



**T.C.
AKSARAY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**MAKİNE ÖĞRENMESİ İLE BİNA İÇİ GÖRÜNÜR IŞIK
KONUMLANDIRMA**

YÜKSEK LİSANS TEZİ

Mehmet Akif ÇELİK

DANIŞMAN

Doç. Dr. Yasin ÇELİK

AKSARAY, 2025

Aksaray Üniversitesi Fen Bilimleri Enstitüsü'nün 222363401 numaralı Yüksek Lisans öğrencisi Mehmet Akif ÇELİK tarafından hazırlanan “(MAKİNE ÖĞRENMESİ İLE BİNA İÇİ GÖRÜNÜR IŞIK KONUMLANDIRMA)” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ/OY ÇOKLUĞU ile Elektrik Elektronik Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Doç. Dr. Yasin ÇELİK

Aksaray Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.....

Üye: Unvanı Adı SOYADI

Üniversite Adı

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.....

Üye: Unvanı Adı SOYADI

Üniversite Adı

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.....

Tez Savunma Tarihi:/...../.....

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Prof. Dr. Fazliye KARABÖRK

Fen Bilimleri Enstitüsü Müdürü

DOĞRULUK BEYANI

Yüksek lisans tezi olarak sunduğum bu çalışmayı, akademik kurallara ve bilimsel etik, ahlak ve geleneklere aykırı düşecek bir yol ve yardıma başvurmaksızın yazdığımı, yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu, çalışmamda kullandığım verilerin orijinallliğini ve her türlü intihalden uzak olduğunu beyan ederim.

Enstitü tarafından belli bir zamana bağlı olmaksızın, tezimle ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçlara katlanacağımı bildiririm.

İmza

Mehmet Akif ÇELİK

TEŞEKKÜR

Bu tezin hazırlanmasında bana rehberlik eden, değerli zamanını ayırıp her türlü desteği ve yönlendirmeleriyle bu süreci kolaylaştıran danışman hocam, Sayın Doç. Dr. Yasin Çelik'e teşekkür ederim.

Hayatımın her alanında her zaman yanımda olan annem, babam, abim ve ablama, sevgi ve anlayışıyla bana güç veren sevgili eşim Gülsüm'e, evlatlarım Abdullah, Ahmet Yasin ve İbrahim Vefa'ya bu süreçte vermiş oldukları maddi-manevi desteklerinden dolayı teşekkür ederim.

Mehmet Akif ÇELİK
AKSARAY, 2025

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
ÖZET	iv
ABSTRACT	v
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER DİZİNİ	viii
SİMGELER VE KISALTMALAR	ix
1. GİRİŞ	1
1.1 Konumlandırmanın Tarihçesi	1
1.2 Konumlandırma Teknikleri	2
1.2.1 Alınan sinyal gücü (Received Signal Strength, RSS) tabanlı konumlandırma	2
1.2.2 Kanal durum bilgisi (Channel State Information, CSI) tabanlı konumlandırma	3
1.2.3 Parmak izi (Fingerprinting) tabanlı konumlandırma	4
1.2.4 Geliş açısı (Angle of Arrival, AoA) tabanlı konumlandırma	4
1.2.5 Varış zamanı / uçuş süresi (Time of Arrival, ToA / Time of Flight, ToF) tabanlı konumlandırma	5
1.2.6 Varış zamanı farkı (Time Difference of Arrival, TDoA) tabanlı konumlandırma	5
1.2.7 Gidiş – dönüş süresi (Return Time of Flight, RToF) tabanlı konumlandırma	6
1.2.8 Geliş fazı (Phase of Arrival, PoA) tabanlı konumlandırma	6
1.3 Mevcut İç Mekan Konumlandırma Teknolojileri	8
1.3.1 Wireless Fidelity (Wi – Fi) teknolojisi	8
1.3.2 Bluetooth teknolojisi	8
1.3.3 ZigBee teknolojisi	8
1.3.4 Radyo frekansı ile tanımlama (Radio Frequency Identification, RFID) teknolojisi	9
1.3.5 Ultra geniş band (Ultra Wideband, UWB) teknolojisi	10
1.3.6 Akustik sinyal (Acoustic Signal) teknolojisi	10
1.3.7 Ultrason (Ultrasound) teknolojisi	11
1.3.8 Milimetre dalga (Milimeter Wave) teknolojisi	12
1.3.9 Görünür ışık iletişimi (Visible Light Communication, VLC) teknolojisi	12
1.4 Görünür Işık Tabanlı Konumlandırma Sistemi	14
1.4.1 Görünür ışık tabanlı konumlandırma sisteminin avantajları ve dezavantajları	15
1.4.2 Makine öğrenmesinin görünür ışık tabanlı konumlandırma sistemine etkisi	17
1.4.2.1 Denetimli öğrenme (Supervised Learning)	17
1.4.2.2 Denetimsiz öğrenme (Unsupervised Learning)	18
1.4.2.3 Pekiştirmeli öğrenme (Reinforcement Learning, RL)	18
1.5 Tezin Katkıları	18
2. KAYNAK ÖZETLERİ	20
3. MALZEME VE YÖNTEM	23
3.1 Sistem Modeli	23

3.2 RSS Verilerinin Elde Edilmesi.....	26
3.3 Kullanılan Makine Öğrenmesi Algoritmaları.....	28
3.3.1 Rastgele orman (Random Forest) algoritması	28
3.3.2 k-en yakın komşu (kNN) algoritması	30
3.3.3 XGBoost algoritması	31
3.3.4 Doğrusal regresyon (Linear Regression) algoritması	33
3.3.5 Üçgenleme (Trilaterasyon) algoritması	34
4. ARAŞTIRMA BULGULARI VE TARTIŞMA.....	36
4.1 Giriş	36
4.2 Tek Bölge ML Tabanlı Yöntem VLP Performansları.....	38
4.2.1 4 LED için tek bölge ML tabanlı yöntem VLP performansı.....	38
4.2.2 5 LED için tek bölge ML tabanlı yöntem VLP performansı.....	40
4.2.3 8 LED için tek bölge ML tabanlı yöntem VLP performansı.....	43
4.2.4 9 LED için tek bölge ML tabanlı yöntem VLP performansı.....	46
4.2.5 12 LED için tek bölge ML tabanlı yöntem VLP performansı.....	49
4.2.6 16 LED için tek bölge ML tabanlı yöntem VLP performansı.....	52
4.2.7 Algoritmalarla göre tek bölge ML tabanlı yöntem VLP performansının hata değerleri	55
4.3 Bölgeleştirmeli ML Tabanlı Yöntem VLP Performansları.....	56
4.3.1 4 LED için 0.5m-4.5m bölgeleştirmeli ML tabanlı yöntem VLP performansı.....	58
4.3.2 4 LED için 0.9m-4.1m bölgeleştirmeli ML tabanlı yöntem VLP performansı.....	59
4.3.3 4 LED için 1.3m-3.7m bölgeleştirmeli ML tabanlı yöntem VLP performansı.....	60
4.3.4 8 LED için 0.5m-4.5m bölgeleştirmeli ML tabanlı yöntem VLP performansı.....	61
4.3.5 8 LED için 0.9m-4.1m bölgeleştirmeli ML tabanlı yöntem VLP performansı.....	62
4.3.6 8 LED için 1.3m-3.7m bölgeleştirmeli ML tabanlı yöntem VLP performansı.....	63
4.3.7 12 LED için 0.5m-4.5m bölgeleştirmeli ML tabanlı yöntem VLP performansı.....	64
4.3.8 12 LED için 0.9m-4.1m bölgeleştirmeli ML tabanlı yöntem VLP performansı.....	65
4.3.9 12 LED için 1.3m-3.7m bölgeleştirmeli ML tabanlı yöntem VLP performansı.....	66
5. SONUÇ VE ÖNERİLER.....	67
KAYNAKLAR	69
ÖZGEÇMİŞ.....	77

YÜKSEK LİSANS TEZİ

MAKİNE ÖĞRENMESİ İLE BİNA İÇİ GÖRÜNÜR IŞIK KONUMLANDIRMA

Mehmet Akif ÇELİK

Aksaray Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Yasin ÇELİK

ÖZET

Görünür ışık tabanlı konumlandırma (VLP) sistemleri, radyo frekansı (RF) temelli konumlandırma sistemlerine alternatif bir yöntem olarak literatürde giderek daha fazla yer almaktadır. Düşük maliyetli altyapı gereksinimleri ve yüksek konumlandırma doğruluğu sayesinde VLP sistemleri, RF tabanlı sistemlere kıyasla önemli avantajlar sunmaktadır. Buna ek olarak, son yıllarda sistem performansını artırmak amacıyla makine öğrenmesi (ML) algoritmalarının kullanımında artış gözlemlenmiş ve bu doğrultuda çeşitli çalışmalar gerçekleştirilmiştir. Bu çalışmada ML algoritmalarının VLP sistemlerinde konum hatasına etkisi analiz edilmektedir. Direkt sinyal (LOS) ve ilk yansımanın (NLOS) dikkate alındığı bina içi senaryoda alınan sinyal gücü (RSS) parametresi kullanılarak hata performansları elde edilmiştir. Işık yayan diyot (LED) sayılarının 4, 5, 8, 9, 12 ve 16 olduğu altı farklı senaryo dikkate alınmıştır. Bu senaryolarda LOS ve NLOS sinyallerden elde edilen RSS bilgileri kullanılarak veri seti oluşturulmuştur. Bu veri seti üzerinde farklı makine öğrenmesi algoritmaları çalıştırılmış ve sonuçlar analiz edilmiştir. Kullanılan algoritmaların performanslarına bakıldığında XGBoost ve rastgele orman (RF) algoritmaları en yüksek başarıyı göstermişlerdir. k en yakın komşu (kNN) algoritması, XGBoost ve RF algoritmalarına kıyasla daha düşük doğruluk göstermektedir. Trilaterasyon algoritması ise kNN, XGBoost ve RF algoritmalarına göre daha zayıf performans göstermiştir. Doğrusal regresyon (LR) en düşük başarıya sahip algoritmadır. Artan LED sayıları ile birlikte bu algoritmaların performansları birbirlerine yaklaşmıştır. LR modelinin tüm LED sayıları için çok düşük performans gösterdiği görülmüştür. Düşük LED sayılarında RF algoritması daha iyi performans gösterirken, LED sayısının artmasıyla XGBoost algoritmasının performansı RF algoritmasını geçmektedir. Ek olarak, iç mekanlarda, özellikle duvarlara yakın bölgelerde yansıma etkisinin daha belirgin olması nedeniyle, veri seti merkez ve kenar bölge olmak üzere ikiye ayrılmıştır. Bu ayrım esas alınarak makine öğrenmesi algoritmaları her bölge için ayrı ayrı eğitilmiş ve bu yöntem sayesinde NLOS sinyallerinin etkisi azaltılarak hem geleneksel trilaterasyon algoritmasına hem de tek bölgeli ML tabanlı yöntemlere göre daha düşük ortalama konumlandırma hataları elde edilmesi sağlanmıştır.

Anahtar Kelimeler: Görünür Işık Konumlandırma (VLP), Makine Öğrenmesi (ML), RSS, Trilaterasyon.

Haziran, 2025; 77 sayfa

M.Sc. THESIS

INDOOR VISIBLE LIGHT POSITIONING WITH MACHINE LEARNING

Mehmet Akif ÇELİK

Aksaray University

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics Engineering

Supervisor: Assoc. Prof. Dr. Yasin ÇELİK

ABSTRACT

Visible Light Positioning (VLP) systems are increasingly being featured in the literature as an alternative method to radio frequency (RF)-based positioning systems. Thanks to their low-cost infrastructure requirements and high positioning accuracy, VLP systems offer significant advantages compared to RF-based systems. In addition, in recent years, there has been a growing trend in the use of machine learning (ML) algorithms to improve system performance, and various studies have been conducted in this direction. This study analyzes the effect of ML algorithms on positioning error in VLP systems. Error performances were obtained using the received signal strength (RSS) parameter in an indoor scenario that considers both line-of-sight (LOS) and the first reflection (non-line-of-sight, NLOS). Six different scenarios with 4, 5, 8, 9, 12, and 16 light-emitting diodes (LEDs) were considered. A dataset was created using RSS information obtained from LOS and NLOS signals in these scenarios. Various machine learning algorithms were run on this dataset and the results were analyzed. Among the algorithms used, XGBoost and Random Forest (RF) demonstrated the highest success rates. The k-nearest neighbors (kNN) algorithm showed lower accuracy compared to XGBoost and RF. The trilateration algorithm performed worse than kNN, XGBoost, and RF. Linear Regression (LR) was the algorithm with the lowest performance. As the number of LEDs increased, the performances of the algorithms converged. However, the LR model consistently showed very poor performance across all LED counts. While the RF algorithm performed better at lower LED counts, the performance of the XGBoost algorithm surpassed that of RF as the number of LEDs increased. Additionally, since reflection effects are more pronounced in indoor areas, especially near walls, the dataset was divided into two regions: center and edge. Based on this separation, ML algorithms were trained separately for each region. Using this method, the impact of NLOS signals was reduced, leading to lower average positioning errors compared to both the traditional trilateration algorithm and single-region ML-based methods.

Keywords: Visible Light Positioning (VLP), Machine Learning (ML), RSS, Trilateration.

June, 2025; 77 pages

ŞEKİLLER DİZİNİ

Şekil 3.1.	Benzetim ortamı.	26
Şekil 3.2.	RF modeli.	29
Şekil 3.3.	kNN modeli.	30
Şekil 3.4.	XGBoost modeli	32
Şekil 3.5.	LR modeli	33
Şekil 3.6.	Trilaterasyon algoritması	34
Şekil 4.1.	4 LED için: a) oda yerleşimi, b)RSS verilerinin oda içindeki dağılımı ..	38
Şekil 4.2.	4 LED için tek bölgesel ML tabanlı yöntem konum hataları CDF grafiği.	39
Şekil 4.3.	4 LED için tek bölgesel ML tabanlı yöntem konumlara göre algoritma hataları: a)LR, b)kNN, c)RF, d)XGBoost.	40
Şekil 4.4.	5 LED için: a) oda yerleşimi, b)RSS verilerinin oda içindeki dağılımı...	41
Şekil 4.5.	5 LED için tek bölgesel ML tabanlı yöntem konum hataları CDF grafiği.	42
Şekil 4.6.	5 LED için tek bölgesel ML tabanlı yöntem konumlara göre algoritma hataları: a)LR, b)kNN, c)RF, d)XGBoost	43
Şekil 4.7.	8 LED için: a) oda yerleşimi, b)RSS verilerinin oda içindeki dağılımı ..	44
Şekil 4.8.	8 LED için tek bölgesel ML tabanlı yöntem konum hataları CDF grafiği.	45
Şekil 4.9.	8 LED için tek bölgesel ML tabanlı yöntem konumlara göre algoritma hataları: a)LR, b)kNN, c)RF, d)XGBoost.	46
Şekil 4.10.	9 LED için: a) oda yerleşimi, b)RSS verilerinin oda içindeki dağılımı...	47
Şekil 4.11.	9 LED için tek bölgesel ML tabanlı yöntem konum hataları CDF grafiği.	48
Şekil 4.12.	9 LED için tek bölgesel ML tabanlı yöntem konumlara göre algoritma hataları: a)LR, b)kNN, c)RF, d)XGBoost	49
Şekil 4.13.	12 LED için: a) oda yerleşimi, b)RSS verilerinin oda içindeki dağılımı.	50
Şekil 4.14.	12 LED için tek bölgesel ML tabanlı yöntem konum hataları CDF grafiği	51
Şekil 4.15.	12 LED için tek bölgesel ML tabanlı yöntem konumlara göre algoritma hataları: a)LR, b)kNN, c)RF, d)XGBoost.	52
Şekil 4.16.	16 LED için: a) oda yerleşimi, b)RSS verilerinin oda içindeki dağılımı.	53
Şekil 4.17.	16 LED için tek bölgesel ML tabanlı yöntem konum hataları CDF grafiği	54
Şekil 4.18.	16 LED için tek bölgesel ML tabanlı yöntem konumlara göre algoritma hataları: a)LR, b)kNN, c)RF, d)XGBoost	55
Şekil 4.19.	LED sayılarına göre algoritmaların hata miktarları: a)Ortalama hata, b)Maksimum hata.....	56
Şekil 4.20.	Veri setinin bölgelere ayrılması: a)0.5m-4.5m, b)0.9m-4.1m, c)1.3m-3.7m.....	57
Şekil 4.21.	4 LED için 0.5m-4.5m bölgelendirmeli ML tabanlı yöntem konum hataları CDF grafiği.	58
Şekil 4.22.	4 LED için tek bölgesel ve 0.5m-4.5m bölgelendirmeli ML tabanlı yöntemlerin ortalama hata miktarlarının karşılaştırılması.	58
Şekil 4.23.	4 LED için 0.9m-4.1m bölgelendirmeli ML tabanlı yöntem konum hataları CDF grafiği	59
Şekil 4.24.	4 LED için tek bölgesel ve 0.9m-4.1m bölgelendirmeli ML tabanlı yöntemlerin ortalama hata miktarlarının karşılaştırılması	59
Şekil 4.25.	4 LED için 1.3m-3.7m bölgelendirmeli ML tabanlı yöntem konum hataları CDF grafiği	60

Şekil 4.26.	4 LED için tek bölge ve 1.3m-3.7m bölgelendirmeli ML tabanlı yöntemlerin ortalama hata miktarlarının karşılaştırılması	60
Şekil 4.27.	8 LED için 0.5m-4.5m bölgelendirmeli ML tabanlı yöntem konum hataları CDF grafiği	61
Şekil 4.28.	8 LED için tek bölge ve 0.5m-4.5m bölgelendirmeli ML tabanlı yöntemlerin ortalama hata miktarlarının karşılaştırılması	61
Şekil 4.29.	8 LED için 0.9m-4.1m bölgelendirmeli ML tabanlı yöntem konum hataları CDF grafiği.	62
Şekil 4.30.	8 LED için tek bölge ve 0.9m-4.1m bölgelendirmeli ML tabanlı yöntemlerin ortalama hata miktarlarının karşılaştırılması.	62
Şekil 4.31.	8 LED için 1.3m-3.7m bölgelendirmeli ML tabanlı yöntem konum hataları CDF grafiği.	63
Şekil 4.32.	8 LED için tek bölge ve 1.3m-3.7m bölgelendirmeli ML tabanlı yöntemlerin ortalama hata miktarlarının karşılaştırılması.	63
Şekil 4.33.	12 LED için 0.5m-4.5m bölgelendirmeli ML tabanlı yöntem konum hataları CDF grafiği.	64
Şekil 4.34.	12 LED için tek bölge ve 0.5m-4.5m bölgelendirmeli ML tabanlı yöntemlerin ortalama hata miktarlarının karşılaştırılması.	64
Şekil 4.35.	12 LED için 0.9m-4.1m bölgelendirmeli ML tabanlı yöntem konum hataları CDF grafiği.	65
Şekil 4.36.	12 LED için tek bölge ve 0.9m-4.1m bölgelendirmeli ML tabanlı yöntemlerin ortalama hata miktarlarının karşılaştırılması.	65
Şekil 4.37.	12 LED için 1.3m-3.7m bölgelendirmeli ML tabanlı yöntem konum hataları CDF grafiği.	66
Şekil 4.38.	12 LED için tek bölge ve 1.3m-3.7m bölgelendirmeli ML tabanlı yöntemlerin ortalama hata miktarlarının karşılaştırılması.	66

ÇİZELGELER DİZİNİ

Çizelge 1.1. Konumlandırma tekniklerinin avantaj ve dezavantajları.....	7
Çizelge 1.2. Konumlandırma teknolojilerinin menzil, verim ve güç tüketimi.	13
Çizelge 1.3. Konumlandırma teknolojilerinin avantaj ve dezavantajları.....	13
Çizelge 3.1. LED’lerin x-y pozisyonları.....	25
Çizelge 3.2. LED parametreleri	28
Çizelge 3.3. RF algoritmasına ait parametreler.	29
Çizelge 3.4. kNN algoritmasına ait parametreler.....	31
Çizelge 3.5. XGBoost algoritmasına ait parametreler.	32
Çizelge 3.6. LR algoritmasına ait parametreler.	33
Çizelge 4.1. Benzetim parametreleri	37
Çizelge 4.2. 4 LED için algoritmalara göre eğitim ve test süreleri	39
Çizelge 4.3. 5 LED için algoritmalara göre eğitim ve test süreleri	41
Çizelge 4.4. 8 LED için algoritmalara göre eğitim ve test süreleri	44
Çizelge 4.5. 9 LED için algoritmalara göre eğitim ve test süreleri	47
Çizelge 4.6. 12 LED için algoritmalara göre eğitim ve test süreleri	50
Çizelge 4.7. 16 LED için algoritmalara göre eğitim ve test süreleri	53

SİMGELER VE KISALTMALAR

ANN	Yapay Sinir Ağı
AoA	Geliş Açısı
AWGN	Toplamsal Beyaz Gauss Gürültüsü
BER	Bit Hata Oranı
CDF	Kümülatif Dağılım Fonksiyonu
CDMA	Kod Bölmeli Çoklu Erişim
CSI	Kanal Durum Bilgisi
dB	Desibel
dBm	Desibel Miliwatt
DC	Doğru Akım
DNN	Derin Sinir Ağı
DT	Karar Ağacı
FOV	Fotodedektör Yarı Açık Görüş Alanı
Gbps	Saniyedeki Gigabit Sayısı
GHz	Giga Hertz
GP	Gauss Süreçleri
GPS	Küresel Konumlandırma Sistemi
ID	Kimlik
IoT	Nesnelerin İnterneti
IPS	İç Mekan Konumlandırma Sistemi
ISM	Endüstriyel, Bilimsel, Medikal
Kbps	Saniyedeki Kilobit Sayısı
KHz	Kilo Hertz
kNN	k-En Yakın Komşu
LED	Işık Yayan Diyot
LOS	Doğrudan Görüş
LR	Doğrusal Regresyon
MAI	Çoklu Erişim Girişimi
Mbps	Saniyedeki Megabit Sayısı
MHz	Mega Hertz
MIMO	Çoklu Giriş Çoklu Çıkış
ML	Makine Öğrenmesi
NLOS	Görüş Hattı Dışı
NN	Sinir Ağı
OCDMA	Optik Kod Bölmeli Çoklu Erişim
OKH	Ortalama Karesel Hata
OOK	Aç Kapa Anahtarlama
PD	Fotodedektör
PoA	Geliş Fazı
RF	Radyo Frekansı
RF	Rastgele Orman
RFID	Radyo Frekansı ile Tanımlama
RL	Pekiştirmeli Öğrenme
RSS	Alınan Sinyal Gücü
RTof	Gidiş-Dönüş Süresi
SHF	Süper Yüksek Frekans
SNR	Sinyal Gürültü Oranı

SVM	Destek Vektör Makineleri
TDoA	Varış Zamanı Farkı
ToA	Varış Zamanı
ToF	Uçuş Süresi
TOV	Kapanma Gerilimi
UHF	Ultra Yüksek Frekans
UWB	Ultra Geniş Band
VLC	Görünür Işık İletişimi
VLP	Görünür Işık Konumlandırma



1. GİRİŞ

Konumlandırma ve navigasyon sistemleri, mobil cihazlar, atalet sensörleri, kameralar, ışık kaynakları gibi donanımların geliştirilmesi nedeniyle son yıllarda büyük teknolojik gelişmelere uğramıştır. Bu gelişme çeşitli uygulamalar için konumlandırma sistemlerinin kullanılmasına imkan sağlamıştır. Açık hava navigasyonunda önemli gelişmeler yaşanmış olsa da iletilen elektromanyetik dalgaların çeşitli nedenlerle zayıflaması sebebiyle iç mekan navigasyonunda konumlandırma sorunları oluşmaktadır. Bu bölüm hem açık hava hem de iç mekan senaryolarında konumlandırmanın arka planını açıklamaktadır.

1.1 Konumlandırmanın Tarihçesi

Konumlandırma, tarih boyunca insanların yer değiştirme ve hedeflerine ulaşma ihtiyaçları doğrultusunda gelişmiş önemli bir bilgi ve beceri alanı olmuştur. İnsanlık, M.Ö. 4000'li yıllardan itibaren yön bulmak amacıyla doğayı gözlemlemeye başlamış, özellikle denizcilik faaliyetleri navigasyonun gelişiminde belirleyici bir rol oynamıştır. İlk denizciler, kıyı çizgilerini, güneşin doğuş ve batış yönlerini, rüzgarları ve gece gökyüzündeki takımyıldızları gibi doğal referans noktalarını kullanarak yön tayini yapmışlardır [1]. Ancak Vikingler gibi bazı erken dönem örnekler dışında, açık deniz seferleri geniş ölçekte ancak 18. yüzyılda sekstant (18. yy. ilk yarısı) ve deniz kronometresi (18. yy. ikinci yarısı) gibi hassas ölçüm araçlarının geliştirilmesiyle mümkün hale gelmiştir. Kristof Kolomb gibi kaşifler, usturlap ve "*cross-staff*" gibi daha basit aletlerle yönlerini bulmaya çalışmışlardır. *Cross-staff*, iki uzak nesne arasındaki açıyı ölçmeye yararken; usturlap, gök cisimlerinin konumlarını belirleyerek zamanı hesaplamak ve konumlandırma problemlerini çözmek için kullanılmıştır [2].

Zamanla bilimsel araştırmaların ve teknolojik ilerlemelerin birikimli sonucu olarak 1973 yılında Amerika Birleşik Devletleri Savunma Bakanlığı (Pentagon), günümüzdeki GPS sisteminin temellerini atmıştır. Sistem, 11.000 mil (yaklaşık 20.000 km) yükseklikte yörüngeye yerleştirilmiş 24 uydudan oluşacak şekilde tasarlanmıştır [3, 4]. Uydular, Dünya'nın her noktasından en az dört tanesinin aynı anda görülebileceği bir düzenlemeyle yerleştirilmiş, her biri son derece hassas atom saatleri ile donatılmıştır. Bu saatler sayesinde hem zaman hem de konum bilgisi

yüksek hassasiyetle hesaplanabilmekte ve bu veriler GPS alıcıları tarafından değerlendirilerek kullanıcının kesin konumu belirlenmektedir.

GPS, açık alanlarda yüksek doğrulukla konum belirleyebilme kapasitesine sahip olsa da iç mekanlarda sinyal zayıflaması ve çoklu yol (multipath) etkileri gibi nedenlerle konum kestiriminde önemli hatalar oluşabilmektedir [5]. Uzmanlar, 2025 yılı itibarıyla dünya genelinde 22 milyardan fazla bağlantılı nesnelerin interneti (Internet of Things – IoT) cihazının bulunacağını öngörmektedir [6]. Bu bağlamda, her bir IoT cihazının konumunun doğru bir şekilde belirlenmesi, sunulan hizmetlerin kalitesini doğrudan etkileyen kritik bir unsur haline gelmektedir. Bu durum yeni nesil iç mekan konumlandırma sistemleri (Indoor Positioning Systems-IPS)'nin geliştirilmesini zorunlu hale getirmiştir.

Bu tezin ilerleyen bölümlerinde iç mekan konumlandırma sistemlerinde kullanılan teknikler ve teknolojilerden detaylı bir şekilde bahsedilmiştir.

1.2 Konumlandırma Teknikleri

1.2.1 Alınan sinyal gücü (Received Signal Strength, RSS) tabanlı konumlandırma

Alınan sinyal gücüne (Received Signal Strength - RSS) dayalı bu yaklaşım, iç mekan konumlandırması için en basit ve yaygın olarak kullanılan tekniklerden biridir [7-11]. RSS, alıcıda alınan gerçek sinyal gücüdür ve genellikle desibel-miliwatt (dBm) ya da miliwatt (mW) cinsinden ölçülür. RSS, bir verici (Tx) ile bir alıcı (Rx) cihaz arasındaki mesafeyi tahmin etmek için kullanılabilir. RSS değeri ne kadar yüksekse, Tx ile Rx arasındaki mesafe o kadar küçüktür. Mutlak mesafe, iletim gücünün veya referans bir noktadaki gücün bilindiği durumlarda çeşitli sinyal yayılım modelleri kullanılarak tahmin edilebilir.

Konum tayini için en az üç referans noktasından elde edilen mesafe tahminleri kullanılarak üçgenleme (trilaterasyon) algoritması ile iki boyutlu (2B) konum belirlenebilir. Ancak çevresel faktörler (duvarlar, yansıma, saçılma vb.) nedeniyle RSS değerleri sıklıkla kararsız hale gelir. Bu nedenle, özellikle iç mekan uygulamalarında geleneksel matematiksel modellere ek olarak makine öğrenmesi

temelli yaklaşımlar da kullanılmaktadır. Bu yöntemlerde, önceden toplanmış RSS verileri üzerinden eğitim yapılarak konum tahmini gerçekleştirilir.

RSS tabanlı konumlandırma sistemlerinin en önemli avantajı, mevcut donanım altyapısının kullanılması sayesinde düşük maliyetle uygulanabilir olmasıdır. Bununla birlikte, çevresel etmenlere karşı yüksek duyarlılık göstermesi, sistemin doğruluğunu olumsuz etkileyebilmektedir. Bu durum, özellikle yüksek hassasiyet gerektiren uygulamalarda (örneğin robotik navigasyon, hasta takibi vb.) performans düşüklüğüne yol açabilmektedir [7, 12].

Sonuç olarak, RSS tabanlı konumlandırma sistemleri, düşük maliyetli ve uygulanabilir olmaları sayesinde özellikle iç mekan uygulamalarında sıkça tercih edilmekte, ancak doğruluk seviyesini artırmak amacıyla geleneksel yöntemlerin yanında makine öğrenmesi gibi veri odaklı yöntemlerin de kullanılması yaygınlaşmaktadır.

1.2.2 Kanal durum bilgisi (Channel State Information, CSI) tabanlı konumlandırma

Kanal Durumu Bilgisi (Channel State Information – CSI), bir kablosuz iletişim kanalının genlik ve faz tepkilerini içeren yüksek çözünürlüklü, frekans seçici kanal parametrelerini ifade eder. Bu bilgi, özellikle IoT gibi düşük güçlü cihazların yer aldığı ortamlarda, kablosuz iletim performansının adaptif olarak optimize edilmesine imkan tanır. CSI; sinyal gücü, kanal zayıflama karakteristikleri, çoklu yol etkileri ve girişim düzeyleri gibi parametrelerin dinamik olarak ölçülmesini sağlar. Bu veriler, iletişim güvenilirliğini artırmak, spektrum verimliliğini iyileştirmek ve iletim parametrelerini gerçek zamanlı olarak uyarlamak için kullanılabilir.

Buna ek olarak, CSI verisi, çok girişli çok çıkışlı (MIMO) sistemlerde ve hüzme şekillendirme (beamforming) gibi gelişmiş iletim tekniklerinin uygulanmasında kritik rol oynar [13, 14]. Frekans düzeyinde detaylı kanal bilgisi sunması nedeniyle, CSI özellikle yüksek hassasiyet gerektiren iç mekan konumlandırma uygulamaları için değerli bir kaynaktır. Bu sayede, cihazların bulunduğu konum yüksek doğrulukla tahmin edilebilmekte ve zaman içindeki konum değişimleri izlenebilmektedir.

Ancak, CSI tabanlı konum tahmin sistemlerinin uygulanmasında birtakım sınırlamalar mevcuttur. Öncelikle, CSI ölçümleri çevresel etmenlere oldukça duyarlıdır. Özellikle çoklu yol yansıması (multipath fading) ve elektromanyetik girişim, sinyal karakteristiklerinde ani dalgalanmalara neden olarak konum tahminlerinin güvenilirliğini olumsuz etkileyebilir. Ayrıca, CSI'nın elde edilmesi ve işlenmesi, standart RSS tabanlı yaklaşımlara kıyasla daha yüksek donanım ve yazılım desteği gerektirir. Bu durum, büyük ölçekli iç mekan konumlandırma sistemlerinde CSI tabanlı çözümlerin uygulanabilirliğini kısıtlayan başlıca etkenlerden biridir [15].

1.2.3 Parmak izi (Fingerprinting) tabanlı konumlandırma

Parmak izi tabanlı konumlandırma, iç mekan konumlandırma sistemlerinde yaygın olarak kullanılan, sahne analizine dayalı bir tekniktir. Bu yöntem çevrimdışı (offline) ve çevrimiçi (online) olmak üzere iki aşamadan oluşur [16, 17].

Çevrimdışı (Offline) Aşama: Bu aşamada, konumlandırma bölgesindeki erişim noktalarından alınan RSS bilgileri toplanır. Bu bilgiler ve onlara karşılık gelen konumlar bir çevrimdışı veri tabanında saklanır ve daha sonra gerçek zamanlı konum tahmini için kullanılır.

Çevrimiçi (Online) Aşama: Bu aşamada, konumlandırma sistemi hem veri tabanında saklanan verileri hem de hedef konumda gerçek zamanlı olarak gözlemlenen verileri kullanarak konumu tahmin eder.

1.2.4 Geliş açısı (Angle of Arrival, AoA) tabanlı konumlandırma

Geliş açısı tabanlı konumlandırma tekniği, sinyalin alıcı antenlere hangi açıyla ulaştığını tespit ederek konum tahmini yapar [18]. AoA yaklaşımının önemli bir avantajı, 2B ortamlarda yalnızca iki, üç boyutlu (3B) ortamlarda ise üç referans istasyonu ile konum tahmini yapılabilmesidir. Ancak, bu yöntemin uygulanabilmesi için fazladan donanım gereksinimi vardır. Yüksek doğrulukla çalışan anten dizileri ve hassas zaman senkronizasyonu gibi unsurlar sistemin karmaşıklığını ve maliyetini artırır.

AoA, kısa mesafelerde yüksek doğruluk sunabilse de verici ile alıcı arasındaki mesafe arttıkça, geliş açısındaki küçük bir hata konum tahmininde ciddi sapmalara neden olabilir [19]. Ayrıca, iç mekanlarda ortaya çıkan çoklu yol etkileri nedeniyle, doğrudan görüş hattı (Line-of-Sight-LOS) bileşeninin belirlenmesi güçleşir ve bu da sistemin doğruluğunu olumsuz etkiler.

1.2.5 Varış zamanı / uçuş süresi (Time of Arrival, ToA / Time of Flight, ToF) tabanlı konumlandırma

Bu yöntemde, sinyalin kaynak (örneğin bir LED) ile alıcı (örneğin bir fotodedektör) arasında kat ettiği süreyi ölçerek aradaki mesafe hesaplanır [20]. Görünür ışık iletişimi (VLC) tabanlı sistemlerde ToA yöntemi, LED'lerden yayılan ışık sinyalinin fotodedektöre ulaşma süresinin ölçülmesine dayanır. Bu süre, ışığın bilinen yayılma hızı (yaklaşık 3×10^8 m/s) ile çarpılarak, verici ile alıcı arasındaki mesafe doğrudan hesaplanabilir.

Bu yöntem, sinyalin gönderim zamanının kesin olarak bilinmesini gerektirir. Bu nedenle, mobil cihazlar ve alıcı birimler, yüksek hassasiyetli bir zaman kaynağına bağlı olarak tam senkronize çalışmalıdır. ToA, özellikle iç mekanlarda sinyal yansımalarından kaynaklanan hataları azaltabilmesi sayesinde, en yüksek doğruluk sunan konumlandırma tekniklerinden biri olarak öne çıkar [21].

Bununla birlikte, ToA yönteminin bazı sınırlamaları da bulunmaktadır. En önemli dezavantajı, tüm cihazlar arasında hassas zaman senkronizasyonu gerektirdiği için sinyalin iletim süresine bağlı gecikmeyi ölçebilmek amacıyla sisteme ek bir zaman sunucusu entegre edilmesi gerekir ki bu durum hem sistemin karmaşıklığını hem de maliyetini artırır. Öte yandan, kalabalık veya fiziksel olarak yoğun ortamlarda, sinyalin engeller sebebiyle dolaylı yollardan ulaşması ek gecikmelere neden olabilir ve konumlama doğruluğunu olumsuz etkileyebilir.

1.2.6 Varış zamanı farkı (Time Difference of Arrival, TDoA) tabanlı konumlandırma

Bu teknik, bilinen konumlara sahip birden fazla referans noktası arasındaki göreceli zaman farklarını ölçerek konum belirler. Konumu belirlemek için senkronize bir gönderim zamanına ihtiyaç duymaz. Bunun yerine, gönderim zamanı bilinmeyen bir

sinyal, birden fazla alıcı düğüm tarafından algılanır ve yalnızca alıcılar arasında zaman senkronizasyonu yeterli olur [22]. Her bir varış zamanı farkı ölçümü, konumlandırma alanı üzerinde hiperbolik bir eğri tanımlar. Birden fazla hiperbolik eğrinin kesişim noktası ise mobil istemcinin olası konumunu verir.

1.2.7 Gidiş-dönüş süresi (Return Time of Flight, RToF) tabanlı konumlandırma

Bu yöntem, sinyalin gönderici-alıcı-gönderici arasında gidiş-dönüş yayılma süresini ölçerek, verici ile alıcı arasındaki mesafeyi tahmin eder [20]. Vericiden bir sinyal aldığı anda, alıcı, vericiye geri yanıt gönderir ve verici, toplam gidiş-dönüş süresine göre sinyalin uçuş süresini hesaplar.

RToF'un ToF ile karşılaştırıldığında temel avantajı, verici ve alıcı arasında nispeten daha az hassas saat senkronizasyonu gerektirmesidir. Ancak, RToF tahmin doğruluğu, ToF ile aynı etkenlerden (örneğin; örnekleme oranı ve sinyal bant genişliği) etkilenir. Bu etkiler, sinyalin iki kez iletilip alınması nedeniyle daha da belirgin hale gelir.

RToF tabanlı sistemlerdeki bir diğer önemli sorun ise, alıcıda meydana gelen yanıt gecikmesidir. Bu gecikme, büyük ölçüde alıcının elektronik yapısına ve protokol ek yüklerine bağlıdır. Eğer verici ile alıcı arasındaki yayılma süresi, yanıt süresine kıyasla büyükse, bu gecikme ihmal edilebilir. Ancak, iç mekan konumlandırması gibi kısa menzilli sistemlerde bu gecikme göz ardı edilemez.

1.2.8 Geliş fazı tabanlı (Phase of Arrival, PoA) konumlandırma

Bu yöntem, verici ile alıcı arasındaki mesafeyi tahmin etmek için taşıyıcı sinyalin fazını kullanır. Alıcı tarafta sinyal fazının belirlenmesi için yaygın bir varsayım, referans düğümlerden ya da kullanıcı cihazından iletilen sinyallerin aynı frekansta ve sıfır faz farkına sahip saf sinüzoidal biçimde olduğudur.

PoA tabanlı konumlandırma tekniği, konumlandırma doğruluğunu artırmak ve sistem performansını iyileştirmek amacıyla RSS, ToF ve TDoA gibi yöntemlerle birlikte kullanılabilir. Ancak, PoA tabanlı yaklaşımın temel sorunu, yüksek konumlandırma doğruluğu için LOS gerektirmesidir ki bu da iç mekan koşullarında nadiren sağlanabilir [23].

Çizelge 1.1’de konumlandırma tekniklerinin avantaj ve dezavantajları açısından karşılaştırması yapılmıştır.

Çizelge 1.1. Konumlandırma tekniklerinin avantaj ve dezavantajları [24].

Teknik	Avantajları	Dezavantajları
RSS	Uygulaması kolay, düşük maliyetli ve farklı teknolojilerle uyumludur.	Çoklu yol etkilerine ve çevresel gürültüye duyarlıdır, parmak izi verisi gerekebilir.
CSI	Çoklu yol ve iç mekan gürültüsüne karşı daha dayanıklıdır.	Her donanım desteklemeyebilir.
AoA	Yüksek konum doğruluğu sağlar, parmak izi verisine gerek yoktur.	Yönlü antenler ve karmaşık donanım gerekebilir. Mesafe arttıkça performans azalabilir.
ToF veya ToA	Yüksek konum doğruluğu sağlar, parmak izi verisine gerek yoktur.	Gönderici ve alıcılar arasında zaman senkronizasyonu ve çoklu anten gerekebilir. Doğrudan görüş şarttır.
TDoA	Parmak izi verisine gerek yoktur. Cihaz ve alıcı nokta arasında saat senkronizasyonuna ihtiyaç yoktur.	Alıcı noktalar arasında saat senkronizasyonu gerektirir, zaman damgaları gerekebilir, daha büyük bant genişliğine ihtiyaç vardır.
RToF	Parmak izi verisine gerek yoktur, yüksek konumlandırma doğruluğu sağlayabilir.	Saat senkronizasyonu gerektirir, işlem gecikmesi kısa mesafede performansı düşürebilir.
PoA	RSS, ToA ve TDoA ile birlikte kullanıldığında konumlandırma doğruluğunu artırabilir.	Görüş açısının olmaması durumunda performans düşer.
Fingerprinting	Kullanımı oldukça kolaydır.	Alanla ilgili küçük bir farklılık olsa bile yeni parmak izleri gereklidir.

1.3 Mevcut İç Mekan Konumlandırma Teknolojileri

1.3.1 Wireless Fidelity (Wi-Fi) teknolojisi

Wi-Fi olarak bilinen IEEE 802.11 standardı, Endüstriyel, Bilimsel ve Medikal (ISM) bandında çalışır ve özel, kamusal ve ticari ortamlarda çeşitli cihazlara ağ bağlantısı ve internet erişimi sağlamak için kullanılır. Başlangıçta Wi-Fi'nin kapsama mesafesi yaklaşık 100 metre iken [25], IEEE 802.11ah standardıyla bu mesafe yaklaşık 1 kilometreye kadar çıkmıştır [26, 27].

Günümüzdeki akıllı telefonların, dizüstü bilgisayarların ve diğer taşınabilir kullanıcı cihazlarının çoğu Wi-Fi desteklidir. Bu durum, Wi-Fi'yi iç mekan konumlandırması için ideal bir aday haline getirmiş ve literatürde en çok çalışılan konumlandırma teknolojilerinden biri olmasını sağlamıştır [28-31]. Ayrıca mevcut Wi-Fi erişim noktaları, sinyal toplama işlemi için referans noktaları olarak da kullanılabilir [29]. Bu sayede, ekstra bir altyapıya ihtiyaç duymadan, makul doğrulukta konum belirleyebilen temel konumlandırma sistemleri kurulabilir.

1.3.2 Bluetooth teknolojisi

Bluetooth (IEEE 802.15.1), cihazlar arasında kısa menzilli kablosuz iletişimi sağlamak amacıyla geliştirilmiştir. Wi-Fi ile benzer şekilde, 2.402 GHz ile 2.480 GHz arasındaki radyo frekanslarını kullanarak iletişim kurar. Bluetooth, düşük iletim gücü, uzun pil ömrü, güvenli ve verimli iletişim sağlamasının yanı sıra, maliyet açısından uygun ve erişilebilir bir çözüm sunar [32, 33].

Yeni sürüm olan Bluetooth Low Energy (BLE), 70–100 metre arası kapsama alanına sahiptir ve 24 Mbps veri hızı sunarken, aynı zamanda daha yüksek enerji verimliliği sağlar [34]. Bu özelliklerine rağmen, Bluetooth geniş alanlarda konum belirleme için uygun değildir [35].

1.3.3 ZigBee teknolojisi

ZigBee, kablosuz iletişimde kullanılan bir teknolojidir ve IEEE 802.15.4 standardına dayanır. Avrupa'da 868 MHz, ABD ve Avustralya'da 915 MHz, diğer yerlerde ise genellikle 2.4 GHz frekansı tercih edilir.

ZigBee'nin en önemli avantajlarından biri düşük maliyetli ve enerji tasarruflu olmasıdır. Wi-Fi gibi yüksek hızlı sistemlerle kıyaslandığında, veri aktarım hızı daha düşüktür ama gecikme süresi kısadır ve özellikle enerji kullanımı açısından çok daha verimlidir. Bu yüzden genellikle sensör ağlarında veya ev otomasyon sistemlerinde tercih edilir.

ZigBee teknolojisi, cihazlar arasındaki mesafeyi ölçmek amacıyla RSS'ye dayalı bir yöntem kullandığı için ek donanım ihtiyacı olmadan konum belirleyebilme imkanı sunar [36, 37].

1.3.4 Radyo frekansı ile tanımlama (Radio Frequency Identification, RFID) teknolojisi

RFID teknolojisi, RFID etiketlerinin geri yansıttığı sinyallerin okunması prensibine dayanır. Bu sistemde, etiketlerle okuyucular arasındaki iletişim, RFID okuyucuları ve bu sinyalleri işleyen ara yazılımlar aracılığıyla gerçekleştirilir [38].

RFID etiketleri aktif, pasif ve yarı-aktif olmak üzere üçe ayrılır. Aktif RFID etiketlerinin devre yapısı içinde dahili bir batarya bulunur. Bu tür etiketler, ultra yüksek frekans (UHF) ve süper yüksek frekans (SHF) aralıklarında çalışır ve 100 metreye kadar tespit menziline ulaşabilir. Bu nedenle, aktif RFID çözümleri, geniş alanlarda nesne takibi ve uzun menzilli konum belirleme uygulamaları için uygundur [39–41]. Bununla birlikte, aktif RFID sistemleri, metre altı hassasiyet gerektiren durumlar için yeterli doğruluk sağlamaz. Ayrıca, bu teknoloji taşınabilir cihazların çoğunda yaygın olarak bulunmaz. Pasif RFID etiketleri ise enerji kaynağı içermez ve baz istasyonundan gelen sinyali geri yansıtarak çalışır. Sadece çip ve anten gerektirdiği için üretimi kolay ve maliyeti düşüktür. Bu sebeple, pasif RFID sistemleri birçok uygulamada tercih edilmektedir. Ayrıca, bu sistemler metre altı hassasiyette tespitler yapabilir ve 10 metreye kadar olan mesafelerde hedefleri algılayabilir [41].

RFID teknolojileri, düşük maliyetli olmaları nedeniyle yaygın kullanım alanına sahiptir. Bu sistemlerde, önceden yerleştirilen çok sayıda referans etiketi bulunur. Her bir etiket, sinyal kaynağı gibi davranır ve çevredeki okuyucular tarafından RSS

verileri ölçülür. Hedef etiketin konumu ise, RSS değeri hedef etikete en yakın olan referans etiketlerine göre tahmin edilir [42, 43].

1.3.5 Ultra geniş band (Ultra Wideband, UWB) teknolojisi

UWB teknolojisi, 3.1 ile 10.6 GHz arasındaki frekanslarda, 500 MHz'in üzerinde bant genişliğine sahip, 1 nanosaniyeden daha küçük darbelerin iletimine dayanır [44]. Bu iletim biçimi, oldukça düşük görev döngüsü ile çalıştığından enerji tüketimi açısından verimlidir. Başlangıçta UWB, kısa menzilli kablosuz veri aktarımı, özellikle bilgisayar çevre birimleri gibi uygulamalar için geliştirilmiştir. Zaman içinde, UWB teknolojisi iç mekan konumlandırma sistemleri açısından öne çıkan bir çözüm haline gelmiştir. Bunun başlıca nedeni, kullanılan sinyal yapısının ve kapsadığı radyo spektrumunun diğer kablosuz sistemlerden farklı olması nedeniyle parazit ve girişimlere karşı yüksek direnç göstermesidir. UWB sinyalleri, metal ve sıvılar dışında pek çok yapısal malzemeyi geçebildiği için iç mekanlarda kullanım açısından önemli avantajlar sunar [45].

UWB darbelerinin süresinin son derece kısa olması, bu teknolojinin çoklu yansımalarla kaynaklanan bozulmalara karşı daha az hassas olmasını sağlar. Bu da özellikle karmaşık iç mekanlarda, LOS üzerindeki sinyalin ayırt edilmesine olanak tanır. Böylece, ToF ölçümleriyle yüksek hassasiyetli konum belirleme gerçekleştirilebilir.

1.3.6 Akustik sinyal (Acoustic Signal) teknolojisi

Akustik sinyallere dayalı konumlandırma teknolojisi, akıllı telefonlarda yerleşik olarak bulunan mikrofon sensörlerini kullanarak, belirli ses kaynakları ya da referans düğümler tarafından yayılan akustik sinyalleri algılar ve bu sinyaller aracılığıyla kullanıcının konumunu belirlemeye çalışır. Bu alandaki klasik yaklaşım, iletilen akustik sinyallerin zaman damgası veya zamanla ilgili bilgileri içermesi esasına dayanır. Mikrofon sensörleri bu bilgileri kullanarak ToF hesaplaması yapar ve bu sayede konum tahmini gerçekleştirilir [46].

Yapılan bazı çalışmalar, akustik sinyallerin alınması sırasında hareket halindeki cihazda ortaya çıkan Doppler etkisini değerlendirerek, sinyaldeki küçük faz ve

frekans deęişimlerinden cihazın görelî hareketini ve konumunu tahmin etmeye odaklanmıřtır [47].

Her ne kadar bu yöntemlerin yüksek doğrulukla konum belirleyebildięi gösterilmiş olsa da sistem performansı bazı donanımsal sınırlamalarla karşı karşıyadır. Özellikle akıllı telefon mikrofonlarının örnekleme hızları ve *anti-aliasing* filtreleme özellikleri, yalnızca insan kulağının duyabildięi frekans aralıęındaki (<20 kHz) sinyallerin kullanılmasına imkan tanır. Bu nedenle, sinyallerin insanlar tarafından duyulmaması adına iletim gücünün düşük tutulması gerekir. Aynı zamanda, bu düşük güçlü sinyallerin doğru bir şekilde algılanabilmesi için alıcı cihazda gelişmiş sinyal işleme tekniklerinin uygulanması önemlidir.

Öte yandan, bu tür sistemlerin çalışabilmesi için gereken ek altyapı gereksinimleri ve yüksek konum güncelleme sıklığının pil tüketimini artırması, akustik sinyal tabanlı konumlandırma çözümlerinin yaygın kullanımı önünde önemli engeller oluşturmaktadır.

1.3.7 Ultrason (Ultrasound) teknolojisi

Ultrasona dayalı konumlandırma teknolojisi, temel olarak 20 kHz üzerindeki ultrason sinyallerinin ToF ölçümlerine ve ses hızına dayanarak bir verici ile alıcı düğüm arasındaki mesafenin hesaplanması prensibine dayanmaktadır. Literatürde, bu yöntemin santimetre düzeyinde hassasiyetle iç mekan konumlandırması sağladığı [48-50], aynı anda birden fazla mobil düğümü yüksek enerji verimliliğiyle takip edebildiği ve farklı odalar arasında sinyal sızıntısı olmaksızın çalışabildiği gösterilmiştir.

Ultrason sinyal iletimi genellikle, sistemin senkronizasyonunu sağlamak amacıyla bir radyo frekansı (RF) darbesiyle birlikte gerçekleştirilir. Bununla birlikte, RF sinyallerinin aksine, sesin yayılma hızı sıcaklık ve nem gibi çevresel faktörlerden önemli ölçüde etkilenmektedir. Bu nedenle, sistem performansını stabilize etmek amacıyla ultrason tabanlı konumlandırma sistemleri genellikle sıcaklık sensörleri ile birlikte yapılandırılmaktadır [51]. Gelişmiş sinyal işleme algoritmaları, çevresel gürültünün konumlandırma doğruluğu üzerindeki olumsuz etkilerini büyük ölçüde

filtreleyebilse de sürekli ve yüksek seviyedeki bir gürültü kaynağı sistem performansını ciddi şekilde düşürebilmektedir.

1.3.8 Milimetre dalga (Milimeter Wave) teknolojisi

İç mekan konumlandırma açısından milimetre dalga (mmWave) teknolojisi, sahip olduğu fiziksel özellikler sayesinde önemli avantajlar sunar. Frekansı 6GHz'in altında olan sinyallere göre çok daha kısa dalga boylarına sahip olan mmWave sinyalleri, bu sayede daha yüksek konumlandırma doğruluğu ve daha düşük hata payı sağlar [52, 53]. Ayrıca mmWave'in LOS yollarının baskın olması ve saçılmanın sınırlı düzeyde gerçekleşmesi, iç mekanda yüksek çözünürlüklü mekansal tarama yapılmasına imkan tanır [54, 55].

Bu özellikler, mmWave teknolojisini sadece veri iletişimi değil, aynı zamanda hassas konum belirleme ve cihazsız (pasif) algılama sistemleri için de uygun bir seçenek haline getirir. Özellikle karmaşık iç mekan ortamlarında, konumlandırma uygulamaları için gelişmiş performans ve doğruluk sunar.

1.3.9 Görünür ışık iletişimi (Visible Light Communication, VLC) teknolojisi

VLC, LED'lerin yaydığı görünür spektrum aralığındaki ışığın hem aydınlatma hem de veri iletimi amacıyla kullanılması esasına dayanan yenilikçi bir kablosuz iletişim teknolojisidir. Bu teknolojide, LED'ler yalnızca çevresel aydınlatma sağlamakla kalmayıp, aynı zamanda yüksek frekansta modüle edilerek veri iletimi için birer kaynak işlevi görür. LED ışık kaynaklarından yayılan bu modüle edilmiş ışık sinyalleri, kullanıcı cihazlarında yer alan optoelektronik dedektörler (örneğin fotodiyotlar veya kameralar) aracılığıyla algılanarak konum bilgisi elde edilir. Konumlandırma, RSS, AoA veya ToA gibi teknikler kullanılarak gerçekleştirilir [56].

VLC sistemlerinin iç mekan konumlandırma uygulamaları açısından pek çok avantajı bulunmaktadır. Özellikle RF sistemlerde yaygın olarak karşılaşılan elektromanyetik girişim sorunlarına karşı bağışıklık göstermesi, VLC'yi hastane, havaalanı gibi RF hassasiyetinin yüksek olduğu ortamlarda ideal bir seçenek haline getirmektedir. Bunun yanı sıra, yüksek konumlandırma doğruluğu (cm seviyesinde) elde edilebilmesi, RF sistemler gibi insan sağlığı üzerinde olumsuz etkilerinin olmaması,

ışığın duvarlardan geçememesi sebebiyle güvenli iletişimin sağlanabilmesi, bant genişliğinin fazla olması sebebiyle daha fazla veri aktarım potansiyeline sahip olması, mevcut LED aydınlatma altyapısına kolayca entegre edilebilmesi, sistemi ekonomik ve teknik açıdan cazip kılmaktadır. Ancak LOS gereksinimi ve ışık engellemeleri, sistem performansını sınırlayabilmektedir [57].

Çizelge 1.2’de konumlandırmada kullanılan teknolojilerin menzil, verim ve güç tüketimi açısından karşılaştırması yapılmıştır.

Çizelge 1.2. Konumlandırma teknolojilerinin menzil, verim ve güç tüketimi [24].

Teknoloji	Maksimum Menzil	Maksimum Verim	Güç Tüketimi
IEEE 802.11 n	250 m dış mekanda	600 Mbps	Orta
802.11 ac	35 m iç mekanda	1.3 Gbps	Orta
802.11 ad	Birkaç metre	4.6 Mbps	Orta
UWB	10-20 m	460 Mbps	Orta
Akustik	Birkaç metre		Düşük-Orta
RFID	200 m	1.67 Gbps	Düşük
Bluetooth	100 m	24 Mbps	Düşük
Ultrason	20-30 m	30 Mbps	Düşük-Orta
Görünür ışık	1,4 km	10 Gbps	Daha yüksek
IEEE 802.11 ah	1 km	100 Kbps	Çok düşük

Çizelge 1.3’de iç mekan konumlandırmada kullanılan teknolojilerin avantajları ve dezavantajları açısından karşılaştırması yapılmıştır.

Çizelge 1.3. Konumlandırma teknolojilerinin avantaj ve dezavantajları [24].

Teknoloji	Avantajları	Dezavantajları
IEEE 802.11 n 802.11 ac 802.11 ad	Kolay erişilebilir, yüksek doğruluk sunar, ek donanım gerektirmez.	Gürültüye duyarlıdır, karmaşık işlem algoritmaları gerektirir.

Çizelge 1.3 (devam). Konumlandırma teknolojilerinin avantaj ve dezavantajları [24].

Teknoloji	Avantajları	Dezavantajları
UWB	Girişime karşı dayanıklıdır, yüksek doğruluk sağlar.	Daha kısa menzile sahiptir. Ek donanım gerektirir ve maliyeti yüksektir.
Akustik	Özel uygulamalarda kullanılabilir, yüksek doğruluk sağlar.	Ses kirliliğinden etkilenir, ek sabit noktalar veya donanım gerektirir.
RFID	Güç tüketimi düşüktür, geniş menzile sahiptir.	Konum belirleme doğruluğu düşüktür.
Bluetooth	Yüksek veri iletim kapasitesine ve düşük enerji tüketimine sahiptir.	Düşük konum doğruluğuna sahiptir ve gürültüye duyarlıdır.
Ultrason	Nispeten daha düşük sinyal emilimine sahiptir.	Sensör yerleşimi önemlidir.
VLC	Geniş ölçekli kullanılabilir, yüksek doğruluk sağlar ve çoklu yol etkisine maruz kalmaz.	Daha fazla güç tüketir, engellerden etkilenir ve LOS gerektirir.
IEEE 802.11 ah	Geniş alım aralığına sahiptir, enerji tüketimi azdır.	Baz istasyonu ile cihazlar arasındaki uzun mesafe ve bina duvarları, dışarıdan içeriye sinyalin zayıflamasına neden olur.

1.4 Görünür Işık Tabanlı Konumlandırma Sistemi

Günümüzde iç mekan konumlandırma için Wi-Fi, Bluetooth, RFID, ultrasonik sensörler ve manyetik alan tabanlı sistemler gibi çeşitli teknolojiler kullanılmaktadır. Ancak, bu teknolojilerin çoğu ya yüksek altyapı maliyetlerine sahiptir ya da hassasiyetleri düşüktür [58]. Özellikle geniş alanlarda kullanılması durumunda altyapının karmaşıklığı artmakta ve veri işleme süreçleri daha fazla hesaplama gücü gerektirmektedir. Bu nedenle, düşük maliyetli, yüksek hassasiyetli ve enerji verimli bir iç mekan konumlandırma yöntemi geliştirilmesi büyük bir araştırma alanı olarak ön plana çıkmaktadır.

Bu bağlamda, alternatif ve yenilikçi bir yaklaşım olarak görünür ışık konumlandırma (Visible Light Positioning, VLP) sistemi dikkat çekmektedir. VLP, LED tabanlı aydınlatma sistemlerini kullanarak iç mekanlarda yüksek doğruluklu konumlandırma yapabilen, elektromanyetik girişimlere dayanıklı bir teknolojidir [59]. LED'lerin günümüzde yaygın kullanımı, düşük enerji tüketimi ve çevre dostu olması gibi avantajları, VLP'nin gelecekte yaygın bir iç mekan konumlandırma teknolojisi olmasını sağlayabilecek önemli faktörlerdendir. Ayrıca, LED aydınlatmaların modüle edilebilir olması, ışık sinyallerinin veri taşıyıcı olarak kullanılmasını mümkün kılmaktadır. Bu da VLP'nin hem aydınlatma hem de konumlandırma amacıyla çift fonksiyonlu bir sistem olarak çalışmasına imkan tanımaktadır.

1.4.1 Görünür ışık tabanlı konumlandırma sisteminin avantajları ve dezavantajları

VLP sistemleri iç mekan konumlandırma çözümleri arasında giderek daha fazla önem kazanmaktadır. LED ışıklar hem aydınlatma hem de veri iletimi sağlayabildiği için konumlandırma sistemleri açısından düşük maliyetli, yüksek doğruluklu ve güvenilir bir alternatif sunmaktadır. Ancak bu teknolojinin bazı sınırlamaları da bulunmaktadır. Aşağıda VLP sistemlerinin avantajları ve dezavantajları detaylı bir şekilde ele alınmıştır.

Avantajları:

- **Yüksek konumlandırma doğruluğu:** VLP sistemleri, Wi-Fi veya Bluetooth tabanlı konumlandırma yöntemlerine kıyasla daha yüksek doğruluk oranlarına ulaşabilir. LED ışıkların doğrultulu yayılım özelliği sayesinde, konum belirleme hassasiyeti santimetre seviyesine kadar düşebilir [60]. Bu doğruluk seviyesi, özellikle hassas navigasyon gerektiren ortamlarda büyük avantaj sağlar.
- **Elektromanyetik girişime karşı dayanıklılık:** RF tabanlı konumlandırma sistemleri, Wi-Fi, Bluetooth veya RFID gibi teknolojilerle çalışırken elektromanyetik girişime maruz kalabilir. Ancak görünür ışık elektromanyetik spektrumun farklı bir bölgesinde çalıştığı için RF sinyallerinden etkilenmez [60]. Bu özellik, özellikle hastaneler, havalimanları

ve sanayi tesisleri gibi elektromanyetik girişime duyarlı ortamlarda VLP sistemlerinin güvenilirliğini artırır.

- **Mevcut aydınlatma altyapısının kullanılabilir olması:** Görünür ışık tabanlı sistemlerin en büyük avantajlarından biri, ek donanım gerektirmeden mevcut LED aydınlatma altyapısı üzerinden çalışabilmesidir [60]. Günümüzde çoğu bina, enerji verimliliğini sağlamak amacıyla LED aydınlatmaya geçiş yapmaktadır. VLP sistemleri, bu altyapıyı kullanarak düşük maliyetli bir konumlandırma çözümü sunar.
- **Lisanssız spektrum kullanımı:** Görünür ışık spektrumu lisanssızdır, ek frekans lisansı veya spektrum tahsisi gerekmez [60].
- **Düşük güç tüketimi:** LED ışıklar enerji verimli olup, düşük güç tüketimi ile çalışır. VLP sistemleri, bu avantajı kullanarak minimum enerji tüketimi ile konum belirleme işlemlerini gerçekleştirebilir [61].

Dezavantajları:

- **Doğrudan görüş gereksinimi:** VLP sistemlerinin en büyük dezavantajlarından biri, verimli çalışabilmesi için doğrudan görüş hattına ihtiyaç duymasıdır. LED ışıklar ile alıcı (fotodedektör veya kamera) arasında bir engel bulunması durumunda sinyal gücü önemli ölçüde azalabilir [62]. Bu nedenle, kişilerin hareketi, mobilyalar veya diğer nesneler konumlandırma doğruluğunu etkileyebilir.
- **Çevresel ışık koşullarına duyarlılık:** Görünür ışık tabanlı sistemler, güneş ışığı, floresan lambalar veya diğer aydınlatma kaynaklarından gelen girişimlerden etkilenebilir. Örneğin, güneş ışığı doğrudan fotodedektörlere ulaştığında, LED kaynaklı sinyallerin algılanmasını zorlaştırabilir. Bu durum, sistemin performansını değişen ışık koşullarına duyarlı hale getirmektedir [60].
- **Yüksek altyapı/donanım maliyeti:** Yeterli konum hassasiyeti için çok sayıda LED verici ve sensör kurulumu gerekebilir. Büyük ölçekli uygulamalarda bu donanım maliyetini artırır [60].

1.4.2 Makine öğrenmesinin görünür ışık tabanlı konumlandırma sistemine etkisi

Makine öğrenmesi (ML), sistemlerin verilerden kurallar ve modeller çıkarabilmesi için çeşitli araçlar ve istatistiksel yöntemler kullanır. ML teknikleri, desen tanıma, finans, eğlence ve biyomedikal gibi birçok alanda etkili şekilde kullanılmaktadır. Bu algoritmalar, deneme yanılma yöntemiyle yapılarını zamanla geliştirerek, verilen görevi daha başarılı bir şekilde yerine getirmeyi öğrenir. Bu öğrenme sürecine “eğitim” denir ve bu süreçte algoritmaya bazı giriş verileri ve bu verilere karşılık gelen doğru çıktılar gösterilir. Eğitim tamamlandığında, algoritma kendini en uygun hale getirerek daha önce hiç görmediği verilere bile doğru tepkiler verebilir ve istenilen sonuçları üretebilir [63].

Geleneksel VLP yöntemleri iç mekanlarda konum belirleme doğruluğunu artırabilir, ancak bu yöntemler fiziksel ortamda oluşan yansımalar, atış ve termal gürültü gibi etkenlerden olumsuz etkilenebilir. Bu tür durumlarda makine öğrenmesi yaklaşımları alternatif bir çözüm sunar. ML, bir eğitim veri setinden öğrenerek ortamın fiziksel yapısını anlayabilir ve daha hassas konum tahmini yaparak konumlandırma başarımını önemli ölçüde artırabilir. Aşağıda makine öğrenmesi yöntemleri hakkında bilgi verilmiştir.

1.4.2.1 Denetimli öğrenme (Supervised Learning)

Denetimli öğrenme, makine öğrenmesinin bir türüdür ve temel olarak, verilen örnek giriş-çıkış çiftlerine bakarak girdileri çıktılarla eşleştiren bir fonksiyon öğrenmeye çalışır [64]. Sınıflandırma ve regresyon gibi işlevlere sahip denetimli öğrenme modelleri, konumlandırma doğruluğunu artırabilir. Ayrıca bu modeller, hesaplama süresini kısaltarak gerçek zamanlı uygulamaların ihtiyaçlarını karşılayabilir ve değişken ışık koşulları ya da çevresel etkenlerden kaynaklanan parazitlere karşı sistemi daha kararlı hale getirebilir. Bu özellikleri sayesinde, denetimli öğrenme yöntemleri VLP sistemlerinde konumlandırma verimliliğini artırmak için oldukça uygundur.

VLP sistemlerinde denetimli makine öğrenmesi kullanmak için önce bir veri kümesi oluşturulmalı ve bu veri kümesi eğitim, doğrulama ve test verilerine ayrılmalıdır.

Eğitim verilerinin hazırlanması genellikle kolay olduğu için, çoğunlukla RSS tabanlı parmak izi yöntemi tercih edilir.

1.4.2.2 Denetimsiz öğrenme (Unsupervised Learning)

Başlangıçta etiketli eğitim verisi gerektirmeyen denetimsiz öğrenme algoritmaları, modelin geliştirilmesi sürecinde zaman tasarrufu sağlayarak sistemin toplam çalışma süresini önemli ölçüde azaltabilir [65]. Bu yöntem genellikle sınıflandırma problemlerini çözmek için kullanılır. Ancak konumlandırma problemlerinde çoğunlukla regresyon modelleri tercih edildiği için, denetimsiz öğrenme bu alanda daha az kullanılır. Yine de son dönemlerde yapılan çalışmalar, denetimsiz öğrenme yöntemlerinin hem sistemin daha hızlı çalışmasına katkı sağladığını hem de konumlandırma doğruluğunu artırmada önemli rol oynadığını göstermiştir [66-69].

1.4.2.3 Pekiştirmeli öğrenme (Reinforcement Learning, RL)

RL, karar verici yapının, çevresiyle etkileşim kurarak ödül ve ceza mekanizması yoluyla en uygun hareket stratejisini öğrenmesini sağlayan makine öğrenmesi türüdür. VLP sistemlerinde RL kullanımı, çevresel değişkenliklere karşı adaptif bir öğrenme süreci sağlar. Örneğin, noktasal pekiştirmeli öğrenme yöntemi kullanılarak, konum tahminlerindeki hatalar “durumlar” olarak tanımlanır ve bu hataların minimize edilmesi yönünde karar verici yapı ödüllendirilerek sistemin doğruluğu artırılır [70].

Geleneksel yöntemlerin aksine, RL algoritmaları geçmiş deneyimlerden öğrenme kapasitesine sahiptir. Bu sayede sistem, ışık şiddetindeki anlık değişimleri veya fiziksel engelleri göz önünde bulundurarak konum tahminlerini iyileştirebilir. Ayrıca, pekiştirmeli öğrenme yöntemleri, önceden etiketlenmiş büyük veri kümelerine ihtiyaç duymadan çalışabildiği için, veri toplama maliyetlerini azaltmak açısından da avantaj sağlar.

1.5 Tezin Katkıları

Bu tez çalışmasında makine öğrenmesi tabanlı görünür ışık konumlandırma sistemi ele alınmakta ve makine öğrenmesi algoritmalarının, VLP sistemlerinde konum tahmin hassasiyetini artırma potansiyeli üzerinde durulmaktadır. Tez kapsamında

görünür ışık sinyallerinden elde edilen RSS verileri kullanılarak makine öğrenmesi algoritmalarının performansları elde edilmiştir. Doğrusal regresyon (LR), k-en yakın komşu (kNN), rastgele orman (RF), XGBoost gibi çeşitli ML algoritmaları ve trilaterasyon algoritması test edilerek performansları karşılaştırılmıştır. Çalışma, farklı sayılarda LED ışık kaynakları kullanılarak yapılan simülasyonlarla test edilmiş ve elde edilen sonuçlar analiz edilmiştir. Ek olarak, iç mekanda duvarlara yakın konumlarda NLOS sinyallerinin konumlandırma doğruluğuna olan olumsuz etkisini azaltmak için veri seti bölgelere ayrılmıştır. Her bölge için özel olarak eğitilen makine öğrenimi modelleri sayesinde önerilen yaklaşım, NLOS sinyallerinin etkisini azaltarak hem geleneksel trilaterasyon algoritmasına hem de tek bölgeli ML tabanlı yöntemlere kıyasla daha düşük ortalama konumlandırma hataları elde edilmesini sağlamıştır. Bu çalışmanın temel katkıları şunlardır:

- İç mekan ortamlarında yansıma şiddetindeki mekansal değişiklikleri dikkate alan uyarlanabilir bir bölgeleme stratejisi.
- Farklı mekansal bölgeler için özelleştirilmiş ML algoritmalarının (LR, kNN, RF, XGBoost) kapsamlı değerlendirmesi.
- Geleneksel görünür ışıkla konumlandırma yöntemlerine göre konumlandırma doğruluğunda sağlanan iyileşme.
- Modellerin farklı aydınlatma koşulları altındaki performansını değerlendirmek amacıyla 4, 8 ve 12 LED'li çeşitli oda yapılandırmalarına yönelik kapsamlı analiz.

Sonuç olarak makine öğrenmesi destekli görünür ışık konumlandırma sistemlerinin iç mekanlarda yüksek doğrulukta çalışabileceği gösterilmiştir.

2. KAYNAK ÖZETLERİ

VLP üzerine yapılan araştırmalar VLC teknolojisinin yaygınlaşması ile son 15 yıl içerisinde hızlanarak artmıştır. Tran ve Ha iç mekan konum belirleme sistemleri için görünür ışık iletişimine dayalı yeni bir yöntem geliştirmiştir [71]. Bu sistem, makine öğrenmesi algoritmaları kullanarak hem daha doğru konum bilgisi sağlamayı hem de işlemleri daha hızlı yapmayı amaçlamaktadır. Önce sinyaldeki parazitleri azaltmak için filtreleme yapılmış, ardından çalışma alanı ikiye bölünerek işlem yükü azaltılmıştır. Son olarak, alıcının yeri tahmin edilmiştir. Yapılan simülasyonlar, bu yöntemin hem işlem süresini önemli ölçüde azalttığını hem de konum doğruluğunu artırdığını göstermiştir.

Raes ve arkadaşları VLP sistemlerinde makine öğrenimi yöntemlerinin güvenilirliği deneysel olarak incelemiştir [72]. Yaptıkları çalışmada, MLP ve Gauss Süreçleri (GP) adlı iki model, görelî sinyal gücü verileri kullanılarak karşılaştırılmıştır. Deneylerde LED'ler ışık kaynağı, fotodiyot ise alıcı olarak kullanılmış; sistem, farklı güç seviyeleri ve alıcıya uygulanan engellemelerle test edilmiştir. İki farklı sinyal işleme yöntemi denenmiştir. Sonuçlara göre, MLP ve GP modelleri geleneksel yöntemlerden daha doğru çalışmış; özellikle GP modeli en güvenilir sonuçları vermiştir.

Çoklu yansımanın yoğun olduğu iç mekanlarda kullanılmak üzere, VLC tabanlı yeni bir konumlandırma yöntemi olan kNN-RF modeli [73]'de geliştirilmiştir. Bu modelde, k-en yakın komşu (kNN) algoritması, rastgele orman (RF) algoritmasına daha iyi özellikler sunmak amacıyla kullanılmış ve önemsiz veriler ayıklanmıştır. Simülasyon sonuçları, kNN-RF modelinin geleneksel kNN algoritmasına göre yaklaşık beş kat daha iyi konumlandırma doğruluğu sağladığını göstermiştir.

Plets ve arkadaşları VLP sistemlerinde LED'lerin eğimlerinin konum doğruluğunu nasıl etkilediği incelemiştir [74]. Monte Carlo benzetimleriyle yapılan çalışmada, küçük açısal sapmaların bile 1–6 cm arasında hatalara yol açtığı ve eğim arttıkça bu hataların da arttığı görülmüştür. Trilaterasyon algoritması, bazı bölgelerde en küçük kareler yöntemine göre daha az doğru sonuçlar vermiştir. Ayrıca, LED eğiminden kaynaklanan hataları düzeltmek için iki farklı yöntem önerilmiş ve bu yöntemler karşılaştırılmıştır.

Karibasappa ve Kumar VLP sistemlerinde en doğru ve güvenilir yöntemi bulmak amacıyla parmak izi tabanlı kNN, yapay sinir ağı (Artificial Neural Network, ANN) ve derin sinir ağı (Deep Neural Network, DNN) modellerinin performanslarını karşılaştırmış ve ANN tabanlı modelin kNN ve DNN modellerine göre daha başarılı olduğunu göstermişlerdir [75].

Abdalmajeed ve arkadaşları VLP hatalarını azaltmak amacıyla yeni bir VLP yöntemi geliştirmiştir [76]. Bu yöntemde, yönlendirilebilir lazer açılar ve LED kaynaklı sinyal verileri, karar ağacı (Decision Tree, DT), destek vektör makineleri (Support Vector Machine, SVM) ve sinir ağı (Neural Network, NN) gibi makine öğrenmesi teknikleriyle birleştirilmiştir. Çalışma, Zemax simülatörüyle oluşturulan gerçekçi bir iç mekan ortamında test edilmiş ve Orange yazılımı ile analiz edilmiştir. Sonuçlar, önerilen sistemin bazı bölgelerde konumlama hatasını %90'dan fazla azalttığını göstermiştir.

RSS tabanlı VLP sistemlerinin çevresel engeller altındaki performansının incelendiği [77]'de simülasyon ortamında çeşitli engeller eklenerek farklı makine öğrenmesi modelleri test edilmiştir. Sonuçlar, engellerin varlığında bu modellerin iyi performans gösterebilmesi için daha fazla eğitim verisine ihtiyaç duyduğunu ortaya koymuştur. Gauss Süreçleri modeli hem engelli hem de engelsiz durumlarda en yüksek doğruluğu sağlamış, ancak gölgeleme etkisi altında performansında azalma görülmüştür.

Duvar yansımalarının etkisini dikkate alan yeni bir VLP sisteminin geliştirildiği [78]'de tek bir LED ve dönebilen bir fotodedektör kullanılmış, konum belirleme işlemi makine öğrenmesine dayalı iki aşamalı bir algoritmayla gerçekleştirilmiştir. Simülasyon sonuçları, yöntemin özellikle duvar ve köşe bölgelerinde konumlama hatasını büyük ölçüde azalttığını ve genel olarak daha yüksek doğruluk sağladığını göstermiştir.

Çoklu fotodiyot içeren özel bir etiketle geliştirilen yeni bir VLP sisteminin tanıtıldığı [79]'da alınan sinyal gücüne dayalı parmak izi yöntemi WkNN algoritmasıyla kullanılmıştır. Çalışma, az sayıda ışık kaynağıyla bile yüksek doğruluk elde edilebileceğini göstermiştir. Ayrıca, iki boyutlu enterpolasyonla oluşturulan yoğun parmak izi veri tabanı sayesinde zaman ve iş gücünden tasarruf sağlanmış,

doğrulukta ise önemli bir kayıp yaşanmamıştır. WkNN algoritmasının, MLP tabanlı yaklaşıma göre daha iyi performans gösterdiği ve sistemin HTC Vive ile benzer doğruluk sunduğu belirtilmiştir.

Rekkas ve arkadaşları dört fotodiyotun yıldız şeklinde yerleştirildiği bir sistem kullanarak, mobil alıcının iç mekandaki iki boyutlu konumunu tahmin etmek için makine öğrenmesi tabanlı bir yöntem geliştirmiştir [80]. Bu çalışmada çeşitli makine öğrenmesi algoritmaları karşılaştırılmış ve sonuçlar, özellikle ANN ve önerilen yöntemlerin yüksek doğrulukla konum tahmini yapabildiğini göstermiştir.

VLP sistemlerinin üç boyutlu (3B) iç mekan drone konumlandırmasında makine öğrenimiyle nasıl geliştirilebileceğinin incelendiği [81]'de dumanlı ortamlarda ANN kullanılarak yapılan tahminlerde, konumlama hatası 21.9 cm'den 5.9 cm'ye düşürülmüştür. Çalışma, zorlu koşullarda bile yüksek doğruluk elde edilebileceğini göstermektedir.

VLP teknolojisinin kapsamlı şekilde incelendiği [82]'de konumlandırma algoritmaları, sistem tasarımları ve performans kriterleri karşılaştırılmış, VLC sistemlerinin diğer teknolojilerle entegrasyonu ve dış mekan uygulamaları da ele alınmıştır. Çalışma, mevcut durum, zorluklar ve gelecek araştırmalar için önemli bilgiler sunmuştur.

Görüntü sensörü ve renkli LED'ler kullanılarak yüksek doğruluklu bir konumlandırma yönteminin geliştirildiği [83]'te 5 cm'den daha düşük hata payı elde edilmiş ve bir robot üzerinde başarıyla uygulanarak hassas konum kontrolü sağlanmıştır. Çalışma, görüntü sensörü tabanlı VLP sistemlerinin etkinliğini ortaya koymaktadır.

RSS tabanlı VLP sistemlerinde, LED dağılımının konum belirleme performansına etkisinin incelendiği [84]'te LED sayısı artışının kestirilen konumun ortalama karesel hata (OKH) değerini azalttığı gösterilmiştir.

3. MALZEME VE YÖNTEM

3.1 Sistem Modeli

Bu çalışmada, sırasıyla en, boy ve yükseklik olmak üzere $5 \times 5 \times 3$ metre boyutlarındaki bir oda içerisinde, farklı LED sayıları (4, 5, 8, 9, 12 ve 16) kullanılarak RSS tabanlı VLP sistemi tasarlanmıştır. Oda tabanından 0,85 m yükseklikte, x ve y eksenlerinin eşit aralıklı 25 parçaya bölünmesiyle oluşan ızgara şeklindeki yapıda toplam 625 konum belirlenmiş ve tek bir PD'nin tüm noktalarda dolaştırılmasıyla her bir LED'e ait RSS verileri elde edilmiştir. Aynı odadaki LED'lerden farklı verilerin iletilmesi için çoklama yöntemi olarak, aç-kapa anahtarlama (On-Off Keying, OOK) ve *Walsh* kodlarıyla kolayca gerçekleştirilebilen optik kod bölmeli çoklu erişim (Optical Code Division Multiple Access, OCDMA) kullanılmıştır [85]. Bu teknikte, her bir LED'e kimliğini ve konum bilgisini temsil eden benzersiz bir kod atanır. Verici tarafında, iki kutuplu (bipolar) kodları tek kutuplu (unipolar) kodlara dönüştürmek için doğru akım (Direct Current, DC) öngerilim (bias) sinyali kullanılır. Ardından tek kutuplu OCDMA sinyaline bir başka DC sinyali olan kapanma gerilimi (Turn Off Voltage, TOV) eklenir. Böylece ortaya çıkan elektriksel sinyal LED'leri sürmek için uygun hale gelir. Alıcı tarafında elde edilen elektriksel sinyal y denklem (3.1)'deki gibi ifade edilir;

$$y = hx + n \quad (3.1)$$

Burada h ve x sırasıyla $1 \times N_t$ boyutunda kanal kazanç vektörünü ve $N_t \times 1$ boyutunda iletilen sembol vektörünü temsil etmektedir. N_t , LED sayısını ifade eder ve n ise gürültü parametresidir. Alıcıdaki toplam gürültü, atış (shot) gürültüleri ile termal gürültünün toplamından oluşur. Arka plan ışınlamından kaynaklanan atış gürültüsü, alınan sinyal ve karanlık akımından kaynaklanan diğer atış gürültülerine kıyasla baskındır. Ancak iletilen sinyale bağlı olmayan ve toplamsal beyaz Gauss gürültüsü (Additive White Gaussian Noise, AWGN) olarak modellenen termal gürültü bu tür sistemlerde her zaman baskın durumdadır. Bu nedenle, n sıfır ortalamalı ve her boyutta varyansı $\sigma^2 = N_0/2$ olan bir Gauss rassal değişkeni olarak kabul edilir. i 'inci LED'den iletilen sinyal $x_i(t)$ denklem (3.2)'deki gibi ifade edilir;

$$x_i(t) = s_i(t) + \Delta + \Lambda \quad (3.2)$$

Burada $s_i(t)$, OCDMA sinyalinin, Δ , DC öngerilim sinyalinin ve Λ ise TOV değerini temsil eder. Her bir LED tarafından yayılan optik güç P_i^0 denklem (3.3)'teki gibi elde edilir;

$$P_i^0 = \frac{1}{T_c} \int_0^{T_c} x_i(t) dt \quad (3.3)$$

Burada T_c , $s_i(t)$ sinyalinin çip periyodunu ifade eder. Bu nedenle, P_i^0 , $x_i(t)$ sinyalinin zaman ortalamasına karşılık gelir ve bu ortalama, $s_i(t)$ sinyali bir çip periyodu boyunca doğal olarak sıfır ortalamalı olduğundan, $\Delta + \Lambda$ değerine eşittir [85].

Alınan sinyalin DC bileşeni, kodlar arasındaki ortogonalliğin korunması amacıyla korelasyon işlemi öncesinde çıkarılır. Kod bölmeli çoklu erişim (Code Division Multiple Access, CDMA) sinyali çözüldükten sonra her bir LED için hem kimlik (ID) hem de RSS bilgisi belirlenir. 15 dB sinyal-gürültü oranı (Signal to Noise Ratio, SNR) altında, modifiye edilmiş iki kutuplu kodlarla 16 kullanıcıya kadar olan OCDMA sistemlerinde bit hata oranı (Bit Error Rate, BER) 10^{-4} seviyesine ulaşmaktadır. Bu BER değeri, hata düzeltme kodları ile güvenilir iletişimi sağlamak için yeterlidir [86].

Bu çalışmada, odanın tamamında SNR değerinin 15 dB'den çok daha yüksek olduğu ve mükemmel senkronizasyonun sağlandığı varsayılmıştır. Bu nedenle, çoklu erişim girişimi (Multiple Access Interference, MAI) tamamen önlenmiştir. Öte yandan, VLP sistemi düşük veri hızları kullandığı için, kanalın korelasyon bant genişliği veri sinyalinin bant genişliğinden büyüktür.


LED'lerin x-y düzlemindeki konumlarını belirlemek amacıyla, $z = 2.5m$ olan sabit tavan düzleminde N_t adet daire dikkate alınmıştır. Oda içinde düzgün aydınlatma sağlamak ve her bir LED'den elde edilen bireysel SNR'lerin en iyi seviyede olması için, tavan düzleminde eşit ve mümkün olan en büyük çapa sahip N_t adet sanal dairenin yerleştirilmesi sağlanmıştır. Daha sonra, bu dairelerin merkezleri LED'lerin

x ve y konumları olarak belirlenmiştir. Farklı LED sayıları için bu konumlar Çizelge 3.1’de verilmiştir.

Çizelge 3.1. LED’lerin x- y pozisyonları.

N_t	x-y Pozisyonları(m)
4	{1.25-1.25; 1.25-3.75; 3.75-1.25; 3.75-3.75}
5	{1.03-1.03; 3.96-1.03; 2.50-2.50; 1.03-3.96; 3.96-3.96}
8	{0.85-0.85; 4.14-0.85; 2.50-1.29; 1.29-2.50; 3.70-2.50; 2.50-3.70; 0.85-4.14; 4.14-4.14}
9	{0.83-0.83; 2.50-0.83; 4.16-0.83; 0.83-2.50; 2.50-2.50; 4.16-2.50; 0.83-4.16; 2.50-4.16; 4.16-4.16}
12	{0.70-0.70; 3.10-0.70; 1.90-1.46; 4.29-1.46; 0.70-2.12; 3.10-2.12; 1.90-2.87; 4.29-2.87; 0.70-3.54; 3.10-3.54; 1.90-4.29; 4.29-4.29}
16	{0.62-0.62; 1.87-0.62; 3.12-0.62; 4.37-0.62; 0.62-1.87; 1.87-1.87; 3.12-1.87; 4.37-1.87; 0.62-3.12; 1.87-3.12; 3.12-3.12; 4.37-3.12; 0.62-4.37; 1.87-4.37; 3.12-4.37; 4.37-4.37}

Benzetim ortamında gerçekleştirilen bu çalışmada, her bir konum noktasında PD’ye ulaşan RSS değerleri, her bir LED kaynağı için ayrı ayrı elde edilmiştir. Bu işlem, farklı sayılardaki LED konfigürasyonları (4, 5, 8, 9, 12 ve 16 LED) için tekrarlanmıştır. Böylece, her bir LED sayısına karşılık gelen ve belirli bir konuma ait RSS ölçümlerini içeren çok boyutlu veri setleri oluşturulmuştur. Bu veri setlerinde, her örnek hem RSS bilgilerini hem de o ölçüme karşılık gelen gerçek x ve y koordinatlarını içermektedir. Oluşturulan veri setlerinin %70’i eğitim, %15’i doğrulama ve %15’i ise test için ayrılmıştır. Konum tahmini amacıyla LR, kNN, RF, *XGBoost* algoritmaları kullanılmıştır. Trilaterasyon algoritması karşılaştırma ölçütü olarak değerlendirilmiştir. Algoritmaların eğitim ve test aşamalarında, veri seti rastgele bölünerek modellerin genelleme yetenekleri incelenmiştir. Şekil 3.1’de benzetimin yapıldığı ortama ait görsel verilmiştir.



Şekil 3.1. Benzetim ortamı.

3.2 RSS Verilerinin Elde Edilmesi

Şekil 3.1’de 4 LED’in olduğu iç mekan senaryomuzda alıcıda LOS ve NLOS bağlantıları dikkate alınmaktadır. LED’ler ile PD arasındaki optik bağlantıların ilgili kanal katsayısı h_i ile temsil edilmektedir. Bu nedenle h_i , h_i^{LOS} ve h_i^{NLOS} olmak üzere iki bileşenden oluşur ve denklem (3.4)’teki gibi elde edilir;

$$h_i = h_i^{LOS} + h_i^{NLOS} \quad (3.4)$$

LED’lerin Lambertian radyasyon desenine sahip olduğu göz önünde bulundurularak, h_i^{LOS} denklem (3.5)’te verilmektedir;

$$h_i^{LOS} = \begin{cases} \frac{(m+1)A}{2\pi d_i^2} \cos^m(\alpha_i) \cos(\beta_i), & \left| \frac{\beta_i}{FOV} \right| \leq 1 \\ 0, & \text{diğer} \end{cases} \quad (3.5)$$

Burada m , düzlemsel LED’lerin Lambertian yayılım sırasını temsil eder ve yarı güçteki yarı açı değerine bağlıdır [87]. A , PD’nin etkili alanını, d_i ise i ’inci LED ile PD arasındaki mesafeyi (metre cinsinden) ifade eder. FOV, PD’nin görüş açısını belirtir. α_i , verici taraftaki i ’inci LED ile PD arasındaki bağlantıya normalden ölçülen çıkış açısını temsil eder. Benzer şekilde, β_i , PD normaline göre geliş açısını belirtir.

LED'ler ve PD'nin normal vektörleri birbirine paralel olduğundan, α_i LOS bağlantısı için β_i 'ye eşittir.

İç mekan yüzeyleri, genellikle görünür ışığın dalga boyuna göre pürüzlüdür. Bu nedenle VLP sinyallerinin yansımaları dengeli bir şekilde her yöne dağılım gösterir. Yansıyan yüzeylerin, gelen açıya bakılmaksızın ışık yoğunluğunu dağılmış bir şekilde yaydığı varsayılabilir. Bu yüzden yansıyan yüzeylerin diferansiyel alanlara ayrıldığını varsayabiliriz. Bu durumda, her diferansiyel elemanın bir Lambertian radyasyon desenine ($m=1$) sahip olduğunu söyleyebiliriz [88]. Dolayısıyla, i 'inci LED'den tek yansıma ile gelen NLOS bileşenleri denklem (3.6)'da verilmektedir;

$$h_i^{NLOS} = \frac{A(m+1)(dA)\rho}{2\pi^2 d_i^{(1)^2} d_i^{(2)^2}} \cos^m(\alpha_i^{(1)}) \cos(\beta_i^{(1)}) \cos(\alpha_i^{(2)}) \cos(\beta_i^{(2)}) \quad (3.6)$$

Burada dA , yansıtıcı yüzeyler üzerindeki diferansiyel elemanın alanını ifade eder. $d_i^{(1)}$, i 'inci LED ile diferansiyel eleman arasındaki bağlantı mesafesidir. Benzer şekilde $d_i^{(2)}$, diferansiyel eleman ile PD arasındaki mesafedir. $\alpha_i^{(1)}$ ve $\beta_i^{(1)}$, sırasıyla i 'inci LED'den yayılan ışının yayılma açısını ve birinci diferansiyel elemana geliş açısını temsil eder. $\alpha_i^{(2)}$, diferansiyel elemandan yansıyan ışının açısını ifade eder. $\beta_i^{(2)}$, PD'ye geliş açısını gösterir. Eğer $\beta_i^{(2)}$, görüş alanından (FOV) büyükse, o zaman h_i^{NLOS} sıfıra eşit olur. Son olarak ρ görünür ışık spektrumu boyunca yansıtıcı yüzeyin ortalama yansıma katsayısını gösterir [88]. Bu çalışmada tek yansıma dikkate alınmıştır. Buna göre i 'inci LED'in toplam kanal kazancı denklem (3.7)'deki gibi ifade edilir;

$$h_i = h_i^{LOS} + \sum_{n=1}^k h_i^{NLOS(n)} \quad (3.7)$$

Bu çalışmada optik filtrenin kazancı $T_s(\beta)$ ve optik toplayıcının kazancı $G(\beta)$, 1 olarak kabul edilmiştir. Son olarak, toplam optik güç denklem (3.8)'de verilmektedir;

$$P_r^O = \sum_{i=1}^{N_t} P_i^O h_i \quad (3.8)$$

Farklı sayıda LED içeren iç mekan senaryolarını adil bir şekilde karşılaştırmak için toplam güç sabit tutulmuştur. Çizelge 3.2’de LED sayısına göre toplam optik güç gösterilmiştir.


Çizelge 3.2. LED parametreleri.

Nt	Güç /LED (W)	Toplam Güç(W)
4	81 W	324 W
5	64.8 W	
8	40.5 W	
9	36 W	
12	27 W	
16	20.25 W	

3.3 Kullanılan Makine Öğrenmesi Algoritmaları

3.3.1 Rastgele orman (Random Forest, RF) algoritması

RF, birden fazla karar ağacının bir araya getirildiği bir topluluk öğrenme modelidir. Her ağaç, eğitim verisinin ve özelliklerin rastgele seçilen alt kümeleriyle oluşturulur [89]. Şekil 3.2’de görüldüğü gibi, RF birçok ağacın birleşik sonucunu kullanır. Tüm ağaçların tahminleri birleştirilerek sonuç elde edilir. Bu rastgelelik, model çeşitliliği oluşturur ve ortalama alındığında performans artışı sağlar [89]. RF, yüksek doğruluk ve genelleme yeteneği sayesinde pek çok regresyon probleminin çözümünde kullanılır. Birden çok ağaç oluşturduğu için tek bir ağacın aşırı öğrenme eğilimi azalır, rastgelelik yüksek model çeşitliliği meydana getirir. Ayrıca eksik veriye ve aykırı değerlere karşı dayanıklıdır, sürekli ve kategorik özellikleri ayrı ayrı ölçeklemeye gerek kalmadan işleyebilir [90].



Şekil 3.2. RF modeli.

RF algoritmasına ait matematiksel model denklem (3.9)'da verilmiştir;

$$y(x) = \frac{1}{B} \sum_{b=1}^B f_b(x) \quad (3.9)$$

Burada, $y(x)$, nihai tahmin, B , karar ağacı sayısı, $f_b(x)$ ise b . karar ağacının x girdisine verdiği tahmindir.

Bu tez kapsamında, RF algoritmasının eğitiminde kullanılan parametreler ve aldıkları değerler Çizelge 3.3'te verilmiştir.

Çizelge 3.3. RF algoritmasına ait parametreler.


Özellik	Değer
Ağaç sayısı	100
Bölme ölçütü	Karesel hata
Maksimum derinlik	Yok
Dallanma için en az örnek sayısı	2
Düğümdeki en az örnek sayısı	1
Maksimum özellik	1.0

3.3.2 k-en yakın komşu (k-Nearest Neighbour, kNN) algoritması

kNN algoritması, sınıflandırma ve regresyon gibi denetimli öğrenme problemlerinde kullanılan bir yöntemdir. Yeni bir veri noktası için tahmin yapılırken, eğitim verisindeki en yakın komşularına bakılarak işlem yapılır. kNN, önceden model oluşturmayan bir algoritmadır. Tüm eğitim verisini bellekte tutar ve sadece tahmin sırasında benzerlik analizine ihtiyaç duyar [91]. Bu nedenle eğitim aşamasında model uydurma işlemi yoktur. Öğrenme, her sorgu adımında doğrudan eğitim verisi üzerinden gerçekleştirilir.

kNN’de benzerlik hesaplamak için genellikle *Öklid*, *Manhattan* veya genelleştirilmiş *Minkowski* mesafeleri kullanılır. Kullanılan mesafe metriğinin seçimi veri kümesinin özelliklerine bağlıdır. Doğru metrik seçimi model performansını önemli ölçüde etkileyebilir [91].

kNN algoritmasının tek hiperparametresi komşu sayısı k ’dır. k değeri çok küçük seçilirse model gürültüye karşı duyarlı ve yüksek varyanslı olabilir. k değeri çok büyük seçilirse model fazla genelleşir ve modelin ayrıştırıcı gücü zayıflar [91]. Bu sebeple en uygun k değeri çapraz doğrulama ile tespit edilir. Şekil 3.3’te kNN algoritmasına ait model görülmektedir.



Şekil 3.3 kNN Modeli.

kNN algoritmasına ait matematiksel model denklem (3.10)'da verilmiştir;

$$f(x_0) = \frac{1}{K} \sum_{x_i \in N_0} y_i \quad (3.10)$$

Burada, K, komşu sayısı, x_i , modelin girdisi, N_0 , x_0 'a en yakın olan K noktaları, x_0 , tahmin noktası, y_i , modelin çıktısını ifade eder.

Bu tez kapsamında, kNN algoritmasının eğitiminde kullanılan parametreler Çizelge 3.4'de verilmiştir.


Çizelge 3.4. kNN algoritmasına ait parametreler.

Özellik	Değer
Komşu Sayısı	3
Ağırlıklandırma	Eşit ağırlıklı
Algoritma	Otomatik
Yaprak düğüm boyutu	30
p	2
Mesafe ölçümü	Minkowski

3.3.3 XGBoost algoritması

XGBoost algoritması, denetimli makine öğrenmesi alanında en popüler regresyon ağaçlarından biridir. XGBoost tabanlı regresyon ağaçları, hızlı eğitim süresine sahiptir [92]. Diğer tipik artırma (boosting) algoritmalarında olduğu gibi, XGBoost algoritması da başlangıçta aşırı basitleştirilmiş (underfitting) zayıf öğrenicilerden oluşan bir yapı kullanır ve artımlı eğitim gerçekleştirir. Bu süreçte, bir sonraki seviyedeki ağaç, bir önceki turdan elde edilen artık değerleri (residuals) giriş olarak alır. Geleneksel artırma algoritmalarından farklı olarak, XGBoost kayıp fonksiyonlarını hesaplamak için Taylor serisi açılımını kullanır ve bu sayede eğitim hızını önemli ölçüde artırır [92]. Ayrıca, doğruluk ve hız dengesini sağlamak amacıyla, ağaçların karmaşıklık fonksiyonunu amaç fonksiyonuna bütünleştirir. Bu

sayede doğruluk performansı korunmuş olur. XGBoost algoritmasına ait model Şekil 3.4'te verilmiştir.



Şekil 3.4. XGBoost modeli.

XGBoost algoritmasına ait matematiksel model denklem (3.11)'de verilmiştir;

$$y_i = \sum_{k=1}^K f_k(x_i), \quad f_k \in \mathcal{F} \quad (3.11)$$

Burada, K , toplam ağaç sayısı, f_k , k . karar ağacı, x_i , i . gözleme ait giriş verisi, y_i , i . gözlem için tahmin edilen değer, $\mathcal{F}$, karar ağaçları kümesidir.


Bu tez kapsamında, XGBoost algoritmasının eğitiminde kullanılan parametreler Çizelge 3.5'de verilmiştir.

Çizelge 3.5. XGBoost algoritmasına ait parametreler.

Özellik	Değer
Toplam ağaç sayısı	100
Öğrenme oranı	0.1
Ağaçların maksimum derinliği	6
Amaç fonksiyonu	Regresyon için kare hata
Güçlendirici türü	Karar ağacı tabanlı model

3.3.4 Doğrusal regresyon (Linear Regression, LR)

LR, gözlem ile bir veya daha fazla özellik arasındaki ilişkiyi modellemek için kullanılan istatistiksel bir yöntemdir. Şekil 3.5'te LR algoritmasına ait model verilmiştir.



Şekil 3.5. LR modeli.

LR algoritmasına ait matematiksel model denklem (3.12)'de verilmektedir;

$$F(x) = b + w_1x_1 + \dots + w_px_p + \varepsilon \quad (3.12)$$

Burada, $x_1, x_2, \dots, x_p$, bağımsız değişkenler, b , y eksenini kestiği nokta, $w_1, w_2, \dots, w_p$, eğim katsayıları, ε , hata terimi, $F(x)$, bağımlı değişkeni ifade etmektedir.


Bu tez kapsamında, LR algoritmasının eğitiminde kullanılan parametreler Çizelge 3.6'de verilmiştir.

Çizelge 3.6. LR algoritmasına ait parametreler.

Özellik	Değer
X matrisinin kopyalanması	Doğru
Sabit terim eklenmesi	Doğru
Pozitif katsayı kısıtlaması	Kapalı
Paralel işlem sayısı	Yok

3.3.5 Üçgenleme (Trilaterasyon) algoritması

Trilaterasyon algoritması, bilinen konumlu sabit referans noktalar ile hedef nokta arasındaki mesafelerin ölçülmesine dayanan bir konumlandırma yöntemidir. Hedefin 2B düzlemdeki konumunu belirlemek için en az üç referans noktasından ölçülen mesafeler kullanılır. Her referans noktasına çizilen çemberin yarıçapı, hedef ile o nokta arasındaki ölçülen mesafeyi gösterir. Üç çemberin kesişim noktası hedefin potansiyel konumlarını verir. Bu yöntem özellikle iç mekanlarda konum belirleme sistemlerinde yaygın olarak kullanılmaktadır. Şekil 3.6’da trilaterasyon algoritmasına ait görsel verilmiştir.



Şekil 3.6. Trilaterasyon algoritması.

Referans alıcıların koordinatları sırasıyla (x_1, y_1) , (x_2, y_2) , (x_3, y_3) , hedef nesnenin koordinatları (x, y) ve referans alıcıların ölçülebilen mesafeleri d_1, d_2, d_3 olmak üzere denklem (3.13)’teki eşitlikler yazılabilir;

$$\begin{aligned}(x - x_1)^2 + (y - y_1)^2 &= d_1^2 \\(x - x_2)^2 + (y - y_2)^2 &= d_2^2 \\(x - x_3)^2 + (y - y_3)^2 &= d_3^2\end{aligned}\tag{3.13}$$

Bu denklem Cramer kuralı kullanılarak çözüldüğünde hedefin x ve y koordinatları denklem (3.14)’teki gibi elde edilir;

$$x = \frac{\left| \begin{array}{c} (d_1^2 - d_2^2) - (x_1^2 - x_2^2) - (y_1^2 - y_2^2)2(y_2 - y_1)y \\ (d_1^2 - d_3^2) - (x_1^2 - x_3^2) - (y_1^2 - y_3^2)2(y_3 - y_1)y \end{array} \right|}{\left| \begin{array}{c} 2(x_2 - x_1)2(y_2 - y_1) \\ 2(x_3 - x_1)2(y_3 - y_1) \end{array} \right|}$$

(3.14)

$$y = \frac{\left| \begin{array}{c} 2(x_2 - x_1)(d_1^2 - d_2^2) - (x_1^2 - x_2^2) - (y_1^2 - y_2^2) \\ 2(x_2 - x_1)(d_1^2 - d_3^2) - (x_1^2 - x_3^2) - (y_1^2 - y_3^2) \end{array} \right|}{\left| \begin{array}{c} 2(x_2 - x_1)2(y_2 - y_1) \\ 2(x_3 - x_1)2(y_3 - y_1) \end{array} \right|}$$



4. ARAŞTIRMA BULGULARI VE TARTIŞMA

4.1 Giriş

Bu bölümde, VLP sistemine yönelik gerçekleştirilen çalışmanın benzetim sonuçları ayrıntılı şekilde sunulmakta ve elde edilen bulgular kapsamlı biçimde değerlendirilmektedir. Önceki bölümlerde detaylı olarak açıklanan yöntemler doğrultusunda oluşturulan RSS tabanlı veri seti, sistemin konum tahmini performansını çeşitli senaryolarda incelemek amacıyla, tek bölge ve bölgelendirmeli olmak üzere iki farklı kategoriye ayrılmıştır.

Tek bölge yapıda, 6 farklı LED sayısı (4, 5, 8, 9, 12 ve 16 LED) kullanılarak oluşturulan veri setleri ile ML algoritmaları eğitilmiş ve algoritmaların konum-hata performansları analiz edilmiştir. Bölgelendirmeli yapıda ise 3 farklı LED sayısı (4, 8 ve 12 LED) kullanılarak oluşturulan veri setleri 2 farklı bölgeye ayrılmış ve her bölge için ML algoritmaları ayrı ayrı eğitilerek algoritmaların konum-hata performansları analiz edilmiştir. Böylece sistemin donanımsal çeşitliliğe karşı duyarlılığı detaylı bir şekilde incelenmiştir.

Çalışmada, farklı ML algoritmalarının (LR, kNN, RF, XGBoost) yanı sıra klasik bir konum tahmin algoritması olan trilaterasyon kullanılmıştır. Böylece, geleneksel matematiksel yöntemlerle modern ML yaklaşımları karşılaştırmalı olarak değerlendirilmiştir. Her algoritma ve yöntem için hata dağılımları, Kümülatif Dağılım Fonksiyonu (CDF) grafikleri aracılığıyla görsel olarak analiz edilmiş; ortalama ve maksimum hata değerlerini içeren tablolar oluşturulmuştur.

Elde edilen sonuçlar, sistemin farklı LED konfigürasyonları altında nasıl performans gösterdiğini, kullanılan yöntemlerin doğruluk seviyelerini ve hangi algoritmanın hangi koşullarda daha başarılı olduğunu ortaya koymaktadır. Ayrıca, ML algoritmaları ile trilaterasyon algoritmasının karşılaştırılması, geleneksel yöntemlerin sınırlamalarını ve veri odaklı yaklaşımların avantajlarını göstermesi açısından önemli bir katkı sunmaktadır.

Bölümün devamında, her bir LED konfigürasyonuna ait detaylı sonuçlara yer verilmekte, ardından genel bir karşılaştırma ve değerlendirme sunulmaktadır.

Çizelge 4.1'de benzetim parametreleri listelenmiştir.

Çizelge 4.1. Benzetim parametreleri.

Parametreler	Değerler
Odanın uzunluğu (x)	5m
Odanın genişliği (y)	5m
Odanın yüksekliği (z)	3m
Verici sayısı (N_t)	4, 5, 8, 9, 12, 16
Alicı sayısı (N_r)	1
LED'in tavana olan mesafesi	0.5 m
LED'lerin yükseltme açısı	-90°
LED'lerin yatay açısı	0°
LED'in yarım güç yarı açısı (ψ)	60°
Lambertian yayılım katsayısı (m)	1
Toplam iletilen optik güç	384 W
LED'in ışık verimi	46 lm/W
Fotodedektörün yerden yüksekliği	0.85 m
PD'nin yükseltme açısı	90°
PD'nin yatay açısı	0°
PD'nin tepki yeteneği (R)	$0.4 \text{ A}/\sqrt{W}$
PD'nin aktif alanı (A)	1 cm^2
PD'nin görüş alanı (FOV)	70°
Duvar yansıtma katsayısı (ρ_w)	0.8
Diferansiyel elemanların alanı (dA)	0.04 m^2


4.2 Tek Bölge ML Tabanlı Yöntem VLP Performansları

Bu bölümde farklı LED sayıları (4, 5, 8, 9, 12 ve 16) kullanılarak ölçülen RSS verilerinden oluşturulan veri setleri, ML algoritmaları kullanılarak eğitilmiş ve sonuçlar detaylı bir şekilde analiz edilmiştir.

4.2.1 4 LED için tek bölge ML tabanlı yöntem VLP performansı

Şekil 4.1(a)'da oda tavanından 0.5 metre aşağıda, koordinatları x-y olmak üzere (1.25, 1.25), (3.75, 1.25), (1.25, 3.75) ve (3.75, 3.75) noktalarına dört adet LED yerleştirilmiş ve kırmızı renkle gösterilmiştir. Fotodedektörün konumlandırıldığı noktalar ise oda tabanından 0.85 metre yükseklikte, 25x25'lik bir ızgara düzeninde mavi noktalarla işaretlenmiştir. Bu fotodedektör, her noktada LED'lerden yayılan RSS şiddetini ölçmek amacıyla yerleştirilmiştir.

Şekil 4.1(b)'de ise belirlenen noktalarda fotodedektör tarafından 4 LED'den alınan RSS bilgilerinin X-Y düzlemindeki dağılımı üç boyutlu yüzey grafiği ile gösterilmiştir. Renk skalası sinyal şiddetinin büyüklüğünü ifade etmekte olup sarı bölgeler yüksek RSS değerlerini, mor bölgeler ise düşük RSS bölgelerini temsil etmektedir. Her bir LED'in konumuna karşılık gelen alanlarda sinyal şiddeti maksimum seviyelere ulaşmakta ve merkezden uzaklaştıkça azalmaktadır.



Şekil 4.1. 4 LED için: a) oda yerleşimi, b) RSS verilerinin oda içindeki dağılımı.


Çizelge 4.2'de konumlara göre fotodedektörler tarafından alınan RSS bilgileri ile oluşturulan veri setinin algoritmalara göre eğitim ve test süreleri görülmektedir. kNN

ve LR algoritmaları en kısa eğitim süresine sahipken, RF algoritması en uzun eğitim ve test süresine sahiptir. XGBoost ise nispeten daha uzun eğitim süresine rağmen test aşamasında hızlı ve verimli bir algoritma olarak öne çıkmaktadır.

Çizelge 4.2. 4 LED için algoritmalara göre eğitim ve test süreleri.

ML algoritmaları	Eğitim süresi (ms)	Test süresi (ms)
kNN	2	0,99
LR	7	1
RF	279.9	5
XGBoost	72,9	0,99


Şekil 4.2’de verilen grafikte XGBoost ve RF algoritmaları verilen test noktalarının %80’lik kısmında 0-20 cm arası hata değerleri ile en yüksek başarıyı göstermişlerdir. kNN algoritması XGBoost ve RF’ye göre, trilaterasyon algoritması da kNN, XGBoost ve RF’ye göre daha zayıf performans göstermiştir. LR algoritması en düşük başarıya sahip modeldir.



Şekil 4.2. 4 LED için tek bölge ML tabanlı yöntem konum hataları CDF grafiği.

Şekil 4.3’te makine öğrenmesi algoritmalarının test edilmesi neticesinde konumlara göre hata miktarlarını göstermektedir. Buna göre RF ve XGBoost algoritmaları konumlara göre daha az hata üreterek daha istikrarlı ve başarılı performans

sergilemiştir. LR algoritması, özellikle bazı konumlarda yüksek hatalarıyla en zayıf model olarak öne çıkmaktadır. Bu grafik, özellikle kenar bölgelerde hata miktarının artması sebebiyle model seçiminde mekansal hata dağılımının dikkate alınmasının önemini vurgulamaktadır.




Şekil 4.3. 4 LED için tek bölgesel ML tabanlı yöntem konumlara göre algoritma hataları: a) LR, b) kNN, c) RF, d) XGBoost.

4.2.2 5 LED için tek bölgesel ML tabanlı yöntem VLP performansı

Şekil 4.4(a)'da oda tavanından 0.5 metre aşağıda, koordinatları x-y olmak üzere (1.03, 1.03), (3.96, 1.03), (2.50, 2.50), (1.03, 3.94), (3.96, 3.96) noktalarına 5 adet LED yerleştirilmiş ve kırmızı renkle gösterilmiştir. Fotodedektörün konumlandırıldığı noktalar ise oda tabanından 0.85 metre yükseklikte, 25x25'lik bir ızgara düzeninde mavi noktalarla işaretlenmiştir. Bu fotodedektör, her noktada LED'lerden yayılan RSS şiddetini ölçmek amacıyla yerleştirilmiştir.

Şekil 4.4(b)'de ise belirlenen noktalarda fotodetektör tarafından 5 LED'den alınan RSS bilgilerinin X-Y düzlemindeki dağılımı üç boyutlu yüzey grafiği ile gösterilmiştir. Renk skalası sinyal şiddetinin büyüklüğünü ifade etmekte olup sarı bölgeler yüksek RSS değerlerini, mor bölgeler ise düşük RSS bölgelerini temsil etmektedir. Her bir LED'in konumuna karşılık gelen alanlarda sinyal şiddeti maksimum seviyelere ulaşmakta ve merkezden uzaklaştıkça azalmaktadır.




Şekil 4.4. 5 LED için: a) oda yerleşimi, b) RSS verilerinin oda içindeki dağılımı.

Çizelge 4.3'de oluşturulan veri setinin algoritmalara göre eğitim ve test süreleri görülmektedir. Buna göre kNN algoritması en kısa eğitim süresine sahipken, RF algoritması en uzun eğitim ve test süresine sahiptir. XGBoost algoritması ise nispeten daha uzun eğitim süresine rağmen test aşamasında hızlı ve verimli bir algoritma olarak öne çıkmaktadır.

Çizelge 4.3. 5 LED için algoritmalara göre eğitim ve test süreleri.


ML algoritmaları	Eğitim süresi (ms)	Test süresi (ms)
kNN	1,99	0,99
LR	16	0,99
RF	313,5	5
XGBoost	65	0,99

Şekil 4.5'te verilen grafikte XGBoost ve RF algoritmaları verilen test noktalarının yaklaşık %85'lik kısmında 0-20 cm arası hata değerleri ile en yüksek başarıyı göstermişlerdir. Trilaterasyon algoritması, XGBoost ve RF'e göre, kNN algoritması da trilaterasyon, XGBoost ve RF'ye göre daha zayıf performans göstermiştir. LR en düşük başarıya sahip modeldir.



Şekil 4.5. 5 LED için tek bölge ML tabanlı yöntem konum hataları CDF grafiği.

Şekil 4.6'da makine öğrenmesi algoritmalarının test edilmesi neticesinde konumlara göre hata miktarları gösterilmiştir. Buna göre RF ve XGBoost algoritmaları konumlara göre daha az hata üreterek daha istikrarlı ve başarılı performans sergilemiştir. LR, özellikle bazı konumlarda yüksek hatalarıyla en zayıf model olarak öne çıkmaktadır. Bu grafik, özellikle kenar bölgelerde hata miktarının artması sebebiyle model seçiminde mekansal hata dağılımının dikkate alınmasının önemini vurgulamaktadır.




Şekil 4.6. 5 LED için tek bölge ML tabanlı yöntem konumlara göre algoritma hataları: a) LR, b) kNN, c) RF, d) XGBoost.

4.2.3 8 LED için tek bölge ML tabanlı yöntem VLP performansı

Şekil 4.7(a)'da oda tavanından 0.5 metre aşağıda, koordinatları x-y olmak üzere (0.85-0.85), (4.14-0.85), (2.50-1.29), (1.29-2.50), (3.70-2.50), (2.50-3.70), (0.85-4.14), (4.14-4.14) noktalarına sekiz adet LED yerleştirilmiş ve kırmızı renkle gösterilmiştir. Fotodetektörün konumlandırıldığı noktalar ise oda tabanından 0.85 metre yükseklikte, 25x25'lik bir ızgara düzeninde mavi noktalarla işaretlenmiştir. Bu fotodetektör, her noktada LED'lerden yayılan RSS şiddetini ölçmek amacıyla yerleştirilmiştir.

Şekil 4.7(b)'de ise belirlenen noktalarda fotodetektör tarafından 8 LED'den alınan RSS bilgilerinin X-Y düzlemindeki dağılımı üç boyutlu yüzey grafiği ile

gösterilmiştir. Renk skalası sinyal şiddetinin büyüklüğünü ifade etmekte olup sarı bölgeler yüksek RSS değerlerini, mor bölgeler ise düşük RSS bölgelerini temsil etmektedir. Her bir LED'in konumuna karşılık gelen alanlarda sinyal şiddeti maksimum seviyelere ulaşmakta ve merkezden uzaklaştıkça azalmaktadır.



Şekil 4.7. 8 LED için: a) oda yerleşimi, b) RSS verilerinin oda içindeki dağılımı.


Çizelge 4.4'te oluşturulan veri setinin algoritmalara göre eğitim ve test süreleri görülmektedir. Buna göre kNN algoritması en kısa eğitim süresine sahipken, RF algoritması en uzun eğitim ve test süresine sahiptir. XGBoost ise nispeten daha uzun eğitim süresine rağmen test aşamasında hızlı ve verimli bir algoritma olarak öne çıkmaktadır.

Çizelge 4.4. 8 LED için algoritmalara göre eğitim ve test süreleri.

ML algoritmaları	Eğitim süresi (ms)	Test süresi (ms)
kNN	1,99	1
LR	6	0,99
RF	460,4	4,9
XGBoost	98,9	2


Şekil 4.8 'de verilen grafiğe göre, XGBoost algoritması test noktalarının yaklaşık %90'lık kısmında 0-20 cm arası hata değerlerini elde ederek diğer algoritmalara kıyasla daha düşük hata ile daha yüksek doğruluk sağlamıştır. RF ve kNN algoritmaları da XGBoost algoritmasının ardından başarılı sonuçlar elde etmiş, düşük

hata aralıklarında yüksek doğruluk oranlarına ulaşmıştır. Trilaterasyon algoritması test noktalarının yaklaşık %70'lik kısmında 0-20 cm arası hata değerlerini elde etmiştir. LR algoritması daha yüksek hata oranıyla en zayıf model olmuştur.



Şekil 4.8. 8 LED için tek bölge ML tabanlı yöntem konum hataları CDF grafiği.

Şekil 4.9’da sunulan konumlara göre hata dağılımları incelendiğinde, makine öğrenmesi tabanlı algoritmalar arasında XGBoost ve RF algoritmalarının konum tahmini açısından en başarılı performansı sergilediği görülmektedir. Buna karşılık, kNN algoritması ortalama olarak iyi sonuçlar verse de özellikle oda kenarlarında hata oranı artmış ve modelin sınırlarda zayıfladığı gözlemlenmiştir. LR algoritması ise genel olarak yüksek hata oranlarına ve bazı konumlarda ciddi sapmalara sahiptir.




Şekil 4.9. 8 LED için tek bölge ML tabanlı yöntem konumlara göre algoritma hataları: a) LR, b) kNN, c) RF, d) XGBoost.

4.2.4 9 LED için tek bölge ML tabanlı yöntem VLP performansı

Şekil 4.10(a)'da oda tavanından 0.5 metre aşağıda, koordinatları x-y olmak üzere (0.83-0.83), (2.50-0.83), (4.16-0.83), (0.83-2.50), (2.50-2.50), (4.16-2.50), (0.83-4.16), (2.50-4.16), (4.16-4.16) noktalarına dokuz adet LED yerleştirilmiş ve kırmızı renkle gösterilmiştir. Fotodedektörün konumlandırıldığı noktalar ise oda tavanından 0.85 metre yükseklikte, 25x25'lik bir ızgara düzeninde mavi noktalarla işaretlenmiştir. Bu fotodedektör, her noktada LED'lerden yayılan RSS şiddetini ölçmek amacıyla yerleştirilmiştir.

Şekil 4.10(b)'de ise belirlenen noktalarda fotodedektör tarafından 9 LED'den alınan RSS bilgilerinin X-Y düzlemindeki dağılımı üç boyutlu yüzey grafiği ile gösterilmiştir. Renk skalası sinyal şiddetinin büyüklüğünü ifade etmekte olup sarı

bölgeler yüksek RSS değerlerini, mor bölgeler ise düşük RSS bölgelerini temsil etmektedir. Her bir LED'in konumuna karşılık gelen alanlarda sinyal şiddeti maksimum seviyelere ulaşmakta ve merkezden uzaklaştıkça azalmaktadır.



Şekil 4.10. 9 LED için: a) oda yerleşimi, b) RSS verilerinin oda içindeki dağılımı.


Çizelge 4.5'te oluşturulan veri setinin algoritmalara göre eğitim ve test süreleri görülmektedir. Buna göre kNN algoritması en kısa eğitim süresine sahipken, RF algoritması en uzun eğitim ve test süresine sahiptir. XGBoost algoritması ise nispeten daha uzun eğitim süresine rağmen test aşamasında hızlı ve verimli bir algoritma olarak öne çıkmaktadır.

Çizelge 4.5. 9 LED için algoritmalara göre eğitim ve test süreleri.

ML algoritmaları	Eğitim süresi (ms)	Test süresi (ms)
kNN	2	0,99
LR	11,9	1
RF	502	4,9
XGBoost	77,9	2


Şekil 4.11'de verilen grafiğe göre, XGBoost algoritması test noktalarının yaklaşık %95'lik kısmında 0-20 cm arası hata değerlerini elde ederek diğer algoritmalara kıyasla daha düşük hata ile daha yüksek doğruluk sağlamıştır. RF ve kNN algoritmaları da XGBoost algoritmasının ardından başarılı sonuçlar elde etmiş, düşük

hata aralıklarında yüksek doğruluk oranlarına ulaşmıştır. Trilaterasyon algoritması test noktalarının yaklaşık %75'lik kısmında 0-20 cm arası hata değerlerini elde etmiştir. LR algoritması daha yüksek hata oranıyla en zayıf model olmuştur



Şekil 4.11. 9 LED için tek bölge ML tabanlı yöntem konum hataları CDF grafiği.

Şekil 4.12'de sunulan konumlara göre hata dağılımları incelendiğinde, makine öğrenmesi tabanlı algoritmalar arasında XGBoost ve RF algoritmalarının konum tahmini açısından en başarılı performansı sergilediği görülmektedir. Buna karşılık, kNN algoritması ortalama olarak iyi sonuçlar verse de özellikle kapsama alanının kenar bölgelerinde hata oranı artmış ve modelin oda kenarlarında zayıfladığı gözlemlenmiştir. LR algoritması ise genel olarak yüksek hata oranlarına ve bazı konumlarda ciddi sapmalara sahiptir.




Şekil 4.12. 9 LED için tek bölge ML tabanlı yöntem konumlara göre algoritma hataları: a) LR, b) kNN, c) RF, d) XGBoost.

4.2.5 12 LED için tek bölge ML tabanlı yöntem VLP performansı

Şekil 4.13(a)'da oda tavanından 0.5 metre aşağıda, koordinatları x-y olmak üzere (0.70-0.70), (3.10-0.70), (1.90-1.46), (4.29-1.46), (0.70-2.12), (3.10-2.12), (1.90-2.87), (4.29-2.87), (0.70-3.54), (3.10-3.54), (1.90-4.29), (4.29-4.29) noktalarına 12 adet LED yerleştirilmiş ve kırmızı renkle gösterilmiştir. Fotodedektörün konumlandırıldığı noktalar ise oda tabanından 0.85 metre yükseklikte, 25x25'lik bir ızgara düzeninde mavi noktalarla işaretlenmiştir. Bu fotodedektör, her noktada LED'lerden yayılan RSS şiddetini ölçmek amacıyla yerleştirilmiştir.

Şekil 4.13(b)'de ise belirlenen noktalarda fotodedektör tarafından 12 LED'den alınan RSS bilgilerinin X-Y düzlemindeki dağılımı üç boyutlu yüzey grafiği ile

gösterilmiştir. Renk skalası sinyal şiddetinin büyüklüğünü ifade etmekte olup sarı bölgeler yüksek RSS değerlerini, mor bölgeler ise düşük RSS bölgelerini temsil etmektedir. Her bir LED'in konumuna karşılık gelen alanlarda sinyal şiddeti maksimum seviyelere ulaşmakta ve merkezden uzaklaştıkça azalmaktadır.



Şekil 4.13. 12 LED için: a) oda yerleşimi, b) RSS verilerinin oda içindeki dağılımı.


Çizelge 4.6'da oluşturulan veri setinin algoritmalarla göre eğitim ve test süreleri görülmektedir. Buna göre kNN algoritması en kısa eğitim süresine sahipken, RF algoritması en uzun eğitim ve test süresine sahiptir. XGBoost algoritması ise nispeten daha uzun eğitim süresine rağmen test aşamasında hızlı ve verimli bir algoritma olarak öne çıkmaktadır.

Çizelge 4.6. 12 LED için algoritmalarla göre eğitim ve test süreleri.

ML algoritmaları	Eğitim süresi (ms)	Test süresi (ms)
kNN	2	1
LR	7,9	0,99
Rf	652	4
XGBoost	90	2


Şekil 4.11'de verilen grafiğe göre, XGBoost ve kNN algoritmaları test noktalarının yaklaşık %95'lik kısmında 0-20 cm arası hata değerlerini elde ederek en başarılı model olmuşlardır. RF ve trilaterasyon algoritmaları test noktalarının yaklaşık

%85'lik kısmında 0-20 cm arası hata değerlerini elde etmişlerdir. LR algoritması yüksek hata oranıyla en zayıf model olmuştur.



Şekil 4.14. 12 LED için tek bölge ML tabanlı yöntem konum hataları CDF grafiği.

Şekil 4.15'deki grafikler incelendiğinde XGBoost algoritması, en düşük ve dengeli hata dağılımıyla en başarılı algoritma olarak öne çıkmaktadır. RF algoritması da düşük hata değerleriyle güçlü bir performans sergilemiştir. kNN algoritması bazı bölgelerde iyi sonuçlar verirken, özellikle köşelerde yüksek hatalar gözlemlenmiştir. LR algoritması ise genel olarak yüksek hata değerleriyle en zayıf performansı göstermiştir.




Şekil 4.15. 12 LED için tek bölge ML tabanlı yöntem konumlara göre algoritma hataları: a) LR, b) kNN, c) RF, d) XGBoost.

4.2.6 16 LED için tek bölge ML tabanlı yöntem VLP performansı

Şekil 4.16(a)'da oda tavanından 0.5 metre aşağıda, koordinatları x-y olmak üzere (0.62-0.62), (1.87-0.62), (3.12-0.62), (4.37-0.62), (0.62-1.87), (1.87-1.87), (3.12-1.87), (4.37-1.87), (0.62-3.12), (1.87-3.12), (3.12-3.12), (4.37-3.12), (0.62-4.37), (1.87-4.37), (3.12-4.37), (4.37-4.37) noktalarına 16 adet LED yerleştirilmiş ve kırmızı renkle gösterilmiştir. Fotodedektörün konumlandırıldığı noktalar ise oda tabanından 0.85 metre yükseklikte, 25x25'lik bir ızgara düzeninde mavi noktalarla işaretlenmiştir. Bu fotodedektör, her noktada LED'lerden yayılan RSS şiddetini ölçmek amacıyla yerleştirilmiştir.

Şekil 4.16(b)'de ise belirlenen noktalarda fotodetektör tarafından 16 LED'den alınan RSS bilgilerinin X-Y düzlemindeki dağılımı üç boyutlu yüzey grafiği ile gösterilmiştir. Renk skalası sinyal şiddetinin büyüklüğünü ifade etmekte olup sarı bölgeler yüksek RSS değerlerini, mor bölgeler ise düşük RSS bölgelerini temsil etmektedir. Her bir LED'in konumuna karşılık gelen alanlarda sinyal şiddeti maksimum seviyelere ulaşmakta ve merkezden uzaklaştıkça azalmaktadır.




Şekil 4.16. 16 LED için: a) oda yerleşimi, b) RSS verilerinin oda içindeki dağılımı.

Çizelge 4.7'de oluşturulan veri setinin algoritmalara göre eğitim ve test süreleri görülmektedir. Buna göre kNN algoritması en kısa eğitim süresine sahipken, RF algoritması en uzun eğitim ve test süresine sahiptir. XGBoost algoritması ise nispeten daha uzun eğitim süresine rağmen test aşamasında hızlı ve verimli bir algoritma olarak öne çıkmaktadır.

Çizelge 4.7. 16 LED için algoritmalara göre eğitim ve test süreleri.


ML algoritmaları	Eğitim süresi (ms)	Test süresi (ms)
kNN	2	1
LR	8	0,99
RF	817	7
XGBoost	84,4	2

Şekil 4.17’de verilen grafiğe göre, XGBoost algoritması test noktalarının yaklaşık %95’lik kısmında 0-20 cm arası hata değerlerini elde ederek en başarılı model olmuştur. kNN algoritması test noktalarının yaklaşık %90’lık kısmında, RF ve trilaterasyon algoritmaları da test noktalarının %85’lik kısmında 0-20 cm arası hata değerlerini elde etmişlerdir. LR algoritması en zayıf model olmuştur.



Şekil 4.17. 16 LED için tek bölge ML tabanlı yöntem konum hataları CDF grafiği.


Şekil 4.18’deki grafikler incelendiğinde XGBoost algoritması, en düşük ve dengeli hata dağılımıyla en başarılı algoritma olarak öne çıkmaktadır. RF algoritması da düşük hata değerleriyle güçlü bir performans sergilemiştir. kNN algoritması bazı bölgelerde iyi sonuçlar verirken, özellikle köşelerde yüksek hatalar gözlemlenmiştir. LR algoritması ise genel olarak yüksek hata değerleriyle en zayıf performansı göstermiştir.



Şekil 4.18. 16 LED için tek bölge ML tabanlı yöntem konumlara göre algoritma hataları: a) LR, b) kNN, c) RF, d) XGBoost.

4.2.7 Algoritmalarla göre tek bölge ML tabanlı yöntem VLP performansının hata değerleri


Şekil 4.19'daki verilere genel olarak bakıldığında, XGBoost ve RF algoritmaları hem ortalama hem maksimum hata açısından en iyi performansı göstermektedir. LR ise tüm metriklerde en yüksek hataları vermiştir. Bu durum, modelin veri setine yeterince iyi uyum sağlayamadığını ve doğrusal yapıların bu tür konumlandırma problemlerinde yetersiz kaldığını göstermektedir. kNN ve trilaterasyon algoritmaları orta düzeyde performans sergilemiştir. Ayrıca, LED sayısı arttıkça tüm algoritmaların hata oranları azalmaktadır. Bu da daha fazla veri noktasının konum tahmin doğruluğunu artırdığını göstermektedir. Genel olarak, makine öğrenimi tabanlı modeller geleneksel yöntemlere göre çok daha başarılı sonuçlar vermektedir.



Şekil 4.19. LED sayılarına göre algoritmaların hata miktarları: a) Ortalama hata, b) Maksimum hata.

4.3 Bölgelendirmeli ML Tabanlı Yöntem VLP Performansları


Bu bölümde 4, 8 ve 12 LED ile 625 noktadan ölçülen RSS verileri, Şekil 4.20'deki gibi 3 farklı senaryoda 2 farklı bölgeye ayrılmış, her bölgede ML algoritmaları ayrı ayrı eğitilip test edilerek konum-hata performansları elde edilmiştir.



Şekil 4.20. Veri setinin bölgelere ayrılması: a) 0.5m-4.5m, b) 0.9m-4.1m, c) 1.3m-3.7m.


4.3.1 4 LED için 0.5m-4.5m bölgelendirmeli ML tabanlı yöntem VLP performansı

Şekil 4.21’de, RF algoritmasının test noktalarının yaklaşık %90’nında 0-20 cm arası hata yaptığı görülmektedir. XGBoost algoritması da RF algoritmasına benzer performans göstermiştir. LR algoritması ise en başarısız model olmuştur.



Şekil 4.21. 4 LED için 0.5m-4.5m bölgelendirmeli ML tabanlı yöntem konum hataları CDF grafiği.


Şekil 4.22’de veri seti bölgelendirildiğinde, tek bölgeli yönteme kıyasla tüm ML algoritmalarının ortalama hata miktarlarında azalma olduğu görülmektedir.



Şekil 4.22. 4 LED için tek bölgeli ve 0.5m-4.5m bölgelendirmeli ML tabanlı yöntemlerin ortalama hata miktarlarının karşılaştırılması.


4.3.2 4 LED için 0.9m-4.1m bölgelendirmeli ML tabanlı yöntem VLP performansı

Şekil 4.23'te, RF ve XGBoost algoritmalarının test noktalarının yaklaşık %80'inde 0-20 cm arası hata yaptığı görülmektedir. LR algoritması ise en başarısız model olmuştur.



Şekil 4.23. 4 LED için 0.9m-4.1m bölgelendirmeli ML tabanlı yöntem konum hataları CDF grafiği.


Şekil 4.24'te veri seti bölgelendirildiğinde, tek bölge yönteme kıyasla LR, kNN ve XGBoost algoritmalarının ortalama hata miktarlarında azalma olurken, RF algoritmasının ortalama hata miktarında artış görülmektedir.



Şekil 4.24. 4 LED için tek bölge ve 0.9m-4.1m bölgelendirmeli ML tabanlı yöntemlerin ortalama hata miktarlarının karşılaştırılması.


4.3.3 4 LED için 1.3m-3.7m bölgelendirmeli ML tabanlı yöntem VLP performansı

Şekil 4.25'te RF ve XGBoost algoritmalarının, test noktalarının yaklaşık %70'inde 0-20 cm arasında hata yaptığı görülmektedir. LR algoritması ise en başarısız model olmuştur.



Şekil 4.25. 4 LED için 1.3m-3.7m bölgelendirmeli ML tabanlı yöntem konum hataları CDF grafiği.


Şekil 4.26'da veri seti bölgelendirildiğinde, tek bölge yönteme kıyasla LR ve kNN algoritmalarının ortalama hata miktarlarında azalma olurken, RF ve XGBoost algoritmalarının ortalama hata miktarlarında artış görülmektedir.



Şekil 4.26. 4 LED için tek bölge ve 1.3m-3.7m bölgelendirmeli ML tabanlı yöntemlerin ortalama hata miktarlarının karşılaştırılması.


4.3.4 8 LED için 0.5m-4.5m bölgelendirmeli ML tabanlı yöntem VLP performansı

Şekil 4.27’de XGBoost, RF ve kNN algoritmalarının, test noktalarının yaklaşık %90’ında 0-20 cm arası hata yaptığı görülmektedir. LR algoritması ise en başarısız model olmuştur.



Şekil 4.27. 8 LED için 0.5m-4.5m bölgelendirmeli ML tabanlı yöntem konum hataları CDF grafiği.


Şekil 4.28’de veri seti bölgelendirildiğinde, tek bölgeli yönteme kıyasla tüm algoritmaların ortalama hata miktarlarında azalma olduğu görülmektedir.



Şekil 4.28. 8 LED için tek bölgeli ve 0.5m-4.5m bölgelendirmeli ML tabanlı yöntemlerin ortalama hata miktarlarının karşılaştırılması.


4.3.5 8 LED için 0.9m-4.1m bölgelendirmeli ML tabanlı yöntem VLP performansı

Şekil 4.29’da XGBoost ve kNN algoritmalarının, test noktalarının yaklaşık %90’ında 0-20 cm arası hata yaptığı görülmektedir. LR algoritması ise en başarısız model olmuştur.



Şekil 4.29. 8 LED için 0.9m-4.1m bölgelendirmeli ML tabanlı yöntem konum hataları CDF grafiği.


Şekil 4.30’da veri seti bölgelendirildiğinde, tek bölge yönteme kıyasla LR, XGBoost ve RF algoritmalarının ortalama hata miktarlarında azalma olurken, kNN algoritmasının ortalama hata miktarında artış görülmektedir.



Şekil 4.30. 8 LED için tek bölge ve 0.9m-4.1m bölgelendirmeli ML tabanlı yöntemlerin ortalama hata miktarlarının karşılaştırılması.


4.3.6 8 LED için 1.3m-3.7m bölgelendirmeli ML tabanlı yöntem VLP performansı

Şekil 4.31’de, XGBoost algoritmasının test noktalarının yaklaşık %95’inde 0-20 cm arası hata yaptığı görülmektedir. RF ve kNN algoritmaları benzer performans göstermişlerdir. LR algoritması ise en başarısız model olmuştur.



Şekil 4.31. 8 LED için 1.3m-3.7m bölgelendirmeli ML tabanlı yöntem konum hataları CDF grafiği.


Şekil 4.32’de veri seti bölgelendirildiğinde, tek bölgeli yönteme kıyasla LR ve XGBoost algoritmalarının ortalama hata miktarlarında azalma olurken, kNN ve RF algoritmalarının ortalama hata miktarlarında artış görülmektedir.



Şekil 4.32. 8 LED için tek bölgeli ve 1.3m-3.7m bölgelendirmeli ML tabanlı yöntemlerin ortalama hata miktarlarının karşılaştırılması.


4.3.7 12 LED için 0.5m-4.5m bölgelendirmeli ML tabanlı yöntem VLP performansı

Şekil 4.33'te, kNN, RF ve XGBoost algoritmalarının, test noktalarının yaklaşık %90'ında 0-20 cm arası hata yaptığı görülmektedir. LR algoritması ise en başarısız model olmuştur.



Şekil 4.33. 12 LED için 0.5m-4.5m bölgelendirmeli ML tabanlı yöntem konum hataları CDF grafiği.


Şekil 4.34'te veri seti bölgelendirildiğinde, tek bölgeli yönteme kıyasla LR ve RF algoritmalarının ortalama hata miktarlarında azalma olurken, kNN ve XGBoost algoritmalarının ortalama hata miktarlarında artış görülmektedir.



Şekil 4.34. 12 LED için tek bölgeli ve 0.5m-4.5m bölgelendirmeli ML tabanlı yöntemlerin ortalama hata miktarlarının karşılaştırılması.


4.3.8 12 LED için 0.9m-4.1m bölgelendirmeli ML tabanlı yöntem VLP performansı

Şekil 4.35'te, kNN ve XGBoost algoritmalarının test noktalarının yaklaşık %90'ında 0-20 cm arası hata yaptığı görülmektedir. LR algoritması ise en başarısız model olmuştur.



Şekil 4.35. 12 LED için 0.9m-4.1m bölgelendirmeli ML tabanlı yöntem konum hataları CDF grafiği.


Şekil 4.36'da veri seti bölgelendirildiğinde, tek bölge yönteme kıyasla LR algoritmasının ortalama hata miktarında azalma olurken, kNN, RF ve XGBoost algoritmalarının ortalama hata miktarlarında artış görülmektedir.



Şekil 4.36. 12 LED için tek bölge ve 0.9m-4.1m bölgelendirmeli ML tabanlı yöntemlerin ortalama hata miktarlarının karşılaştırılması.


4.3.9 12 LED için 1.3m-3.7m bölgelendirmeli ML tabanlı yöntem VLP performansı

Şekil 4.37’de, XGBoost ve kNN algoritmalarının, test noktalarının yaklaşık %90’ında 0-20 cm arası hata yaptığı görülmektedir. LR algoritması ise en başarısız model olmuştur.



Şekil 4.37. 12 LED için 1.3m-3.7m bölgelendirmeli ML tabanlı yöntem konum hataları CDF grafiği.

Şekil 4.38’de veri seti bölgelendirildiğinde, tek bölgeli yönteme kıyasla LR algoritmasının ortalama hata miktarında azalma olurken, XGBoost, kNN ve RF algoritmalarının ortalama hata miktarlarında artış görülmektedir.



Şekil 4.38. 12 LED için tek bölgeli ve 1.3m-3.7m bölgelendirmeli ML tabanlı yöntemlerin ortalama hata miktarlarının karşılaştırılması.

5. SONUÇ VE ÖNERİLER

Bu tezde, VLP sistemleri için ML algoritmalarının performansı incelenmiştir. Belirlenen bina içi senaryoda değişen LED sayıları ile konum-hata performansları çıkartılmıştır. Sinyal modelinde LOS sinyal ve NLOS dikkate alınmış ve toplanan RSS verileri ile farklı ML algoritmaları eğitilmiştir. Performanslar karşılaştırıldığında XGBoost ve RF algoritmaları en iyi performansı sergilemiştir. kNN algoritmasının konum-hata performansı bu algoritmaların gerisinde kalmıştır. LR algoritması en düşük performans göstermiştir. Geleneksel trilaterasyon algoritması ile karşılaştırıldığında, XGBoost, RF ve kNN algoritmalarının daha iyi performans sağladığı gösterilmiştir. Bina içi senaryodaki LED sayıları arttıkça algoritmaların konum-hata değerlerinin azaldığı görülmüştür. Düşük LED sayılarında RF algoritması en iyi performansı gösterirken, yüksek LED sayılarında XGBoost algoritması daha iyi performans göstermiştir. Çalışmanın devamında bina içi ortam bölgelendirilerek ML algoritmaları bu bölgeler için ayrı ayrı eğitilmiştir.

4 LED'in kullanıldığı senaryoda tek bölgede test edilen ML algoritmalarında en düşük ortalama hata RF algoritması ile elde edilmiş olup 12 cm olarak hesaplanmıştır. İç mekan ortamının bölgelendirilmesi sonucu bu hata miktarı yine RF algoritması ile 9 cm'ye düşmüş ve konum-hata performansında 3 cm'lik iyileşme meydana gelmiştir.

8 LED'in kullanıldığı senaryoda tek bölgede test edilen ML algoritmalarında en düşük ortalama hata XGBoost algoritması ile elde edilmiş olup 9 cm olarak hesaplanmıştır. İç mekan ortamının bölgelendirilmesi sonucu bu hata miktarı yine XGBoost algoritması ile 7.6 cm'ye düşmüş ve konum-hata performansında 1.4 cm'lik iyileşme meydana gelmiştir.

12 LED'in kullanıldığı senaryoda tek bölgede test edilen ML algoritmalarında en düşük ortalama hata XGBoost algoritması ile elde edilmiş olup 9.7 cm olarak hesaplanmıştır. İç mekan ortamının bölgelendirilmesi sonucu bu hata miktarı RF algoritması ile 9.2 cm'ye düşmüş ve konum-hata performansında 0.5 cm'lik iyileşme meydana gelmiştir.

Elde edilen konum hataları dikkate alındığında tek bölgede test edilen ML algoritmalarına göre performans iyileşmeleri sağlandığı gösterilmiştir. Önerilen yaklaşım, NLOS sinyallerinin etkisini azaltarak hem geleneksel trilaterasyon algoritmasına hem de tek bölgede test edilen ML tabanlı yöntemlere kıyasla daha düşük ortalama konumlandırma hataları elde edilmesini sağlamıştır.

Gelecekteki çalışmalarda bölgelendirme senaryosu üzerinden adaptif performanslar elde edilebilir. Bölgelendirilmiş kısımlardaki farklı ML algoritma performansları içerisinde en iyi olanlar birleştirilerek bina içi ortamda daha iyi bir ortalama hata performansı elde etmek mümkün olabilir. Yansımaların yoğun olduğu duvar kenarları dikkate alınarak iç kısma doğru amorf bölgeler tespit edildikten sonra farklı algoritmalarla performanslar çıkartılıp adaptif sonuçlar değerlendirilebilir. Objelerin de yer aldığı gerçekçi bina içi senaryolar için RSS veri setleri oluşturulup bu veri setleri üzerinden adaptif performanslar gelecekteki çalışmalarda değerlendirilebilir. Bununla birlikte ML algoritmalarının belirli bir işlem maliyeti karşılığında optimizasyonu yapılarak ortalama hata oranlarında iyileştirme sağlanabilir.

Bu tez hem akademik hem de endüstriyel uygulamalarda iç mekan konumlandırma sistemlerine yönelik yeni bir bakış açısı sunmayı hedeflemiştir. Özellikle, hastaneler, alışveriş merkezleri, havaalanları, fabrikalar ve akıllı binalar gibi kapalı alanlarda konum belirleme ihtiyacının arttığı günümüzde, VLP tabanlı konumlandırma sistemlerinin önemli bir alternatif olduğu ortaya konulmuştur. LED tabanlı sistemlerin yaygınlaşması ile, gelecekte bu teknolojinin iç mekan navigasyonu, akıllı aydınlatma sistemleri ve artırılmış gerçeklik gibi farklı alanlarda kullanılması muhtemeldir.

KAYNAKLAR

1. Samama, N., 2008. Global positioning: technologies and performance, Wiley.
2. Goswami, S., 2012a. Indoor Location Technologies, Springer.
3. Paksoy, A., Bak, O. A. ve Sarısakal, M. N. S., 2012. The global positioning system—Navigation tool of the future. *IU-Journal of Electrical & Electronics Engineering*, 2, 1, 467–476.
4. Cheung, K., Lightsey, G. ve Lee, C., 2018. Accuracy/computation performance of a new trilateration scheme for GPS-style localization1. *IEEE Aerospace Conference*, 1–10.
5. Watson, R., Lachapelle, G., Klukas, R., Turunen, S., Pietilä, S. ve Halivaara, I., 2005. Investigating GPS Signals Indoors with Extreme High-Sensitivity Detection Techniques. *NAVIGATION Journal of the Institute of Navigation*, 52, 4, 199–213.
6. Twana, M. ve Varol, A., 2020. Review of the Internet of Things for Healthcare Monitoring. *8th International Symposium on Digital Forensics and Security (ISDFS)*, 1–6.
7. Yang, Z., Zhou, Z. ve Liu, Y., 2013. From RSSI to CSI. *ACM Computing Surveys*, 46, 2, 1–32.
8. Castro, P., Chiu, P., Kremenek, T. ve Muntz, R., 2001. A probabilistic room location service for wireless networked environments. In *Lecture notes in computer science*, 18–34.
9. Haeberlen, A., Flannery, E., Ladd, A. M., Rudys, A., Wallach, D. S. ve Kavraki, L. E., 2004. Practical robust localization over large-scale 802.11 wireless networks. *Proceedings of the 28th Annual International Conference on Mobile Computing and Networking*, 70-84.
10. Krishnan, P., Krishnakumar, A., Ju, W., Mallows, C. ve Gamt, S., 2004. A system for LEASE: Location estimation assisted by stationary emitters for indoor RF wireless networks. *INFOCOM 2004. Twenty-third Annual Joint Conference of the IEEE Computer and Communications Societies*, 2, 1001–1011.
11. Ladd, A. M., Bekris, K. E., Rudys, A., Kavraki, L. E. ve Wallach, D. S., 2005. Robotics-Based location sensing using wireless ethernet. *Wireless Networks*, 11, 1–2, 189–204.
12. Xiao, J., Wu, K., Yi, Y., Wang, L. ve Ni, L. M., 2013. Pilot: Passive Device-Free Indoor Localization Using Channel State Information. *IEEE 33rd International Conference on Distributed Computing Systems*, 236–245.

13. Che, R. ve Chen, H. (2023). Channel State Information Based Indoor Fingerprinting Localization. *Sensors*, 23, 13, 5830.
14. Sharma, M. 2014. Effective Channel State Information (CSI) Feedback for MIMO Systems in Wireless Broadband Communications. Doktora Tezi, Queensland University of Technology, Brisbane, Australia.
15. Sanam, T. 2020. A Channel State Information Based Device Free Indoor Localization for Context Aware Computing: A Machine Learning Approach. Doktora Tezi, The State University of New Jersey, New Jersey, USA.
16. Obeidat, H., Shuaieb, W., Obeidat, O. ve Abd-Alhameed, R., 2021. A review of indoor localization techniques and wireless technologies. *Wireless Personal Communications*, 119, 1, 289–327.
17. Zafari, F., Gkelias, A. ve Leung, K. K., 2019. A survey of indoor localization Systems and technologies. *IEEE Communications Surveys & Tutorials*, 21, 3, 2568–2599.
18. Xiong, J. ve Jamieson, K., 2013. ArrayTrack: a fine-grained indoor location system. *Networked Systems Design and Implementation*, 71–84. <http://groups.csail.mit.edu/netmit/6.888/www/papers/arraytrack.pdf>.
19. Kumar, S., Gil, S., Katabi, D. ve Rus, D., 2014. Accurate indoor localization with zero start-up cost. *Proceedings of the 28th Annual International Conference on Mobile Computing and Networking*.
20. Dargie, W. ve Poellabauer, C., 2010. *Fundamentals of Wireless Sensor Networks: Theory and practice*. Wiley.
21. Gu, Y., Lo, A. ve Niemegeers, I., 2009. A survey of indoor positioning systems for wireless personal networks. *IEEE Communications Surveys & Tutorials*, 11, 1, 13–32.
22. Zhang, D., Xia, F., Yang, Z., Yao, L. ve Zhao, W., 2010. Localization Technologies for Indoor Human Tracking. 2010 5th International Conference on Future Information Technology, 1–6.
23. De-La-Llana-Calvo, Á., Lázaro-Galilea, J., Gardel-Vicente, A., Rodríguez-Navarro, D., Bravo-Muñoz, I. ve Espinosa-Zapata, F., 2019. Characterization of multipath effects in indoor positioning systems by AOA and POA based on optical signals. *Sensors*, 19, 4, 917.
24. Zafari, F., Gkelias, A. ve Leung, K. K., 2019. A survey of indoor localization Systems and technologies. *IEEE Communications Surveys & Tutorials*, 21, 3, 2568–2599.
25. Liu, H., Darabi, H., Banerjee, P. ve Liu, J., 2007. Survey of wireless indoor Positioning Techniques and Systems. *IEEE Transactions on Systems Man and Cybernetics Part C (Applications and Reviews)*, 37, 6, 1067–1080.

26. Centenaro, M., Vangelista, L., Zanella, A. ve Zorzi, M., 2016. Long-range communications in unlicensed bands: the rising stars in the IoT and smart city scenarios. *IEEE Wireless Communications*, 23, 5, 60–67.
27. Adame, T., Bel, A., Bellalta, B., Barcelo, J. ve Oliver, M., 2014. IEEE 802.11AH: the WiFi approach for M2M communications. *IEEE Wireless Communications*, 21, 6, 144–152.
28. Vasisht, D., Kumar, S. ve Katabi, D., 2016. Decimeter-level localization with a single WiFi access point. *Networked Systems Design and Implementation*, 165–178.
29. Kumar, S., Gil, S., Katabi, D. ve Rus, D., 2014. Accurate indoor localization with zero start-up cost. *Proceedings of the 28th Annual International Conference on Mobile Computing and Networking*. 483-494.
30. Joseph, R. ve Sasi, S. B., 2018. Indoor positioning using WiFi fingerprint. In *2018 International Conference on Circuits and Systems in Digital Enterprise Technology*, 1–3. IEEE.
31. Kotaru, M., Joshi, K., Bharadia, D. ve Katti, S., 2015. SpotFi. *ACM SIGCOMM Computer Communication Review*, 45, 4, 269–282.
32. Qureshi, U. M., Umair, Z. ve Hancke, G. P., 2019. Evaluating the implications of varying Bluetooth low energy (BLE) transmission power levels on wireless indoor localization accuracy and precision. *Sensors*, 19, 15, 3282.
33. Altini, M., Brunelli, D., Farella, E. ve Benini, L., 2010. Bluetooth indoor localization with multiple neural networks. In *IEEE 5th International Symposium on Wireless Pervasive Computing 2010*, 295–300.
34. Zafari, F., Gkelias, A. ve Leung, K. K., 2019. A survey of indoor localization systems and technologies. *IEEE Communications Surveys & Tutorials*, 21, 3, 2568–2599.
35. Cheung, K. C., Intille, S. S. ve Larson, K., 2006. An inexpensive bluetooth-based indoor positioning hack. In *Proceedings of UbiComp*, vol. 6.
36. Bianchi, V., Ciampolini, P. ve De Munari, I., 2018. RSSI-Based indoor localization and identification for ZigBee wireless sensor networks in smart homes. *IEEE Transactions on Instrumentation and Measurement*, 68, 2, 566–575.
37. Sugano, M., Kawazoe, T., Ohta, Y. ve Murata, M., 2006. Indoor localization system using RSSI measurement of wireless sensor network based on ZigBee standard. *Wireless Optical Communication*, 538, 1–6.
38. Tesoriero, R., Tebar, R., Gallud, J., Lozano, M. ve Penichet, V., 2009. Improving location awareness in indoor spaces using RFID technology. *Expert Systems With Applications*, 37, 1, 894–898.

39. Tesoriero, R., Gallud, J., Lozano, M. ve Penichet, V., 2008. Using active and passive RFID technology to support indoor location-aware systems. *IEEE Transactions on Consumer Electronics*, 54, 2, 578–583.
40. Borriello, G., 2005. Session details: RFID: tagging the world. *Communications of the ACM*, 48, 9.
41. Deak, G., Curran, K. ve Condell, J., 2012. A survey of active and passive indoor localisation systems. *Computer Communications*, 35, 16, 1939–1954.
42. Dian, Z., Kezhong, L. ve Rui, M., 2015. A precise RFID indoor localization system with sensor network assistance. *China Communications*, 12, 4, 13–22.
43. Bekkali, A., Sanson, H. ve Matsumoto, M., 2007. RFID Indoor Positioning Based on Probabilistic RFID Map and Kalman Filtering. In *Third IEEE International Conference on Wireless and Mobile Computing, Networking and Communications*, 21-21.
44. Liu, H., Darabi, H., Banerjee, P. ve Liu, J., 2007. Survey of wireless indoor Positioning Techniques and Systems. *IEEE Transactions on Systems Man and Cybernetics Part C (Applications and Reviews)*, 37, 6, 1067–1080.
45. Alarifi, A., Al-Salman, A., Alsaleh, M., Alnafessah, A., Al-Hadhrani, S., Al-Ammar, M. A. ve Al-Khalifa, H. S., 2016. Ultra Wideband Indoor Positioning Technologies: Analysis and Recent Advances. *Sensors*, 16, 5, 707.
46. Liu, K., Liu, X. ve Li, X., 2013. Guoguo. In *Proceeding of the 11th Annual International Conference on Mobile Systems, Applications, and Services*, 235–248.
47. Huang, W., Xiong, Y., Li, X., Lin, H., Mao, X., Yang, P., Liu, Y. ve Wang, X., 2014. Swadloon: direction finding and indoor localization using acoustic signal by shaking smartphones. *IEEE Transactions on Mobile Computing*, 14, 10, 2145–2157.
48. Hazas, M. ve Hopper, A., 2006. Broadband ultrasonic location systems for improved indoor positioning. *IEEE Transactions on Mobile Computing*, 5, 5, 536–547.
49. McCarthy, M. R., 2007. The BUZZ: Narrowband Ultrasonic Positioning for Wearable Computers. *Doktora Tezi*, University of Bristol, Bristol, UK.
50. Priyantha, N. B., 2005. The Cricket indoor location system. *Doktora Tezi*, Massachusetts Institute of Technology, Massachusetts, USA.
51. Ijaz, F., Yang, H. K., Ahmad, A. W. ve Lee, C., 2013. Indoor positioning: A review of indoor ultrasonic positioning systems. In *2013 15th International Conference on Advanced Communications Technology (ICACT)*, 1146-1150.
52. Abu-Shaban, Z., Zhou, X., Abhayapala, T., Seco-Granados, G. ve Wymeersch, J., 2015. A survey of indoor localization systems and techniques. *IEEE Communications Surveys and Tutorials*, 17, 3, 1333–1367.

- H., 2018. Error bounds for uplink and downlink 3D localization in 5G millimeter wave systems. *IEEE Transactions on Wireless Communications*, 17, 8, 4939–4954.
53. Ghaseminajm, F., Abu-Shaban, Z., Ikki, S. S., Wymeersch, H. ve Benson, C. R., 2020. Localization error bounds for 5G MMWAVE systems under I/Q imbalance. *IEEE Transactions on Vehicular Technology*, 69, 7, 7971–7975.
 54. Rappaport, T. S., Sun, S., Mayzus, R., Zhao, H., Azar, Y., Wang, K., Wong, G. N., Schulz, J. K., Samimi, M. ve Gutierrez, F., 2013. Millimeter wave mobile communications for 5G cellular: It will work! *IEEE Access*, 1, 335–349.
 55. Rappaport, T. S., Gutierrez, F., Ben-Dor, E., Murdock, J. N., Qiao, Y. ve Tamir, J. I., 2013. Broadband Millimeter-Wave propagation measurements and models using Adaptive-Beam antennas for outdoor urban cellular communications. *IEEE Transactions on Antennas and Propagation*, 61, 4, 1850–1859.
 56. Zhuang, Y., Hua, L., Qi, L., Yang, J., Cao, P., Cao, Y., Wu, Y., Thompson, J. ve Haas, H., 2018. A survey of positioning systems using visible LED lights. *IEEE Communications Surveys & Tutorials*, 20, 3, 1963–1988.
 57. Pathak, P. H., Feng, X., Hu, P. ve Mohapatra, P., 2015. Visible Light Communication, Networking, and Sensing: A Survey, Potential and challenges. *IEEE Communications Surveys & Tutorials*, 17, 4, 2047–2077.
 58. He, S. ve Chan, S. G., 2015. Wi-Fi Fingerprint-Based indoor positioning: recent advances and comparisons. *IEEE Communications Surveys & Tutorials*, 18, 1, 466–490.
 59. Hassan, N. U., Naeem, A., Pasha, M. A., Jadoon, T. ve Yuen, C., 2015. Indoor positioning using visible LED lights. *ACM Computing Surveys*, 48, 2, 1–32.
 60. Wang, R., Niu, G., Cao, Q., Chen, C. S. ve Ho, S.-W., 2024. A Survey of Visible-Light-Communication-Based Indoor Positioning Systems. *Sensors*, 24, 16, 5197.
 61. Chew, M.-T., Alam, F., Noble, F. K., Legg, M. ve Gupta, G. S., 2024. Visible Light Positioning-Based Robot Localization and Navigation. *Electronics*, 13, 2, 368.
 62. Rahman, A. B. M. M., Li, T. ve Wang, Y., 2020. Recent Advances in Indoor Localization via Visible Lights: A Survey. *Sensors*, 20, 5, 1382.
 63. Ghonim, A. M., Salama, W. M., El-Fikky, A. E. A., Khalaf, A. a. M. ve Shalaby, H. M. H., 2021. Underwater localization system based on visible-light communications using neural networks. *Applied Optics*, 60, 13, 3977.
 64. Han, J., Pei, J. ve Kamber, M., 2011. *Data mining: Concepts and techniques*, Elsevier.

65. Celebi, M. E. ve Aydin, K., 2016. Unsupervised learning algorithms (1st ed.), Springer.
66. Feng, P., Qin, D., Zhao, M., Guo, R. ve Berhane, T. M., 2019. Unsupervised indoor positioning system based on environmental signatures. *Entropy*, 21, 3, 327.
67. Xue, W., Hu, Z., Wang, N. ve Zhang, L., 2020. Unsupervised Learning Based Acoustic NLOS Identification for Smart phone Indoor Positioning. 2022 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC), 1–6.
68. Tran, H. Q. ve Ha, C., 2022. Machine learning in indoor visible light positioning systems: A review. *Neurocomputing*, 491, 117–131.
69. Choi, J., Choi, Y.-S. ve Talwar, S., 2019. Unsupervised learning technique to obtain the coordinates of Wi-Fi access points. In 2019 International Conference on Indoor Positioning and Indoor Navigation (IPIN), 1–6.
70. Zhang, Z., Chen, H., Hong, X. ve Chen, J., 2019. Accuracy enhancement of indoor visible light positioning using point-wise reinforcement learning. In 2019 Optical Fiber Communications Conference and Exhibition (OFC), 1–3. San Diego, CA, USA.
71. Tran, H. Q. ve Ha, C., 2019. Improved Visible Light-Based Indoor Positioning System Using Machine Learning Classification and Regression. *Applied Sciences*, 9, 6, 1048.
72. Raes, W., Knudde, N., De Bruycker, J., Dhaene, T. ve Stevens, N., 2020. Experimental Evaluation of Machine Learning Methods for Robust Received Signal Strength-Based Visible Light Positioning. *Sensors*, 20, 21, 6109.
73. Tran, H. Q. ve Ha, C., 2019. Fingerprint-Based Indoor Positioning System Using Visible Light Communication—A Novel Method for Multipath Reflections. *Electronics*, 8, 1, 63.
74. Plets, D., Bastiaens, S., Martens, L. ve Joseph, W., 2019. An Analysis of the Impact of LED Tilt on Visible Light Positioning Accuracy. *Electronics*, 8, 4, 389.
75. Karibasappa, R. ve Kumar, A., 2024. Comparative analysis of fingerprint-based models for indoor visible light positioning: superior performance of ANN over KNN and DNN. *Journal of Optics*.
76. Abdalmajeed, A. M. M., Mahmoud, M., El-Fikky, A. E. A., Fayed, H. A. ve Aly, M. H., 2023. Improved indoor visible light positioning system using machine learning. *Optical and Quantum Electronics*, 55, 3.
77. De Bruycker, J., De Wilde, M., Garbuglia, F., Nikova, I., Couckuyt, I., Dhaene, T. ve Stevens, N., 2024. Evaluation of Machine Learning Models for Received

- Signal Strength Based Visible Light Positioning with Obstacles. 2022 13th International Symposium on Communication Systems, Networks and Digital Signal Processing (CSNDSP), 318–323.
78. Liu, R., Liang, Z., Yang, K. ve Li, W., 2022. Machine Learning based visible light indoor positioning with Single-LED and single rotatable photo detector. *IEEE Photonics Journal*, 14, 3, 1–11.
 79. Bakar, A. H. A., Glass, T., Tee, H. Y., Alam, F. ve Legg, M., 2020. Accurate visible light positioning using Multiple-Photodiode receiver and machine learning. *IEEE Transactions on Instrumentation and Measurement*, 70, 1–12.
 80. Rekkas, V. P., Sotiroudis, S., Plets, D., Joseph, W. ve Goudos, S. K., 2022. Visible Light Positioning: a machine learning approach. 2022 7th South-East Europe Design Automation, Computer Engineering, Computer Networks and Social Media Conference (SEEDA-CECNSM), 1–5.
 81. Alkandari, Y., Ijaz, M., Ekpo, S., Adebisi, B., Soto, I., Zamorano-Illanes, R. ve Azurdia, C., 2023. Optimization of Visible Light Positioning in Industrial Applications using Machine Learning. 2023 South American Conference on Visible Light Communications (SACVLC), 141–146.
 82. Zhuang, Y., Hua, L., Qi, L., Yang, J., Cao, P., Cao, Y., Wu, Y., Thompson, J. ve Haas, H., 2018. A survey of positioning systems using visible LED lights. *IEEE Communications Surveys & Tutorials*, 20, 3, 1963–1988.
 83. Tanaka, T. ve Haruyama, S., 2009. New Position Detection Method Using Image Sensor and Visible Light LEDs. 2009 Second International Conference on Machine Vision, 150–153.
 84. Çelik, Y., 2019. LED dağılımının RSSI tabanlı görünür ışık konum belirleme sistemleri üzerindeki etkisi. *European Journal of Science and Technology*, 823–832.
 85. Lausnay, S. D., Strycker, L. D., Goemaere, J., Stevens, N. ve Nauwelaers, B., 2015. Influence of MAI in a CDMA VLP system. 2015 International Conference on Indoor Positioning and Indoor Navigation (IPIN), 1–9.
 86. Qiu, Y., Chen, S., Chen, H. ve Meng, W., 2017. Visible light communications based on CDMA technology. *IEEE Wireless Communications*, 25, 2, 178–185.
 87. Mousa, F. I. K., Almaadeed, N., Busawon, K., Bouridane, A., Binns, R. ve Elliott, I., 2018. Indoor visible light communication localization system utilizing received signal strength indication technique and trilateration method. *Optical Engineering*, 57, 1, 1.
 88. Lee, K., Park, H. ve Barry, J. R., 2011. Indoor channel characteristics for visible light communications. *IEEE Communications Letters*, 15, 2, 217–219.
 89. Biau, G. ve Scornet, E., 2016. A random forest guided tour. *Test*, 25, 2, 197–227.

90. Zhou, Z., Qiu, C. ve Zhang, Y., 2023. A comparative analysis of linear regression, neural networks and random forest regression for predicting air ozone employing soft sensor models. *Scientific Reports*, 13, 1.
91. Halder, R. K., Uddin, M. N., Uddin, M. A., Aryal, S. ve Khraisat, A., 2024. Enhancing K-nearest neighbor algorithm: a comprehensive review and performance analysis of modifications. *Journal of Big Data*, 11, 1.
92. Chen, T. ve Guestrin, C., 2016. XGBoost: A Scalable Tree Boosting System, 785–794.



ÖZGEÇMİŞ

Adı ve Soyadı : Mehmet Akif ÇELİK

EĞİTİM BİLGİLERİ (Kurum ve Yıl)

Lisans : Balıkesir Üniversitesi, Bilgisayar ve Öğretim Teknolojileri Öğretmenliği Bölümü, 2009-2013

Lisans : Niğde Ömer Halisdemir Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, 2014-2019

Yüksek Lisans : Aksaray Üniversitesi, Elektrik-Elektronik Mühendisliği Anabilim Dalı, 2022-2025

MESLEKİ DENEYİM VE ÖDÜLLERİ

1. Milli Eğitim Bakanlığı / Bilişim Teknolojileri Öğretmeni (2013-2021)
2. Milli Eğitim Bakanlığı / Elektronik Öğretmeni (2021-2025)

TEZDEN ÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER

Kongrelerde Sunulan Bildiriler

1. Çelik, M. A. ve Çelik, Y., 2025. Makine Öğrenmesi Tabanlı Bina İçi Görünür Işık Konumlandırma Sistemi. 6th International Congress on Engineering and Sciences, İstanbul, Türkiye, 284-292.