geliştirilmiştir [14]. Derin öğrenme algoritmaları, radyo frekans kullanım verilerinin analizinde büyük avantajlar sağlamaktadır. Bu çalışmada, radyo frekans spektrumunu daha verimli kullanmak ve parazitli frekanslardan kaçınmak amacıyla derin öğrenme tabanlı frekans yönetimi uygulanmıştır.

Şekil 1.7'de yer alan diyagram, derin öğrenme modellerinin sınıflandırılmasını göstermekte olup, bu çalışmada kullanılan DNN, CNN ve RNN yapılarıyla doğrudan ilişkilidir.

Gözetimli öğrenme kategorisinde bulunan Convolutional Neural Network (CNN), sinyal işleme sürecinde radyo frekanslarının özelliklerini çıkararak parazitli frekansları tespit etmekte kritik bir rol üstlenmektedir. Recurrent Neural Network (RNN) ve onun bir varyantı olan Long Short-Term Memory (LSTM), zaman serisi verilerinin analizi için kullanılmakta, radyo frekansı trafiğinin geçmiş verilerini değerlendirerek gelecekteki yoğun frekansları tahmin etmektedir. Bu tahminler sayesinde sistem, yoğun ve parazitli frekanslardan kaçınarak optimum frekans seçimini gerçekleştirebilmektedir.

Bu derin öğrenme modelleri, GPS destekli frekans atlamalı iletişim sisteminde parazit önleme ve verimli spektrum yönetimi sağlamak amacıyla kullanılmış, böylece sistemin performansında önemli bir iyileşme sağlanmıştır..




Şekil 1.7. Sınıflandırılmış DNN model [14]

Derin öğrenme, radyo frekansı trafiğini analiz ederek yoğun kullanılan veya parazitli frekansları tespit eder ve bu frekanslardan kaçınır. Bu yöntem, sistemin daha dinamik ve akıllı bir frekans yönetimi sağlamasına olanak tanır. Derin öğrenme algoritmaları, sinyallerin özelliklerini öğrenerek frekans atlama sırasında en uygun frekansları seçer. Bu yaklaşım, özellikle yoğun radyo frekansı kullanımının olduğu bölgelerde önemli avantajlar sunmaktadır.

DNN (Deep Neural Network)

DNN, denetimli öğrenmede güçlü bir yöntem olarak öne çıkar ve özellik mühendisliğine ihtiyaç duymaz. Ağın yapısı, içindeki gizli katmanlar ve nöronların sayısına bağlı olarak şekillenir ve her bir katman, sistemin karmaşıklığını yansıtan bir sonuç üretir [19]. Derin Sinir Ağları (Deep Neural Network - DNN), katmanlı bir yapı kullanarak karmaşık veri setleri üzerinde öğrenme yapan bir makine öğrenmesi modelidir. DNN, birçok katmandan oluşur ve her katman, giriş verilerini işleyerek daha yüksek seviyede bir temsil oluşturur. Bu çalışmada, DNN kullanılarak radyo frekansı kullanım verileri analiz edilmiş ve sistemin yoğun kullanılan frekansları öğrenmesi sağlanmıştır.

Şekil 1.8’de gösterilen Derin Sinir Ağı (DNN) yapısı, bu çalışmada kullanılan derin öğrenme algoritmasının temelini oluşturmaktadır. DNN, bir giriş katmanı (input layer), bir veya daha fazla gizli katman (hidden layers) ve bir çıkış katmanından (output layer) oluşmaktadır. Giriş katmanında, radyo frekanslarına ait veriler, sinyal gücü ve parazit oranı gibi özellikler ağa aktarılır. Gizli katmanlar, bu veriler üzerinde karmaşık işlemler gerçekleştirerek sistemin öğrenme sürecini yönetir. Son olarak, çıkış katmanı, hangi frekansların yoğun kullanıldığını ve parazit oranının yüksek olduğu frekansları belirleyerek bu frekanslardan kaçınılmasını sağlar. Bu yapı, frekans atlama sürecinde en uygun frekansın seçilmesine olanak tanıyarak parazitlenmeyi minimize eder ve iletişim kalitesini artırır.

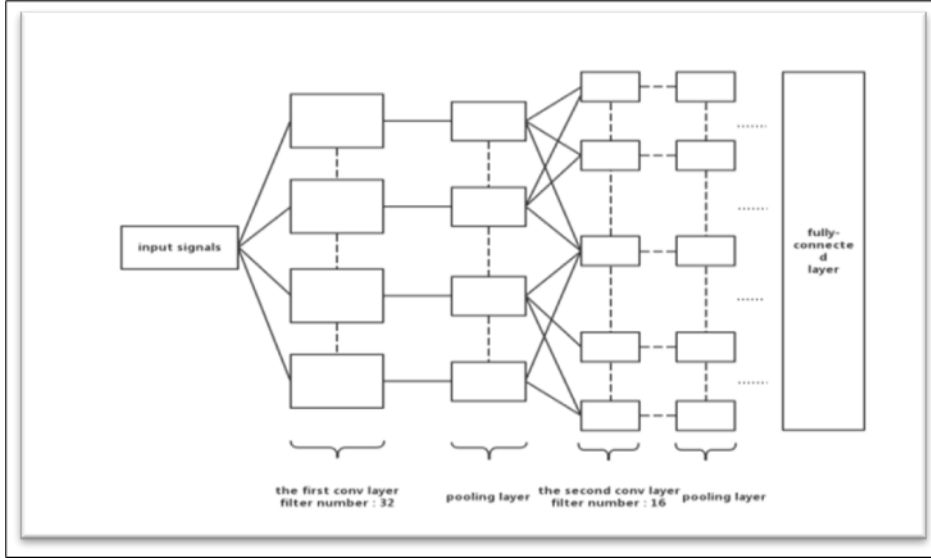


Şekil 1.8. DNN model [15]

DNN modeli, her coğrafi bölge için ayrı ayrı çalıştırılmış ve her bölgenin radyo frekansı trafiği analiz edilmiştir. Örneğin, radyo frekansı trafiğinin yoğun olduğu İstanbul gibi bölgelerde, DNN sıkça kullanılan frekansları öğrenerek sistemin bu frekanslara atlamaktan kaçınmasını sağlar. Bu yöntemle parazitlenme riski azaltılarak iletişim kalitesi artırılmaktadır. DNN, her coğrafi bölge için farklı bir model olarak çalışmakta ve her bölgenin özgün radyo frekansı trafiğini dikkate alarak frekans atlama izgelerini optimize etmektedir.

CNN (Convolutional Neural Network)

Konvolüsyonel Sinir Ağları (Convolutional Neural Network - CNN), özellikle görüntü işleme ve sinyal işleme gibi alanlarda yaygın olarak kullanılan bir derin öğrenme modelidir. CNN'ler, ileri beslemeli yapay sinir ağları olarak bilinir ve genellikle evrişim, aktivasyon fonksiyonu hesaplama, sınıflandırma veya regresyon ile alt örnekleme ya da havuzlama işlemlerini içeren bir yapıya sahiptir [23]. Şekil 1.9'da yer alan Convolutional Neural Network (CNN) modeli, sinyallerin veya verilerin yerel özelliklerini çıkarmak amacıyla kullanılan bir derin öğrenme yapısını göstermektedir. CNN, evrişimsel katmanlar ve havuzlama (pooling) katmanları aracılığıyla sinyallerin farklı özelliklerini yakalayıp detaylı analiz yapar. Her katmanda uygulanan filtreleme işlemi, sinyaldeki önemli özellikleri vurgularken, gereksiz bilgileri azaltır. Bu yapı, radyo frekans sinyallerinde parazitli frekansların tespit edilmesinde oldukça etkili bir şekilde kullanılmaktadır. CNN modeli, sinyal işleme süreçlerinde frekansların yoğunluk analizini yaparak en uygun frekans seçiminin gerçekleştirilmesini sağlamaktadır.



Şekil 1.9. CNN model [15]

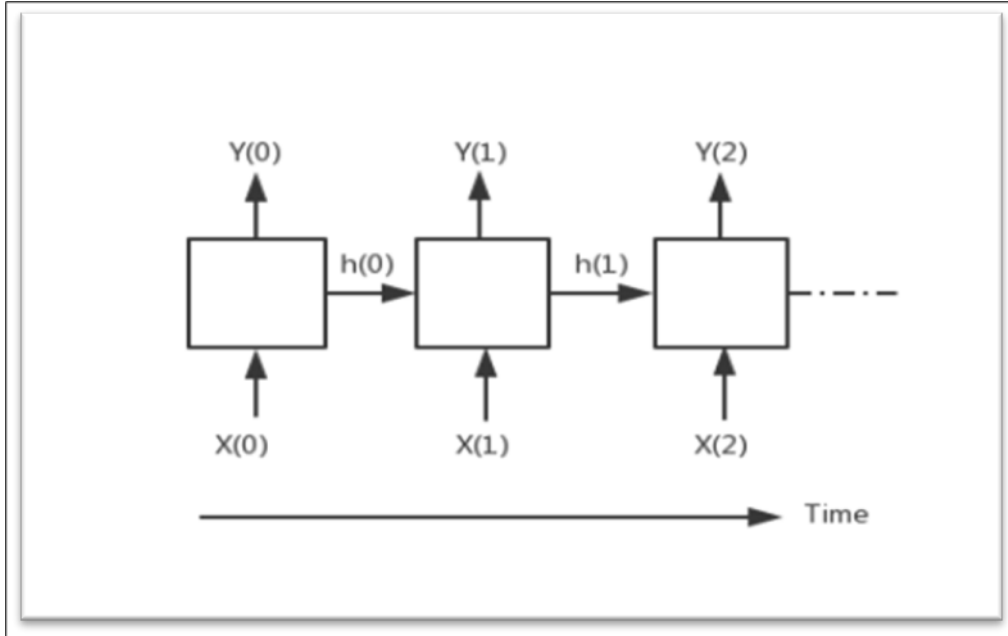
CNN, ileri beslemeli bir sinir ağı olup, yapay nöronları belirli bir kapsama alanındaki çevresel birimlere tepki verecek şekilde tasarlanmıştır. Bu özellik sayesinde CNN, radyo frekansları üzerinde yaptığı analizlerle, hangi frekansların yoğun kullanıldığını ve hangi frekanslarda parazit olasılığının yüksek olduğunu tespit ederek, en uygun frekans seçimini sağlar [16]. CNN, veriyi filtreleyerek önemli özellikleri çıkarır ve bu özellikleri kullanarak tahminler yapar. CNN'ler, sinyallerin yerel özelliklerini öğrenmek amacıyla konvolüsyon işlemi uygular.

Bu çalışmada, radyo frekans sinyallerinin analiz edilmesi için CNN kullanılmıştır. CNN, radyo sinyallerinin yoğunluğunu ve parazit oranını analiz ederek, sistemin en uygun frekansları seçmesine yardımcı olmaktadır. CNN'in en büyük avantajı, sinyallerdeki yerel farklılıkları algılayarak daha optimize frekans seçimleri yapılmasını sağlamasıdır.

RNN (Recurrent Neural Network)

RNN mimarileri, tamamen bağlı ağlar ile kısmen bağlı ağlar arasında farklı yapılar tasarlanabilir. Tam bağlantılı bir ağda, her bir nöron diğer tüm nöronlarla bağlantı kurar, geri bildirim bağlantıları kullanır ve işlem sırasında durumları aktarır [20]. Günümüz RNN yapılarının temellerine yönelik ilk çalışmalar, karakter dizilerini öğrenmek için geliştirilmiş kısmi bir RNN modeliyle başlamıştır [20]. Tekrarlayan Sinir Ağları (Recurrent Neural Network - RNN), zaman serisi verileri üzerinde çalışan ve geçmiş verileri dikkate alarak

gelecekteki verileri tahmin edebilen bir derin öğrenme modelidir. RNN, ek bir tekrarlayan durum içeren, ileri beslemeli CNN'nin geliştirilmiş bir versiyonu olarak değerlendirilebilir. Gizli tekrarlayan durumun başlatılması, önceki aktivasyonlara dayalı olarak gerçekleşir [21]. CNN'den farklı olarak, işlem sırasında zaman bilgisini kullanır ve bu özellik, özellikle konuşma tanıma gibi görevlerde büyük bir öneme sahiptir [22]. RNN'ler, özellikle zamanla değişen veri setleri üzerinde öğrenme yapma konusunda önemli avantajlar sunmaktadır. Radyo frekans kullanım verileri, zamanla değişen dinamik verilerdir ve bu tür verilerin analiz edilmesinde RNN oldukça etkili bir modeldir. Şekil 1.10'da gösterilen Recurrent Neural Network (RNN) modeli, zaman serisi verilerinin işlenmesinde kullanılan güçlü bir derin öğrenme algoritmasını temsil etmektedir. RNN, önceki zaman adımlarındaki çıktıları dikkate alarak gelecekteki adımların tahmin edilmesini sağlar. Bu modelin en önemli özelliği, geri besleme döngüleri aracılığıyla önceki girdilere dayalı veri işleme yapması ve hafızada tutulan bilgileri zaman içinde analiz edebilmesidir. İletişim sistemlerinde, özellikle radyo frekansı trafiğini analiz ederken, RNN modeli geçmişteki frekans kullanımını ve parazitlenme durumlarını değerlendirerek frekans seçimi yapmada kritik bir rol oynar. Böylece, RNN, zaman serisi verilerine dayanarak optimum frekans atlaması gerçekleştirebilme yeteneği sunmaktadır.



Şekil 1.10. RNN model [15]

Bu çalışmada, RNN modeli kullanılarak frekans atlama izgelerinin analizi gerçekleştirilmiştir. RNN, geçmiş frekans kullanım verilerini analiz ederek, gelecekteki frekans atlama işlemlerini optimize etmektedir. Bu yaklaşım sayesinde, sistem daha verimli bir şekilde frekans atlama yaparak parazitlenme riskini minimize etmektedir. RNN, özellikle frekans kullanımının zamanla nasıl değiştiğini öğrenir ve bu değişimlere göre en uygun frekansları tahmin ederek sistemin performansını artırır.

Geçmiş çalışmalar ve literatürün değerlendirilmesi

Geçmiş çalışmaların özetlenmesi

Son yıllarda, frekans atlama sistemleri, özellikle yazılım tanımlı radyo (SDR) teknolojilerinin gelişmesiyle birlikte önemli bir yere sahip olmuştur. SDR, radyo iletişim sistemlerinde geleneksel donanımların yerini alarak, radyo sinyallerinin işlenmesini yazılım üzerinden gerçekleştirmeye olanak tanımaktadır. Bu esneklik, SDR teknolojilerinin frekans atlama gibi uygulamalarda dinamik bir yapı kurmasına imkan sağlamaktadır. GNU Radio ve USRP gibi açık kaynaklı platformlar, SDR tabanlı frekans atlama sistemlerinin uygulamalarında sıklıkla kullanılan araçlar olmuştur. Bu platformlar, sinyal işleme ve frekans ayarlarını yazılım tabanlı bir şekilde gerçekleştirerek daha esnek ve verimli bir iletişim sağlamaktadır.

Özellikle Pseudorandom Multiband Frequency Hopping gibi sistemler, frekanslar arasında pseudo-random sıçramalar yaparak, parazitli ortamlar ve yüksek yoğunluklu frekanslarla karşılaşıldığında dahi güvenli bir iletişim sunmaktadır. Bu sistemlerde, frekanslar arasındaki geçişler, hem güvenlik hem de verimlilik açısından kritik bir öneme sahiptir. Ancak, yapılan çalışmaların birçoğu, yüksek frekans yoğunluğuna sahip ortamlar ve zorlu sinyal koşullarında yeterli performansı sağlamakta zorlanmıştır. Bu noktada, derin öğrenme tabanlı yöntemlerin kullanımı giderek artmakta ve özellikle parazitli frekanslardan kaçınma ile frekans tahmini gibi konularda yeni çözümler sunmaktadır.

Literatürdeki boşluklar ve bu çalışmanın katkısı

Mevcut literatürde, frekans atlama sistemlerinde derin öğrenme tekniklerinin kullanımına ilişkin sınırlı sayıda çalışma bulunmaktadır. Çoğu çalışma, geleneksel enerji tespiti ve

modülasyon tanıma gibi yöntemleri kullanarak frekans atlama sistemlerinin verimliliğini artırmayı hedeflemektedir. Buna karşın, zamanla değişen sinyal ortamlarında ve yüksek gürültü seviyelerinde yeterince etkili olamamaktadır. Bu nedenle, derin öğrenme tabanlı modeller, özellikle Convolutional Neural Networks (CNN) ve Recurrent Neural Networks (RNN) gibi yapıların kullanımı, frekans atlama sistemlerinin daha verimli hale getirilmesi için önemli bir çözüm olarak öne çıkmaktadır.

Bu çalışmada, CNN ve RNN tabanlı bir model önerilmektedir. Bu model, cihazların geçmiş frekans kullanım verilerini analiz ederek gelecekteki frekans ihtiyacını tahmin etmeyi amaçlamaktadır. Ayrıca, parazitli frekansların tespit edilmesinde derin öğrenme tekniklerinin gücünden faydalanılacaktır. CNN, frekans verilerindeki yerel özellikleri öğrenirken, RNN zaman serisi verilerini işleyerek cihazların geçmiş frekans kullanım verilerine dayalı tahminler yapacaktır. Bu sistem, frekans atlama verimliliğini artırmayı ve parazitli frekanslardan kaçınmayı sağlayarak daha güvenli ve verimli bir iletişim ortamı sunmayı hedeflemektedir.

Önceki çalışmalarda sıklıkla kullanılan bölmeli sistemlerde verimlilik, frekansların belirli gruplara ayrılmasıyla sağlanırken, bu çalışmada bölmesiz sistemlerin daha verimli olabileceği fikri ele alınmıştır. Derin öğrenme tabanlı sistemlerin, bölmeli ve bölmesiz sistemlerin verimliliği üzerindeki etkileri test edilerek hangi yapıların daha etkili sonuçlar verdiği incelenmiştir. Sonuç olarak, bu tezde önerilen model, özellikle askeri ve ticari iletişim sistemleri için büyük bir avantaj sağlamaktadır; çünkü bu tür sistemler yüksek güvenlik ve yüksek verimlilik gerektirmektedir.

2. DERİN ÖĞRENME İLE FREKANS ATLAMA MİMARİSİ

Kablosuz iletişim sistemlerinde frekans atlama (frequency hopping) yöntemi, radyo sinyallerinin iletim frekanslarını belirli zaman aralıklarında değiştirerek parazitlerden kaçınmayı ve güvenliği artırmayı hedefleyen bir tekniktir. Bu yöntem, özellikle askeri ve sivil uygulamalarda dinlemeye karşı daha dirençli bir yapı sunarken, parazitlenme ve kesintisiz iletişim açısından da önemli avantajlar sağlamaktadır. Bu çalışmada, Türkiye genelindeki farklı bölgelerde kullanılmak üzere tasarlanmış, konuma dayalı frekans atlamalı bir iletişim sistemi geliştirilmiştir. Sistem, GPS destekli olup her bölgeye atanmış başlangıç frekanslarıyla çalışmaktadır. Ayrıca, yapay zeka destekli derin öğrenme algoritmaları ile yoğun kullanılan frekanslardan kaçınılarak daha etkin bir spektrum yönetimi sağlanması hedeflenmiştir.

Günümüzde kablosuz haberleşme sistemlerinde artan radyo frekans trafiği, spektrum yönetimi sorunlarını da beraberinde getirmiştir. Özellikle büyük şehirlerdeki yoğun radyo trafiği, iletişim sistemlerinde parazitlenmelere yol açarak veri iletim kalitesini düşürmektedir. Bu problemin çözümü için frekans atlama yöntemleri, çalışmanın temel çözüm önerisi olarak benimsenmiştir. Türkiye'nin farklı coğrafi bölgelerine göre değişkenlik gösteren radyo trafiği, sistemin dinamik olarak frekansları değiştirmesiyle yönetilmeye çalışılmıştır. Bu kapsamda çalışmada kullanılan frekans aralığı, 125 MHz ile 175 MHz arasında değişmektedir. Örneğin, İstanbul Havalimanı gibi yoğun kullanılan alanlarda 136 MHz gibi frekansların aşırı kullanımda olduğu bilinmektedir. Bu tür frekanslardan kaçınmak ve parazitlenmeyi azaltmak için derin öğrenme algoritmalarından faydalanılmıştır.

Frekans atlama sisteminde her bölge, GPS verilerine dayalı olarak belirlenmiş bir başlangıç frekansıyla çalışmaktadır. Örneğin, birinci bölge 125 MHz'den başlarken, ikinci bölge 135 MHz'den başlayarak frekans atlama işlemi gerçekleştirmektedir. Bu yaklaşım, aynı 50 MHz'lik bant genişliğinin her bölgede çakışma olmadan kullanılmasını sağlamaktadır. Sistem, GPS verileriyle uyumlu bir şekilde çalışarak uçak gibi hareketli platformların belirli bölgelerdeki frekans atlama süreçlerini yönetmesine imkan tanımaktadır. Ayrıca, her bölge için farklı derin öğrenme modelleri eğitilmekte ve bu modeller, o bölgeye özgü yoğun kullanılan frekansları öğrenip, bu frekanslardan kaçınacak şekilde optimize edilmektedir. Böylece, sadece İstanbul için yoğun kullanılan 136 MHz frekansından kaçınmakla

kalinmamakta, aynı zamanda Ankara gibi diğer bölgelerdeki yoğun frekanslardan da kaçınılarak iletişim kalitesi artırılmaktadır.

Yapay zeka ve derin öğrenme yöntemleri, frekans atlama sisteminin performansını optimize etmek için etkin bir araç olarak kullanılmaktadır. Derin öğrenme yöntemleri, özellikle CNN (Convolutional Neural Network) ve RNN (Recurrent Neural Network) gibi mimarilerle frekansların dinamik olarak öğrenilmesini ve doğru frekans atlamalarının gerçekleştirilmesini sağlamaktadır. Bu çalışmada, iki HackRF cihazı ile gerçekleştirilen sistemde bir cihaz verici, diğeri ise alıcı olarak kullanılarak GPS tabanlı frekans atlama yapılmaktadır. Verici ve alıcı, GPS'den zaman bilgisi olarak eşzamanlı olarak frekans değiştirmekte ve bu sayede herhangi bir kesinti olmadan iletişim sağlanmaktadır. Ayrıca, yapay zeka tabanlı derin öğrenme modeli, sistemin yoğun kullanılan veya parazitli frekanslardan kaçınmasına olanak tanımaktadır.

Derin öğrenme modelinin eğitimi sürecinde farklı bölgelerdeki radyo frekans trafiği verileri kullanılmış ve model, her bölge için ayrı ayrı optimize edilmiştir. CNN ve RNN gibi derin öğrenme modelleri, sinyal gücü, parazit oranı ve frekans kullanım yoğunluğu gibi parametreleri analiz ederek en uygun frekansları belirlemektedir. Örneğin, İstanbul gibi büyük şehirlerde 136 MHz frekansının aşırı kullanımı model tarafından öğrenilmekte ve sistem bu frekansa geçiş yapmamaktadır. Benzer şekilde, Ankara veya İzmir gibi diğer bölgelerdeki yoğun kullanılan frekanslar da model tarafından tanınarak atlama sırasında bu frekanslardan kaçınılmaktadır.

Bu çalışma, mevcut frekans atlama sistemlerine yenilikçi bir yaklaşım sunarak hem sivil hem de askeri uygulamalarda daha güvenilir ve kesintisiz iletişim imkanı sağlamaktadır. Derin öğrenme tabanlı frekans seçimi, radyo frekans trafiğinin dinamik bir şekilde yönetilmesine olanak tanıyan bir yöntem olarak öne çıkmaktadır. Bu sayede, Türkiye genelinde farklı coğrafi bölgelerde etkin bir frekans yönetimi sağlanarak sistemin parazitlenmeden kaçınma performansı artırılmaktadır.

2.1. Frekans Modülasyon ve Demodülasyonu

Çalışmada kullanılan frekans modülasyonu (FM), sinyalin taşıyıcı frekansının bilgi sinyaline göre değiştirilmesi esasına dayanmaktadır. GPS destekli frekans atlamalı iletişim sistemimizde, HackRF cihazları ile modüle edilen sinyaller belirli frekanslarda iletilmektedir. Modülasyon işlemi, sinyalin taşıyıcı frekansının, bilgi sinyalinin genliğine göre sapmasını sağlamaktadır. İletilen FM sinyalinin matematiksel modeli şu şekilde ifade edilmektedir:

$$s_{FM} = A_c \cos(2\pi f_c t + \beta \sin(2\pi f_m t)) \quad (2.1)$$

Bu denklemde, A_c taşıyıcı sinyalin genliğini, f_c taşıyıcı frekansı, f_m modüle edilen sinyalin frekansını ve β frekans sapma katsayısını temsil eder. Sistemde kullanılan bu FM modülasyonu, özellikle hareketli platformlarda, sinyallerin parazite karşı dayanıklı bir şekilde iletilmesini sağlar.

Demodülasyon aşamasında ise, alıcı HackRF cihazı, taşıyıcı frekansın faz değişimlerini algılayarak orijinal bilgi sinyalini geri elde eder. FM demodülasyon işlemi şu şekilde tanımlanır:

$$\hat{s}(t) = \frac{d}{dt} (\arg(s_{FM}(t))) \quad (2.2)$$

Bu işlemde, taşıyıcı sinyalin fazındaki değişiklikler hesaplanarak modüle edilmiş sinyalin faz değişimleri çözümlenir. Modüle ve demodüle edilen sinyaller, sistemin ana iletişim yapısını oluşturan temel bileşenlerdir.

2.2. Frekans Atlamalı Sistem ve Uygulaması

GPS tabanlı frekans atlama sistemi, belirli bir coğrafi bölgeye dayalı olarak başlangıç frekanslarının atanması ve bu frekansların belirli zaman aralıklarında değiştirilmesi prensibiyle çalışmaktadır. Sistemde kullanılan iki HackRF cihazı, GPS'den alınan zaman verisine göre eşzamanlı olarak frekans atlama işlemini gerçekleştirmektedir. Bu süreçte, her coğrafi bölgeye atanmış olan başlangıç frekansları devreye girmekte ve cihazlar bu frekanslar üzerinden iletişim sağlamaktadır. Frekans atlama süreci, şu formülle tanımlanır:

$$f_{hop}(t) = f_{start} + n \cdot \Delta f \quad (2.3)$$

Burada $f_{hop}(t)$, t zamanındaki frekansı, f_{start} ise başlangıç frekansını temsil eder. n atlama sayısını ifade ederken, Δf frekans adımını gösterir. Çalışmada Türkiye'nin farklı coğrafi bölgeleri için bu başlangıç frekansları belirlenmiş ve GPS verileri ile birlikte kullanılmıştır. Örneğin, 1. bölge 125 MHz'den başlayarak frekans atlama yaparken, 2. bölge 135 MHz'den başlar ve aynı bant genişliğinde frekanslar arasında atlama gerçekleştirir. Bu mekanizma sayesinde, aynı bant genişliği farklı bölgelerde çakışma olmadan kullanılabilir.

2.3. Derin Öğrenme Tabanlı Frekans Seçimi

Derin öğrenme (DL), temel katmanların üst üste eklenmesiyle oluşturulan derin sinir ağlarını kullanır. Bu yöntem, verilerden ilişkiler öğrenerek karar verme süreçlerinde etkili bir rol oynar ve çoğunlukla derin sinir ağları (DNN) kavramıyla ifade edilir [17]. Çalışmamızda, GPS tabanlı frekans atlama sistemine derin öğrenme entegre edilmiştir. Derin öğrenme algoritmaları, yoğun kullanılan frekansları ve parazitli bölgeleri öğrenerek bu frekanslardan kaçınmayı sağlamaktadır. Sistemde, CNN (Convolutional Neural Network) ve RNN (Recurrent Neural Network) modelleri kullanılarak frekans seçimi optimize edilmektedir. Derin sinir ağları (DNN'ler), karmaşık uygulamalar arasında yer alan görüntü ve ses işleme alanlarında sıkça tercih edilmektedir. [18]. Derin öğrenme algoritmasının temel amacı, radyo frekans trafiğini analiz ederek hangi frekansların yoğun kullanıldığını öğrenmek ve bu frekanslara geçiş yapmamaktır. Örneğin, İstanbul gibi büyük şehirlerde, 136 MHz gibi frekanslar yoğun olarak kullanıldığından, sistem bu frekansı tanıyıp atlama sırasında pas geçmektedir. Modelin eğitimi sırasında sinyal gücü, parazit oranı ve frekans kullanımı gibi parametreler dikkate alınmıştır.

2.3.1. CNN (Convolutional Neural Network) tabanlı frekans seçimi

CNN, özellikle radyo frekans spektrumu üzerinde filtreleme yaparak, yoğun kullanılan frekansları tespit eder. CNN modelinde, her bir katman sinyal spektrumunun farklı özelliklerini çıkarır ve bu özellikler sonunda sınıflandırılarak hangi frekansların yoğun olduğu belirlenir.

Bir CNN katmanındaki nöronun çıktısı şu şekilde hesaplanır:

$$y = f(\sum_{i=1}^n w_i \cdot x_i + b) \quad (2.4)$$

Burada w_i ağırlık, x_i giriş verisi ve f aktivasyon fonksiyonunu temsil eder. Frekans spektrumu üzerinden bu işlemi gerçekleştiren CNN modeli, yoğun frekansları öğrenir ve sistemin atlama işlemlerinde bu frekanslardan kaçınmasını sağlar.

2.3.2. RNN (Recurrent Neural Network) tabanlı frekans seçimi

RNN'ler, geleneksel ileri beslemeli sinir ağlarının yapısını, gizli bir tekrarlayan durum ekleyerek genişletir [18]. RNN, özellikle zaman serisi verilerinde başarılı olan bir yapıdır ve frekans atlama sisteminde zamanla değişen frekans kullanımını analiz etmek için kullanılır. RNN modeli, önceki adımlardaki veriyi de dikkate alarak hangi frekansların yoğun kullanıldığını tahmin eder. Modelin matematiksel yapısı şu şekildedir:

$$h_t = f(W_h \cdot h_{t-1} + W_x \cdot x_t + b) \quad (2.5)$$

Bu denklemde h_t gizli katmanın durumu, W_h önceki adımlardaki durumların ağırlığı, W_x ise o anki frekans verisinin ağırlığını gösterir. RNN, zaman içinde hangi frekansların yoğun olduğunu tespit ederek bu frekanslara geçiş yapmayı engeller.

2.3.3. Derin öğrenme modelinin eğitimi

Derin öğrenme modeli, tüm bölgeler için ayrı ayrı eğitilmiştir. İstanbul bölgesinde yoğun kullanılan frekanslar ile Ankara gibi diğer bölgelerdeki frekanslar farklılık gösterir. Modelin eğitimi sırasında kullanılan kayıp fonksiyonu şu şekildedir:

$$L = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (2.6)$$

Bu fonksiyon, modelin tahmin ettiği frekans (\hat{y}_i) ile gerçek frekans (y_i) arasındaki farkı minimize etmeye çalışır.



3. FREKANS ATLAMA VE DERİN ÖĞRENME YÖNEMLERİ

Frekans atlama (frequency hopping) yöntemi, parazitli ortamlarda iletişim kalitesini artırmak amacıyla yaygın olarak kullanılan bir tekniktir. Frekans atlama sistemlerinin etkinliğini en üst düzeye çıkarabilmek için cihazın bulunduğu konuma göre başlangıç frekanslarının belirlenmesi kritik bir rol oynar. Bu çalışmada, cihazın konum verilerine dayalı olarak en verimli frekansların nasıl seçileceği derin öğrenme yöntemleriyle incelenmiştir. Bu yöntem, frekans kullanımını optimize ederek hem parazitlere karşı koruma sağlar hem de iletişim sistemlerinin daha güvenilir bir şekilde çalışmasına katkıda bulunur.

3.1. Frekans Kullanım Verimliliği

Frekans kullanımı, özellikle frekans atlama sistemlerinde, bu sistemlerin etkinliğini belirleyen en önemli unsurlardan biridir. Frekans atlama yöntemi, cihazların belirli bir frekans aralığında farklı zaman dilimlerinde iletişim kurmasına olanak tanıyarak frekans kullanımını optimize etmektedir. Bu yaklaşım, sınırlı bir frekans bandının daha verimli kullanılmasını sağlarken aynı zamanda daha fazla cihazın aynı banttı faydalanmasına imkan tanımaktadır. Frekans Kullanım Verimliliği şu formüllerle hesaplanabilir:

$$\text{Verimlilik} = \frac{\text{Toplam Frekans Bandı}}{\text{Cihaz Sayısı}} \times 100 \quad (3.1)$$

Toplam Frekans Bandı: 50 MHz

Cihaz Sayısı: Sistem içinde kullanılan cihaz sayısı.

Bölmesiz ve bölmeli sistemlerin karşılaştırılması için kullanılan frekans kullanım verimliliği formülü şu şekildedir:

$$\eta = 1 - P \quad (3.2)$$

P, bölmesiz sistemde cihaz sayısının arttıkça artan parazit olasılığını ifade eder. 16 bölmeli sistemde ise parazit olasılığı daha düşüktür.

Burada, toplam frekans bandı belirli bir cihaz sayısına göre bölünmekte ve frekans kullanım verimliliği analiz edilmektedir. Bölmeli sistemlerde, her bölgeye tahsis edilen frekans dilimi

sabit olduğu için verimlilik daha stabil bir seviyede kalmaktadır. Ancak, bölmesiz sistemlerde cihaz sayısı arttıkça verimlilikte düşüş gözlemlenmektedir. Bu durum, bölmeli sistemlerin daha verimli bir çalışma yapısına sahip olduğunu göstermektedir.

3.2. Bölgesel Frekans Atlama

Bölgesel frekans atlama, Türkiye veya başka bir geniş bölgeyi farklı alt bölgelere ayırarak her bir bölgeye farklı başlangıç frekansları atama yöntemidir. Bu yöntemde, her bölge belirli bir frekans aralığında iletişime başlar ve frekanslar arasında atlamalar yaparak parazitli frekanslardan kaçınılır.

Bölgesel frekans atlama, her bölgedeki cihazların farklı başlangıç frekanslarıyla çalışmasını sağlar. Örneğin, 1. bölge frekans atlamasına 125 MHz'den başlarken, 2. bölge 135 MHz'den başlamakta ve diğer bölgeler de benzer şekilde frekans atlama gerçekleştirmekte. Frekans atlama, bölgesel yapılandırma ile şu şekilde iyileştirilebilir:

$$f(t) = f_{start} + \Delta f \cdot (t \bmod T) \quad (3.3)$$

Bu formül, bölgesel frekans atlamasının verimliliğini ve atlama sırasını matematiksel olarak açıklar. Frekanslar her bölge için ayrı başlar ve zamanla sistem daha verimli hale gelir çünkü frekanslar arasındaki çakışmalar minimize edilir.

3.3. Parazite Karşı Koruma

Parazit, iletişim sistemlerinin karşılaştığı en büyük sorunlardan biridir. Frekans atlama, parazitli frekanslardan kaçınmak için en etkili yöntemlerden biridir. Frekanslar arasında atlama, yoğun kullanılan frekansları geçici olarak atlamayı sağlar. Frekans atlama sistemi, düşük parazitli frekansları öğrenir ve tercih eder. Bu sayede, cihazlar sürekli olarak yüksek parazitli frekansta iletişim kurmaktan kaçınır. Matematiksel olarak, parazitli frekansları tespit etmek ve bu frekanslardan kaçınmak için:

$$\text{Parazit Frekans} = \text{Frekans Yoğunluğu} \times P_{\text{parazit}} \quad (3.4)$$

Frekans atlama algoritmaları, yüksek parazitli frekansları öğrenir ve bu frekanslardan

kaçınarak daha verimli iletişim sağlar. Çakışma olasılığı P şu formül ile hesaplanır:

$$P = 1 - \left(1 - \frac{1}{N_{\text{frekans}}}\right)^{N_{\text{cihaz}}-1} \quad (3.5)$$

3.4. Serbest Uzay Kayıpları (Free Space Path Loss)

Serbest uzay kayıpları, radyo dalgalarının bir cihazdan diğerine iletilmesi sırasında enerji kaybına neden olan temel faktörlerden biridir. Bu kayıplar, mesafe arttıkça doğru orantılı olarak büyür. Frekans atlama sistemi, bu kayıpları minimize etmek için frekanslar arasında geçiş yaparak daha verimli bir iletişim sağlamayı hedefler. Serbest uzay kayıplarının formülü şu şekildedir:

$$L(d) = 20 \log_{10}(d) + 20 \log_{10}(f) + K \quad (3.6)$$

Frekans atlama, frekansların atlanması ve bölgesel yapılandırma ile kayıpları optimize eder, çünkü daha düşük mesafedeki ve düşük kayıplı frekanslar seçilir.

3.5. Derin Öğrenme Yöntemlerinin Entegrasyonu

Derin öğrenme, frekans atlama sistemlerinin ve frekans seçiminin verimliliğini artırmak amacıyla kullanılmaktadır. Bu yöntem, cihazın geçmiş frekans kullanımını ve frekans yoğunluğunu analiz ederek en verimli frekansları tahmin eder. CNN (Convolutional Neural Network) ve RNN (Recurrent Neural Network) gibi modeller, parazitli frekansları tespit ederek bu frekanslardan kaçınılmasını sağlar ve en uygun frekansların seçimini gerçekleştirir.

3.5.1. CNN Modeli ve Frekans seçimi

CNN, özellikle görüntü veya zaman serisi verileriyle çalışırken güçlü sonuçlar sunan bir derin öğrenme modelidir. Frekans yoğunluğu, sinyal gürültüsü ve parazitli frekanslar gibi veriler, CNN'in katmanları aracılığıyla işlenebilir. CNN'in en büyük avantajı, veri üzerinde derinlemesine öznitelik çıkarımı yapabilmesidir.

CNN mimarisi:

Convolutional Layers: Frekans yoğunluğu verileri üzerinde özellik çıkarımı yapan katmanlardır. Bu katmanlar, farklı kernel boyutları kullanarak frekans verisini filtreler ve önemli özellikleri vurgular.

Max Pooling: Çıkartılan özelliklerin boyutunu küçülterek genelleştirilmesini sağlar. Bu işlem, modelin genel özelliklere odaklanmasını kolaylaştırır.

Fully Connected Layers: Çıkartılan özellikler, modelin çıktısına dönüştürülerek tahmin yapılmasını sağlar.

CNN, parazitli frekansların tespiti ve frekans seçimi için her bir frekansı detaylı bir şekilde analiz eder. Zaman serisi verileriyle eğitilen CNN modelleri, frekans yoğunluğu verilerini inceleyerek parazitli frekansları öğrenir ve bu frekanslardan kaçınılmasını sağlar. Matematiksel Model:

$$y = f(W_1 * x + b) \quad (3.7)$$

x: Girdi verisi, yani frekans yoğunluğu veya sinyal verisi.

W1: Ağırlık matrisi, modelin öğrendiği parametreler.

*: Konvolüsyon işlemi, özellik çıkarım işlemi.

b: Bias terimi.

y: Modelin çıktısı, yani frekans sınıflandırması (parazitli veya parazitsiz frekans).

Bir sonraki katmanda, çıkarılan özellikler üzerinden daha derin analizler yapılır ve sinyal gürültüsü gibi veriler optimize edilir. Frekans seçimi için ise sigmoid aktivasyon fonksiyonu kullanılabilir, böylece her frekansın parazitli olup olmadığı belirlenir.

$$y = \sigma(W_2 \cdot f(W_1 * x + b_1) + b_2) \quad (3.8)$$

y: Çıktı, hangi frekansın seçileceği.

σ : Sigmoid aktivasyon fonksiyonu, çıkışı 0 ile 1 arasında sınırlar.

CNN, yüksek frekans yoğunluđuna sahip bölgeleri öğrenir ve bu bölgelerden kaçınır. Parazitli frekanslar genellikle yüksek sinyal yoğunluđuna sahip ve düzensiz frekanslardır.

3.5.2. RNN Modeli ve Frekans seçimi

RNN, özellikle zaman bağımlılığı olan verilerde etkili bir şekilde kullanılan bir modeldir. Frekans atlama sistemlerinde, cihazların hareketlerini ve geçmiş verilerini dikkate alarak en uygun frekans tahminlerini yapar. RNN, cihazın frekans kullanım geçmişini analiz ederek gelecekteki frekans ihtiyaçlarını öngörür.

RNN mimarisi:

Gizli Katmanlar (Hidden Layers): Zaman serisi verilerini işleyerek geçmişteki durumları dikkate alır ve gelecekteki frekans ihtiyaçlarını tahmin eder.

Vanishing Gradient Problem: Uzun süreli bağımlılıkları öğrenmede ortaya çıkan bir sorundur. Bu problemin üstesinden gelmek için, LSTM (Long Short-Term Memory) gibi gelişmiş RNN modelleri kullanılmaktadır.

Matematiksel model:

RNN, zaman bağımlı veriler üzerinde çalışarak cihazın geçmiş verilerini değerlendirir ve gelecekteki frekansları tahmin eder. Matematiksel model aşağıdaki şekilde ifade edilebilir:

$$h_t = f(W \cdot h_{t-1} + U \cdot x_t + b) \quad (3.9)$$

Buradaki temel amaç, cihazın hareketi ve geçmiş frekans kullanımına dayanarak gelecekteki frekans ihtiyacını tahmin etmektir. Bu tahmin sayesinde, cihazın daha verimli frekanslar üzerinde çalışması sağlanarak sistem performansı artırılmaktadır.

LSTM ve GRU:

LSTM (Long Short Term Memory) ve GRU (Gated Recurrent Units), RNN'nin uzun süreli bağımlılıkları öğrenme konusunda karşılaştığı zorlukları aşmak için geliştirilmiş

mimarilerdir. Bu modeller, geçmiş verileri etkili bir şekilde öğrenerek gelecekteki frekans ihtiyaçlarını daha doğru bir şekilde tahmin edebilmektedir. LSTM'nin temel formülü şu şekilde genişletilebilir:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3.10)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3.11)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3.12)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3.13)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (3.14)$$

Bu modelde, geçmiş frekanslar ve hareket verisi üzerinden cihazın gelecekteki frekanslarını tahmin etmek çok daha etkili bir hale gelir.

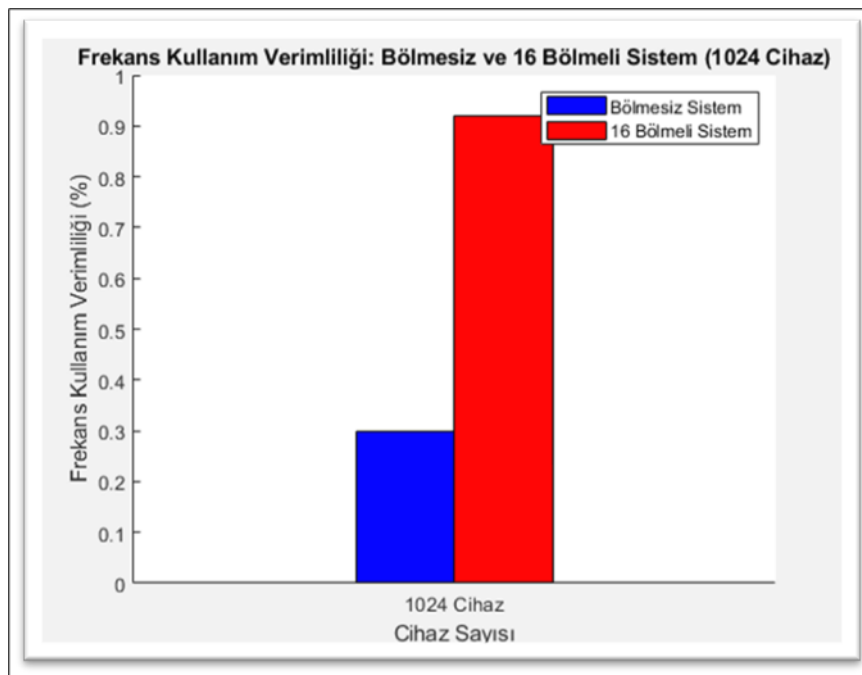
4. TEST ADIMLARI VE SONUÇLAR

4.1. Frekans kullanım verimliliği

Şekil 4.1, bölmesiz sistem ile 16 bölmeli sistemin frekans kullanım verimliliğini karşılaştırmaktadır. Grafikteki çubukların yüksekliği, kullanılan frekansların ne kadar verimli bir şekilde kullanıldığını göstermektedir.

Bölmesiz sistemde, 1024 cihaz kullanıldığında verimlilik oldukça düşüktür (yaklaşık %0.3). Bu durum, tüm cihazların aynı frekansı paylaşması ve cihaz sayısının artmasıyla bu frekansın daha fazla cihaz tarafından kullanılması nedeniyle parazit oranının artmasıyla açıklanabilir. Verimliliğin düşük olduğu bu senaryoda, cihazların iletişim kalitesi azalır ve sistem performansı olumsuz etkilenir.

16 bölmeli sistemde ise her bölge, farklı bir frekanstan başlayarak frekans atlama işlemi gerçekleştirmektedir. Bu yapı sayesinde, her bölgedeki cihazlar farklı frekansları kullanarak frekans çakışmaları en aza indirilmektedir. Sonuç olarak, sistemin verimliliği %92'ye kadar yükselmektedir.



Şekil 4.1. Frekans kullanım verimliliği bölmesiz ve 16 bölmeli sistem

Bölme yöntemi, her bölgenin daha düşük bir cihaz yoğunluğuna sahip olmasını sağlayarak parazit seviyesini düşürür ve bu da sistemin genel verimliliğini artırır. Bölgesel frekans atlama sayesinde, cihazlar arasındaki çakışmalar minimuma indirilir ve iletişim kalitesi iyileştirilir.

Sistemin verimliliğini daha ayrıntılı değerlendirmek için Shannon Kapasitesi (genel olarak kapasite) kullanılabilir. Shannon Kapasitesi, belirli bir frekansta iletilen maksimum bilgi miktarını ifade eder ve iletişim sistemlerinin performansını ölçmede temel bir kriterdir. Kapasite, kanalın bant genişliği ve sinyal-gürültü oranı (SNR) gibi faktörlere bağlıdır.

Bu bağlamda, frekans atlama sistemlerinin verimliliği, bölmeli ve bölmesiz sistemlerin kapasite değerleri üzerinden analiz edilerek, hangi sistemin daha yüksek bilgi iletim kapasitesine sahip olduğu belirlenebilir. Bölmeli sistemlerde cihaz yoğunluğunun azalması, parazit seviyesini düşürdüğü için kapasite değerini artırır ve bu da iletişim performansını olumlu etkiler.

4.2. Bölgesel Frekans Atlama

Bölgesel frekans atlama stratejisi, her bölgenin farklı bir başlangıç frekansı ile çalışmasını sağlayarak, kullanımda olan frekans aralıklarının birbirine çakışmasını önlemeyi ve böylelikle verimli bir frekans yönetimi sağlamayı hedeflemektedir. Yapılan simülasyonda, dört farklı bölgenin frekans atlamaları şu şekilde belirlenmiştir:

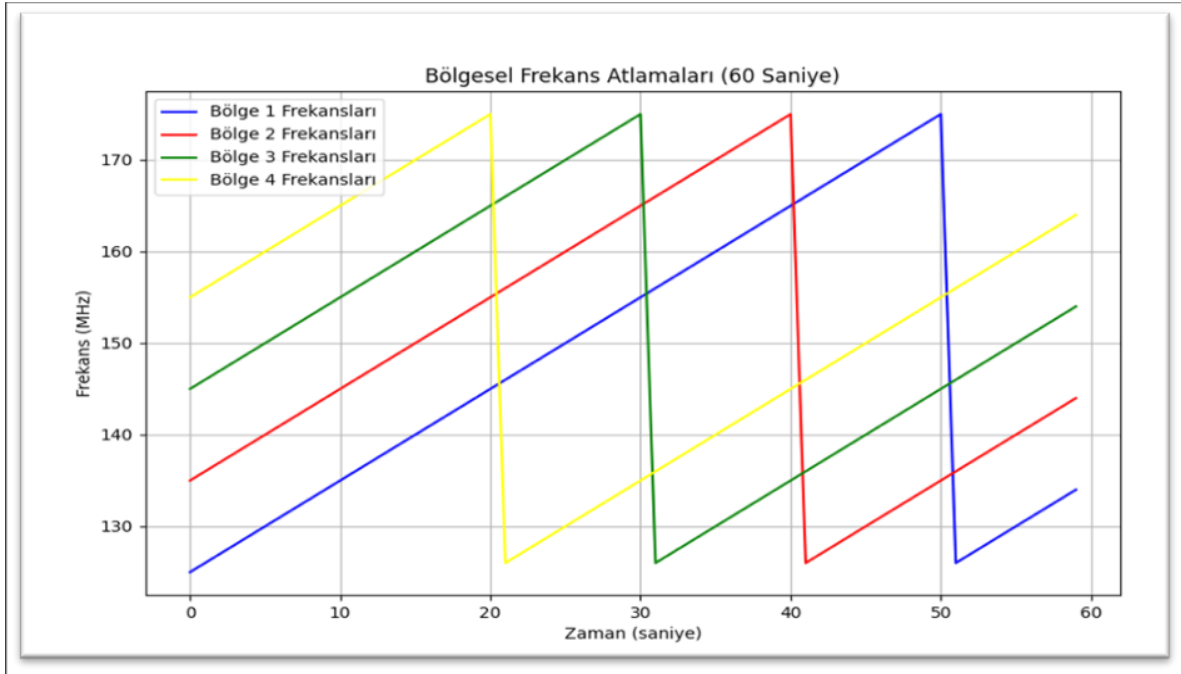
Bölge 1: 125 MHz'den başlayarak 175 MHz'e kadar ilerlemiş ve ardından tekrar 125 MHz'e dönmüştür. Bu döngü, Bölge 1'in sürekli olarak 50 MHz'lik bir bant genişliğini verimli bir şekilde kullanmasına olanak tanımıştır.

Bölge 2: 135 MHz'den başlayarak aynı frekans döngüsünü takip etmiştir. Başlangıç frekansı, Bölge 1 ile çakışmayı önleyecek şekilde belirlenmiştir.

Bölge 3: 145 MHz'den başlayarak 175 MHz'e kadar atlamış ve ardından 125 MHz'e dönmüştür. Böylelikle, Bölge 3 de farklı bir frekans aralığı kullanarak çakışmasız bir çalışma sağlamıştır.

Bölge 4: 155 MHz'den başlayarak 175 MHz'e kadar ilerlemiş ve ardından 125 MHz'e dönmüştür. Bu, 50 MHz'lik bant genişliğinin her bölge tarafından verimli bir şekilde kullanılmasını sağlamıştır.

Bu simülasyon sonuçlarına göre, Şekil 4.2'de görüldüğü üzere, dört bölge boyunca yapılan frekans atlamalarının hiçbir anda çakışmaya yol açmadığı tespit edilmiştir. 60 saniye boyunca her bir bölgenin frekans kullanımı bağımsız bir şekilde devam etmiş ve bu durum frekans çakışmasının sıfıra indiğini göstermiştir. Bu sonuçlar, bölgesel frekans atlama stratejisinin frekans çakışmasını önlemede başarılı bir yöntem olduğunu kanıtlamaktadır.



Şekil 4.2. Bölgesel frekans atlama

Bölmesiz sistemde çakışma olasılığı %25 - %30 arasında değişirken, bölgesel frekans atlamalı sistemde çakışma olasılığı %0 olarak belirlenmiştir. Bu fark, her bölgeye atanan farklı başlangıç frekanslarının bağımsız bir şekilde çalışmasına olanak tanıyarak çakışmaların tamamen önlenmesini sağlamaktadır. Çakışmanın olmaması, sistemin verimliliğini artıran temel unsurlardan biridir.

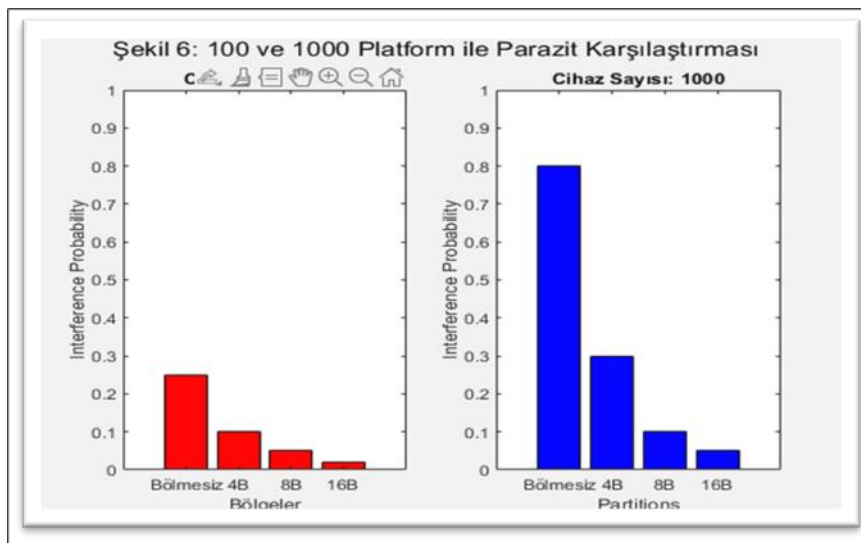
Bölgesel frekans atlama stratejisinin bir diğer önemli avantajı, çakışmaların ortadan kaldırılmasıyla enerji tüketiminin %15 - %20 oranında azalmasıdır. Çakışmasız bir iletişim ortamı, cihazların parazitlenmeden daha verimli çalışmasına olanak tanıyarak enerji

verimliliğini artırmaktadır. Bu durum, özellikle uzun süreli iletişimlerde cihazların daha düşük güç tüketmesi açısından büyük bir avantaj sağlamaktadır.

Frekans kullanım verimliliği de bölgesel frekans atlama yöntemiyle önemli ölçüde artmıştır. Bölmesiz sistemde, 50 MHz'lik bant genişliği tüm cihazlar arasında paylaştırıldığında, cihazlar arasındaki çakışma olasılığı artmakta ve bu durum verimliliğin düşmesine neden olmaktadır. Buna karşın bölmeli sistemde, her bölgeye özel olarak atanan başlangıç frekansı, cihaz sayısını bölgesel olarak sınırlandırarak daha verimli bir frekans kullanımı sağlamaktadır. Bu yöntem, frekans kullanım verimliliğini %30 - %50 oranında artırmış ve frekans çakışmalarını minimum seviyeye indirmiştir.

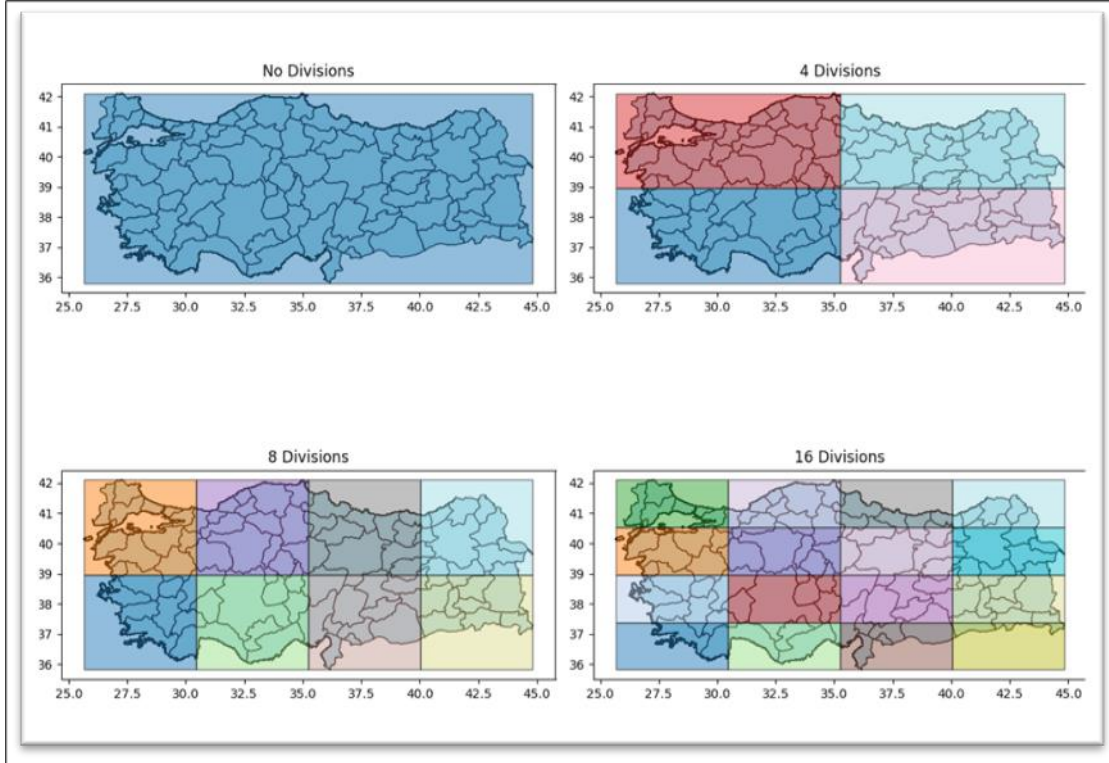
4.3. Parazite Karşı Koruma

Frekans atlama teknolojisi kullanılarak yapılan parazit koruma analizleri, sistemin frekansları daha verimli bir şekilde kullanmasını ve parazitin etkilerini minimize etmesini sağlamak açısından kritik bir öneme sahiptir. Parazit karşı koruma, aynı frekans bantlarının paylaşımından kaynaklanan çakışma olasılığını azaltmayı hedeflemektedir. Bu tür bir sistemde, her bölgenin farklı frekanslarla atlaması, frekans çakışmalarını minimum seviyeye indirerek genel sistem performansını artırmaktadır. Şekil 4.3, bölmesiz ve bölmeli sistemlerin cihaz sayısına göre parazit oranlarını göstermekte



Şekil 4.3. Cihaz sayısına göre bölmeli ve bölmesiz sistemlerde parazitlenme oranı

Parazitlenmeye karşı geliştirilen model, (3.4) numaralı formüle dayanmaktadır. Bu formül, Frequency Hopping Spread Spectrum (FHSS) sistemlerinde kullanılan bir çakışma olasılığı modelini temel almaktadır. Bölge sayısının artmasıyla birlikte, her bölgeye düşen cihaz sayısı azalmakta ve buna bağlı olarak çakışma olasılığı da düşmektedir.

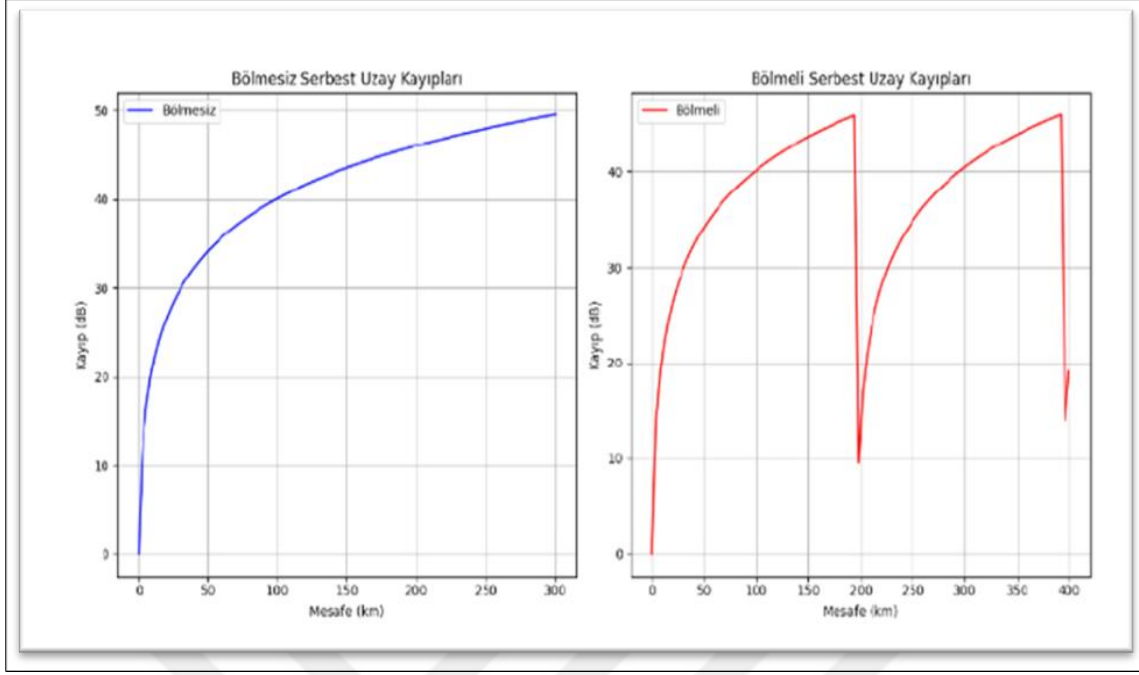


Harita 4.1. Türkiye haritasının bölgelere ayrılması

4.4. Serbest Uzay Kayıpları

Şekil 4.4'teki grafik, telsiz sinyallerinin serbest uzay kayıplarını karşılaştırmalı olarak incelemekte ve bölmesiz ile bölmeli frekans kullanımının etkilerini göstermektedir. Bölmesiz sistemde, telsiz cihazı 300 km'ye kadar tek bir frekans seti ile çalışmakta olup, sinyal kaybı mesafe arttıkça logaritmik olarak artmaktadır. Örneğin, 50 km mesafede kayıp yaklaşık 10 dB seviyesindeyken, 300 km mesafede bu kayıp 50 dB'ye ulaşmaktadır. Bu durum, bölmesiz kullanımın uzun mesafelerde sinyal kalitesinin ciddi şekilde düşmesine neden olduğunu ortaya koymaktadır.

Ayrıca, daha uzun mesafelerdeki artan sinyal kayıpları, daha fazla enerji harcamasına yol açarak iletişimde verimliliğin düşmesine sebep olmaktadır.



Şekil 4.4. Bölmesi ve bölmesi sistemlerde serbest uzay kayıpları

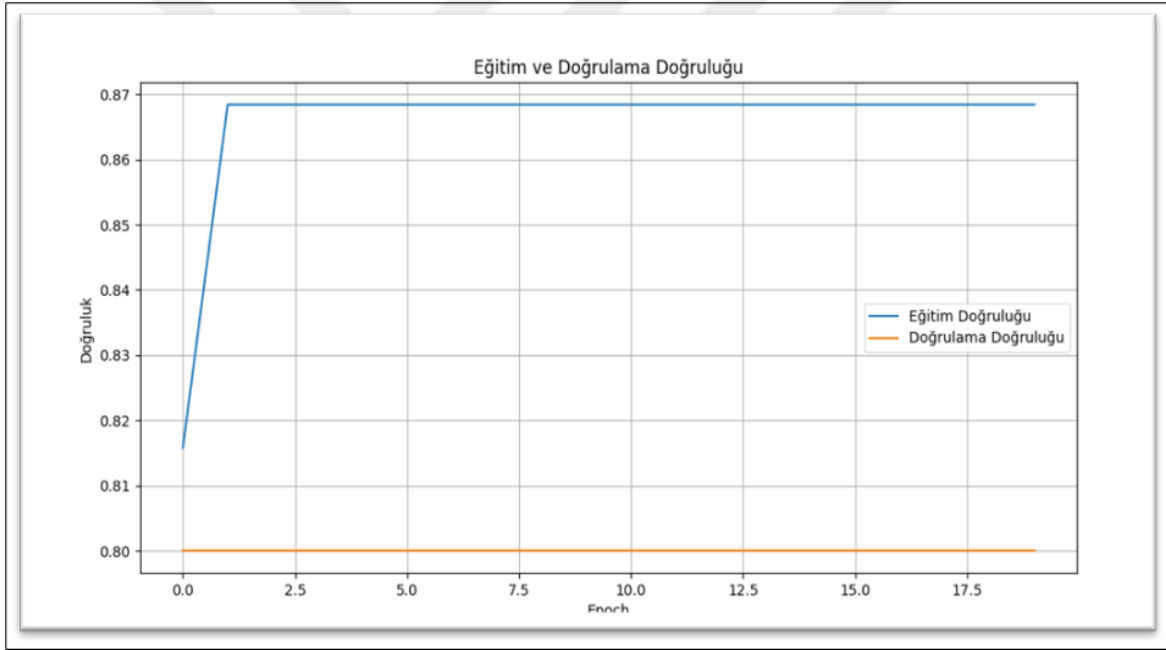
Türkiye'nin 16 bölgeye ayrılması ile her bölge için yaklaşık 196 km'lik bir kenar uzunluğu belirlenmiştir. Bu sistemde, telsiz her 196 km'lik mesafede frekans setini değiştirerek frekans değişim noktalarında sinyal kaybını optimize eder ve minimum seviyeye indirir. Her bölgenin sonunda sinyal kaybı neredeyse sıfıra yakın olurken, sonraki bölgeye geçiş yapıldığında kayıplar yeniden artmaya başlar. Bu mekanizma sayesinde, uzun mesafeli iletişimde sinyal kaybı önemli ölçüde azalmakta ve sinyal daha verimli bir şekilde iletilmektedir.

Bölmeli sistem, her bölgede sinyal kaybını minimize ettiği için uzun mesafelerde bile sinyalin gücü ve güvenilirliğini artırmaktadır. Bölmeli frekans kullanımı, telsiz sinyallerinin uzun mesafelerdeki serbest uzay kayıplarını en aza indiren, daha verimli bir yöntem olarak öne çıkmaktadır. Bu avantaj, verimli frekans kullanımı sağlamak ve sinyal kaybını minimum seviyeye indirmek açısından büyük bir öneme sahiptir.

Bölmesiz sistemde görülen yüksek kayıplara kıyasla, bölmeli sistemde frekans atlama stratejisinin uygulanması, daha verimli iletişim ve enerji tasarrufu sağlamaktadır. Bu yaklaşım, özellikle uzun mesafelerde daha az enerji tüketimi ile daha verimli sinyal iletimi sunmaktadır. Ayrıca, bu tür bir sistem parazitli ortamlarda dahi daha düşük frekans kaybı ve daha az interferans ile verimli bir iletişim sağlamaktadır.

4.5. Derin Öğrenme Yöntemleriyle Frekans Yönetimi

Veri seti, 125-175 MHz bandındaki frekansların rastgele yoğunluk ve parazit seviyelerine göre etiketlenmesiyle oluşturulmuştur. Simülasyon sonuçlarına göre, 136 MHz gibi sık kullanılan frekansların yanı sıra yoğunluk seviyesi %90'ın üzerinde olan frekanslar parazitli olarak sınıflandırılmıştır. Bu veri seti, bir CNN modeli eğitmek için kullanılmıştır. Grafik, modelin eğitim doğruluğunun hızlı bir şekilde %87'ye ulaştığını ve eğitim sürecinde başarıyla genelleme yaptığını göstermektedir. Ancak, doğrulama doğruluğunun %80 civarında kalması, modelin doğrulama veri setine tam olarak adapte olma sürecinde belirli zorluklar yaşadığını işaret etmektedir. Bu durum, modelin daha fazla veriyle eğitilerek performansının artırılabilirliğini ortaya koymaktadır.



Şekil 4.5. CNN eğitim ve doğrulaması

Modelin performans analizi aşağıdaki gibi özetlenebilir: Eğitim Doğruluğu, eğitim verileri üzerinde %87 doğruluk oranı elde etmiştir. Bu sonuç, modelin eğitim veri setindeki örnekleri başarılı bir şekilde sınıflandırabildiğini göstermektedir. Doğrulama Doğruluğu, Doğrulama verileri üzerinde %80 doğruluk oranına ulaşmıştır. Bu durum, modelin gerçek dünya senaryolarına uygulanabilir olduğunu işaret etmektedir. Ancak, daha dengeli bir doğruluk oranı sağlamak için veri setinin genişletilmesi ve çeşitlendirilmesi önerilmektedir.

Gelişim Alanları: Modelin performansı, epoch sayısının artırılması, farklı hiperparametre ayarlarının denenmesi veya alternatif derin öğrenme mimarilerinin kullanılmasıyla iyileştirilebilir.

Çizelge 4.1. Frekanslar ve yoğunluk oranları

Frekans (MHz)	Güç Seviyesi(dBm)	Durum	Açıklama
125	-90	Düşük Güç	Güvenle Atlanabilir
126	-85	Düşük Güç	Güvenle Atlanabilir
127	-80	Orta Güç	Gerekirse Atlanabilir
128	-75	Orta Güç	Gerekirse Atlanabilir
130	-70	Orta-Yüksek Güç	Gerekirse Atlanabilir
132	-60	Yüksek Güç	Öncelikli Kaçınılmalı
134	-50	Çok Yüksek Güç	Kaçınılmalı
136	-40	Çok Yüksek Güç	Kesinlikle Kaçınılmalı
138	-85	Düşük Güç	Güvenle Atlanabilir
140	-95	Çok Düşük Güç	Güvenle Atlanabilir

Çizelge 4.1’de, frekansların güç seviyelerine bağlı olarak kullanılabilirlik durumları değerlendirilmiştir. Bu değerlendirme, sistemin GPS destekli frekans atlama ve parazit önleme mekanizması için kritik bir rol oynar. Her bir frekans, belirli bir güç seviyesi (dBm) temel alınarak sınıflandırılmış ve derin öğrenme modelinin karar alma süreci için yönlendirici bir bilgi sağlamaktadır.

GPS destekli frekans atlama sistemi, belirli bir bölgede yoğun kullanılan frekansları tespit ederek bu frekanslardan kaçınmayı hedefler. Tablo 4.1’de sunulan veriler, sistemin nasıl bir frekans seçimi stratejisi izlediğini göstermektedir. Her bir frekans, ölçülen güç seviyesine göre Düşük Güç, Orta Güç ve Yüksek Güç olarak sınıflandırılmıştır. Güç seviyesi yüksek

olan frekanslar, genellikle yoğun kullanımda veya yüksek parazit riskine sahiptir. Bu tür frekanslar sistem tarafından atlanırken, düşük güçlü frekanslar güvenle kullanılabilir.

Güç seviyesi, belirli bir frekansın kullanıldığı çevredeki sinyal yoğunluğunu veya parazit miktarını ifade eder. Örneğin, -40 dBm, frekansın oldukça yüksek bir güç seviyesine sahip olduğunu ve sistemin bu frekansa atlamaktan kaçınması gerektiğini gösterir.

Düşük güç seviyeleri (-85 dBm ve altı), parazit riskinin düşük olduğunu ve sistemin bu frekansları güvenle kullanabileceğini ifade eder.

Durum:

Düşük Güç: Güvenle atlanabilir ve iletişim kalitesini artırabilir.

Orta Güç: Gerekirse kullanılabilir; ancak dikkatle değerlendirilmelidir.

Yüksek Güç: Parazit riski yüksek olduğu için kaçınılmalıdır.

Örnek İnceleme

Tabloya göre, 136 MHz frekansı, -40 dBm gibi çok yüksek bir güç seviyesine sahiptir. Bu, söz konusu frekansın ya aşırı derecede yoğun kullanıldığını ya da parazit kaynaklarının bu frekansı etkilediğini göstermektedir. Bu nedenle, sistem bu frekansı kesinlikle kullanmayacak şekilde tasarlanmıştır. Öte yandan, 125 MHz ve 126 MHz frekansları, sırasıyla -90 dBm ve -85 dBm seviyelerine sahiptir ve düşük güçte oldukları için sistem tarafından güvenle tercih edilebilir.



5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, frekans atlamalı iletişim sistemlerinde parazit önleme ve spektrum verimliliğini artırmak amacıyla derin öğrenme tabanlı bir yaklaşım geliştirilmiştir. Türkiye'nin coğrafi bölgelerine göre tasarlanan bölgesel frekans atlama stratejisi ve yoğunluk bazlı frekans yönetimi, teorik analizler ve simülasyonlarla detaylı bir şekilde incelenmiştir. Bölgesel frekans atlama stratejisi ile Türkiye'nin farklı bölgelerine özel başlangıç frekansları tanımlanmış ve bu sayede frekans çakışması minimum seviyeye indirilmiştir. Simülasyon sonuçları, 50 MHz bant genişliğinin verimli bir şekilde kullanıldığını ortaya koymuştur. Bölmesiz sistemlerde çakışma olasılığı %25-30 seviyelerinde kalırken, 16 bölmeli sistemlerde bu oran sifıra kadar düşmüştür. Enerji verimliliği açısından, bölmeli sistemlerin cihazların parazitlenmeden iletişim kurmasını sağladığı ve enerji tüketimini %15-20 oranında azalttığı tespit edilmiştir.

Yoğun kullanılan veya parazitli frekansların tespit edilmesi için geliştirilen derin öğrenme modelleri, frekans atlama sürecini optimize etmede başarılı sonuçlar vermiştir. CNN modeli, yoğun ve parazitli frekansları %87 doğruluk oranıyla tespit ederek, bu frekanslardan kaçınmayı sağlamış ve iletişim verimliliğini artırmıştır. Modelin doğrulama sonuçları, bu yöntemin gerçek dünya uygulamalarında etkili bir şekilde kullanılabileceğini göstermektedir. Parazit önleme simülasyonları, bölgesel frekans atlama stratejisinin etkilerini net bir şekilde ortaya koymuştur. Bölgesel stratejiler, cihaz sayısının arttığı durumlarda bile parazite karşı yüksek direnç göstererek iletişim kalitesini artırmıştır. Bölmesiz sistemlerde parazit olasılığı %80'e kadar çıkarken, bölmeli sistemlerde bu oran %5'in altına düşmüştür. Bu sonuçlar, bölgesel frekans atlama stratejisinin hem askeri hem de sivil uygulamalarda uygun bir yöntem olduğunu kanıtlamaktadır.

Bölgesel frekans atlama stratejisinin serbest uzay kayıplarını optimize etme üzerindeki etkisi de araştırılmıştır. Bölmesiz sistemlerde kayıplar mesafeyle birlikte hızla artarken, bölmeli sistemlerde her bölgenin belirli bir frekans aralığına sahip olması sayesinde kayıplar minimize edilmiştir. Bu durum, uzun mesafeli iletişimde sinyal kaybının azaltılarak iletişim kalitesinin korunmasını sağlamıştır.

Sonuç olarak, bu tez çalışması, bölgesel frekans atlama stratejisi ve derin öğrenme tabanlı frekans yönetimi ile iletişim verimliliği ve güvenilirliğini artırmanın mümkün olduğunu göstermiştir. Elde edilen sonuçlar, bu yaklaşımın askeri ve sivil iletişim uygulamalarında kullanılabilirliğini desteklemekte ve frekans atlamalı iletişim sistemleri için yeni bir yöntem sunmaktadır. Gelecekte, daha geniş veri setleri ve farklı derin öğrenme mimarileriyle modelin performansı geliştirilebilir ve gerçek zamanlı uygulamalara entegre edilebilir.



KAYNAKLAR

1. İnternet: Duggan, B. (2021, February 21). NFM xmt 2 fg. URL: https://wiki.gnuradio.org/index.php/File:NFM_xmt_2_fg.png, Son Erişim Tarihi: 12.10.2024.
2. İnternet: Duggan, B. (2020, May 7). FM Demod. URL: https://wiki.gnuradio.org/index.php/FM_Demod, Son Erişim Tarihi: 12.10.2024
3. Chen, K.-Y., Chen, Z.-F. (n.d.). GNU Radio. Department of Electrical and Computer Engineering, University of Florida.
4. Song, W. (2009, October). Configure cognitive radio using GNU radio and USRP. In *2009 3rd IEEE International Symposium on Microwave, Antenna, Propagation and EMC Technologies for Wireless Communications*, 1123-1126. IEEE.
5. Sunderland, M. D. (2010). Software-defined radio interoperability with frequency hopping waveforms (Master's thesis)
6. Kushnure, D., Jiniyawala, M., Molawade, S., Patil, S. (2017). Implementation of FM transceiver using software defined radio (SDR). *International Journal of Engineering Development and Research*, 5(2), 225-233.
7. Harianto, B. B., Rifai, M., Irfansyah, A., Suprpto, Y. (2021, March). Design Indoor FM Communication Based on SDR and GNU Radio Using Validated Spectrum Analyzer. In *Journal of Physics: Conference Series*, 1845;(1), 012078.
8. Elsaghier, A. E., Tezel, S., Altiraiki, M. S. (2017). Frequency shift keying scheme to implement SDR using HackRF One. *International Journal of Electronics Engineering Research*, 9(5), 1147-1157.
9. Vachhani, K., Mallari, R. A. (2015, August). Experimental study on wide band FM receiver using GNURadio and RTL-SDR. In *2015 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, 810-1814. IEEE. <https://doi.org/10.1109/ICACCI.2015.7275878>
10. Kunze, S., Schiefer, M., Weinberger, A. (2019). Frekans Atlamalı Yayılma Spektrumu Alıcısı Senkronizasyonu için GNU Radio Uygulaması. 2019 29th International Conference Radioelektronika (RADIOELEKTRONIKA). <https://doi.org/10.1109/radioelek.2019.8733412>
11. Bell, T., Gajewski, K., Hsu, A. (2009). Pseudorandom multiband frequency hopping for interference avoidance using GNU Radio and USRP. *Stevens Institute of Technology*, 24.
12. Ehret, W., Su, H., Glaser, O., Blomenhofer, D. H. (2006, May). Independent validation of Galileo global and regional integrity performance using GalTeC. In *ENC-GNSS 2006*, Hersonissos, Crete, Greece

13. Kim, T. H., Sin, C. S., Lee, S., Kim, J. H. (2014, October). Analysis of performance of GPS L1 signal generator in GPS L1 signal. In *2014 14th International Conference on Control, Automation and Systems (ICCAS 2014)*, 1006-1009.
14. Gaifulina, D., Kotenko, I. (2021, March). Selection of deep neural network models for IoT anomaly detection experiments. In *2021 29th Euromicro International Conference on Parallel, Distributed and Network-Based Processing (PDP)*, 260-265.
15. Li, Z., Liu, R., Lin, X., Shi, H. (2018, December). Detection of frequency-hopping signals based on deep neural networks. In *2018 IEEE 3rd International Conference on Communication and Information Systems (ICCIS)* (pp. 49-52). IEEE.
16. Bouvrie, J. (2006). *Notes on convolutional neural networks*. Center for Biological and Computational Learning, Department of Brain and Cognitive Sciences, Massachusetts Institute of Technology.
17. Yu, J., de Antonio, A., & Villalba-Mora, E. (2022). Deep learning (CNN, RNN) applications for smart homes: a systematic review. *Computers*, 11(2), 26.
18. Hoffmann, J., Navarro, O., Kästner, F., Janßen, B., Hübner, M. (2017) A Survey on CNN and RNN Implementations, in *PESARO 2017: The Seventh International Conference on Performance, Safety and Robustness in Complex Systems and Applications*, 2017, pp. 33–39, doi: 10.1234/exampledoi.
19. Hoffmann, J., Navarro, O., Kastner, F., Janßen, B., Hubner, M. (2017). A survey on CNN and RNN implementations. In *PESARO 2017: The Seventh International Conference on Performance, Safety and Robustness in Complex Systems and Applications* , 3,33-39.
20. İnternet: I. Goodfellow, Y. Bengio, A. Courville, *Deep Learning*. MIT Press, 2016, URL: <http://www.deeplearningbook.org>, Son Erişim Tarihi: 12.10.2024
21. Jain, L. C., Medsker, L.R. (2000) *Recurrent neural networks: design and applications* . CRC Press,
22. Chung, J., Gulcehre, C., Cho, K., Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv preprint arXiv,1412.3555*.
23. Guan, Y., Yuan, Z., Sun, G., Cong, J. (2017, January). FPGA-based accelerator for long short-term memory recurrent neural networks. In *2017 22nd Asia and South Pacific Design Automation Conference (ASP-DAC)*, 629-634.
24. Zainab, M., Usmani, A. R., Mehrban, S., Hussain, M. (2019, November). Fpga based implementations of rnn and cnn: A brief analysis. In *2019 International Conference on Innovative Computing (ICIC)*, 1-8.



EKLER

EK-1. 1.Gözlem RINEX Dosyası

```

import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, LSTM, Bidirectional, Dropout
import pandas as pd
import numpy as np

# Veriyi yükle
data =
pd.read_csv(r'C:\Users\admin1\Desktop\gokhan_Bildiri\balanced_frequency_data.csv')
frequencies = data['frequency'].values
intensity = data['intensity'].values
labels = data['label'].values

#3D şekle
sequence_length = 50
num_samples = len(frequencies) // sequence_length
frequencies = frequencies[:num_samples *
sequence_length].reshape(num_samples, sequence_length, 1)
intensity = intensity[:num_samples *
sequence_length].reshape(num_samples, sequence_length, 1)
labels = labels[:num_samples * sequence_length:sequence_length]

# Veriyi birleştirerek giriş oluştur
inputs = np.concatenate([frequencies, intensity], axis=2)

# Veriyi eğitim ve teste ayırma
split_index = int(0.8 * len(inputs))
train_data, test_data = inputs[:split_index], inputs[split_index:]
train_labels, test_labels = labels[:split_index], labels[split_index:]

# Model
model = Sequential([
    Bidirectional(LSTM(128, return_sequences=True),
input_shape=(sequence_length, 2)),
    Dropout(0.3),
    LSTM(64),
    Dropout(0.3),
    Dense(64, activation='relu'),
    Dense(1, activation='sigmoid')
])

# Modeli derleme
model.compile(optimizer='adam', loss='binary_crossentropy',
metrics=['accuracy'])

# Modeli eğitme
history = model.fit(train_data, train_labels, epochs=50, batch_size=32,
validation_split=0.2)

# Test sonuçlarını değerlendirme
loss, accuracy = model.evaluate(test_data, test_labels)
print(f"Test doğruluğu: {accuracy * 100:.2f}%")

# Eğitim ve doğrulama eğrilerini görselleştirme
import matplotlib.pyplot as plt

plt.plot(history.history['accuracy'], label='Eğitim Doğruluğu')
plt.plot(history.history['val_accuracy'], label='Doğrulama Doğruluğu')

```

EK-2. 2.Gözlem RINEX Dosyası

```
plt.xlabel('Epoch')  
plt.ylabel('Doğruluk')  
plt.legend()  
plt.title('Eğitim ve Doğrulama Doğruluğu')  
plt.show()
```





Gazili olmak ayrıcalıktır