

TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**İNSANSIZ HAVA ARACI (İHA) VE İNSANSIZ SU ARACI (İSA) BAZ
İSTASYONLARININ KARA VE SUALTI AĞLARDA MAKSİMUM KAPSAMA
SAĞLAYACAK ŞEKİLDE YERLEŞİMİ**

YÜKSEK LİSANS TEZİ

Berkay KAHRİMAN

Elektrik ve Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Ali Murat DEMİRTAŞ

AĞUSTOS 2021

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, alıntı yapılan kaynaklara eksiksiz atıf yapıldığını, referansların tam olarak belirtildiğini ve ayrıca bu tezin TOBB ETÜ Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırlandığını bildiririm.

Berkay KAHRİMAN

ÖZET

Yüksek Lisans Tezi

İNSANSIZ HAVA ARACI (İHA) VE İNSANSIZ SU ARACI (İSA) BAZ
İSTASYONLARININ KARA VE SU ALTI AĞLARDA MAKSİMUM KAPSAMA
SAĞLAYACAK ŞEKİLDE YERLEŞİMİ

Berkay KAHRİMAN

TOBB Ekonomi ve Teknoloji Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik ve Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Ali Murat DEMİRTAŞ

Tarih: Ağustos 2021

Son yıllarda insansız araçlarda meydana gelen teknolojik gelişmeler sayesinde insansız araçlar telekomünikasyon, sualtı araştırmaları ve savunma gibi birçok alanda spesifik uygulamalarda kullanılmaya başlanmıştır. Bu uygulamalarda cihazlar (sensör, mobil cihaz, veri depolama merkezi vb.) arası veri iletiminde meydana gelebilecek kayıpların minimum seviyede tutulması amaçlanmıştır. Bunun için hareket kabiliyeti yüksek olan insansız araçların baz istasyonu olarak kullanılması alternatif bir çözüm olmuştur. Bu çalışmada hem kara hem de deniz ağlarının iyileştirilmesi kapsamında maksimum sayıda kullanıcıyı veya sualtı algılayıcıyı kapsayacak şekilde İnsansız Hava Aracı Baz İstasyonu (İHABİ) ve İnsansız Su Aracı Baz İstasyonu (İSABİ) yerleşimi incelenmiştir.

Çalışmanın ilk kısmında, birden fazla İHABİ yerleşim problemi için makine öğreniminde kullanılan metotlar önerilmiştir ve gerekli olan veri setinin oluşturulması için çoklu İHABİ yerleşim optimizasyon modeli oluşturulmuştur. Makine öğrenimi yaklaşımında sırasıyla; Evrişimsel Sinir Ağları (CNN), Artçıl Sinir Ağları (ResNet), Derin Sinir Ağları (DNN) ve K-Means algoritması kullanılmıştır. Makine öğrenimi

yaklaşımında kullanılan yöntemler, Karma Tamsayılı Doğrusal Olmayan Programlama (KTDOP) optimizasyon modeli ile kapsanan kullanıcı sayısı bakımından kıyaslanmıştır. ResNet modelinin diğer makine öğrenimi modellerine göre üstün bir sonuç verdiği gözlemlenmiştir.

Çalışmanın ikinci kısmında, tek İSABİ yerleşimi için amaç fonksiyonu maksimum sayıda sualtı algılayıcı kapsanması olan KTDOP optimizasyon modeli oluşturulmuştur. Optimizasyon modeli sonuçları, farklı sayıda sualtı algılayıcı ve iletim gücü seviyeleri açısından Kıyaslama Konum Merkezi noktaları ile kıyaslanmıştır. Daha sonra birden fazla İSABİ kullanımı için optimizasyon modeli güncellenip, K-Means algoritması ile kapsanan sualtı algılayıcı sayısı bakımından kıyaslanmıştır.

Anahtar Kelimeler: İnsansız su araçları, İnsansız hava araçları, Karma tamsayılı doğrusal olmayan programlama, Makine öğrenimi, Sinir ağları, Hareketli baz istasyonlarının konumlandırılması

ABSTRACT

Master of Science

LOCALIZATION OF UNMANNED AERIAL VEHICLE (UAV) AND UNMANNED WATER VEHICLE (UWV) BASE STATIONS TO PROVIDE MAXIMUM COVERAGE ON TERRESTRIAL AND UNDERWATER NETWORKS

Berkay KAHRIMAN

TOBB University of Economics and Technology
Institute of Natural and Applied Sciences
Electrical and Electronics Engineering Science Programme

Supervisor: Dr. Ali Murat DEMIRTAS

Date: August 2021

Nowadays, due to technological developments, unmanned vehicles have started to be used in specific applications in many areas such as telecommunication, underwater research, civilian, and defense. In these applications, it is aimed to keep the losses that may occur in data transmission between devices (sensor, mobile device, data storage center, etc.) at a minimum level. Therefore, the use of unmanned vehicles with high mobility as a base station has been an alternative solution. In this study, the placement of Unmanned Aerial Vehicle Base Station (UAVBS) and the placement of Unmanned Water Vehicle Base Station (UWVBS) were investigated to cover the maximum number of users or underwater sensors for the improvement of both terrestrial and underwater network.

In the first part of our study, machine learning approach is proposed for multiple UVABS's placement problem. Required data that are used on machine learning models are generated by using a Mixed Integer Non-linear Programming (MINLP)

optimization model of multi UAVBS placement problem. In the machine learning approach; Convolutional Neural Networks (CNN), Residual Neural Networks (ResNet), Deep Neural Networks (DNN) and K-Means algorithms were used respectively. The results are compared with the MINLP model in terms of user coverage. It is observed that the ResNet model gives better results than other machine learning models.

In the second part of our study, we defined a MINLP optimization model for a single UWVBS placement to maximize the sensor coverage. The results of the optimization model were compared with the Benchmark Location in terms of a different number of underwater sensors and transmission power levels. For multiple UWVBS's deployment scenario, the optimization model is re-evaluated and compared with K-Means algorithm.

Keywords: Unmanned water vehicle, Unmanned aerial vehicle, Mixed integer non-linear programming, Machine learning, Neural networks, Placement of mobile base stations

TEŐEKKÖR

Çalıőmalarım boyunca yardım ve katkılarıyla beni yönlendiren deęerli hocalarım Dr. Ali Murat DEMİRTAŐ'a ve Prof. Dr. BÖlent TAVLI'ya, kıymetli tecrÖbelerinden faydalandıęım TOBB Ekonomi ve Teknoloji Üniversitesi Elektrik ve Elektronik MÖhendislięi BÖlÖmÖ Öęretim Öyelerine, lisansÖstÖ eęitimime destek olan Őirketim ASELSAN A.Ő.'ye ve destekleriyle her zaman yanımda olan aileme, rahmetli babam Abdulkadir KAHRİMAN'a, annem Selvi KAHRİMAN'a, abim Kubilay KAHRİMAN'a ve arkadaşlarıma çok teŐekkÖr ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	iv
ABSTRACT	vi
İÇİNDEKİLER	ix
ŞEKİL LİSTESİ	x
ÇİZELGE LİSTESİ	xi
KISALTMALAR	xii
SEMBOL LİSTESİ	xiii
1. GİRİŞ	1
1.1. Tezin Amacı ve Kapsamı	2
1.2. Literatür Araştırması	3
1.2.1 İHABİ Literatür Araştırması	3
1.2.2 İSABİ Literatür Araştırması.....	8
1.3. Tezin Organizasyonu.....	12
2. METODOLOJİ	15
2.1. Makine Öğrenimi Tanımı	15
2.2. Denetimli Öğrenme	16
2.3. Denetimsiz Öğrenme.....	16
2.4. Kümeleme ve K- Means Algoritması.....	17
2.5. Sinir Ağları ve Derin Sinir Ağları	18
2.6. Evrişimsel Sinir Ağları	22
2.7. Artçıl Sinir Ağları.....	25
2.8. Karma Tamsayı Doğrusal Olmayan Programlama	26
3. İHABİ SİSTEM MİMARİSİ VE ENİYİLEME MODELİ	29
3.1. İHABİ Sistem Modeli	29
3.2. Hava Kanal Modeli	29
3.3. İHABİ Yerleşim Optimizasyon Modeli	32
4. İHABİ KONUMLANDIRMA ANALİZ SONUÇLARI	35
4.1. Veri Setinin Hazırlanması	35
4.2. NN Tabanlı Öğrenme Modeli	35
4.3. Konumlandırma Performans Sonuçları	37
5. İSABİ SİSTEM MİMARİSİ VE ENİYİLEME MODELİ	41
5.1. İSABİ Sistem Modeli	41
5.2. Sualtı Kanal Modeli	41
5.3. İSABİ Yerleşim Optimizasyon Modeli	44
6. İSABİ KONUMLANDIRMA ANALİZ SONUÇLARI	47
7. SONUÇ	53
KAYNAKLAR	55
ÖZGEÇMİŞ	59

ŞEKİL LİSTESİ

Şekil 1.1: Kapsanan kullanıcı sayısının CDF grafiği [8]	6
Şekil 2.1: Kümeleme Uygulaması.....	17
Şekil 2.2: K-Means Blok Diyagramı.....	18
Şekil 2.3: McCulloch ve Pitts tarafından modellenmiş nöron yapısı.....	19
Şekil 2.4: Aktivasyon fonksiyonları [35]	19
Şekil 2.5: İleri beslemeli örnek NN modeli.....	20
Şekil 2.6: 3 Katmanlı örnek DNN modeli.....	22
Şekil 2.7: LeNet-5 CNN modeli [44].....	23
Şekil 2.8: 6x6 girdi ile 2x2 filtrenin evrişim işlemi [45].....	24
Şekil 2.9: Maksimum değer havuzlama uygulaması.....	25
Şekil 2.10: Derinlik arttıkça hata oranının artabileceği gözlenmiştir. [47].	25
Şekil 2.11: ResNet artçıl blok	26
Şekil 3.1: İki İHABİ için sistem modeli.....	30
Şekil 4.1: Konumlandırma problemi NN yaklaşımı.....	36
Şekil 4.2: Oluşturulan NN modelleri (ResNet, CNN, DNN)	36
Şekil 4.3: Kapsanan kullanıcı sayısı için kümülatif dağılım fonksiyon grafiği	38
Şekil 4.4: Kapsanan kullanıcı sayısının bütün durumlardaki oranı.....	39
Şekil 4.5: ResNet ve optimal konum için kapsama alanları	39
Şekil 5.1: Tek İSABİ yerleştirilmiş sistem modeli [29].....	41
Şekil 5.2: 3 Boyutlu bağlantı alanı gösterimi [29].	43
Şekil 6.1: KKM ve optimum konum için kapsama alanları [29]	48
Şekil 6.2: Farklı iletim güç değerleri ve SA sayısı için kapsama kapasitesi [29].	48
Şekil 6.3: 50 SA'da farklı iletim güç değerleri için kapsama kapasitesi [29].....	49
Şekil 6.4: 30 SA'da farklı iletim güç değerleri için kapsama kapasitesi.....	50
Şekil 6.5: 2 İSABİ'li ve 4 İSABİ'li durumda MKN'nin kapsama kapasitesi	51
Şekil 6.6: MKN ve optimum konum için kapsama alanı ($P_t=100\text{dB}$, $SA=40$).....	51

ÇİZELGE LİSTESİ

Tablo 3.1: Farklı çevre tipleri için kullanılan yayılım parametreleri. [1]	31
Tablo 4.1: İHABİ optimizasyonunda kullanılan simülasyon parametreleri.	35
Tablo 4.2: Yazılım ve konfigürasyon bilgileri.....	37
Tablo 4.3: Kapsanan kullanıcı sayısı dağılım bilgileri.....	37
Tablo 6.1: Tek İSABİ optimizasyonunda kullanılan simülasyon parametreleri.....	47



KISALTMALAR

Kısaltmalar	Açıklama
Bİ	Baz İstasyonu
CDF	Kümülatif Dağılım Fonksiyonu
CNN	Evrişimsel Sinir Ağları
DNN	Derin Sinir Ağları
ES	Kapsamlı Arama
HS	Harmonik Arama
İHA	İnsansız Hava Aracı
İHABİ	İnsansız Hava Aracı Baz İstasyonu
İSA	İnsansız Su Aracı
İSABİ	İnsansız Su Aracı Baz İstasyonu
KHHA	Kablosuz Hava Haberleşme Ağı
KKM	Kıyaslama Konum Merkezi
KTDOP	Karma Tamsayılı Doğrusal Olmayan Programlama
LoS	Görüş Hattı
LQ	En büyük Hizmet Kalitesi
MKN	Merkez Konum Noktaları
ML	Makine Öğrenimi
MWA	Maksimum Ağırlıklı Alan
nLoS	Görüş Hattı Dışı
NN	Sinir Ağları
PF	Parçacık Filtre
PSO	Parçacık Sürü Optimizasyonu
QL	Q Öğrenme
QoS	Hizmet Kalitesi
ResNet	Artçıl Sinir Ağları
SA	Sualtı Algılayıcı
SAA	Sualtı Algılayıcı Ağ
SGO	Sinyal Gürültü Oranı
SINR	Sinyal Girişim Artı Gürültü Oranı

SEMBOL LİSTESİ

Bu çalışmada kullanılmış olan simgeler açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklama
$a(f)$	Akustik sinyal emilim kaybı
$A(l, f)$	Sualtı akustik sinyal yol kaybı (dB/km)
f	Sinyal çalışma frekansı (Hz)
f_c	Taşıyıcı frekansı (Hz)
h	Derinlik ve yükseklik parametresi (m)
k	Akustik sinyal çevresel yayılım katsayısı
l	Sualtı iletim mesafesi (m)
l_{max}	Maksimum sualtı iletim mesafesi (m)
L_{LoS}^{ij}	Kullanıcı i ile İHABİ j arası görüş hattı yol kaybı
L_{NLoS}^{ij}	Kullanıcı i ile İHABİ j arası görüş hattı dışı yol kaybı
L_{th}	Ortam kaybı eşik değeri (dB)
$N_s(f)$	Aktarım gürültüsü (dB)
$N_t(f)$	Türbülans gürültüsü (dB)
$N_{th}(f)$	Termal gürültü (dB)
$N_w(f)$	Dalga gürültüsü (dB)
P_{LoS}	Görüş hattında olma olasılığı
P_{NLoS}	Görüş hattı dışı olma olasılığı
P_t	İletim gücü (dB)
P_{th}	Alıcı güç eşik değeri (dB)
$r_{i,j}$	Kullanıcı i ile İHABİ j arasındaki yatay mesafe (m)
r_c	Kapsama alanı yarıçapı (m)
s	Aktarım katsayısı
$S_{i,j}$	Sualtı algılayıcı ikili değişkeni
$u_{i,j}$	Kullanıcı ikili değişkeni
w	Rüzgâr Hızı (m/sn)
(x_{a_i}, y_{a_i})	SA düzlemsel koordinatları (m)
(x_b, y_b)	İSABİ düzlemsel koordinatları (m)
(x_{d_j}, y_{d_j})	İHABİ düzlemsel koordinatları (m)
(x_u, x_l)	X koordinatı alt ve üst limiti (m)
(y_u, y_l)	Y koordinatı alt ve üst limiti (m)
(α, β)	Görüş hattında olma olasılığı hesaplanırken kullanılacak çevresel parametreler
η_{LoS}	Görüş hattı ortalama çevresel kayıp (dB)
η_{NLoS}	Görüş hattı dışı ortalama çevresel kayıp (dB)
$\theta_{i,j}$	Kullanıcı i ile İHABİ j arasındaki yükselme açısı

1. GİRİŞ

Son yıllarda mekanik, donanım ve yazılım teknolojilerinin gelişmesiyle beraber insansız araçlar hakkında yapılan çalışmalar da artmıştır. Teknolojideki bu ilerleme; günümüzde insansız araçların hareket kabiliyetinin artmasına, üretim masraflarının azalmasına ve kontrol edilebilirliğin artmasına yardımcı olmuş ve de yapay zekâ uygulamalarının da entegre edilmesiyle beraber ziraat, haberleşme, sivil ve savunma gibi birçok alanda insansız araçların kullanımını yaygınlaştırmıştır. İnsansız araçlar temelde; sualtı ekosistemin incelenmesinde, atmosferik verilerin araştırılmasında, haberleşmede, bölge güvenliği için alan gözetlenmesinde veya kolay erişilemeyen sistemlerin denetlemede kullanılmaktadır.

İnsansız araçlar kullanıldıkları çevreye ve uygulamaya göre farklı isimler almaktadır. Bu tez çalışması kapsamında sırasıyla İnsansız Hava Aracı Baz İstasyonunun (İHABİ) ve İnsansız Su Aracı Baz İstasyonunun (İSABİ) konumlandırma problemleri incelenmiştir.

İHABİ sistemler İnsansız Hava Aracının (İHA) üzerine alıcı-verici (ing. *tranceiver*) takılmasıyla baz istasyonu (Bİ) işlevinin kazandırıldığı sistemlerdir. Günümüzde teknolojinin de gelişmesiyle beraber üretilen veri miktarı artmaktadır. Bu yüzden Kablosuz Hava Haberleşme Ağlarında (KHHA) kullanılan frekans bantlarında yoğunluk artmaktadır. Bu yoğunluk artışı kullanıcıların hizmet kalitesini düşürmektedir. Hizmet kalitesinin artırılması için yeni bir statik baz istasyonu kurulumu maliyet ve uygulama süresi bakımından avantajlı olmamaktadır. Ek olarak olağanüstü durumlarda (doğal afetler, anlık kullanıcı yoğunluk artışı vb.) statik baz istasyonları geçici veya kalıcı bir süre hizmet verememektedir. Bu tip sorunların çözümü için İHABİ tabanlı haberleşme ağlarının kurulması maliyet ve uygulama süresi bakımından daha avantajlı ve tercih edilebilir bir seçenek olmaktadır.

İSABİ sistemler ise İHABİ sistemlerde olduğu gibi İnsansız Su Aracının (İSA) üzerine alıcı-verici cihazların entegre edilmesiyle Bİ işlevinin kazandırıldığı, su yüzeyinde kullanılan araçlardır. Günümüzde gürbüz Sualtı Algılayıcı Ağlar (SAA) kurularak okyanus ekosisteminin incelenmesinde, sualtı sismik keşif uygulamalarında ve gerçek

zamanlı uyarı ve görüntüleme sistemlerinin gerçekleştirilmesinde kullanılmaktadır. SAA'da elde edilen sualtı ölçüm verileri karasal uygulama merkezlerine iletilmektedir [32]. Fakat sualtı yol kaybı hava ortamındaki yol kaybından daha yüksek olduğu için veri kaybına sebep olmaktadır. Oluşabilecek veri kayıplarını engellemek için İSABİ kullanımını tercih edilen bir yöntemdir.

1.1. Tezin Amacı ve Kapsamı

Tez çalışması İHABİ ve İSABİ konumlandırma problemlerinin ele alınması bakımından iki ana başlık altında toplanmaktadır. Bunlar amaçlarıyla birlikte sırasıyla aşağıda verilmiştir:

- İHABİ konumlandırma problemlerinde oluşturulan konveks optimizasyon modellerinin çözüm süresi uzun sürmektedir [15]. Bu yüzden [14] ve [15] numaralı çalışmalardan referans alınarak birden fazla İHABİ konumlandırılmasında alternatif olarak kullanılabilen makine öğrenimi tabanlı modellerin oluşturulması amaçlanmıştır. Oluşturduğumuz modelleri kapsayan kullanıcı sayısı bakımından, oluşturduğumuz Karma Tamsayı Doğrusal Olmayan Programlama (KTDOP) optimizasyon modeline yakınsama durumu incelenmiştir.
- İSABİ konumlandırma probleminde maksimum sayıda Sualtı Algılayıcıyı (SA) kapsayan optimizasyon modeli oluşturulmuştur. Literatürdeki yaklaşımların İSABİ konumunu belirlerken bütün deniz yüzeyini taramadığı gözlemlenmiştir. Bu yüzden İSABİ konumlandırma problemini çözmek için KTDOP türünden bir optimizasyon modelinin oluşturulması amaçlanmıştır. Optimizasyon modeli ilk olarak tek İSABİ yerleşimi için tanımlanmıştır. Daha sonra birden fazla İSABİ'nin konumlandırılması durumu için geliştirilmiştir. Tek İSABİ'li durum için SA konumlarının ortalaması ile hesaplanan Kıyaslama Konum Merkezi (KKM) ve optimizasyon sonuçları; farklı güç seviyesi ve algılayıcı sayısı bakımından kıyaslanmıştır. Daha sonra birden fazla İSABİ'li durum için İSABİ sayısı parametre olarak tanımlanıp, K-Means algoritması ve optimizasyon modeli ile elde edilen sonuçlar kıyaslanmıştır.

1.2. Literatür Araştırması

1.2.1 İHABİ Literatür Araştırması

Yeni nesil kablosuz haberleşme ağlarının güvenilirlik ve kullanılabilirlik açısından gürbüz olması için son kullanıcıların belirli bir hizmet kalitesi seviyesi üzerinde bağlantı kurması gereklidir [1]. Fakat teknolojinin gelişmesiyle üretilen ve iletilen veri miktarının her geçen gün üstel bir şekilde artması veri trafiğinin yoğunluğunu artırmaktadır. Bu yüzden mevcut haberleşme alt yapısıyla arzu edilen gürbüz ağların oluşturulması zorlaşmaktadır. Statik Bİ'lerin yeniden kurulması maliyet açısından pahalı olduğu ve kurulum süresi uzun sürdüğü için pratik bir yaklaşım değildir. İHABİ'lerin istenilen bölgeye hızlıca intikal etmesi, bulunduğu bölgede 3 boyutlu hareket kabiliyetinin olması gibi avantajlara sahip olduğundan; erişimi zor, yoğun bölgelerde hizmet verilmesi açısından İHABİ kullanımı hızlı ve ekonomik bir çözümdür [3]. Bu sayede İHABİ konumlandırılması literatürde halen araştırılmakta olan bir konudur. Tezin bu başlığında, İHABİ'lerin konumlandırılması hakkında yapılan literatür çalışmaları incelenmiştir.

Rohde ve Wietfeld'in yapmış oldukları [2] numaralı çalışmada; haberleşme ağlarında yaşanan anlık yoğunluk artışı durumunda, hücrelerde yaşanabilecek aşırı yüklenmeyi dengelemek için İHABİ'lerin röle olarak kullanılması önerilmiştir. Bu çalışmada hücrelerde kullanılacak frekans bantlarının planlanması, İHABİ'nin gönderme gücü, hücresel ağdaki yoğunluğu dengelemek için gerekli olan İHABİ sayısı ve kullanılacak İHABİ'lerin yerleşimi üzerine çalışılmıştır. Çalışmada İHABİ kullanımının, aşırı yüklenme durumundan kaynaklanacak sistemsel kaybı önemli ölçüde azalttığı ve 4 İHABİ kullanımında toplam sistem kapasitesinin 40MBit/s arttığı gözlemlenmiştir.

Al-Hourani ve çalışma arkadaşları [3] numaralı çalışmalarında hava kanal modelini istatistiksel olarak çıkarmışlardır ve [3] numaralı çalışmayı kullanarak [4] çalışmalarında düşük irtifada çalışan platformların kapsama alanı ile yükseklik arasındaki ilişkiyi farklı ortam koşulları için matematiksel olarak ifade etmişlerdir. Elde ettikleri sonuçlar incelendiğinde yükseklik arttıkça kapsama yarıçapının bir süre arttığı daha sonra ise kırıma uğrayıp azaldığı gözlemlenmiştir. Bu kırımın noktasındaki yükseklik, kapsama yarıçapının yüksekliğe olan kısmi türevinin sıfıra eşitlenmesiyle hesaplanmakta olup, maksimum kapsama alanını veren optimum

yükseklik olarak ifade edilmiştir. [3] ve [4] numaralı çalışmalardaki çıkarımlar literatürdeki birçok araştırmada referans olmuştur.

Mozaffari ve ekibinin [5] numaralı çalışmaları temelde iki bölümden oluşmaktadır. İlk bölümde tek bir İHABİ'nin minimum düzeyde iletim gücü harcadığı optimal yükseklik hesaplanmıştır. İHABİ'nin kapsama yarıçapı sabit olduğu varsayılmıştır. Bu sayede optimum yükseklikle kapsama yarıçapının parametre olarak kullanıldığı ve sonucunda minimum iletim gücünün hesaplandığı matematiksel denklem elde edilmiştir. Çalışmanın ikinci bölümünde ise iki adet İHABİ'nin; kullanıcıların konumlandırıldığı bölgeyi maksimum düzeyde kapsayacak şekilde nasıl yerleştirilmesi gerektiği incelenmiştir. Her bir İHABİ'nin optimal yükseklik değeri bir önceki bölümde ifade ettikleri denklemle hesaplanmıştır. Yatay konum ise İHABİ'lerin üst üste gelmesini engellemek için kullanıcıların konumlandırıldığı dikdörtgen alan içerisindeki köşe bölgelere yerleştirilecek şekilde belirlenmiştir. İHABİ'lerin çarpışmasını engellemek için aralarındaki gerekli olan yatay mesafe hesaplanmıştır. Özel durum olarak, iki İHABİ özdeş olduğunda aralarındaki yatay mesafenin kapsama yarıçaplarının toplamından büyük olması gerektiği çıkarımında bulunulmuştur. Son olarak bu çalışmada İHABİ'lerin yerleşiminde girişimin etkisi de incelenmiştir.

Bor Yalınız ve ekibinin yaptığı çalışmada [1], hizmet kalite (ing. *quality of service*, QoS) isteri bulunan kullanıcıları maksimum sayıda kapsayacak şekilde, tek İHABİ'nin 3 boyutlu konumlandırma problemi ele alınmıştır. Çalışmada önceden belirlenmiş QoS isteri kullanılarak, ikili arama algoritmasıyla İHABİ'nin optimum yükselme açısı bulunmuştur. Ardından optimum yükselme açısı kullanılarak İHABİ'nin kapsama yarıçapı ve optimum yüksekliği hesaplanmıştır. Daha sonra İHABİ'nin yatay konumunun belirlenmesi için KTDOP türünden optimizasyon modeli oluşturulmuştur. Çalışma sonuçları; banliyö, şehir, yoğun şehir ve yüksek katlı şehir ortamları için analiz edilmiştir. İlgili ortamların yol kayıp değerleri farklı oldukları için optimal sonuçlar aynı çıkmamıştır. Ek olarak yüksek katlı şehir ortamında yol kaybının fazla olmasından dolayı en küçük kapsama yarıçapı bu ortamda elde edilmiştir.

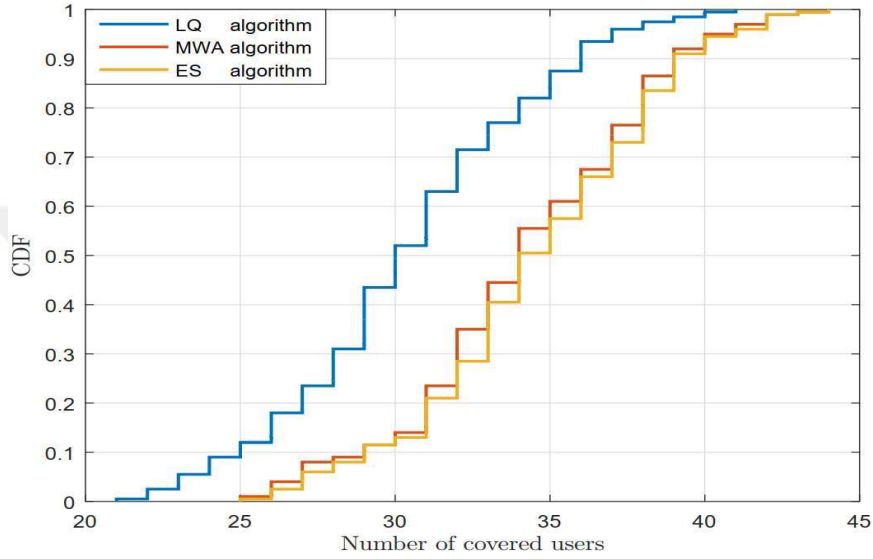
Kalantari, Yanıkömeroğlu ve Yongaçoğlu'nun yaptıkları [6] numaralı çalışmada, minimum sayıda İHABİ kullanılarak belirli bir oranın üstünde kullanıcıyı kapsayacak şekilde İHABİ'nin 3 boyutlu konumu hesaplanmıştır. Önceki çalışmalardan farklı olarak bu çalışmada parçacık sürü optimizasyon (ing. *particle swarm optimization*, PSO) algoritması kullanılmıştır. Çalışmanın ilk aşamasında bütün kullanıcıların

kapsanması için ihtiyaç duyulan İHABİ sayısı, kullanıcı sayısının İHABİ kapasitesine oranıyla belirlenmiştir. Daha sonra PSO algoritması kullanılarak belirlenen İHABİ sayısı kadar, İHABİ'nin 3 boyutlu konumları belirlenmiştir. Belirlenen bu konumlar değiştirilmeden ve kapsama oranı isteri ihlal edilmeden ihtiyaç fazlası İHABİ'ler iteratif bir şekilde kaldırılmıştır. Çalışmanın sonucunda, kullanıcı yoğunluğu arttıkça İHABİ sayısının arttığı ve girişim etkisinin azaltılması için İHABİ yüksekliğinin düşürülmesi gerektiği sonucuna varılmıştır.

Alzenad ve çalışma arkadaşlarının yapmış olduğu [7] numaralı çalışmada; minimum iletim gücü seviyesinde, maksimum sayıda kullanıcıyı kapsayacak şekilde İHABİ'nin 3 boyutlu konumlandırma problemi incelenmiştir. Problemin çözümü için önerdikleri yaklaşım 2 aşamadan oluşmaktadır. Birinci aşamada İHABİ'nin optimum yükselme açısı ve buna bağlı olarak İHABİ kapsama yarıçapıyla optimum çalışma yüksekliği hesaplanmıştır. Optimum yükselme açısı bulunurken [5] numaralı çalışmadan farklı olarak, kullanıcıların hizmet kalitesi için tanımlanan eşik değeri kullanılmıştır. Daha sonra İHABİ'nin kapsama yarıçapı kullanılarak, maksimum sayıda kullanıcıyı kapsayacak optimizasyon modeli oluşturulmuştur ve İHABİ'nin yatay konumu belirlenmiştir. İkinci aşamada ise iletim gücü ile kapsama yarıçapı arasında ilinti olduğunu ve kapsama yarıçapı arttıkça iletim gücünün de arttığını savunmuşlardır. Bunun için bir önceki aşamada elde ettikleri kapsanan kullanıcı kümesini kullanarak, kapsama yarıçapını minimize eden optimizasyon modeli oluşturulmuştur. Oluşturdukları optimizasyon modeliyle İHABİ'nin yeni kapsama yarıçapını ve yatay konumunu elde etmişlerdir. İkinci aşamada, birinci aşamada bulunan optimum yükselme açısı kullanılarak ikinci bir yükseklik değeri hesaplanmıştır. İHABİ'nin optimal yükseklik seçiminde ise birinci ve ikinci aşamada bulunan yükseklik değerlerinden en büyük olanı atanmıştır. Kullanıcı dağılımında heterojenliğin artmasıyla, kullanıcılar birbirine daha fazla yaklaşmaktadır ve düşük iletim gücü ile kapsanabilecek kümelenmeler meydana gelmektedir. Bu sayede kullanıcı dağılımındaki heterojenlik arttıkça, önerdikleri yöntemle ortalama iletim gücünün azaldığı sonucuna varmışlardır.

Alzenad, El-Keyi ve Yanıkömeroğlu'nun yapmış olduğu [8] numaralı çalışmada; farklı QoS isteri bulunan kullanıcıları, maksimum sayıda kapsayacak şekilde İHABİ'nin 3 boyutlu konumlandırılması araştırılmıştır. İHABİ'nin yerleşiminde önce optimal yükseklik daha sonra yatay konum bilgileri bulunmuştur. Optimal yükseklik

değeri ilk önce kapsamlı arama (ing. *exhaustive search*, ES) algoritması ile incelenmiştir. Fakat ES algoritması, yükseklik değeri belirli bir aralıkta yer alan yol kaybıyla hesaplandığından, optimizasyon modelinin çözüm süresini ve karmaşıklığını artırmaktadır. Bu yüzden İHABİ yüksekliği bulunurken alternatif yöntem olarak maksimum ağırlıklı alan (ing. *maximal weighted area*, MWA) algoritmasını önermişlerdir. Şekil 1.1'de kapsanan kullanıcı sayısı için kümülatif dağılım fonksiyon (ing. *cumulative distribution function*, CDF) grafiği verilmiştir.



Şekil 1.1: Kapsanan kullanıcı sayısının CDF grafiği [8]

En büyük hizmet kalitesi (ing. *largest QoS*, LQ) algoritmasında kalite isteri sabit varsayılmıştır ve araştırılan diğer iki algoritma ile kıyaslamak için eklenmiştir. Yukarıdaki CDF grafiği incelendiğinde MWA algoritmasının, ES algoritmasına yakın bir sonuç verdiği gözlemlenmiştir. LQ algoritması ise diğer iki algoritmaya göre daha düşük bir performans göstermiştir. Ek olarak MWA algoritmasının sonuç bulma süresi, ES'ye göre daha kısadır. Bu sayede MWA algoritması daha iyi bir alternatif çözüm olarak karşımıza çıkmaktadır.

[1], [6], [7] ve [8] numaralı çalışmalarda, kullanıcı konumlarının bilindiği durum için İHABİ'nin konumlandırma problemi incelenmiştir. Kullanıcı konumlarının mümkün olmadığı taktiksel uygulamalarda, İHABİ'nin kullanıcı konumlarının tespit edilmesi de önemli bir konudur [9]. Karaman, Akarsu ve Girici'nin yapmış olduğu [9] numaralı çalışmada; durağan bir kullanıcının İHABİ tarafından yer kestirimi, parçacık filtre (ing. *particle filter*, PF) metoduyla gerçekleştirilmiştir. Çalışmada; yeniden örnekleme tekniklerinin (çok terimli, katmanlı, artçıl, sistematik), İHABİ hareket tipinin (daireesel,

grid) kullanıcı konumu kestirimi ve enerji tüketimi üzerindeki etkisi incelenmiştir. Kullanıcı konumu kestiriminde sistematik örneklemenin en iyi sonucu verdiği ve dairesel hareketin enerji tüketimini azalttığı gözlemlenmiştir. Son olarak kestirim sonuçları maksimum olasılık kestirimi (ing. *maximum likelihood estimation*, MLE) ile kıyaslanmıştır. PF ile MLE kestirim sonuçlarının çok yakın olduğu belirtilmiştir.

İleri ve ekibinin yapmış olduğu [10] numaralı çalışmada, yüksek bir bina içerisinde rassal olarak dağıtılmış kullanıcıları maksimum sayıda kapsayacak şekilde İHABİ'nin konumlandırılması ele alınmıştır. Konumlandırmada kullanıcılar ile İHABİ arasındaki toplam yol kaybının minimize edilmesi için harmonik arama (ing. *harmonic search*, HS) metodu kullanılmıştır. PSO, HS ve yapay arı koloni metotları kullanılarak farklı bina yükseklikleri ve taban genişlikleri için elde edilen sonuçlar incelendiğinde en düşük toplam yol kaybının HS metodu ile sağlandığı gözlemlenmiştir.

Krijestorac ve çalışmaları arkadaşlarının yapmış olduğu [11] numaralı çalışmada; İHABİ konumlandırma problemi, uygulama bölgesinin topoloji bilgileri kullanılarak Derin Pekiştirmeli Öğrenme (ing. *Deep Reinforcement Learning*, DRL) yöntemiyle çözülmüştür. İHABİ yüksekliği sabit kabul edilip yatay pozisyondaki konumuyla ilgilenilmiştir. Yatay konum belirlenirken, sinyal girişim artı gürültü oranı (ing. *signal to interference plus noise ratio*, SINR) eşik değeri ve maksimum adım (t_{max}) kısıtı belirlenmiştir. Yani İHABİ, SINR eşik değerini sağlayacak şekilde hareket edebilir ve sonsuz denemeyi engellemek için en fazla t_{max} kadar deneme yapabilir. Girdi verisi olarak kullanıcıların bulunduğu bölgenin 2 boyutlu topoloji haritası ve kullanıcıların alıcı sinyal SINR değerleri kullanılmıştır. Bu sayede kullanıcı konumlarından bağımsız bir yaklaşım elde ettikleri iddia edilmiştir. Çalışmada kullanıcıların SINR değerleri, Wireless InSite emülatörü ile önceden hesapladıkları belirtilmiştir. İHABİ'nin yatay konumdaki hareket kabiliyeti, yatay düzlemde sabit mesafe ilerleyecek şekilde ortogonal 4 adet yöne tanımlanmıştır. DRL ödül fonksiyonu SINR cinsinden tanımlanmıştır. Çalışmanın sonucunda İHABİ'nin optimum konuma ulaşmasında birden fazla rota çizebileceği ve istenen SINR seviyesine de t_{max} adımdan daha kısa bir sürede eriştiği gözlemlenmiştir.

Abeywickrama ve ekibinin yapmış olduğu [12] numaralı çalışmada; maksimum sayıda kullanıcıyı kapsayacak şekilde İHABİ'nin rota ve konum belirleme problemi, önermiş oldukları DRL tabanlı Q-Öğrenme (ing. *Q-Learning*, QL) metoduyla incelenmiştir. İHABİ'nin çalışma yüksekliği ve kapsama yarıçapı sabit kabul edilip yatay konumdaki

hareketiyle ilgilenilmiştir. [11] numaralı çalışmadan farklı olarak, İHABİ enerjisinin verimli kullanılması, adil servis durumu, İHABİ'lerin girişim etkisi ve İHABİ'lerin birbirleriyle çarpışma durumu ele alınmıştır. Bu yüzden ödül fonksiyonu yeniden tanımlanmıştır. Ek olarak İHABİ hareket yönü radyal cinsten tanımlanıp yatayda 9 farklı istikamette hareket edebilmektedir. Çalışma tek İHABİ ve çoklu İHABİ'li durum olmak üzere iki aşamadan oluşmaktadır. Çoklu İHABİ'li durumda ödül fonksiyonuna çarpışma durumunu ve girişimi en az seviyeye indirmek için ceza değeri eklenmiştir. Çalışmanın sonuç kısmında sistem hizmet adilliği, kapsanan kullanıcı sayısı ve toplam sistem kapsama miktarı bakımından; [13] numaralı çalışmada önerilen yöntemle, açgözlü (ing: *greedy*) ve rassal hareket metotlarıyla kıyaslanmıştır. Tek İHABİ'li durum için [13] numaralı çalışmada önerilen yöntemin; toplam sistem kapsama miktarı bakımından daha iyi sonuç verdiği, QL metodu ise hizmet adilliği ve kapsanan kullanıcı bakımında üstün performans gösterdiği gözlemlenmiştir. Ödül fonksiyonundaki ceza değeri İHABİ hareketini kısıtladığı için; çoklu İHABİ'li senaryoda kullanılacak İHABİ sayısı arttıkça, QL metodu için belirtilen performans metriklerinin her zaman artmadığı gözlemlenmiştir.

Sun ve ekibinin yapmış olduğu [14] numaralı çalışmada; sinyal işleme optimizasyon modellerinin çözüm süresinin uzun olması sebebiyle gerçek zamanlı uygulamalarda kullanılabilir olmadığını; alternatif metot olarak bu problemlerin Derin Sinir Ağları (ing: *Deep Neural Network*, DNN) ile çözülebileceğini önerilmiştir. Duong ve ekibi ise önerilen DNN yaklaşımını referans alarak, [15] numaralı çalışmada birden fazla İHABİ'nin konumlandırma problemini incelemişlerdir ve [8] numaralı çalışmada belirtilen optimizasyon probleminin DNN ile çözülebileceğini önermişlerdir. DNN için gerekli olan veri seti, [8]'de belirtilen optimizasyon modelinden elde edilmiştir. Çalışmanın sonucunda, çözüm elde etme süresinin optimizasyon modeline göre azaldığı ve optimizasyon modeli sonuçlarına en az %90 doğrulukla yakınsadıkları gözlemlenmiştir. Fakat çalışmada İHABİ'nin optimum yüksekliği incelenmemiştir ve [8]'de elde edilen optimum yükselme açısı kullanılmıştır.

1.2.2 İSABİ Literatür Araştırması

Dünyamızın dörtte üçü su ile kaplı olduğundan; sualtı araştırma uygulamalarında kullanılan SAA teknolojileri hakkında yapılan çalışmalar, son yıllarda önemli bir araştırma konusu haline gelmiştir. SAA'lar bilimsel, ticari ve askeri alanlar dahil

olmak üzere; sualtı keşfi, gerçek zamanlı izleme ve uyarı sistemleri gibi kritik uygulamalarda kullanılmaktadır [19]. Fakat sualtı yol kaybının yüksek olması, sınırlı bant genişliğinde çalışılması ve sualtı algılayıcı (SA) enerjilerinin sınırlı olması SAA performansını olumsuz yönde etkileyebilmektedir. Bu yüzden İSABİ'lerin hava ve sualtı ortamları arasında röle olarak kullanılması, SAA performansının geliştirilmesinde ve toplam ağ yaşam ömrünün uzatılmasında gelecek vadeden bir çözümdür. Bu alt başlıkta, SAA uygulamalarında İSABİ'lerin kullanımı hakkında yapılan literatür çalışmaları incelenmiştir.

Stojanovic'in yapmış olduğu [20] numaralı çalışmada; akustik haberleşmede gerekli olan bant genişliği, kanal kapasitesi ve eşik SGO için gerekli olan iletim gücünün, iletim mesafesi ile olan ilişkisi incelenip matematiksel olarak ifade edilmiştir. Lucani, Stojanovic ve Medard'ın [21] numaralı çalışmasında ise iletim gücü kanal kapasitesi etkileşimi ve iletim gücü ile iletim mesafesi arasındaki ilişki yaklaşık bir model ile formüle edilip gerçek model sonuçlarıyla kıyaslanmıştır. Yaklaşık modelin pratik uygulamalarda hesaplama maliyetini düşürmek için alternatif olarak kullanılabileceği önerilmiştir. [20] ve [21] numaralı çalışmalar literatürde birçok çalışmada kullanılmakta olup, bu tez çalışmasında İSABİ sistem modelinin açıklanmasında da kullanılmıştır.

İbrahim ve çalışma arkadaşlarının yapmış olduğu [22] numaralı çalışmada; önceden kurulmuş SAA için İSABİ konumlandırma problemi doğrusal tamsayı programlama ile modellenmiştir. İSABİ yerleşiminin, tüketilen güç ve veri paketi gecikmesi üzerindeki etkisini incelemek için 3 farklı amaç fonksiyonu tanımlanmıştır. Bunlar sırasıyla; veri gecikmesinde beklenen değerin minimize edilmesi, beklenen enerji tüketiminin minimize edilmesi ve maksimum veri gecikmesinin minimize edilmesidir. SA 3 boyutlu konumlarının sabit olduğu varsayılmıştır. İSABİ'nin konumlandırılacağı aday lokasyonların önceden bilindiği varsayılmıştır ve su yüzeyindeki bütün alan incelenmemiştir. Çalışmanın sonuç kısmında ise SA dağılımının, kullanılan SA sayısının ve kullanılan İSABİ sayısının; tüketilen güç ve oluşan veri gecikmesi üzerindeki etkisi incelenmiştir. Kullanılan İSABİ sayısının artmasıyla tüketilen enerjinin ve veri gecikmesinin üstel olarak azaldığı gözlemlenmiştir. SA dağılımında kümelenmenin artması, kullanılacak İSABİ sayısını azaltsa da yüksek veri trafiği oluşuma sebep olmaktadır ve SAA'da tüketilen toplam enerji seviyesini artırmaktadır. Ek olarak kanal kapasitesi arttıkça İSABİ'de oluşacak veri trafiği yoğunluğu

yükseldiği için gerekli olan minimum İSABİ sayısının artması gerektiği sonucuna varılmıştır.

İbrahim ve ekibinin yapmış olduğu [23] numaralı çalışmada; SAA yaşam ömrünü maksimize etmek için İSABİ yerleşim stratejisi önerilmiştir. [22] numaralı çalışmadan farklı olarak, bu çalışmalarında optimizasyon modeli oluşturulurken veri akış ve girişim için belirli isterler tanımlanmıştır. SAA yaşam ömrü, ağır fonksiyonelliğini kesintiye uğratabilecek kritik SA'lerden en az birinin enerjisini tükettiği en erken zaman olarak tanımlanmıştır. Bu yüzden kritik SA'lar için bozunma hızı, SA'nın sahip olduğu toplam enerjinin tükettiği birim enerjiye oranı olarak tanımlanmıştır ve SAA bozunma hızı ise en yüksek SA bozunma hızına eşitlenmiştir. SAA yaşam ömrü için tanımlanan optimizasyon amaç fonksiyonu ise ortalama veri gecikmesini de dahil ederek SAA bozunma hızının minimize edilmesi olarak tanımlanmıştır. [22] numaralı çalışmada olduğu gibi bu çalışmada da İSABİ'nin yerleştirileceği 2 boyutlu aday konumlar önceden bilinmemektedir ve su yüzeyi tamamen incelenmemiştir. Çalışmanın sonuç kısmında ise İSABİ'lerin optimum konuma yerleştirilmesi ortalama veri gecikmesini %5 artırmasına rağmen SAA yaşam ömrünü de %20 seviyelerinde artırdığı gözlemlenmiştir.

İbrahim ve ekibinin yapmış olduğu [24] numaralı çalışmada ise [22] ve [23] numaralı çalışmalardan farklı olarak İSABİ'nin yerleştirilebileceği konumlar önceden bilinmeyip, SA konum bilgileri kullanılarak İSABİ aday konumları belirlenmiştir. Çalışmanın sonuç kısmında ise önerdikleri yöntemin [22] numaralı çalışmaya göre daha hızlı sonuç verdiği dikkat çekmektedir.

Liu ve ekibinin yapmış olduğu [25] numaralı çalışmada, belirli bir zaman periyodu için maksimum sayıda SA'yı kapsamayı amaçlayan dinamik İSABİ yerleştirme algoritması önerilmiştir. [25] numaralı çalışmanın; [22], [23] ve [24] numaralı çalışmalardan en büyük farkı ise SA konumlarının dinamik varsayılmasıdır. Yani SA'lar zaman içerisinde çevresel etkilerden dolayı farklı konumlarda yer alabilir. Bu yüzden SA'ların konum bilgisi, anlık ve gelecekteki belirli bir zaman aralığı için tanımlanmıştır. SA'nın gelecekte olabileceği konumlar Kalman filtresi ile tahmin edilmektedir. Tahmin edilen SA konum bilgisi ve anlık SA konum bilgisi optimizasyon modelinde kullanılmıştır. Modeldeki amaç fonksiyonu, belirli zaman aralığında maksimum sayıda SA kapsanması olarak tanımlanmıştır. Model kısıtları ise maksimum sayıda kullanılacak İSABİ sayısı, İSABİ'nin maksimum hareket

edebileceği mesafe ve minimum kapsama oranı olarak tanımlanmıştır. Çalışmanın sonuç kısmı incelendiğinde; belirli bir zaman periyodunda kapsanan SA sayısının dinamik SA varsayımı kullanıldığında statik SA varsayımına göre daha yüksek olduğu, iletim mesafesi arttıkça kapsanan SA sayısının arttığı ve minimum kapsama oranı kısıtı artırıldıkça problemin optimal çözüme yakınsayamadığı gözlemlenmiştir.

Sualtı kablosuz haberleşme ağlarının çalışma frekans aralığı dar bir bant genişliğinde yer aldığı için yüksek miktardaki verilerin iletiminde yetersiz kalmaktadır. Bu yüzden Xing ve çalışma arkadaşlarının yapmış olduğu [26] numaralı çalışmada, optik-akustik hibrit SA'ların röle olarak kullanıldığı SAA mimarisi önerilmiştir. Önerdikleri mimari için ilk önce SA'ların dağılım katsayıları hesaplanıp daha sonra İSABİ yerleşim problemi toplam tüketilen enerji miktarını minimize edecek şekilde modellenmiştir. Modelin çözümünde bulanık tabanlı (ing. *fuzzy-based*) yerleşim algoritması kullanılıp, sonuçlar K-Means algoritmasından elde edilen sonuçlar ile kıyaslanmıştır. Çalışmanın analiz kısmında İSABİ sayısı arttıkça bulanık tabanlı algoritmanın yakınsama adım sayısının, K-Means algoritmasına göre daha büyük olduğu gözlemlenmiştir. Fakat buna rağmen toplam tüketilen enerji miktarının bulanık tabanlı algoritma ile %30-60 aralığında azaldığı tespit edilmiştir.

Al-Bzoor ve ekibinin yapmış olduğu [27] numaralı çalışmada, sürekli değişen SAA çevresel faktörlerin etkisini en aza indirmek için İSABİ'lerin adaptif şekilde yeniden yerleştirilmesi gerektiği önerilmiştir. İSABİ'nin yeniden yerleşim zamanına, SA'nın iletim güç seviyesinin takibiyle karar verilmektedir. İSABİ'nin yeni koordinatları belirlenirken de İSABİ'nin bağlantı kurduğu sınır bölgede yer alan SA'ya en yakın olacak şekilde yeniden hesaplanmaktadır. Amaç fonksiyonu ise SA'ların kullanmış olduğu güç seviyelerinin toplamının minimize edilmesi olarak tanımlanmıştır. Çalışmanın analiz kısmında; oluşturdukları optimizasyon modeli global optimizasyon ve açgözlü algoritma yaklaşımlarıyla incelenmiştir. Toplam tüketilen iletim gücü ve ortalama veri gecikmesi bakımında her iki yaklaşımın benzer sonuçlar verdiği gözlemlenmiştir. Fakat açgözlü algoritmasının global optimizasyon yaklaşımına göre daha hızlı sonuç verdiği gözlemlenmiştir. Bu yüzden hesaplama süresinin kısaltılması için açgözlü algoritmanın alternatif olarak kullanılabilmesi önerilmiştir.

Yıldız'ın yapmış olduğu [28] numaralı çalışmada tek ve birden fazla İSABİ kullanımının SAA yaşam ömrü, ortalama veri gecikmesi ve ortalama SA enerji tüketimi üzerindeki etkisi incelenmiştir. Optimizasyon modeli karma tamsayı

programlama ile oluşturulmuştur. SAA yaşam ömrü [22] numaralı çalışmadan farklı olarak ilk SA'nın enerjisinin bitmesi olarak tanımlanmıştır. Çevresel etkilerden dolayı SA konumunda oluşabilecek değişiklikler ihmal edilmiş olup İSABİ batarya enerjisi hakkında herhangi bir kısıt olmadığı varsayılmıştır. Çalışmanın analiz kısmında ortalama SAA yaşam ömrünün, ağır yoğunluğundan bağımsız bir şekilde kullanılan İSABİ sayısı ile orantılı olarak arttığı gözlemlenmiştir. Birden fazla İSABİ kullanımının tek İSABİ kullanımına kıyasla, ortalama veri gecikmesini maksimum %51 azalttığı ve ortalama SA enerji tüketimini de en fazla %42 oranında azalttığı gözlemlenmiştir.

Kahriman ve ekibinin yapmış olduğu [29] numaralı çalışmada ise maksimum sayıda SA kapsayacak şekilde tek İSABİ'nin yerleşimi ele alınmıştır. Diğer çalışmalardan farklı olarak İSABİ yerleşim problemi ilk defa KTDOP ile modellenmiştir. Çalışmada SA konumları sabit varsayıp, İSABİ'nin yatay düzlemdeki konumu bulunmuştur. Analiz kısmında ise farklı sayıdaki SA ve iletim gücü seviyesi için KTDOP ve KKM ile elde edilen sonuçlar kıyaslanmıştır. İletim gücü 100 dB olduğunda, KTDOP ile kapsanan SA sayısının KKM'nin kapsadığı SA sayısından %35 daha yüksek olduğu ve iletim gücü arttıkça KKM'nin KTDOP'a yakınsadığı gözlemlenmiştir. Fakat iletim gücünü yüksek seviyelerde seçmek pratik anlamda uygulanabilir bir yaklaşım değildir.

1.3. Tezin Organizasyonu

Tez akışı sırasıyla,

- Bölüm 2'de Makine öğrenimi hakkında genel bilgilerin verilmesi, konumlandırma probleminde kullanılacak makine öğrenimi ve optimizasyon modeli hakkında temel bilgilerin verilmesi,
- Bölüm 3'te İHABİ sistem modeli ve hava kanal modelinin açıklanması, ardından optimizasyon modelinin oluşturulması,
- Bölüm 4'te İHABİ konumlandırmada, makine öğrenimi metotlarının nasıl kullanıldığı, veri setinin nasıl hazırlandığı ve elde edilen sonuçların kıyaslanması,
- Bölüm 5'te İSABİ sistem modeli ve sualtı kanal modelinin açıklanması, ardından optimizasyon modelinin oluşturulması,

- Bölüm 6’da İSABİ için oluşturulan optimizasyon modeli kullanılarak ilk önce tek İSABİ’li durum için sonuçlar elde edilip KKM ile farklı kullanıcı ve güç seviyeleri için kıyaslanması, daha sonra birden fazla İSABİ için elde edilen sonuçların K-Means algoritması ile farklı SA sayısı, İSABİ sayısı ve güç seviyeleri için kıyaslanması,
- Bölüm 7’de İHABİ ve İSABİ için elde edilen sonuçlardan yapılan genel çıkarımlar ve gelecekte yapılabilecek çalışmaların açıklanması,

olacak şekilde oluşturulmuştur.





2. METODOLOJİ

Bu bölümde makine öğreniminde kullanılan temel kavramlar ve ardından tez çalışması kapsamında kullanılan metotlar hakkında temel bilgiler verilecektir.

2.1. Makine Öğrenimi Tanımı

Makine Öğrenimi (ing. *Machine Learning*, ML); makinelerin her bir koşulu programlanmadan karar verebilme mekanizmasının geliştirilmesini, başka bir ifadeyle makinelerin deneyim yoluyla öğrenme kabiliyetinin geliştirilmesini amaçlayan bir araştırma alanıdır. Günümüzde ML; otonom araçlar, arama motorları, sesli asistan uygulamaları, sağlık, ekonomi piyasa analizi gibi birçok uygulamada kullanılan ve halen araştırılmakta olan bir alandır. Günlük hayatımızda sıklıkla kullandığımız teknolojik cihazlar (telefon, bilgisayar, akıllı saatler vb.) sayesinde hayatımıza daha çok entegre olmaktadır.

ML'nin tarihsel gelişimi incelendiğinde, ilk kullanımı olarak 1940'lı yıllarda McCulloch ve Pitts tarafından sinir ağları modelinin önerilmesi ve bu modelin elektrik devre elemanları ile uygulanması verilebilir. Alan Turing 1950'li yıllarda "Makineler düşünebilir mi?" [33] sorusuyla "Evrensel Makine" (ing. *Universal Machine*) tanımını yapmıştır ve bu tanım günümüzde ML alanındaki çalışmaların temelini oluşturmaktadır. Yine aynı yıllarda bilgisayar teknolojisinin gelişmesiyle birlikte, 1959 yılında Bernard Widrow ve Marcian Hoff tarafından "ADALINE" ve "MADALINE" isiminde iki adet sinir ağı modeli geliştirilmiştir. "ADALINE" telefon hatlarındaki bitleri dinleyerek bir sonraki biti tahmin etmek için kullanılmıştır, "MADALINE" ise adaptif filtreleme yaparak telefon hatlarındaki geri yansıma problemini engellemek için kullanılmıştır [34]. Bu iki model de günümüzdeki haberleşme sistemlerinde halen kullanılmaktadır. İnsan beyninden ilham alınmış metotlar, sinir ağları ve derin öğrenme teknikleri aslında ML'nin bir alt kümesidir [35].

2.2. Denetimli Öğrenme

Denetimli öğrenme, bilinen girdi verisi ve bu girdi verisine karşılık gelen bilinen çıktı verisinin kullanılmasıyla her iki veri seti arasındaki mantıksal ilişkiyi kuran algoritmanın çıkarılmasıdır [36]. Elde edilen algoritma, temelde girdi verileri ile çıktı verileri arasında bir fonksiyon tahmin etmektedir [37]. Tahmin edilen fonksiyon sayesinde sisteme farklı bir girdi verildiğinde, en anlamlı çıktı verisi kısa sürede hesaplanmaktadır.

Modelin çıkarımında bulunduğu algoritmanın performansı, bilinen test veri setiyle ölçülebildiği için makine öğrenme uygulamalarında denetimli öğrenme tercih edilen bir yöntem olmuştur. Denetimli öğrenme yönteminin çözüm bulduğu problemler incelendiğinde temelde “Regresyon” ve “Sınıflandırma” olmak üzere iki gruba ayrılmaktadır. [51]

Sınıflandırma probleminde amaç, girdi verisinin hangi kümeye ait olduğunu tespit etmektir. Çıktı verisinde kullanılan kümeler birbirinden ayrıktır ve atama esnasında her bir kümenin kendine ait bir eşik değeri bulunmaktadır. Bu eşik değerleri, denetimli öğrenme yönteminde kullanılan girdi ve çıktı veri setlerinden elde edilmektedir.

Regresyon probleminde ise amaç, girdi verileri ve çıktı verileri kullanılarak en iyi interpolasyon fonksiyonunu bulmaktır. İnterpolasyon yapılacak fonksiyonun katsayıları, girdi ve çıktı veri setlerinden elde edilmektedir.

Her iki denetimli öğrenme probleminde de aranan algoritmanın elde edilmesinde gerekli olan parametreler girdi ve çıktı veri setinden elde edilmektedir. Bu yüzden girdi ve çıktı verileri arasında istatistiksel çıkarımların yapılması ve veri setinin düzgün bir şekilde işlenip modele verilmesi önem arz etmektedir.


2.3. Denetimsiz Öğrenme

Denetimsiz öğrenme yöntemi, girdi verisinden anlamlı bilgi çıkartılması amacıyla veri görselleştirmek veya eldeki verilerde bulunan korelasyonu daha iyi anlamlandırmak için kullanılmaktadır. Denetimli öğrenme ve denetimsiz öğrenme yöntemleri arasındaki en temel fark, denetimsiz öğrenmede girdi verisine karşılık gelecek çıktı verisi ML modeline sağlanmaz. Model önceki girdi verilerinden öğrenmiş olduğu özellikleri kullanarak yeni verilerini işleyebilmektedir.

Denetimsiz öğrenme yöntemi genellikle kümeleme problemlerinde ve nitelik azaltmak için kullanılır [38].

2.4. Kümeleme ve K-Means Algoritması

Kümeleme, veri analizi ve veri madenciliği uygulamalarında tercih edilen bir yöntemdir. Denetimsiz öğrenme yönteminin bir alt dalıdır [39]. Kümeleme de girdi verisinde benzerlikler saptanarak gruplandırma süreci bulunmaktadır. Başka bir ifade ile benzer nitelikteki elemanlar kendi kümesini oluşturmaktadır. Şekil 2.1’de örnek bir kümeleme uygulaması gösterilmiştir.



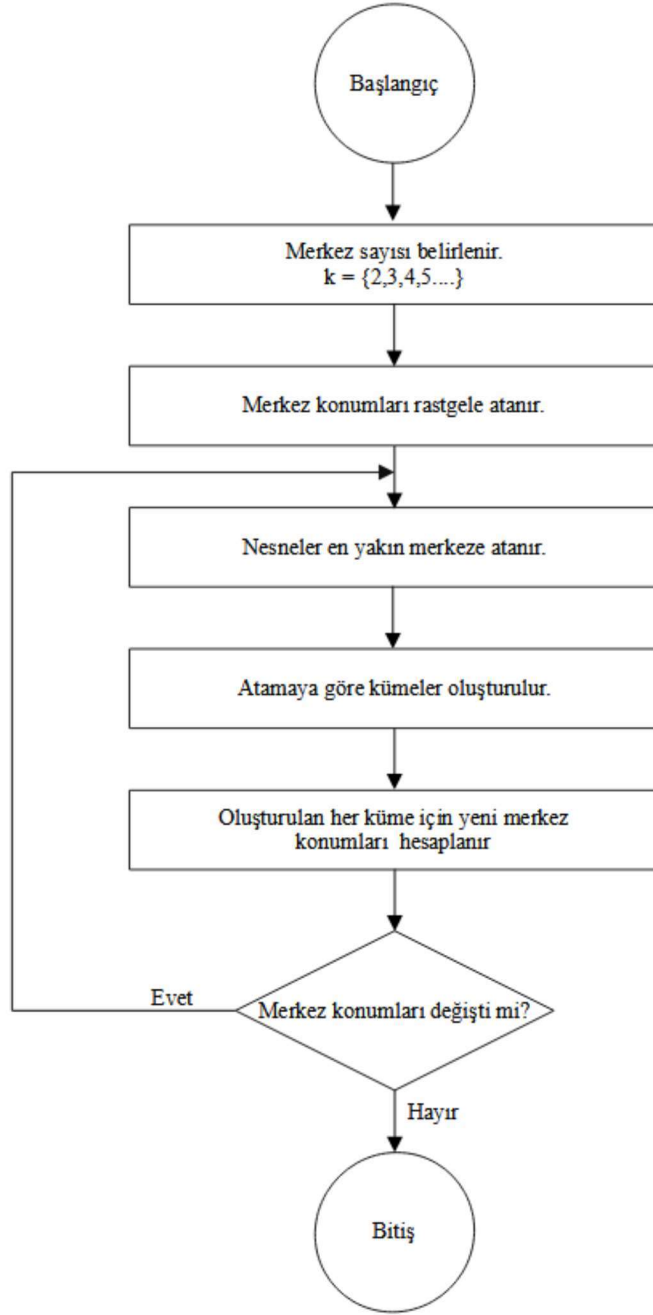
Şekil 2.1: Kümeleme Uygulaması

Kümeleme yönteminde en çok karşılaştığımız algoritma ise K-Means algoritmasıdır. K-Means algoritması temelde 3 aşamadan oluşmaktadır. Bunlar:

1. Önceden tanımlanmış k sayısı kadar merkezin rastgele yerleştirilmesi.
2. Girdi verilerinin en yakın mesafedeki merkeze atanarak küme oluşturulması.
3. Her bir küme içinde ortalama alınıp yeni merkez konumunun belirlenmesi.

2. ve 3. adımlar hesaplanan merkez konumları sabit kalana kadar tekrarlanmaktadır.

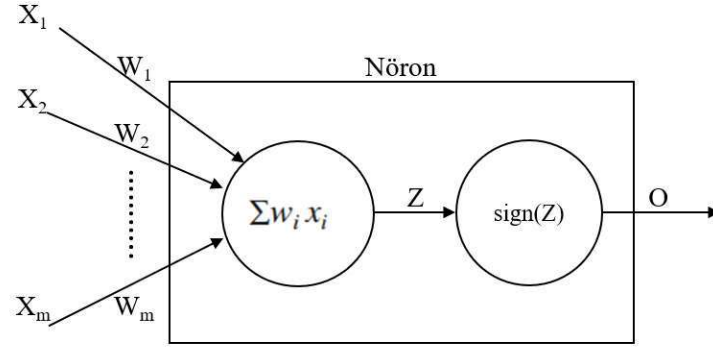
K-Means algoritmasının akış diyagramı Şekil 2.2’de gösterilmiştir.



Şekil 2.2: K-Means Blok Diyagramı


2.5. Sinir Ağları ve Derin Sinir Ağları

Sinir Ağları (ing. *Neural Networks*, NN) hakkında yapılan ilk sistematik çalışma 1943 yılında McCulloch ve Pitts tarafından gerçekleştirilmiştir [40]. Bu çalışmada sinir sisteminde yer alan nöronlardan esinlenilmiştir ve Şekil 2.3'te gösterilen nöron modeli oluşturulmuştur.



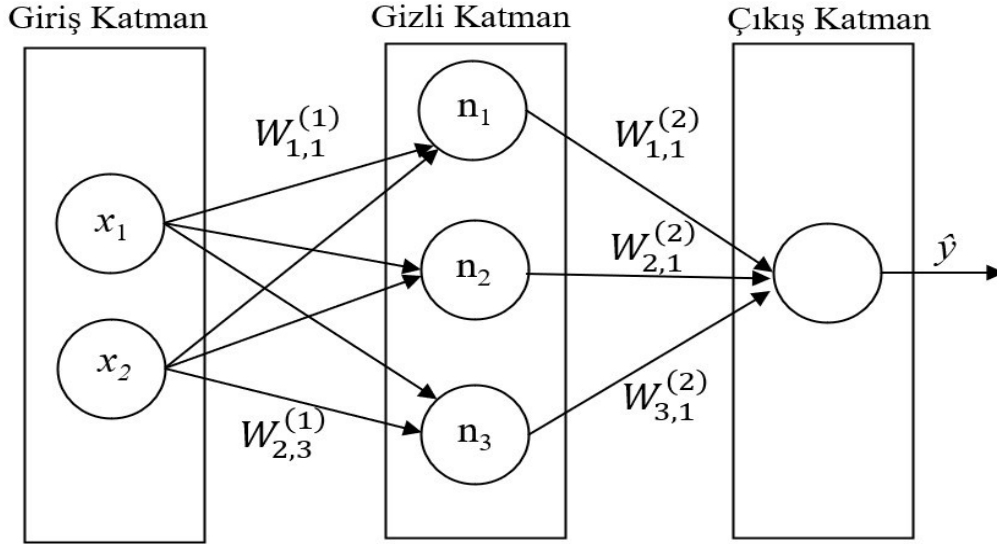
Şekil 2.3: McCulloch ve Pitts tarafından modellenmiş nöron yapısı

Oluşturulan bu modelde girişler, nörona gelen uyarı sinyallerini temsil etmektedir. Nöron, kendine gelen uyarı sinyallerini (x_i) ağırlık katsayıları (w_i) ile çarpıp kümülatif toplamını almaktadır. Kullanılan ağırlık katsayıları negatif ise inhibe edici, pozitif ise uyarıcı bir etkiyi temsil etmektedir. Kümülatif toplam belirli bir eşik değerinden yüksek ise nöron aktif hale gelir ve pozitif bir değer alır aksi takdirde negatif bir değer almaktadır [40]. Geliştirilen bu model, günümüzde kullanılan NN mimarilerindeki düğümü temsil etmektedir. Yani NN’de kullanılan her bir düğüm, önce kendisine gelen girdileri belli bir katsayı ile çarpıp kümülatif toplamını almaktadır daha sonra belirlenen bir aktivasyon fonksiyonu ile çıktı üretmektedir. McCulloch ve Pitts’in oluşturdukları bu modelde kullanılan aktivasyon fonksiyonu signum fonksiyonudur. Günümüzde Şekil 2.4’te gösterilen diğer aktivasyon fonksiyonları da kullanılmaktadır.



Şekil 2.4: Aktivasyon fonksiyonları [35]

Bir NN modeli temelde Şekil 2.5'te gösterildiği gibi giriş katmanı (ing. *input layer*), gizli katman (ing. *hidden layer*) ve çıkış katmanı (ing. *output layer*) olmak üzere 3 katmandan oluşmaktadır.



Şekil 2.5: İleri beslemeli örnek NN modeli

NN modelinde ileri besleme ve geri yayılım olmak üzere temel iki işlem bulunmaktadır. Bu işlemler sayesinde modelde yer alan katmanlar arasındaki en optimal ağırlık katsayıları belirlenmektedir. İlgili işlemler, Şekil 2.5'te gösterilmiş olan mimari üzerinden açıklanacaktır. Aktivasyon fonksiyonu olarak Şekil 2.4'te yer alan sigmoid fonksiyonu kullanılmıştır ve sapma değeri (ing. *bias*) yok sayılmıştır.

İleri besleme işleminde gizli katmana gelen 2 boyutlu X girdi vektörü, gizli katmanın ağırlık matrisi olan $W^{(1)}$ ile çarpılır ve $z^{(2)}$ çıktısı elde edilir. Daha sonra çarpım sonucu aktivasyon fonksiyonundan geçirilir. Gizli katmanda yapılan işlemler aşağıda verilen denklemler ile özetlenmiştir:

$$z^{(2)} = X W^{(1)} \quad (2.1)$$

$$\sigma^2 = f(z^{(2)}) = \frac{1}{1 + e^{-z^{(2)}}} \quad (2.2)$$

Sonrasında çıkış katmanı için gizli katmandan elde edilen aktivasyon fonksiyon sonucu $W^{(2)}$ ağırlık matrisi ile çarpılır ve elde edilen $z^{(3)}$ sonucu aktivasyon fonksiyonundan geçirilip çıktı elde edilir. İkinci katmanda yapılan işlemler Eşitlik (2.3) ve Eşitlik (2.4) ile özetlenmiştir:

$$z^{(3)} = \sigma^2 W^{(2)} \quad (2.3)$$

$$\hat{y} = f(z^{(3)}) = \frac{1}{1 + e^{-z^{(3)}}} \quad (2.4)$$

NN modelinde bu işlemler yapılırken ağırlık katsayılarının ilk değerleri rastgele atanmaktadır. Bu katsayıların en optimal değerlerine erişmesi için geri yayılım işlemi uygulanmaktadır. Geri yayılım işleminde kayıp fonksiyonu minimize edilmektedir ve gradyan iniş algoritması kullanılarak ağırlık katsayıları iteratif bir şekilde güncellenmektedir. Gradyan iniş algoritmasında kullanılan güncelleme fonksiyonu Eşitlik (2.5)'te ifade edilmiştir.

$$W^{(i)} = W^{(i)} - \alpha \frac{\partial L}{\partial W^{(i)}} \quad (2.5)$$

Eşitlik (2.5)'te, α öğrenme oranını ifade etmektedir ve 0 ile 1 arasında bir değer almaktadır. L ise kayıp fonksiyonunu ifade etmektedir. Kayıp fonksiyonu minimize edilirken, kayıp fonksiyonunun güncellenecek parametreye göre kısmi türevi alınır ve hata eğiminin ters istikametinde güncellenir. Bu sayede kayıp fonksiyonundaki hata miktarı azaltılır.

$$L(y, \hat{y}) = \sum_{x=1}^N \left(\frac{1}{2} (y - \hat{y})^2 \right) \quad (2.6)$$

Şekil 2.5'te göstermiş olduğumuz NN modelinde geri yayılım işlemi anlatmak için [41]'de belirtilen kayıp fonksiyonu kullanılmıştır ve Eşitlik (2.6)'da verilmiştir. Kayıp fonksiyonundaki N girdi vektör sayısını, y ise her bir girdi vektörüne karşılık gelen çıktıyı ifade etmektedir.

Eşitlik (2.6)'da belirtilen kayıp fonksiyonunun $W^{(1)}$ ve $W^{(2)}$ 'e göre kısmi türevi bulunurken zincir kuralından yararlanılır. Kısmi türev aşağıda belirtilen Eşitlik (2.8) ve Eşitlik (2.9) ile ifade edilir. Sigmoid aktivasyon fonksiyonunun birinci derece türevi ise Eşitlik (2.7) ile hesaplanmaktadır. Eşitlik (2.8) ve Eşitlik (2.9) ifade edilirken, kayıp fonksiyonunda 1 tane girdi vektörü, $N=1$, olduğu varsayılmıştır.

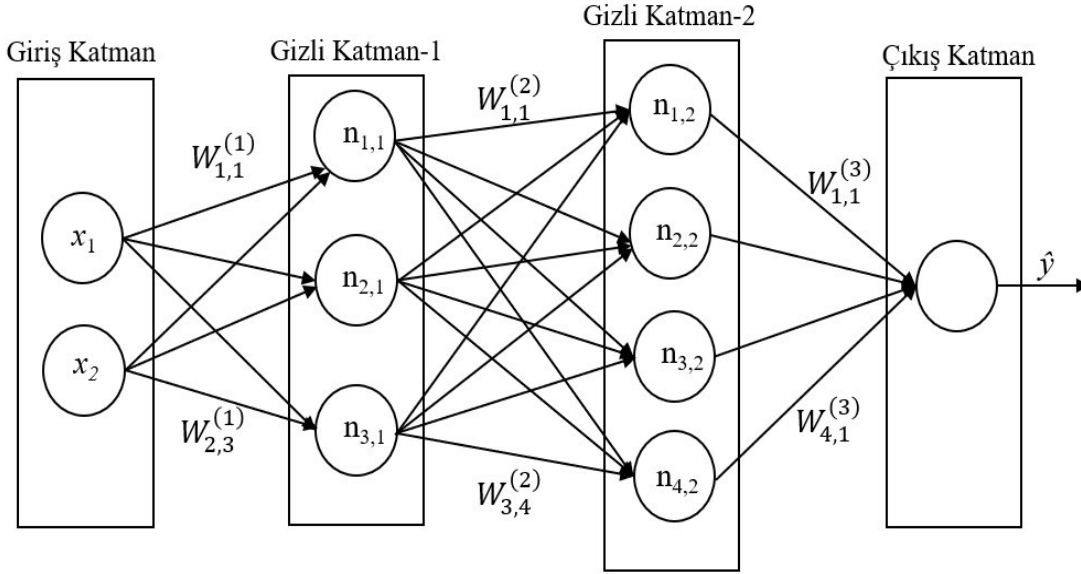
$$\frac{df(z)}{dz} = \frac{e^{-z}}{(1 + e^{-z})^2} \quad (2.7)$$

$$\frac{\partial L}{\partial W^{(2)}} = \frac{\partial L}{\partial \hat{y}} \frac{\partial f(z^3)}{\partial z^3} \frac{\partial z^3}{\partial W^{(2)}} = -(y - \hat{y}) f'(z^3) \sigma^2 \quad (2.8)$$

$$\frac{\partial L}{\partial W^{(1)}} = -(y - \hat{y}) f'(z^3) (W^{(2)})^T f'(z^2) (X)^T \quad (2.9)$$

Yukarıdaki belirtilen denklemler ile geri yayılım işleminin matematiksel yaklaşımı özetlenmiştir.

Derin Sinir Ağlar (ing. *Deep Neural Networks*, DNN) ise, makine öğrenmesinin bir alt kümesi olarak 1959 yılında Arthur Samuel tarafından, bilgisayarlara öğrenme yeteneğini kazandırmayı amaçlayan bir çalışma alanı olarak tanımlanmıştır [35]. NN ile arasındaki en temel fark ise mimaride kullanılan gizli katman sayısının birden fazla olmasıdır. Şekil 2.6'da örnek bir DNN mimarisi gösterilmiştir. DNN' de kullanılan ağırlık fonksiyonları da NN'de olduğu gibi geri yayılım işlemiyle kayıp fonksiyonunun minimize edilmesiyle bulunmaktadır.




Şekil 2.6: 3 Katmanlı örnek DNN modeli

2.6. Evrişimsel Sinir Ağları

Evrişimsel Sinir Ağları (ing. *Convolutional Neural Networks*, CNN) çok boyutlu verilerin analizi için özelleştirilmiş bir derin öğrenme yöntemidir [50]. Hubel ve Wisel tarafından 1960'lı yıllarda beyindeki görsel korteks yapısından esinlenerek ilk CNN modeli önerilmiştir [42].

DNN modellerinde kullanılan parametre sayısının artması, DNN'nin hesaplama performansını olumsuz yönde etkilemektedir. Hesaplama performansını geliştirmek için ortak parametre kullanan yöntemler üzerine yapılan çalışmalar CNN modellerine olan ilgiyi artırmıştır. CNN modellerinde diğer geleneksel DNN modellerine kıyasla daha az parametre kullanılmaktadır. Bu sayede CNN modellerinin kullanıldığı uygulamalarda, donanımsal olarak bellek kullanımı azalmaktadır ve hesaplamalardaki verimlilik gelişmektedir. Ek olarak çok boyutlu verilerin tek boyuta indirilmesi veri içerisindeki uzaysal bağlantı kaybına neden olmaktadır [43]. Bu yüzden resim gibi tek boyutlu olmayan verilerin işlenmesinde CNN modellerinin kullanılması daha uygundur.

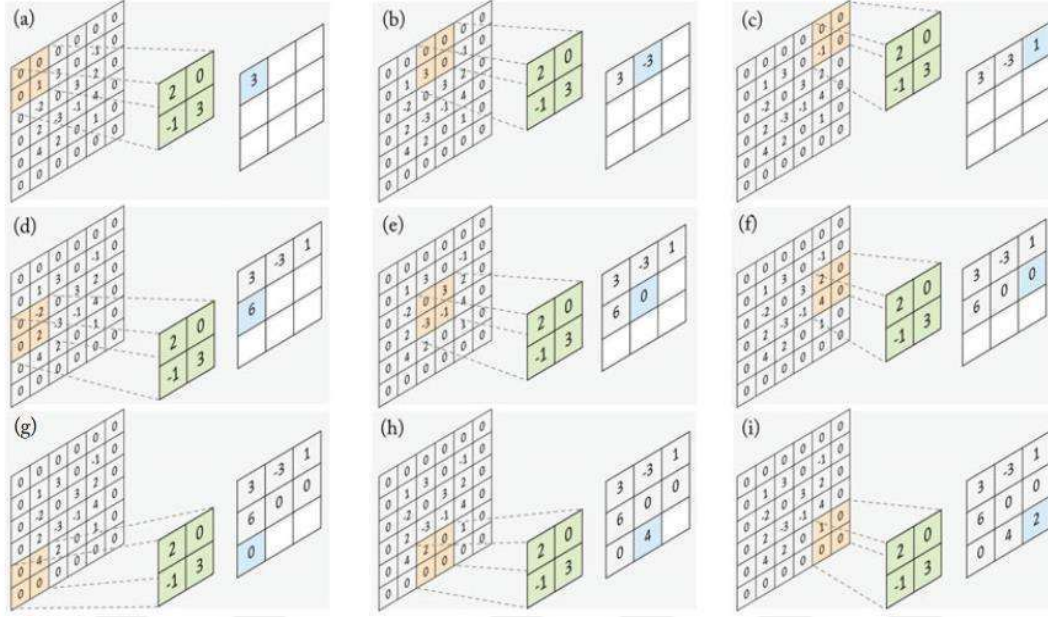
CNN modelinin kullanımı 1960'lı yıllarda önerilse de ilk gradyan tabanlı CNN öğrenme modeli 1998 yılında LeCun ve arkadaşları tarafından posta kodlarının sınıflandırılmasında uygulanmıştır [44]. Uyguladıkları model, LeNet-5, Şekil 2.7'de yer almaktadır.



Şekil 2.7: LeNet-5 CNN modeli [44]

Standart bir CNN modeli; konvolüsyon katmanı (ing. *convolution layer*), normalizasyon katmanı (ing. *normalization layer*), havuzlama katmanı (ing. *pooling layer*) ve tam bağlantı katmanından (ing. *fully connected layer*) oluşmaktadır. Kullanılan önemli katmanlar aşağıda açıklanmıştır.

Konvolüsyon katmanı, CNN modelinin en temel katmanıdır. Bu katmanda girdi verisini ile önceden boyutları tanımlanmış filtreler arasında evrişim işlemi yapılarak girdi verisinin özellikleri saptanmaktadır. Şekil 2.8'de konvolüsyon katmanında yapılan evrişim işlemi gösterilmiştir.



Şekil 2.8: 6x6 girdi ile 2x2 filtrenin evrişim işlemi [45]

Evrişim işleminde kullanılacak filtrenin ağırlık katsayıları DNN’de olduğu gibi öğrenme aşamasında kayıp fonksiyonunun minimize edilmesi ile bulunmaktadır.

Normalizasyon katmanı, girdi verisinin ve katmanlar arası iletilen verinin dağılımını kontrol etmek için kullanılır. Bu kontrol sayesinde ağırlık eğitimi önemli ölçüde hızlanmaktadır. Bu katmanda gelen verinin (σ, μ) , ortalaması 0 ve standart sapması 1 olacak şekilde ölçeklenip kaydırılır. Toplu normalizasyonda (ing. *batch normalization*, BN) kullanılan fonksiyonun matematiksel ifadesi Eşitlik (2.10)’da yer almaktadır.

$$y = \frac{x - \mu}{\sqrt{\sigma^2 - \epsilon}} \gamma + \beta \quad (2.10)$$

Eşitlik (2.10)’da γ ve β parametreleri ağırlık öğrenme aşamasında optimize edilen değerlerdir. ϵ ise numerik hataları önlemek için kullanılan sabit küçük bir değerdir [46].

Havuzlama katmanı, konvolüsyon katmanları arasına opsiyonel olarak eklenen bir katmandır. Ağda ilerleyen verinin boyutu küçültülerek, ağ içerisinde kullanılan parametre ve hesaplama sayısını azaltmak için kullanılır. Havuzlama yapılırken, ortalama değer hesaplama fonksiyonu veya maksimum değer seçim fonksiyonu sıklıkla kullanılmaktadır. Şekil 2.9’da maksimum değer seçim fonksiyonunun kullanıldığı bir havuzlama operasyonu gösterilmiştir.




Şekil 2.9: Maksimum değer havuzlama uygulaması

Tam bağlantı katmanı ise CNN modelinin son katmanı olarak eklenmektedir ve bu katmanda standart NN modelinde uygulanan tüm işlemler yapılmaktadır.

2.7. Artçıl Sinir Ağları

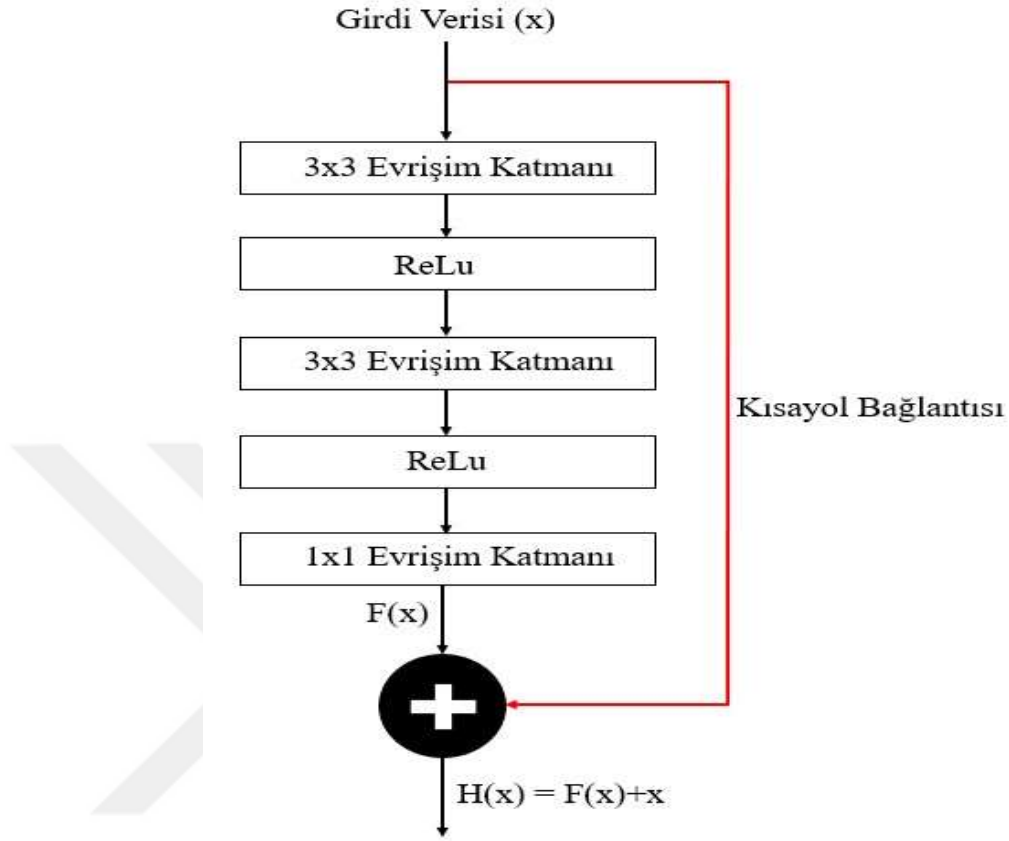
Günümüzde kullanılan NN mimarileri görüntü işleme, doğal dil işleme ve robotik gibi birçok uygulama alanında önemli başarılar elde etmiştir. Uygulamalarda, kullanılan ağ yapılarındaki derinlik arttıkça oluşan hatanın arttığı gözlemlenmiştir. Şekil 2.10' da farklı katman sayısında olan NN modellerinin CIFAR-10 verisindeki sınıflandırma hata oranları gösterilmiştir.



Şekil 2.10: Derinlik arttıkça hata oranının artabileceği gözlenmiştir. [47].

Ağ derinliği arttıkça aşırı öğrenmeyle alakalı olmayan bir bozunum (ing. *degradation*) problemi oluşmaktadır. Bu bozunum problemi [47]'ye göre derinlik arttıkça ağ performansının doyuma ulaşmış bir anda düşmesi olarak tanımlanmıştır. 2015 yılında Kaiming He ve arkadaşları bu bozunum problemine çözüm olarak Artçıl Ağ (ing.

Residual Network, ResNet) mimarisini önermiştir. ResNet mimarisinde standart NN mimarisinden farklı olarak Şekil 2.11’de gösterilen artçıl bloklar kullanılmaktadır.



Şekil 2.11: ResNet artçıl blok

Artçıl blokta kullanılan kısayol bağlantısı ağda ekstra parametre gerektirmediği için hesaplama performansını olumsuz yönde etkilememektedir. Eşitlik (2.11)’de artçıl blok için kullanılacak genelleştirilmiş matematiksel formül verilmiştir [47].

$$y = H(x) = F(x, \{W_i\}) + W_s x \quad (2.11)$$

Eşitlik (2.11)’de W_s , F ile x arasındaki boyut uyumsuzluğunu engellemek için kullanılan bir kare matristir.

2.8. Karma Tamsayı Doğrusal Olmayan Programlama

Optimizasyon, belirli bir tasarımda eldeki kısıtlı kaynaklar ile en iyi tasarımın nasıl yapılabileceğini bulmaya yardımcı olan bir araştırma alanıdır. Optimizasyon günümüzde endüstriyel planlama, kaynak ataması, zaman planlaması gibi birçok alanda kullanılmaktadır.

Karma Tamsayılı Doğrusal Olmayan Programla (ing. *Mixed-Integer Non-linear Programming*, MINLP) ise değişkenleri sürekli ve tamsayılı olan, doğrusal olmayan problemleri ele alan bir optimizasyon yaklaşımıdır [48]. Standart bir MINLP modeli aşağıda gösterildiği gibi oluşturulabilir [49]:

$$Z_{MINLP} = \underset{x \in X, y \in Y}{\text{minimize}}(f(x, y)) \quad (2.12)$$

$$\text{Kst.: } g(x, y) < 0 \quad (2.13)$$

$f(x, y)$ ve $g(x, y)$ fonksiyonları sürekli ve türevlenebilir fonksiyonlardır. Fonksiyonlardan en az bir tanesi doğrusal olmayan bir ifadeyi direkt ya da dolaylı olarak içinde barındırmaktadır. x ve y değişkenlerinden en az biri sürekli değişkendir, diğeri ise ayrık değişkendir. Eğer amaç fonksiyonu ve kısıt fonksiyonları konveks ise optimizasyon problemi konveks MINLP olarak isimlendirilir [49].



3. İHABİ SİSTEM MİMARİSİ VE ENİYİLEME MODELİ

Bu bölümde İHABİ için uygulamaya özel sistem ve optimizasyon modeli sırasıyla açıklanacaktır. İHABİ optimizasyon modeli, makine öğrenme tekniklerinde ve performans analiz takibinde kullanılacak veri setinin oluşturulmasında kullanılacaktır.

3.1. İHABİ Sistem Modeli

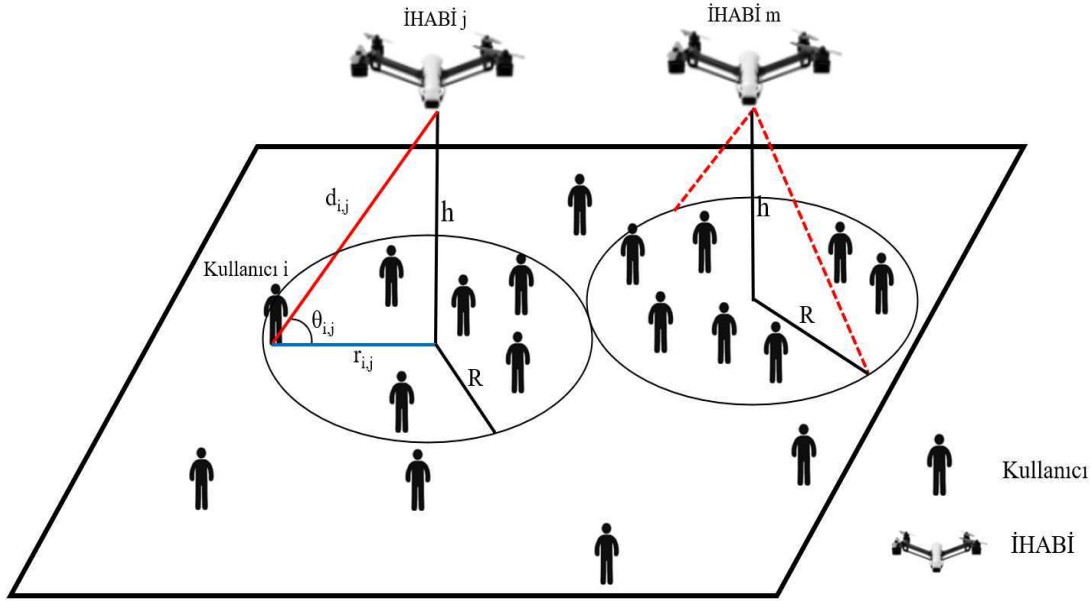
Sistem modeli, durağan kullanıcılar ile sabit yükseklikte çalışan İHABİ'ler arasında bağlantı oluşturacak şekilde kurulmuştur. Kullanıcı konumları altıgen bir alanda alt sınırı 0, üst sınırı 2000 olan düzgün rastgele dağılıma göre atanmıştır. Sistem modeli oluşturulurken aşağıdaki varsayımlarda bulunulmuştur:

- İHABİ'ler aynı yükseklikte hizmet vermektedir.
- Her kullanıcının servis kalite isteri (QoS) eşittir.
- Her bir kullanıcı en fazla bir tane İHABİ ile bağlantı kuracaktır.
- Ortogonal sinyalleme metodu kullanılarak, sinyal girişimi yok sayılmıştır. [17]
Girişimi önlemek için İHABİ'ler farklı frekans bantlarında çalışacaktır.

3.2. Hava Kanal Modeli

Radyo frekansında iletilen sinyallerin hava yol kayıpları modellenirken; çevre koşullarına, alıcı ve vericinin konumlarına dikkat edilmektedir. Modelleme yapılırken alıcıya iletilen sinyal tipleri üç temel grupta incelenmektedir. Birinci grup, alıcı ve verici arasında herhangi bir engel yokken alıcının sinyal alma durumudur. Alıcı vericinin görüş hattı içinde olduğu için bu gruptaki sinyaller görüş hattı (ing. *Line of Sight*, LoS) sinyal olarak isimlendirilir. İkinci grup, alıcının verici görüş hattında olmamasına rağmen yüksek güç seviyesinde olan yansıyan sinyalleri alma durumudur. Bu grupta alıcı, vericinin görüş hattında olmadığı için bu gruptaki sinyaller görüş hattı dışı (ing. *Non-Line of Sight*, NLoS) sinyal olarak isimlendirilir. Üçüncü grup, alıcı vericinin görüş hattında değildir ve alıcı düşük güç seviyesindeki sinyalleri almaktadır.

Üçüncü gruptaki sinyallerin hava yol kayıp modeline etkisi %3'ün altında olduğu için ihmal edilmiştir [16].



Şekil 3.1: İki İHABİ için sistem modeli

İHABİ sistem modeli Şekil 3.1'de gösterildiği gibi önceden tanımlanmış sabit bir yükseklikte çalışan İHABİ ve durağan konumda olan kullanıcılardan oluşmaktadır. Her bir kullanıcının bağlantı kurduğu İHABİ ile arasındaki yükselme açısı radyal olarak $\theta_{i,j}$ ile ifade edilmektedir ve $\tan^{-1}\left(\frac{h_j}{r_{i,j}}\right)$ ile hesaplanmaktadır. Kullanıcıların ve İHABİ'nin yatay konum bilgileri sırasıyla (x_{u_i}, y_{u_i}) ve (x_{d_j}, y_{d_j}) ile ifade edilmektedir. Kullanıcı i'nin almış olduğu sinyalin görüş hattı grubundan olma olasılığı j'ninci İHABİ ile arasındaki yatay mesafeye ve j'ninci İHABİ'nin yüksekliğine bağlıdır. Görüş hattında olma olasılığı Eşitlik (3.1) ile hesaplanmaktadır [1].

$$P_{Los}(h_j, r_{i,j}) = \frac{1}{1 + \alpha \exp\left(-\beta \left(\frac{180}{\pi} \times \tan^{-1}\left(\frac{h_j}{r_{i,j}}\right) - \alpha\right)\right)} \quad (3.1)$$

Eşitlik (3.1)'deki $r_{i,j}$, kullanıcı i ile İHABİ j arasındaki yatay mesafeyi ifade etmektedir ve $r_{i,j} = \sqrt{(x_{d_j} - x_{u_i})^2 + (y_{d_j} - y_{u_i})^2}$ ile hesaplanmaktadır. α ve β

parametreleri ortam koşullarına göre belirlenen sabit değerlerdir [1]. Alıcı sinyalinin görüş hattında olmama olasılığı ise Eşitlik (3.2) ile hesaplanmaktadır.

$$P_{NLoS}(h_j, r_{i,j}) = 1 - P_{LoS}(h_j, r_{i,j}) \quad (3.2)$$

Görüş hattındaki sinyalin ve görüş hattında olmayan sinyalin, kullanıcı i ile İHABİ j arasındaki yol kayıpları desibel cinsinde sırasıyla Eşitlik (3.3) ve Eşitlik (3.4) ile ifade edilmektedir. [7].

$$L_{LoS}^{ij} = 20 \log \left(\frac{4\pi f_c d_{i,j}}{c} \right) + \eta_{LoS} \quad (3.3)$$

$$L_{NLoS}^{ij} = 20 \log \left(\frac{4\pi f_c d_{i,j}}{c} \right) + \eta_{NLoS} \quad (3.4)$$

Eşiklik (3.3) ve Eşitlik (3.4)' de yer alan f_c , sinyalin taşıyıcı frekansını, c , ışık hızını, $d_{i,j}$ kullanıcı i ile İHABİ j arasındaki mesafeyi vermektedir ve $d_{i,j} = \sqrt{h_j^2 + r_{i,j}^2}$ eşitliğiyle hesaplanmaktadır. Görüş hattında olan ve olmayan sinyaller için ortalama çevresel kayıp desibel cinsinden sırasıyla η_{LoS} ve η_{NLoS} ile ifade edilmiştir. Farklı çevre tipleri için [1]'de belirtilen η_{LoS} , η_{NLoS} , α ve β değerleri aşağıdaki çizelgede verilmiştir:

Tablo 3.1: Farklı çevre tipleri için kullanılan yayılım parametreleri. [1]

Çevre	α	β	η_{LoS}	η_{NLoS}
Banliyö	4.88	0.43	0.1	21
Şehir	9.61	0.16	1	20
Yoğun Şehir	12.08	0.11	1.6	23
Yüksek Katlı Şehir	27.23	0.08	2.3	34

Eşitlik (3.1), (3.2), (3.3) ve (3.4) kullanılarak toplam yol kaybı Eşitlik (3.5)'de olduğu gibi ifade edilmektedir [4]:

$$L(h_j, r_{i,j}) = P_{LoS}(h_j, r_{i,j}) \times L_{LoS}^{ij} + P_{NLoS}(h_j, r_{i,j}) \times L_{NLoS}^{ij} \quad (3.5)$$

Eşitlik (3.5)'deki denklemi açtığımızda [1]'de verildiği gibi aşağıdaki basitleştirilmiş ifade elde edilmektedir.

$$L(h_j, r_{i,j}) = 20 \log(d_{i,j}) + A P(h_j, r_j) + B \quad (3.6)$$

Eşitlik (3.6)'da, A ve B sabit değerlerdir. $A = \eta_{LOS} - \eta_{NLOS}$ ve $B = 20 \log\left(\frac{4\pi f_c}{c}\right) + \eta_{NLOS}$ eşitlikleriyle hesaplanmaktadır.

Her bir kullanıcının minimum hizmet kalitesi kısıtı bulunmaktadır ve bu kısıtın kullanıcılar için eşit olduğu varsayılmıştır. İHABİ'nin bu kısıtı sağlayabilmesi için ortam kayıp eşik değeri, L_{th} , tanımlanmıştır. Kullanıcıların kesintisiz hizmet alabilmesi için kullanıcının bağlantı kurmuş olduğu linkteki toplam ortam kaybı, L_{th} 'den küçük veya eşit olmalıdır [7].

Ortam parametreleri ve L_{th} kullanılarak İHABİ'nin kapsama alanı yarıçapı, R , ve çalışma yüksekliği hesaplanmaktadır. İHABİ kapsama yarıçapı hesaplanırken aşağıdaki matematiksel ifade kullanılmaktadır [7]:

$$L_{th} = 20 \log\left(\frac{R}{\cos(\theta_{opt})}\right) + \frac{A}{1 + \alpha \exp\left(-\beta\left(\frac{180}{\pi} \times \theta_{opt} - \alpha\right)\right)} + B \quad (3.7)$$

Eşitlik (3.7)'de yer alan A ve B değerleri Eşitlik (3.6)'daki değerler ile aynıdır, θ_{opt} ise radyal olarak İHABİ'nin optimum yükselme açısını belirtmektedir. Optimum yükselme açısı aşağıdaki belirtilen eşitlik ile hesaplanmaktadır [7]:

$$\frac{\pi}{9 \ln(10)} \tan(\theta_{opt}) + \frac{\alpha \beta A \exp\left(-\beta\left(\frac{180}{\pi} \times \theta_{opt} - \alpha\right)\right)}{\left(\alpha \exp\left(-\beta\left(\frac{180}{\pi} \times \theta_{opt} - \alpha\right)\right) + 1\right)^2} = 0 \quad (3.8)$$

3.3. İHABİ Yerleşim Optimizasyon Modeli

Bu alt başlıkta birden fazla İHABİ'nin konumlandırılmasında kullanılacak optimizasyon modeli açıklanacaktır. Optimizasyon modelinin amaç fonksiyonu maksimum sayıda kullanıcıyı kapsayacak şekilde İHABİ'lerin yatay konumunu belirlemektir.

Kullanıcı kümesi $U = \{1, 2, 3 \dots n\}$ olarak tanımlanmıştır ve i indeksi her bir kullanıcıyı temsil etmek için kullanılmıştır. Ortamda bulunan kullanıcı sayısı n ile belirtilmektedir. İHABİ kümesi $D = \{1, 2, 3 \dots m\}$ olarak tanımlanmıştır, j indeksi ise

İHABİ'yi temsil etmek için kullanılmıştır. Kullanılacak İHABİ sayısı ise m ile ifade edilmektedir.

Kullanıcıların İHABİ tarafından kapsandığını belirtmek için $u_i \in \{0,1\}$ ikili değişkeni tanımlanmaktadır. Eğer kullanıcı i kapsama yarıçapı içerisindeki dairesel bölgede yer alıyor ise İHABİ tarafından kapsanmıştır ve $u_i=1$ olmaktadır. Aksi takdirde $u_i = 0$ olmaktadır. Kapsama yarıçapı ise önceden tanımlanmış ortam kayıp eşik değeri, Eşitlik (3.7) ve Eşitlik (3.8) kullanılarak hesaplanmaktadır. Her bir İHABİ'nin kapsama yarıçapı $R_j = R$ olacak şekilde atanmıştır. Eşitsizlik (3.9) ile kullanıcının kapsama yarıçapı içerisinde olma durumu ifade edilmiştir.

$$r_{i,j} \leq R_j + M_1 (1 - u_i) \quad \forall_i \in U \quad (3.9)$$

Eşitsizlik (3.9)'da yer alan M_1 , R_j 'den büyük pozitif bir sayıyı temsil etmektedir. Eğer kullanıcı i bağlantı alanı içerisinde ise u_i 1 değerini, aksi takdirde 0 değerini almaktadır.

İHABİ'nin yatay konumu, koordinat düzleminde belirli bir aralık içinde olmalıdır. Maksimum ve minimum sınır değerleri sırasıyla x_u/x_l ve y_u/y_l ile ifade edilmektedir. Eşitsizlik (3.10) düzlemsel sınır limiti tanımlanmıştır.

$$x_l \leq x_{d_j} \leq x_u, y_l \leq y_{d_j} \leq y_u \quad (3.10)$$

Eşitsizlik (3.11) sayesinde her bir kullanıcının en fazla bir tane İHABİ tarafından kapsanacağı kısıtı sağlanmaktadır.

$$\sum_{j \in D} u_{i,j} \leq 1, \forall_i \in U \quad (3.11)$$

Birden fazla İHABİ'nin konumlandırma amaç fonksiyonu maksimum sayıda kullanıcıyı kapsayacak şekilde yatay düzlem koordinatlarını bulmaktır. Optimizasyon amaç fonksiyonu aşağıdaki gibi ifade edilmiştir.

$$\underset{x_{d_j}, y_{d_j}, u_{i,j}}{\text{maximize}} \sum_{j \in D} \sum_{i \in U} u_{i,j} \quad (3.12)$$

İHABİ sistem modelinde yer alan doğrusal olmayan fonksiyonlardan dolayı optimizasyon modeli dolaylı olarak doğrusal değildir. Ek olarak optimizasyon modelinde ikili değişken de tanımlanmıştır. Bu yüzden tanımlanan optimizasyon modeli KTDOP sınıfına girmektedir.



4. İHABİ KONUMLANDIRMA ANALİZ SONUÇLARI

Bu bölümde, Bölüm 3.3'te tanımlanan optimizasyon modeline alternatif olarak kullanılabilen ML modellerinin kullanımı açıklanmıştır. Kullanılan ML modelleriyle elde edilen kapsanan kullanıcı sayısı sonuçları, optimizasyon modeli sonuçlarıyla kıyaslanmıştır.

4.1. Veri Setinin Hazırlanması

ML modellerinde kullanılacak veri setlerinin hazırlanmasında Bölüm 3.3'te tanımlanan optimizasyon modeli ve Tablo 4.1'de belirtilen parametreler kullanılmıştır.

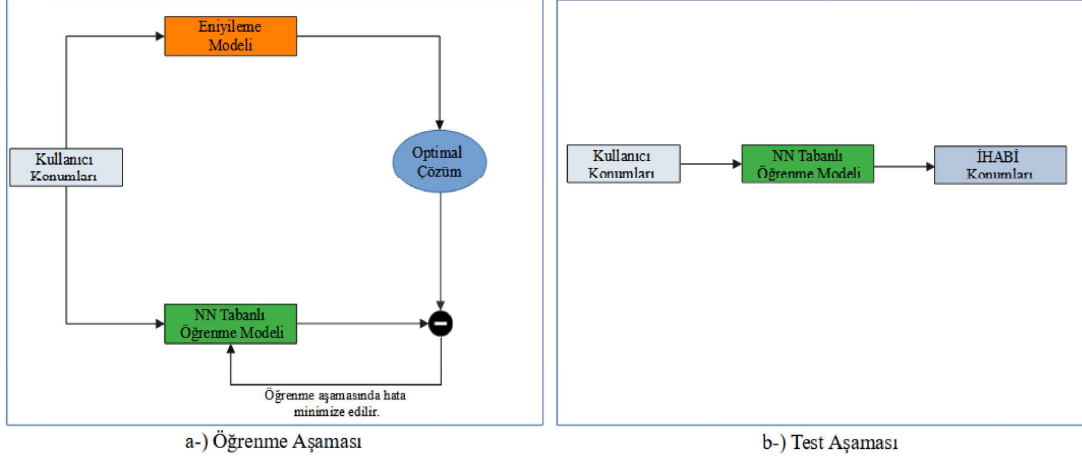
Tablo 4.1: İHABİ optimizasyonunda kullanılan simülasyon parametreleri.

Parametre	Değer
İHABİ Sayısı	2
Kullanıcı Sayısı	30
Servis Kalite İsteri (QoS)	107 dB
Sinyal Taşıyıcı Frekansı (f_c)	2.5 Ghz
Yükseklik	1140 m
$\alpha, \beta, \eta_{LOS}, \eta_{NLOS}$	12.08, 0.11, 1.6, 23
$(x_l, x_u), (y_l, y_u)$	(-2, +2), (-2, +2) (km)

Optimizasyon modelinin çalıştırılmasında MATLAB® kullanılmıştır ve çözücü olarak MOSEK seçilmiştir. Veri seti için 90000 adet çözüm sonucu elde edilmiştir. Her bir çözüm sonucu 100 adet simülasyon sonucunun ortalaması ile elde edilmiştir. Kullanıcı konumları ise altıgen bir alan içerisinde alt sınırı 0, üst sınırı 2000 olan düzgün rastgele dağılıma göre atanmıştır.

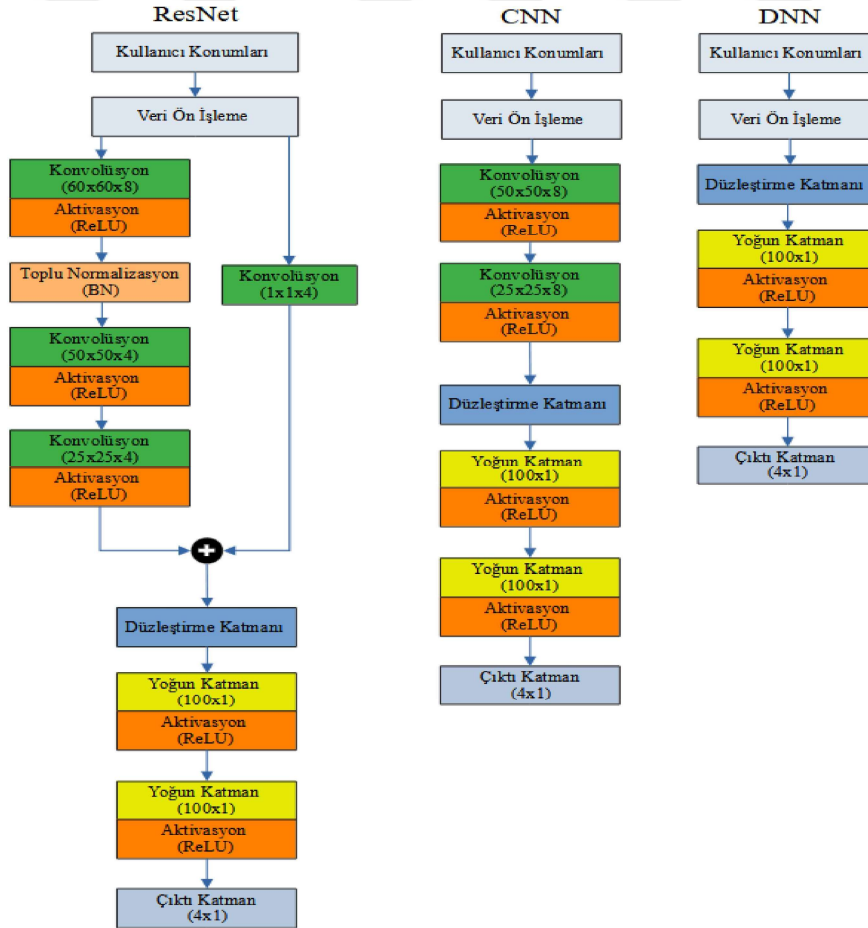
4.2. NN Tabanlı Öğrenme Modeli

Tez çalışması kapsamında, İHABİ konumlandırma problemini çözmek için Şekil 4.1'de yer alan NN tabanlı yaklaşım uygulanmıştır. Bu yaklaşımda amaç, optimizasyon verilerini kullanarak bir NN modelini eğitmektir. Daha sonra eğitilmiş bu NN modelini kullanarak sadece kullanıcı konumlarıyla İHABİ konumlarını tespit etmektir.



Şekil 4.1: Konumlandırma problemi NN yaklaşımı

Önerilen bu yöntemde, kullanılacak NN modellerinin mimarisi Şekil 4.2’de yer almaktadır.



Şekil 4.2: Oluşturulan NN modelleri (ResNet, CNN, DNN)

Kullanıcı konumlarını karşılıklı değiştirdiğimizde elde ettiğimiz İHABİ konumlarının farklı geldiği gözlemlenmiştir. Yani kullanıcı 1’in konum bilgileri ile kullanıcı 20’nin

konum bilgileri karşılıklı olarak değiştirildiğinde sistemde yoğunluk olarak bir değişiklik olmamasına rağmen İHABİ konumunun değiştiği gözlemlenmiştir. Bu durumun önüne geçmek için Şekil 4.2’de gösterildiği gibi her bir modele kullanıcı konumları girdi olarak direkt verilmeyip, ön bir işlemde geçmiştir. Uygulanan bu ön işlemde kullanıcıların bulunduğu uygulama alanı 40m x 40m’lik birim alanlara bölünüp, birim alan içerisindeki kullanıcı sayısı hesaplanmıştır. Hesaplanan kullanıcı sayılarıyla 2 boyutlu bir matris oluşturulmuş.

Oluşturulan modellerin eğitilmesinde ve test aşamasında kullanılacak olan veriler optimizasyon modeli kullanılarak elde edilmiştir. Elde edilen bu verilerin %75’i eğitim aşamasında %25’i ise test aşamasında kullanılmıştır. Ek olarak K-Means algoritmasının konumlandırma performansı da tez kapsamında incelenmiştir.

4.3. Konumlandırma Performans Sonuçları

NN tabanlı öğrenme modelleri oluşturulup simülasyonlarının yapılması için kullanılan yazılım araçları ve konfigürasyon bilgileri Tablo 4.2’de verilmiştir.

Tablo 4.2: Yazılım ve konfigürasyon bilgileri.

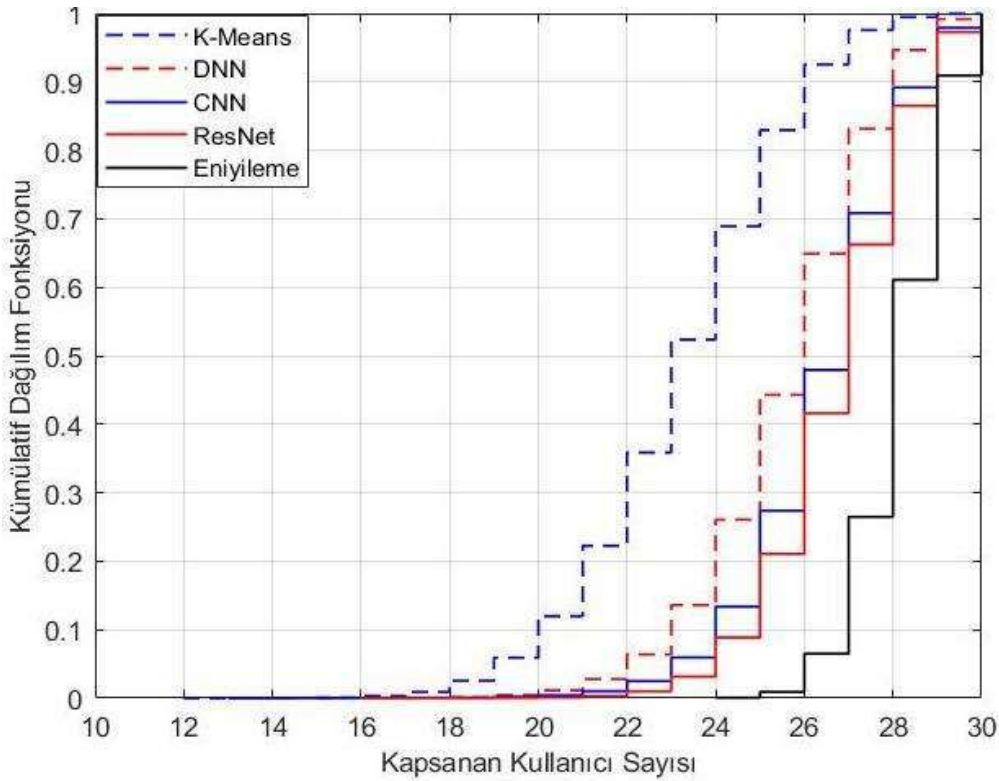
İsim	Versiyon	Açıklama
Python	3.6.9	Programlama dili
Keras	2.4.3	Makine öğrenme uygulama programlama arayüzü (API)
Tensorflow	2.4.1	Makine öğrenimi modelleri geliştirmenize ve eğitilmesinde kullanılan kütüphane.
Numpy	1.19.5	Python hesaplama kütüphanesi

Sırasıyla ResNet, CNN, DNN modelleri ve K-Means algoritması çalıştırılmıştır. Performans metriği olarak kapsanan kullanıcı sayısı baz alınmıştır ve optimizasyon modelinin sonuçları ile kıyaslanmıştır.

Tablo 4.3: Kapsanan kullanıcı sayısı dağılım bilgileri.


Metot	Minimum	Maksimum	Ortalama	Standart Sapma
K-Means	12	30	23.263	2.333
DNN	15	30	25.632	1.965
CNN	13	30	26.431	1.803
ResNet	16	30	26.783	1.663
Optimum	24	30	28.198	1.073

Her bir metotta kapsanan kullanıcı sayılarının durumunu incelemek için Tablo 4.3'te sonuç dağılım bilgileri verilmiştir. Şekil 4.3'te ise kapsanan kullanıcı sayısının kümülatif dağılım grafiği gösterilmiştir. Tablo 4.3'te ResNet'in diğer ML metotlarına göre daha iyi sonuç verdiği gözlenmiştir. Ek olarak DNN'nin minimum kapsadığı kullanıcı sayısı CNN'e göre daha büyük olmasına rağmen CNN'nin standart sapma ve ortalama bakımından daha üstün olduğu belirlenmiştir. Bu yüzden ResNet'ten sonra en başarılı metot CNN olmaktadır. Kapsanan kullanıcı sayısı bakımından en düşük performansı ise K-Means algoritması vermiştir.



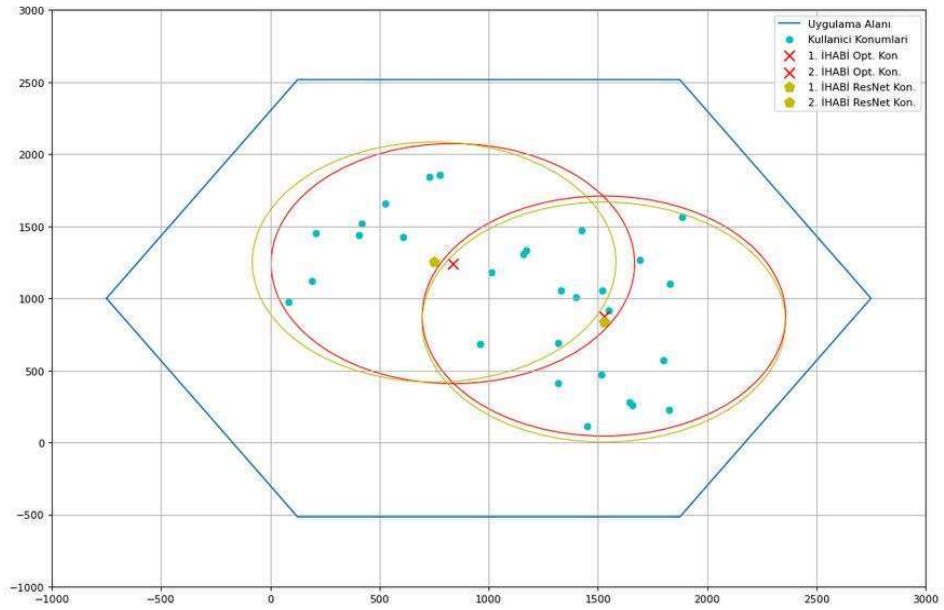
Şekil 4.3: Kapsanan kullanıcı sayısı için kümülatif dağılım fonksiyon grafiği

Şekil 4.3'te verilen kümülatif dağılım grafiği incelendiğinde Tablo 4.3'teki çıkarımlarımıza ek olarak optimizasyon modeline en yakın sonucu ResNet'in verdiği gözlemlenmiştir. Şekil 4.4' de ise ResNet ve optimizasyon modeli için test verilerindeki, kapsanan kullanıcı sayısının yüzdelik grafiği verilmiştir.



Şekil 4.4: Kapsanan kullanıcı sayısının bütün durumlardaki oranı

Şekil 4.4 incelendiğinde ResNet modelinde kapsanan kullanıcı sayısının 24'ten küçük olduğu durumların bütün test verilerine oranı maksimum %5 olmaktadır. ResNet ve optimizasyon modeli ile elde edilen konum bilgileri ve kapsama alanı örnek bir test verisi için Şekil 4.5'te gösterilmiştir ve yatay konumların ortalama farkı ise 157 metre olarak hesaplanmıştır.



Şekil 4.5: ResNet ve optimal konum için kapsama alanları




5. İSABİ SİSTEM MİMARİSİ VE ENİYİLEME MODELİ

Bu bölümde İSABİ için uygulamaya özel sistem ve optimizasyon modelleri sırasıyla açıklanmıştır.

5.1. İSABİ Sistem Modeli

SA'lar topladıkları verileri karadaki baz istasyonuna veya veri işleme merkezine iletirken veri kayıpları yaşanmaktadır. Oluşan bu kayıpları en aza indirebilmek için İSABİ kullanımı alternatif bir çözümdür. Sistem modeli, Şekil 5.1'de gösterildiği gibi SA'dan İSABİ'ye bağlantı kuracak şekilde oluşturulmuştur.



Şekil 5.1: Tek İSABİ yerleştirilmiş sistem modeli [29]

5.2. Sualtı Kanal Modeli

Sualtı akustik haberleşmede alıcı ve verici arasında sinyal güç kaybı yaşanmaktadır. Sualtındaki sinyal güç kaybı bütünsel olarak değerlendirilir ve sualtı yol kaybı ile ortamsal gürültünün toplamından hesaplanmaktadır. Sualtı yol kaybı $(A(l,f))$, [30]'da belirtildiği gibi Eşitlik (5.1)'de yer alan denklem ile hesaplanmak

$$A(l,f)[dB] = k \cdot 10 \log_{10}(1000 \times l) + l \cdot 10 \log_{10} a(f) [dB/km] \quad (5.1)$$

Eşitlik (5.1)'de, l iletim mesafesini, f akustik sinyal çalışma frekansını, $a(f)$ emilim kaybını, k ise ortamdaki yayılma katsayısını ifade etmektedir. Yayılma katsayısı sinyalin ortamdaki yayılım geometrisini ifade etmektedir. [21]'de küresel yayılım, $k = 2$, silindirik yayılım, $k = 1$, ve pratik yayılım, $k = 1,5$, olarak belirtilmiştir. Oluşturduğumuz sistem mimarisinde yayılım katsayısı 1,5 olarak atanmıştır.

Emilim kaybı temelde deniz suyunun akışkanlığa karşı direncinden oluşmaktadır. Bu direnç akustik sinyalin çalışma frekansı ile orantılıdır. Akustik sinyalin çalışma frekansına göre William H. Thorp tarafından formüle edilmiş iki adet emilim kaybı formülü bulunmaktadır. Kilohertz ve üstü yüksek çalışma frekansı için emilim kaybı [21]'de aşağıdaki formül ile ifade edilmiştir:

$$a(f)[dB/km] = \frac{0.11 f^2}{1+f^2} + \frac{44 f^2}{4100+f^2} + 2.75 \cdot 10^{-4} f^2 + 0.003 \quad (5.2)$$

Denizde oluşan ortam gürültüsü dört temel kaynaktan oluşmaktadır. Bunlar sırasıyla aşağıdaki gibidir:

1. Türbülans gürültüsü ($N_t(f)$): Denizde meydana gelen düzensiz su akıntısından kaynaklı bir gürültüdür.
2. Aktarım gürültüsü ($N_s(f)$): Deniz trafiğinin oluşturmuş olduğu bir gürültüdür.
3. Dalga gürültüsü ($N_w(f)$): Rüzgâr gücünden dolayı su yüzeyinde dalgalar oluşmaktadır. Oluşan dalgalar rüzgâr gücüne bağlı olarak farklı dalga boylarına sahip olabilmektedir. Bu oluşan dalgalar ortama gürültü olarak eklenmektedir.
4. Termal gürültü ($N_{th}(f)$): Deniz suyundaki yoğunluk, sıcaklık ve ısıya bağlı olarak moleküler seviyede değişiklik gösterebilmektedir. Bu değişiklik, algılayıcılardaki hassasiyeti etkilemektedir ve termal gürültü yaratmaktadır.

Her bir gürültü kaynağı [20]'de ifade edildiği gibi desibel cinsinde aşağıda verilen eşitlikler ile hesaplanmaktadır.

$$10 \log_{10} N_t(f) = 17 - 30 \log_{10}(f) \quad (5.3)$$

$$10 \log_{10} N_s(f) = 40 + 20(s - 0.5) + 26 \log_{10}(f) - 60 \log_{10}(f + 0.03) \quad (5.4)$$

$$10 \log_{10} N_w(f) = 50 + 7.5 w^{1/2} + 20 \log_{10}(f) - 40 \log_{10}(f + 0.3) \quad (5.5)$$

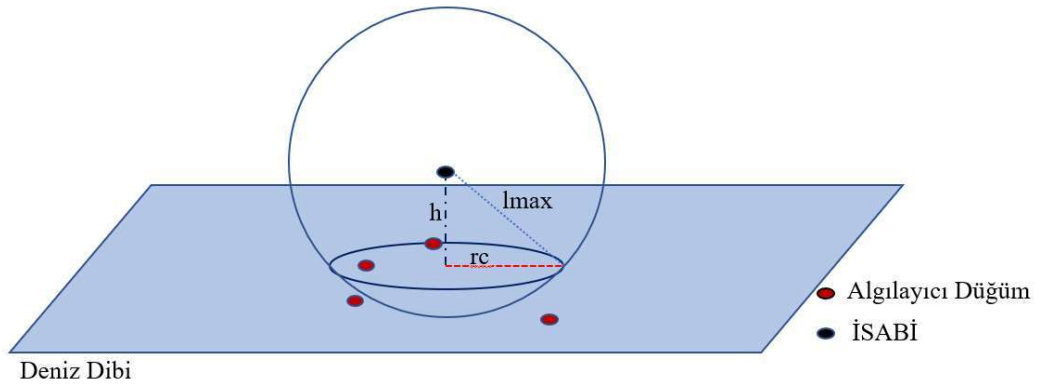
$$10 \log_{10} N_{th}(f) = -15 + 20 \log_{10}(f) \quad (5.6)$$

Eşitlik (5.4)'de, s aktarım katsayısını belirtmektedir. Aktarım katsayısı, 0 ile 1 aralığında bir değer almaktadır [21] ve oluşturduğumuz sistem modelinde $s = 0,5$ olarak alınmıştır. Eşitlik (5.5)'de, w rüzgâr hızını ifade etmektedir. Sistem modelinde rüzgâr hızı 0 m/sn olarak alınmıştır.

Ortam gürültüsü modellenirken, Eşitlik (5.7)'deki gibi denizde meydana gelen gürültü kaynaklarının toplamıyla ifade edilmektedir [30].

$$N(f) = N_t(f) + N_s(f) + N_w(f) + N_{th}(f) \quad (5.7)$$

Veri iletim mesafesi ortam gürültüsü ve yol kaybından dolayı sınırlıdır. Bunun için Şekil 5.2'de gösterildiği gibi dairesel bir “bağlantı alanı” tanımlanmıştır. SA bağlantı dairesinin içerisinde yer alıyorsa, İSABİ ile başarılı bir bağlantı kurmuş olur.



Şekil 5.2: 3 Boyutlu bağlantı alanı gösterimi [29].

Şekil 5.2'de yer alan, r_c dairesel yarıçapı, h SA'nın deniz yüzeyine olan mesafesini, l_{max} ise maksimum veri iletim mesafesini belirtmektedir. Dairesel yarıçap, $r_c = \sqrt{l_{max}^2 + h^2}$ ile hesaplanmaktadır.

İSABİ ve SA arasında veri iletiminin başarılı bir şekilde gerçekleşmesi için, alınan sinyalin sinyal gürültü oranı (SGO) belirli bir eşik değerinden büyük veya eşit olmalıdır. Alınan sinyalin SGO'su aşağıdaki eşitlikle hesaplanmaktadır [31]:

$$SGO[dB] = P_t - A(l, f) - N(f) \quad (5.8)$$

Maksimum veri iletim mesafesi Eşitlik (5.1), Eşitlik (5.2) ve Eşitlik (5.8) kullanarak aşağıda ifade edilen Eşitsizlik (5.9) ile belirlenmektedir:

$$l_{max} \times a(f) + k \cdot 10 \log_{10}(1000 \times l_{max}) \leq P_t - P_{th} - N(f) \quad (5.9)$$

Eşitsizlik (5.9)'da, P_{th} eşik değerini, P_t akustik sinyalin iletim gücünü ifade etmektedir. Eşitsizlik (5.9)'u sağlayan en büyük l_{max} değeri ise maksimum veri iletim mesafesini vermektedir. Bir SAA sistemi tasarımında, ilk önce iletim gücü, eşik değeri çalışma frekansı ve SA su derinliği belirlenmelidir. Bu belirlenen değerler kullanılarak l_{max} ve r_c hesaplanır.

5.3. İSABİ Yerleşim Optimizasyon Modeli

Bu alt başlıkta, ilk önce tek bir İSABİ için konumlandırma probleminin optimizasyon modeli açıklanacaktır. Daha sonra birden fazla İSABİ yerleşimi için optimizasyon modeli güncellenecektir. Her iki durumda da optimizasyon modelinin amaç fonksiyonu maksimum sayıda SA'yı kapsayacak şekilde İSABİ'nin yatay konumunu belirlemektir.

Sistem modelinde her bir SA altıgen bir alanda Gaussian dağılımı ile rastgele atanmış konumlara yerleştirilmiştir. SA kümesi $S = \{1,2,3...n\}$ olarak tanımlanmıştır ve i indeksi her bir algılayıcıyı temsil etmek için kullanılmıştır. Ortamda bulunan SA sayısı n ile belirtilmiştir. Her bir SA'nın yatay konumu (x_{a_i}, y_{a_i}) ile tanımlanmıştır. İSABİ'nin yatay konumu ise (x_b, y_b) ile ifade edilmiştir. İSABİ ile i ' ninci SA arasındaki yatay mesafe Eşitlik (5.10) ile hesaplanmıştır.

$$r_i = \sqrt{(x_b - x_{a_i})^2 + (y_b - y_{a_i})^2} \quad (5.10)$$

Her bir SA'nın İSABİ tarafından kapsandığını durumunu için $s_i \in \{0,1\}$ ikili değişkeni tanımlanmıştır. Eğer i ' ninci SA *bağlantı alanı* içerisinde ise İSABİ tarafından kapsanmıştır ve $s_i=1$ olmaktadır. Aksi takdirde i ' ninci SA *bağlantı alanı* içerisinde değildir ve $s_i=0$ olmaktadır. Diğer bir ifade ile r_i, r_c 'den küçük veya eşitse SA ile İSABİ arasında bir bağlantı kurulmaktadır.

İSABİ'nin yatay konumu, koordinat düzleminde belirli bir aralık içinde olmalıdır. Maksimum ve minimum sınır değerleri sırasıyla x_u/x_l ve y_u/y_l ile ifade edilmektedir. Yatay konum kısıtı Eşitsizlik (5.11)'de ifade edilmiştir.

$$x_l \leq x_b \leq x_u, y_l \leq y_b \leq y_u \quad (5.11)$$

SA'nın bağlantı alanı içerisindeki durumu Eşitsizlik (5.12)'de belirtilmiştir.

$$r_i^2 \leq r_c^2 + M_1 (1 - s_i) \quad \forall_i \in S \quad (5.12)$$

Eşitsizlik (5.12)'deki M_1 pozitif büyük bir sayıyı temsil etmektedir. Eğer i 'ninci SA bağlantı alanı içinde ise s_i 1 değerini alır, aksi takdirde 0 değerini alır.

Tek İSABİ için konumlandırma optimizasyon modelinin amaç fonksiyonu aşağıdaki şekilde ifade edilmiştir [29]:

$$\underset{x_b, y_b, s_i}{\text{maximize}} \sum_{i \in S} s_i \quad (5.13)$$

Birden fazla İSABİ için optimizasyon modelini ifade ederken ikinci bir j indeksi ve İSABİ kümesi $B = \{1, 2, 3 \dots m\}$ tanımlanmalıdır. Konumlandırmada kullanılacak İSABİ sayısı m ile ifade edilmiştir. İkili değişken $s_{i,j}$ olarak güncellenir. Her bir İSABİ'nin konum bilgisi ise (x_{b_j}, y_{b_j}) ile ifade edilir ve yatay konum kısıtı $x_l \leq x_{b_j} \leq x_u, y_l \leq y_{b_j} \leq y_u$ olacak şekilde güncellenir.

SA ile İSABİ arasındaki yatay mesafe, $r_{i,j}$, her bir ikili için hesaplanmaz. Yani her i 'ninci SA'nın, j 'ninci İSABİ'ye olan yatay mesafesi, $\sqrt{(x_{b_j} - x_{a_i})^2 + (y_{b_j} - y_{a_i})^2}$ ile hesaplanmaktadır. Bu sayede Eşitsizlik (5.12) aşağıdaki şekilde güncellenir [29]:

$$r_{i,j}^2 \leq r_c^2 + M_1 (1 - s_{i,j}), \quad \forall_i \in S \quad (5.14)$$

Eşitsizlik (5.15) ile her bir SA'nın sadece bir tane İSABİ tarafından kapsanacağı kısıtı oluşturulmuştur.

$$\sum_{j \in B} s_{i,j} \leq 1, \quad \forall_i \in S \quad (5.15)$$

Belirtilen güncellemelere ek, birden fazla İSABİ'nin konumlandırma amaç fonksiyonu da Denklem (5.16)'da olduğu gibi ifade edilmektedir.

$$\underset{x_{b_j}, y_{b_j}, s_{i,j}}{\text{maximize}} \sum_{j \in B} \sum_{i \in S} s_{i,j} \quad (5.16)$$

İSABİ sistem modelinde yer alan doğrusal olmayan fonksiyonlardan dolayı optimizasyon modeli dolaylı olarak doğrusal değildir. Ek olarak optimizasyon modelinde ikili değişken de tanımlanmıştır. Bu yüzden her iki durumda yerleşim problemi için oluşturulan optimizasyon modelleri KTDOP sınıfına girmektedir.



6. İSABİ KONUMLANDIRMA ANALİZ SONUÇLARI

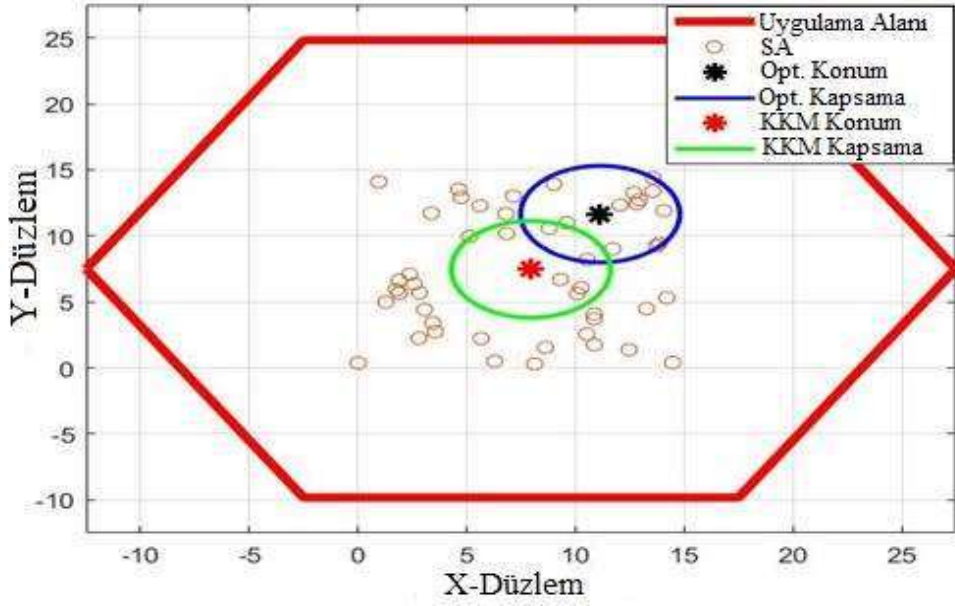
Bu başlık altında Bölüm 5’te tanıtilan optimizasyon modellerinin performansı sayısal olarak incelenmiştir. Her iki optimizasyon modeli için farklı iletim gücünün ve kullanılan SA sayısının İSABİ kapsama performansına olan etkisi incelenmiştir. Tek İSABİ optimizasyon modelinin sonuçlarını kıyaslamak için SA konumlarının ortalaması alınarak Kıyaslama Konum Merkezi (ing. *Benchmark Location*, KKM) hesaplanmıştır [29]. Birden fazla İSABİ optimizasyon modelinin sonuçları ise K-Means algoritması ile elde edilen Merkez Konum Noktaları (MKN) ile kıyaslanmıştır. Her iki optimizasyon modeli için MATLAB® kullanılmıştır ve çözücü olarak MOSEK seçilmiştir.

Tek İSABİ için sistem parametreleri olarak [29]’da belirtilen değerler kullanılmıştır ve bu değerler Tablo 6.1’de yer almaktadır. Sonuçlar elde edilirken 100 adet simülasyon çözümünün ortalaması alınmıştır. SA’lar altıgen bir alanda ortalaması 0, varyansı 15 olan Gaussian dağılımı ile belirlenen konumlara yerleştirilmiştir.


Tablo 6.1: Tek İSABİ optimizasyonunda kullanılan simülasyon parametreleri.

Parametre	Değer
SA Sayısı	30, 40, 50
İletim Gücü (P_t)	(100, 102.5, 105) (dB)
Eşik Güç (P_{th})	10 dB
(x_l, x_u)	(-15, +15) (km)
(y_l, y_u)	(-15, +15) (km)
Derinlik (h)	1 km
Çalışma Frekansı(f)	8 kHz
Aktarım Katsayısı (s)	0.5
Rüzgâr Hızı (w)	0 m/sn
Yayılm Katsayısı (k)	1.5
Monte Carlo Simülasyon	100

KKM’nin konum bilgisi, SA konumlarının ortalaması alınarak hesaplanmaktadır. Bu yüzden KKM’nin kapsama kapasitesi, optimum sonuç kadar efektif değildir. KKM ile optimum konum arasındaki kapsama farkı %73’e kadar çıkmaktadır [29]. İletim gücü 100 dB ve kullanılan SA sayısı 50 iken hesaplanan KKM ve optimum İSABİ konumlarındaki kapsama kapasitesi farkı Şekil 6.1’de gösterilmiştir.



Şekil 6.1: KKM ve optimum konum için kapsama alanları [29]




Şekil 6.2: Farklı iletim güç değerleri ve SA sayısı için kapsama kapasitesi [29].

Kullanılan SA sayısının ve iletim gücünün optimum çözüm üzerindeki etkisini incelemek için Şekil 6.2'deki grafik oluşturulmuştur. Şekil 6.2 incelendiğinde; iletim gücü artışının, optimum konumda bulunan İSABİ'nin kapsama kapasitesi üzerinde daha etkili olduğu gözlemlenmiştir. Eşitsizlik (5.9) kullanılarak belirli bir eşik değeri

için, iletim gücü arttıkça hesaplanan maksimum iletim mesafesi ve kapsama yarıçapı artmaktadır. Bu sayede kapsama kapasitesi, iletim gücünden dolayı olarak etkilenmektedir [29].

Kullanılan farklı iletim güç değerleri için KKM ve optimum konumlardaki kapsama oranları Şekil 6.3'te verilmiştir. Kapsama oranı, kapsanan SA sayısının toplam SA sayısına olan yüzdelik oranı ile hesaplanmıştır. İletim gücü 100 dB iken, optimum konumun kapsama oranı KKM'nin kapsama oranından %35 daha yüksektir. Fakat iletim gücü %5 artırıldığında bu farkın %14'e düştüğü gözlemlenmiştir [29]. Bu sayede iletim gücü arttıkça KKM'nin kapsama kapasitesi, optimum konumun kapsama kapasitesine yakınsamaktadır. Fakat yüksek iletim gücünde çalışmak enerji verimliliği açısından her zaman uygulanabilir bir yaklaşım olmayabilir [29].




Şekil 6.3: 50 SA'da farklı iletim güç değerleri için kapsama kapasitesi [29]

Birden fazla İSABİ'li durum için konumlandırma analizi yapılırken Tablo 6.1'deki parametrelere ek olarak İSABİ sayısı da değişken olarak atanmıştır. Kullanılan İSABİ sayısı 2 ve 4 olacak şekilde optimizasyon modeli ve K-Means algoritması kullanılarak elde edilen lokasyon sonuçlarından kapsama kapasitesi performans analizi yapılmıştır.


MKN'nin kapsama kapasitesi 2 ve 4 İSABİ'li durum için optimum çözüm ile kıyaslanmıştır. 2 İSABİ'li durumda, MKN'nin kapsama oranı ile optimum konumdaki kapsama oranı arasındaki farkın için %17,9 olduğu hesaplanmıştır. 4 İSABİ'li

durumda ise bu farkın azaldığı ve %7,5 olduğu gözlemlenmiştir. 4 İSABİ'li durumda iletim gücü %5 artırıldığında optimum konum ile aynı kapsama kapasitesine sahip olduğu gözlemlenmiştir. Fakat bu durumun en önemli sebebi 105 dB'de hesaplanan kapsama alanının, uygulama alanını tamamen kaplamaya başlamasından kaynaklıdır. Kullanılan İSABİ sayısı 2 ve 4 iken, MKN ile optimum konumdaki İSABİ'lerin kapsama oranları Şekil 6.4'te gösterilmiştir.




Şekil 6.4: 30 SA'da farklı iletim güç değerleri için kapsama kapasitesi

Şekil 6.5'te iletim güç değeri artışının, MKN kapsama performansındaki etkisi gösterilmiştir. İletim gücünün artışının, 4 İSABİ'li durumda kapsanan SA sayısını daha çok arttırdığı gözlemlenmiştir. 40 SA'lı bir sualtı ağda iletim gücü %2,5 artırıldığında 4 İSABİ'li durumda kapsanan SA sayısı %25 artarken, 2 İSABİ'li durum için bu artışın %15 olduğu hesaplanmıştır. Şekil 6.5'te kullanılan farklı SA sayısı ve iletim güç değerleri için MKN konumundaki İSABİ'lerin kapsadığı SA sayısı verilmiştir.



Şekil 6.5: 2 İSABİ'li ve 4 İSABİ'li durumda MKN'nin kapsama kapasitesi

Şekil 6.6'da ise 2 İSABİ için MKN ve optimum konumda yerleşimi gösterilmiştir. MKN ile optimum konum arasındaki Öklid mesafe farkı sırasıyla 0,93 km ve 1,07 km olarak hesaplanmıştır. Ek olarak optimum konumda kapsanan SA sayısı ise MKN'de kapsanan SA sayısından %11 daha büyüktür.



Şekil 6.6: MKN ve optimum konum için kapsama alanı (Pt=100dB, SA=40)



7. SONUÇ

Bu tez çalışmasında insansız araçların baz istasyonu olarak kullanımını 2 temel başlık altında araştırılmıştır ve mevcut bir ağda yatay konumun belirlenmesinde kullanılacak alternatif yaklaşımlar üzerinde durulmuştur.

Çalışmanın ilk kısmında İHABİ konumlandırma probleminin literatürde nasıl ele alındığı incelenmiştir ve kullanılacak hava kara modeli açıklanmıştır. Mevcut optimizasyon yaklaşımlarında İHABİ yatay konumunun belirlenmesi için oluşturulmuş modellerin çözüm süresi uzun sürmektedir [15]. Bu yüzden alternatif yaklaşım olarak makine öğrenimi metotlarının kullanımı incelenmiştir. Makine öğrenimi metotlarında kullanılacak veri setlerinin oluşturulması için çoklu İHABİ konumlandırma optimizasyon modeli oluşturulmuştur. Daha sonra 2 adet İHABİ'nin konumları ResNet, CNN, DNN ve K-Means algoritması kullanılarak belirlenmiştir. Elde edilen sonuçlar incelendiğinde ResNet metodunun optimizasyon modeline en yakın sonucu verdiği ve ortalamada %92 oranında yakınsadığı gözlemlenmiştir.

İHABİ konumlandırma probleminde kullanıcı konumlarının statik olduğu varsayılmıştır. Fakat önceden eğitilmiş bir ResNet ağı aynı zamanda dinamik değişen kullanıcı konumlarına anlık sonuç verebilme kabiliyetine sahiptir. Bu sayede gelecekte, kullanıcı konumlarının dinamik olarak değiştiği bir senaryoda önceden eğitilmiş bir ResNet ağının başarımı mevcut diğer çalışmalar ile kıyaslanabilir ve İHABİ'nin enerji tüketimi de sistem parametresi olarak eklenip ResNet'in enerji verimliliği üzerindeki başarımı incelenebilir.

Çalışmanın ikinci kısmında İSABİ konumlandırma probleminin üzerinde durulmuştur. İlk önce literatürde yapılan çalışmalar incelenmiştir ve sualtı kanal modeli tanımlanmıştır. Daha sonra bir ve birden fazla İSABİ konumlandırılması için KTDOP optimizasyon modeli tanımlanmıştır. Optimizasyon modelinin sonuçları tek İSABİ'li durumda KKM ile çoklu İSABİ durumunda ise MKN ile kıyaslanmıştır. Her iki kıyaslama durumunda da iletim gücü artırıldıkça, optimum sonuç ile olan fark azalmaktadır. Fakat iletim gücünün büyük bir değer seçilmesi her zaman uygulanabilir bir yöntem değildir.

Gelecekte literatür çalışması olarak; İSABİ konumlandırma problemi için mevcut optimizasyon modeline SA'nın enerji tüketim durumu eklenebilir ve KTDOP optimizasyon yaklaşımına alternatif olarak üst sezgisel metotlarda incelenebilir. Ayrıca bu çalışmada SA konumlarının statik olduğu varsayılmıştır. Bu yüzden SA konumlarının sürekli değiştiği bir senaryo için ML tabanlı hibrit konumlandırma modelleri oluşturulup kapsama kapasitesinin artırılması ve tüketilen enerjinin minimize edilmesi hakkında çalışmalar yapılabilir.



KAYNAKLAR

- [1] **Bor-Yaliniz, I., El-Keyi., and Yanikomeroğlu, H.,** (2016). Efficient 3-D placement of an aerial base station in next generation cellular networks. In: IEEE Int. Conf. Commun. (ICC), pp. 1-5.
- [2] **Rohde, S., and Wietfeld, C.,** (2012). Interference aware positioning of aerial relays for cell overload and outage compensation. In: IEEE Vehicular Technology Conference, pp. 1-5.
- [3] **Al-Hourani, A., Kandeepan, S., and Jamalipour, A.,** (2014). Modeling air-to-ground path loss for low altitude platforms in urban environments. In: IEEE Global Communications Conference, pp. 2898-2904.
- [4] **Al-Hourani, A. Kandeepan, S., and Lardner, S.,** (2014). Optimal LAP altitude for maximum coverage. In: IEEE Wireless Commun. Lett., vol. 3, no. 6, pp. 569–572.
- [5] **Mozaffari, M., Saad, W., Bennis, M., and Debbah, M.,** (2015). Drone Small Cells in the Clouds: Design, Deployment and Performance Analysis. In: IEEE Global Communications Conference (GLOBECOM), pp.1-6.
- [6] **Kalantari, E., Yanikomeroğlu, H., and Yongacoglu, A.,** (2016). On the Number and 3D Placement of Drone Base Stations in Wireless Cellular Networks. In: IEEE 84th Vehicular Technology Conference, pp. 1-6.
- [7] **Alzenad, M., El-Keyi, A., Lagum, F., and Yanikomeroğlu, H.,** (2017). 3-D placement of an unmanned aerial vehicle base station (UAV-BS) for energy-efficient maximal coverage. In: IEEE Wireless Communications Letters, vol. 6, no. 4, pp. 434-437.
- [8] **Alzenad, M., El-Keyi, A., and Yanikomeroğlu, H.,** (2018). 3-D Placement of an Unmanned Aerial Vehicle Base Station for Maximum Coverage of Users With Different QoS Requirements. In: IEEE Wireless Communications Letters, vol. 7, no 1, pp. 38–41.
- [9] **Karaman, S. S., Akarsu, A., and Girici, T.** (2019). Use of Particle Filtering in RSSI-Based Localization by Drone Base Stations. In: International Symposium on Networks, Computers and Communications (ISNCC).
- [10] **Ileri, S. C., Aslan, S., and Demirci, S.,** (2020). Finding optimum location for a mobile aerial base station with harmony search algorithm. In: 5th International Conference on Computer Science and Engineering (UBMK).
- [11] **Krijestorac, E., Hanna, S., and Cabric, D.,** (2019). UAV access point placement for connectivity to a user with unknown location using deep RL. In: IEEE Globecom Workshops.
- [12] **Abeywickrama, H. V., He, Y., Dutkiewicz, E., Jayawickrama, B. A., and Mueck, M.** (2020). A reinforcement learning approach for fair user coverage using UAV mounted base stations under energy constraints. In: IEEE Open Journal of Vehicular Technology, vol.1, pp. 67-81.
- [13] **Liu, C. H., Ma, X., Gao, X., and Tang, J.,** (2019). Distributed energy-efficient multi-UAV navigation for long-term communication coverage by deep reinforcement learning. In: IEEE Transactions on Mobile Computing, vol. 19, no. 6, pp.1274–1285.

- [14] **Sun, H., Chen, X., Shi, Q., Hong, M., Fu, X., and Sidiropoulos, N. D.,** (2018). Learning to optimize: Training deep neural network for interface management. In: IEEE Transactions on signal processing, vol. 66, no.20, pp. 5438-5453.
- [15] **Duong, T. Q., Nguyen, L. D., Tuan, H. D., and Hanzo, L.** (2019). Learning-aided realtime performance optimisation of cognitive UAV-assisted disaster communication. In: IEEE Global Communications Conference (GLOBECOM), pp.1-6.
- [16] **Akarsu, A., and Girici, T.** (2018). Fairness aware multiple drone base station deployment. In: IET Communications, pp. 425-431.
- [17] **Taghavi, M., and Abouei, J.,** (2019). Two-Dimensional drone base station placement in cellular networks using MINLP model. In: Intl Journal of Electronics and Telecommunications, vol 65, no, 4, pp.701-706.
- [18] **Cicek, C. T., Gultekin, H., Tavli, B., and Yanikomeroglu, H.,** (2019). UAV Base Station Location Optimization for Next Generation Wireless Networks: Overview and Future Research Directions. In: 1st International Conference on Unmanned Vehicle Systems-Oman (UVS), pp. 1–6.
- [19] **Ibrahim, S., Al-Bzoor, M., Liu, J., Ammar, R., Rajasekaran, S., and Cui, J.,** (2013). General optimization framework for surface gateway deployment problem in underwater sensor networks. In: EURASIP J Wirel Commun., pp. 1- 13.
- [20] **Stojanovic, M.,** (2006). On the relationship between capacity and distance in an underwater acoustic communication channel. In: Proc. 1st ACM Int. Workshop Underwater Netw., pp. 41-47.
- [21] **Lucani, D., Stojanovic, M., and Medard, M.,** (2008). On the relationship between transmission power and capacity of an underwater acoustic communication channel. In: OCEANS 2008-MTS/IEEE Kobe Techno-Ocean. IEEE, pp. 1–6.
- [22] **Ibrahim, S., Cui, J.-H., and Ammar, R.** (2007). Surface-level gateway deployment for underwater sensor networks. In: IEEE Military Communications Conference, pp. 1-7.
- [23] **Ibrahim, S., Ammar, R., and Cui, J.,** (2010). Surface gateway placement strategy for maximizing underwater sensor network lifetime. In: Proc. IEEE Symp. on Comput. and Commun., pp. 342–346.
- [24] **Ibrahim, S., Ammar, R., and Cui, J.H.,** (2009). Geometry-assisted gateway deployment for underwater sensor networks. In: IEEE Symp. on Computers and Commun. (ISCC), pp. 932-937.
- [25] **Liu, J., Han, X., Al-Bazoor, M., Cui, J-H, Ammar, R.A., and Rajasekaran, S.,** (2012). PADP: Prediction assisted dynamic surface gateway placement for mobile underwater networks. In: Proc. IEEE Symp. Comput. Commun. (ISCC), pp. 139-144.
- [26] **Xing, F., Yin, H., Ji, X., and Leung, V. C. M.** (2018). An adaptive and energy-efficient algorithm for surface gateway deployment in underwater optical/acoustic hybrid sensor networks. In: IEEE Communications Letters, vol. 22, no. 9, pp. 1810-1813.
- [27] **Al-Bzoor, M., Ammar, R., Cui, J.H., and Rajasekaran, S.** (2014). Coordinated multi-surface gateway redeployment for enhanced performance in underwater sensor networks. In: IEEE Symposium on Computers and Communications (ISCC), pp. 1-6.

- [28] **Yildiz, H. U.** (2019). Utilization of multi-sink architectures for lifetime maximization in underwater sensor networks. In: 2nd IEEE Middle East and North Africa Communications Conference (MENACOMM), pp. 123-127
- [29] **Kahriman, B., Demirtas, A.M, and Tavli, B.,** (2020) Surface gateway placement optimization for underwater sensor networks. In: Telecommunications Forum (TELFOR), Belgrade, Serbia, Nov. 24-25.
- [30] **Yildiz, H. U., Gungor V. C., and Tavli, B.,** (2019). Packet size optimization for lifetime maximization in underwater acoustic sensor networks. In: IEEE Trans. Ind. Inform., vol. 15, no. 2, pp. 719–729.
- [31] **Wang, Q., Dai, H.-N., Wang, Q., Shukla, M. K., and Zhang, W.,** (2020). On connectivity of UAV-assisted data acquisition for underwater internet of things. In: IEEE Internet Things J., vol. 7, no 6, pp. 5371-5385.
- [32] **Palmer, J., Yuen, N., Ore, J.-P., Detweiler, C., and Basha, E.,** (2015). On air to water radio communication between UAVs and water sensor networks. In: Proc. IEEE Int. Conf. Robot. Autom. (ICRA), pp. 5311–5317.
- [33] **Turing, A. M. (1950).** Computing machinery and intelligence. In: MIND, A Quarterly Review of Psychology and Philosophy, no 236 ,pp. 236-433.
- [34] Stanford University, Computer Science, The Intellectual Excitement of Computer Science,
<https://cs.stanford.edu/people/eroberts/courses/soco/projects/neural-networks/History/history1.html> (Erişim tarihi: 25.04.2021).
- [35] **Sze, V., Chen, Y.H., Yang, T.Y., and Emer, J.S.,** (2017). Efficient processing of deep neural networks: A tutorial and survey. In: Proceedings of the IEEE, vol. 105, pp. 2295-2329.
- [36] **Kotsiantis, S.B.,** (2007). Supervised machine learning: A review of classification techniques. In: Informatica, vol. 31, no. 3, pp. 249-268.
- [37] **T. M. Mitchell,** (2006). The discipline of machine learning. Vol. 9, Carnegie Mellon University, School of Computer Science, Machine Learning.
- [38] **Dey, A.,** (2016). Machine learning algorithms: A review. In: International Journal of Computer Science and Information Technologies, vol. 7, pp. 1174-1179.
- [39] **Yadav, A., and Dhingra, S.,** (2016). A review on K-means clustering technique. In: International Journal of Latest Research in Science and Technology, vol. 5, pp. 13-16.
- [40] **Andina, D. et al,** (2007). Neural networks historical review. In: Computational Intelligence, Springer, pp.36-65.
- [41] **Seyfioglu, M.S,** (2017). Deep neural network initialization and training methodologies for radar micro doppler signature classification. Master of science, Electrical and electronics engineering, TOBB University of Economics and Technology.
- [42] **Liu, W., et al,** (2017). A survey of deep neural network architecture and their applications. In: Neurocomputing, Elsevier, pp. 11-26.
- [43] **Uckun, F. A., Ozer, H., Nurbas, E., and Onat, E.,** (2020). Direction finding using convolutional neural networks and convolutional recurrent neural networks, In: 28th Signal Processing and Communications Applications Conference (SIU).
- [44] **Lecun, Y., Bottou, L., Bengio, Y., and Haffner, P.** (1998). Gradient-based learning applied to document recognition. In: Proceedings of the IEEE, pp. 2278–2324.

- [45] **Khan, S., Rahmani, H., Shah, S.A.A, and Bennamoun, M.,** (2018). A guide to convolutional neural networks for computer vision. In: Synthesis lectures on computer vision, pp. 1-207.
- [46] **Ioffeand, S., and Szegedy. C.,** (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. In: Proc. ICML, pp. 448–456.
- [47] **Kaiming, H.,** et al (2016). Deep residual learning for image recognition. In: Proc. IEEE Conf. Comput. Vis. Pattern Recognit., pp. 770-778.
- [48] **Sahinidis, N. V. (2019).** Mixed-integer nonlinear programming 2018. In: Optimization and Engineering, pp. 301–306.
- [49] **Leyffer, S., Linderoth, J., Luedtke, J., Miller, A., and Munson, T.** (2009). Applications and algorithms for mixed integer nonlinear programming. In: Journal of Physics: Conference Series, 180, 012014.
- [50] **Goodfellow, I., Bengio, Y., and Courville, A.,** (2016) “Deep Learning”, MIT Press.
- [51] **Choudhary, R., and Gianey, H. A.,** (2017). Comprehensive review on supervised machine learning algorithms. In: International Conference on Machine Learning and Data Science (MLDS), pp. 37-43.