T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

# YÜKSEK LİSANS TEZİ

## Wi-Fi VE BLE HİBRİT TEKNOLOJİLERE DAYALI MAKİNE ÖĞRENME DESTEKLİ İÇ MEKAN KONUMLANDIRMA

**Yunus HAZNEDAR**

**DANIŞMAN**
**Dr. Öğr. Üyesi Gülsüm Zeynep GÜRKAŞ AYDIN**

**II. DANIŞMAN**
**Dr. Öğr. Üyesi Zeynep TURGUT AKGÜN**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Bilgisayar Mühendisliği Programı**

**İSTANBUL-2021**

Bu çalışma, 06.07.2021 tarihinde aşağıdaki jüri tarafından Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Programında Yüksek Lisans tezi olarak kabul edilmiştir.

TEZ JÜRİSİ

Dr. Öğr. Üyesi Gülsüm Zeynep GÜRKAŞ AYDIN
(Danışman)
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi

Doç. Dr. Rüya ŞAMLI
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi

Dr. Öğr. Üyesi Ali BOYACI
İstanbul Ticaret Üniversitesi
Mühendislik Fakültesi

20.04.2016 tarihli Resmi Gazete'de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi-Cerrahpaşa'nın abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü'nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

# ÖNSÖZ

Eğitim bir bireyin hem duygusal hem bedensel olarak sahip olduğu yeteneklerini istediği ve hedeflediği amaçlar doğrultusunda geliştirmesidir. Bilgi kazanmak, sosyal davranışlarını geliştirmek bu yolda atılan adımların birer parçasıdır. Aynı zamanda eğitim bireyin kendini tanımasını, yapabileceklerini keşfetmesini sağlayan en önemli süreçlerden biridir.

Fedakârlıkları, maddi ve manevi desteği, hayatında hem anne hem baba olma rolünü üstlenen, yaşadığı imkânsızlıklar ve zamanın getirdiği anlayış sebebiyle eğitim hayatına devam edememiş olsa da, çocuklarının iyi bir eğitim alması için varını yoğunu ortaya koyan biricik anneme,

Tez ve eğitim dönemi süresince desteklerini, sabırlarını ve yardımlarını eksik etmeyen çok kıymetli danışman hocalarım Dr. Öğr. Üyesi Gülsüm Zeynep GÜRKAŞ AYDIN ve Dr. Öğr. Üyesi Zeynep TURGUT AKGÜN'e,

Tez yazım ve değerlendirme süresince yardımları, fikirleri ve yönlendirmeleriyle bu çalışmada emeği geçen sevgili hocalarım Doç. Dr. Muhammed Ali AYDIN, Doç. Dr. Rüya ŞAMLI, Dr. Öğr. Üyesi Ali BOYACI, Arş. Gör. Mehmet Yavuz YAĞCI ve sevgili meslektaşım Hürkan Mustafa AYDIN'a,

Hayattaki en büyük şanslarımdan biri olan tek ve biricik kardeşime ve sevgili dostlarım Aslı ÖNTÜRK, Büşra ÇOLLAK, İrem ÖZKARALI, İrem YILMAZ, Kürşat BEYOĞLU, Melike BAYIR ve Sinan ÖZPUYLAT'a çok teşekkür ederim.

Yüksek lisans tezimi eğitimin ne denli önemli olduğunu her defa vurgulayan, çalışkan olmaktan başka bir şeye ihtiyacımızın olmadığını, bağımsızlığın karakterimizin olması gerektiğini, fikri ve vicdanı hür bir bireyin her şeyi başarabileceğini bize gösteren, "Eğitimdir ki, bir milleti ya özgür, bağımsız, şanlı, yüksek bir topluluk halinde yaşatır; ya da esaret ve sefalete terk eder." sözünün sahibi Türkiye Cumhuriyeti'nin baş kurucusu Gazi Mustafa Kemal ATATÜRK'ün aziz anısına ithaf ediyorum.

Temmuz 2021 Yunus HAZNEDAR

# İÇİNDEKİLER

**Sayfa No**

**ÖNSÖZ** ..... **iv**
**İÇİNDEKİLER** ..... **v**
**ŞEKİL LİSTESİ** ..... **vii**
**TABLO LİSTESİ** ..... **x**
**SİMGE VE KISALTMA LİSTESİ** ..... **xii**
**ÖZET** ..... **xiv**
**SUMMARY** ..... **xv**
**1. GİRİŞ** ..... **1**
**2. GENEL KISIMLAR** ..... **3**
2.1. DIŞ MEKAN KONUMLANDIRMA YÖNTEMLERİ ..... 3
2.2. İÇ MEKAN KONUMLANDIRMA YÖNTEMLERİ ..... 4
2.2.1. Üçgenleme Algoritmaları ..... 4
*2.2.1.1. Alınan Sinyal Gücü Göstergesi* ..... 4
*2.2.1.2. Varış Zamanı* ..... 7
*2.2.1.3. Varış Zamanında Meydana Gelen Fark* ..... 8
2.2.2. Üç Açılama Algoritmaları ..... 9
*2.2.2.1. Açı Tabanlı Yöntem* ..... 9
*2.2.2.2. Varış Yönü* ..... 10
2.2.3. Sahne (Mekan) Analizi ..... 11
*2.2.3.1 Parmak İzi Yöntemi* ..... 11
2.3. İÇ MEKAN KONUMLANDIRMADA KULLANILAN TEKNOLOJİLER ..... 12
2.3.1. Wi-Fi ve Bluetooth ile Hibrit İç Mekan Konumlandırma ..... 13
2.3.2. iBeacon ve Wi-Fi ile Hibrit İç Mekan Konumlandırma ..... 15
2.3.3. RFID ve Kablosuz Sensör Ağı ile Hibrit İç Mekan Konumlandırma ..... 16
2.3.4. UltraSound ve RFID ile Hibrit İç Mekan Konumlandırma ..... 18
**3. MALZEME VE YÖNTEM** ..... **19**
3.1. KULLANILAN TEKNOLOJİLER ..... 19
3.1.1. Android İşletim Sistemi ..... 19
3.1.2. MongoDB Realm Veritabanı ..... 20
3.2. KULLANILAN SİNYAL ÇEŞİTLERİ ..... 22

3.2.1. Wi-Fi Temelli Konum Belirleme ..... 22
3.2.2. Bluetooth Düşük Enerji Temelli Konum Belirleme ..... 23
3.3. KULLANILAN YÖNTEM VE ALGORİTMALAR ..... 25
3.3.1. Kalman Filtresi ..... 25
*3.3.1.1. Kalman filtresi için parametre seçimi* ..... 26
3.3.2. Doğrusal Olmayan En Küçük Kareler Yöntemi ..... 27
3.3.3. Levenberg - Marquardt Algoritması ..... 28
3.3.4. K - En Yakın Komşuluk Algoritması ..... 28
3.3.5. Destek Vektör Makinesi Algoritması ..... 29
3.4. OLUŞTURULAN TEST ORTAMI ..... 31
3.4.1. Ortamda Kullanılan Cihazlar ..... 31
*3.4.1.1. Wi-Fi ve Beacon Cihazlarının Yerleşimi* ..... 31
3.4.1.2. Akıllı Cihazların Yerleşimi ..... 33
**4. BULGULAR ..... 34**
4.1. DOĞRUSAL OLMAYAN EN KÜÇÜK KARELER YÖNTEMİ İLE ELDEN EDİLEN SONUÇLAR ..... 34
4.1.1. Rastgele Yörünge İle Elde Edilen Sonuçlar ..... 35
*4.1.1.1. 13 Noktalı Rastgele Yörünge* ..... 36
*4.1.1.2. 20 Noktalı Rastgele Yörünge* ..... 40
4.1.2. Belirlenmiş Yörünge İle Elde Edilen Sonuçlar ..... 46
*4.1.2.1. S Şeklindeki Yörünge* ..... 46
*4.1.2.2. W Şeklindeki Yörünge* ..... 50
4.2. MAKİNE ÖĞRENMESİYLE ELDE EDİLEN SONUÇLAR ..... 55
4.2.1. KNN Algoritması İle Elde Edilen Sonuçlar ..... 56
4.2.2. SVM Algoritması İle Elde Edilen Sonuçlar ..... 57
**5. TARTIŞMA VE SONUÇ ..... 61**
**KAYNAKLAR ..... 63**
**EKLER ..... 68**
EK 1. ANLIK VERİTABANI GÖRÜNTÜSÜ ..... 68
**ÖZGEÇMİŞ ..... 70**

# ŞEKİL LİSTESİ

**Sayfa No**

**Şekil 2.1:** GPS'in ana bileşenleri. .....3

**Şekil 2.2:** RSSI ve mesafe arasındaki ideal ilişki [4]. .....6

**Şekil 2.3:** Hedef konumun ToA tekniği kullanılarak hesaplandığı örnek. .....8

**Şekil 2.4:** Hedef konumun TDoA tekniği kullanılarak hesaplandığı örnek. .....9

**Şekil 2.5:** Varış açısı yöntemi [9]. .....10

**Şekil 2.6:** Varış yönü yöntemi [11]. .....11

**Şekil 2.7:** Çevrimiçi ve çevrimdışı aşamalar [15]. .....12

**Şekil 2.8:** Wi-Fi ve Bluetooth hibrit konumlandırma mimari bileşenleri [16]. .....15

**Şekil 2.9:** RSSI'ın parmak izi metodu ile toplanması [17]. .....16

**Şekil 2.10:** Hibrit WSN - RFID topolojisi [18]. .....17

**Şekil 3.1:** Mobil uygulamaya ait ekran görüntüleri. .....20

**Şekil 3.2:** Varlık - ilişki diyagramı. .....22

**Şekil 3.3:** Gürültü kovaryans varsayımlarının filtreye etkisi. .....27

**Şekil 3.4:** SVM sınıflandırıcı yapısı [34]. .....30

**Şekil 3.5:** Verilerin toplandığı alana ait plan. .....31

**Şekil 3.6:** Verilerin toplandığı alana ait Wi-Fi ve BLE cihaz yerleşim planı. .....32

**Şekil 3.7:** Verilerin toplandığı alana ait akıllı cihazların yerleşim planı. .....33

**Şekil 4.1:** Doğrusal Olmayan En Küçük Kareler yöntemine ait akış diyagramı .....34

**Şekil 4.2:** Wi-Fi noktasından elde edilen RSSI - uzaklık grafiği. .....35

**Şekil 4.3:** Beacon cihazlarından elde edilen RSSI - uzaklık değişim grafiği. .....35

**Şekil 4.4:** 13 noktalı rastgele yörüngede senaryo 1 üzerinde istemcinin izlediği gerçek yol ve bölgeleri. .....37

**Şekil 4.5:** 13 noktalı rastgele yörüngede senaryo 1 üzerinde istemcinin izlediği tahmini yol ve bölgeleri. ....37

**Şekil 4.6:** 13 noktalı rastgele yörüngede senaryo 1 üzerinde istemcinin izlediği tahmini ve gerçek yol ve bölgeleri....38

**Şekil 4.7:** 13 noktalı rastgele yörüngede senaryo 2 üzerinde istemcinin izlediği gerçek yol ve bölgeleri. ....38

**Şekil 4.8:** 13 noktalı rastgele yörüngede senaryo 2 üzerinde istemcinin izlediği tahmini yol ve bölgeleri. ....39

**Şekil 4.9:** 13 noktalı rastgele yörüngede senaryo 2 üzerinde istemcinin izlediği tahmini ve gerçek yol ve bölgeleri....39

**Şekil 4.10:** 20 noktalı rastgele yörüngede senaryo 1 üzerinde istemcinin izlediği gerçek yol ve bölgeleri. ....42

**Şekil 4.11:** 20 noktalı rastgele yörüngede senaryo 1 üzerinde istemcinin izlediği tahmini yol ve bölgeleri. ....42

**Şekil 4.12:** 20 noktalı rastgele yörüngede senaryo 1 üzerinde istemcinin izlediği tahmini ve gerçek yol ve bölgeleri....43

**Şekil 4.13**: 20 noktalı rastgele yörüngede senaryo 2 üzerinde istemcinin izlediği gerçek yol ve bölgeleri. ....43

**Şekil 4.14:** 20 noktalı rastgele yörüngede senaryo 2 üzerinde istemcinin izlediği tahmini yol ve bölgeleri. ....44

**Şekil 4.15:** 20 noktalı rastgele yörüngede senaryo 2 üzerinde istemcinin izlediği tahmini ve gerçek yol ve bölgeleri....44

**Şekil 4.16:** S yörüngede senaryo 1 üzerinde istemcinin izlediği gerçek yol ve bölgeleri. ....47

**Şekil 4.17:** S yörüngede senaryo 1 üzerinde istemcinin izlediği tahmini yol ve bölgeleri. ....47

**Şekil 4.18:** S yörüngede senaryo 1 üzerinde istemcinin izlediği tahmini ve gerçek yol ve bölgeleri. ....48

**Şekil 4.19:** S yörüngede senaryo 2 üzerinde istemcinin izlediği gerçek yol ve bölgeleri. ....48

**Şekil 4.20:** S yörüngede senaryo 2 üzerinde istemcinin izlediği tahmini yol ve bölgeleri. ....49

**Şekil 4.21:** S yörüngede senaryo 2 üzerinde istemcinin izlediği tahmini ve gerçek yol ve bölgeleri. ....49

**Şekil 4.22:** W yörüngede senaryo 1 üzerinde istemcinin izlediği gerçek yol ve bölgeleri. .....51

**Şekil 4.23:** W yörüngede senaryo 1 üzerinde istemcinin izlediği tahmini yol ve bölgeleri. .....52

**Şekil 4.24:** W yörüngede senaryo 1 üzerinde istemcinin izlediği tahmini ve gerçek yol ve bölgeleri. .....52

**Şekil 4.25:** W yörüngede senaryo 2 üzerinde istemcinin izlediği gerçek yol ve bölgeleri. .....53

**Şekil 4.26:** W yörüngede senaryo 2 üzerinde istemcinin izlediği tahmini yol ve bölgeleri. .....53

**Şekil 4.27:** W yörüngede senaryo 2 üzerinde istemcinin izlediği tahmini ve gerçek yol ve bölgeleri. .....54

**Şekil 4.28:** Rastgele ve belirlenen yörüngeler için doğruluk değişim grafiği. .....55

**Şekil 4.29:** Makine öğrenmesi ile edilen doğruluk oranlarının değişim grafiği. .....59

# TABLO LİSTESİ

**Sayfa No**

**Tablo 2.1:** Kabul edilebilir sinyal güçleri [3]. .....5

**Tablo 2.2:** İç mekan konum belirleme teknolojileri. .....13

**Tablo 3.1:** Android işletim sürümleri [20].....19

**Tablo 3.2:** Device sınıfı değişkenleri.....21

**Tablo 3.3:** Location sınıfı değişkenleri.....21

**Tablo 3.4:** Wi-Fi sinyal kalitesi ve nitelikleri [22]. .....23

**Tablo 3.5:** Bluetooth teknolojilerinin karşılaştırması. .....25

**Tablo 3.6:** Test ortamında yer alan cihaz bilgileri.....32

**Tablo 3.7:** Test ortamında yer alan Bluetooth akıllı cihaz bilgileri.....33

**Tablo 4.1:** 13 noktalı rastgele yörünge için nokta karşılaştırma tablosu. .....36

**Tablo 4.2:** 13 noktalı rastgele yörünge için bölge karşılaştırma tablosu. .....40

**Tablo 4.3:** 20 noktalı rastgele yörünge için nokta karşılaştırma tablosu. .....41

**Tablo 4.4:** 20 noktalı rastgele yörünge için bölge karşılaştırma tablosu. .....45

**Tablo 4.5:** S yörüngesi için nokta karşılaştırma tablosu.....46

**Tablo 4.6:** S yörüngesi için bölge karşılaştırma tablosu.....50

**Tablo 4.7:** W yörüngesi için nokta karşılaştırma tablosu. .....51

**Tablo 4.8:** W yörüngesi için bölge karşılaştırma tablosu .....54

**Tablo 4.9:** Rastgele ve belirlenen yörüngeler için özet sonuç tablosu. .....55

**Tablo 4.10:** KNN algoritmasında kullanılan değişkenler. .....56

**Tablo 4.11:** Wi-Fi ve Beacon için KNN algoritması ile elde edilen doğruluk oranları. .....56

**Tablo 4.12:** Wi-Fi ve Beacon ve BSD için KNN algoritması ile elde edilen doğruluk oranları.....57

**Tablo 4.13:** SVM algoritmasında kullanılan değişkenler. .....57

**Tablo 4.14:** Wi-Fi ve Beacon için SVM algoritması ile elde edilen doğruluk oranları. .....58

**Tablo 4.15:** Wi-Fi ve Beacon ve BSD için SVM algoritması ile elde edilen doğruluk oranları.....58

**Tablo 4.16:** Makine öğrenmesi ile edilen özet sonuç tablosu.....59

# SİMGE VE KISALTMA LİSTESİ

**Simgeler** **Açıklama**

**c** : Işık hızı (Speed of light)
**d** : Uzaklık (Distance)
**dBm** : Desibel Miliwatt (Decibel Milliwatt)
**f** : Frekans (Frequency)
**m** : Metre (Meter)
**Mbps** : Saniyede megabit (megabit per second)
**msn** : Milisaniye (Millisecond)
**sn** : Saniye (Second)
**t** : Zaman (Time)
**$T_x$** : İletim gücü (Transmission power)

**Kısaltmalar** **Açıklama**

**AoA** : Varış Açısı (Angle of Arrival)
**BLE** : Bluetooth Düşük Enerji (Bluetooth Low Energy)
**BSD** : Bluetooth Akıllı Cihazı (Bluetooth Smart Device)
**DoA** : Varış Yönü (Direction of Arrival)
**GPS** : Küresel Konumlandırma Sistemi (Global Positioning System)
**IEEE** : Elektrik ve Elektronik Mühendisleri Enstitüsü (Institute of Electrical and Electronics Engineers)
**KNN** : K-En Yakın Komşuluk (K-Nearest Neighbor)
**LE** : Düşük Enerji (Low Energy)
**LM** : Levenberg-Marquardt (Levenberg-Marquardt)
**NLLS** : Doğrusal Olmayan En Küçük Kareler Yöntemi (Non-linear Least Squares)
**RFID** : Radyo Frekanslı Tanıma (Radio Frequency Identification)
**RSS** : Alınan Sinyal Gücü (Received Signal Strength)
**RSSI** : Alınan Sinyal Gücü Göstergesi (Received Signal Strength Indicator)
**SVM** : Destek Vektör Makinesi (Support Vector Machine)
**TDoA** : Varış Zamanında Meydana Gelen Fark (Time Difference of Arrival)
**ToA** : Varış Zamanı (Time of Arrival)

**UUID** : Evrensel Benzersiz Tanımlayıcı (Universally Unique Identifier)

**Wi-Fi** : Kablosuz Bağlantı Alanı (Wireless Fidelity)

# ÖZET

## YÜKSEK LİSANS TEZİ

### Wi-Fi VE BLE HİBRİT TEKNOLOJİLERE DAYALI MAKİNE ÖĞRENME DESTEKLİ İÇ MEKAN KONUMLANDIRMA

**Yunus HAZNEDAR**

**İstanbul Üniversitesi-Cerrahpaşa**

**Lisansüstü Eğitim Enstitüsü**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Danışman : Dr. Öğr. Üyesi Gülsüm Zeynep GÜRKAŞ AYDIN**

**II. Danışman : Dr. Öğr. Üyesi Zeynep TURGUT AKGÜN**

İç mekan konumlandırma problemlerinde kablosuz sinyallerin karakteristik özelliklerinden dolayı dış mekan konumlandırmada kullanılan GPS teknolojisi oldukça yetersiz kalmaktadır. Günümüzde iç mekan konumlandırma için genel kabul görmüş standart bir yöntem bulunmamaktadır. Bu tez çalışmasında, Wi-Fi ve BLE teknolojilerini hibrit şekilde kullanarak iç mekanda etkin bir konum belirleme yöntemi önerebilmek için Beacon cihazları, Bluetooth akıllı cihazlar, ve Wi-Fi erişim noktasından oluşan bir ekosistem oluşturulmuştur. Parmak izi yöntemi kullanılarak RSSI verisi toplanmıştır. Elde edilen RSSI verileri üzerindeki gürültüyü azaltmak ve daha kararlı hale getirmek için Kalman Filtresi kullanılmıştır. İlk bölümde Wi-Fi ve Beacon cihazlarından toplanan veriler kullanılarak istemciye ait tahmini konum, bölge ve tespit etmek amacıyla NLLS yöntemi kullanılmıştır. İkinci bölümde istemcinin bulunduğu alanı kestirebilmek için makine öğrenmesi yöntemiyle KNN ve SVM algoritmaları kullanılmıştır. Her bir algoritma için farklı eğitim ve test verileri üzerinde doğruluk oranları hesaplanmıştır.

Temmuz 2021, 85 sayfa.

**Anahtar kelimeler:** iç mekan konumlandırma, makine öğrenmesi, hibrit konumlandırma

# SUMMARY

## M.Sc. THESIS

### MACHINE LEARNING-AIDED INDOOR POSITIONING BASED ON Wi-Fi AND BLE HYBRID TECHNOLOGIES

**Yunus HAZNEDAR**

**Istanbul University-Cerrahpasa**

**Institute of Graduate Studies**

**Department of Computer Engineering**

**Supervisor : Assist. Prof. Dr. Gülsüm Zeynep GÜRKAŞ AYDIN**

**Co-Supervisor : Assist. Prof. Dr. Zeynep TURGUT AKGÜN**

In indoor positioning problems, the GPS technology used in outdoor positioning is quite inadequate due to the characteristics of the wireless signals. There is still no generally accepted standard method for the indoor positioning. In this thesis, an ecosystem consisting of Beacon devices, Bluetooth smart devices, and Wi-Fi access point has been created in order to propose an effective indoor location determination method by using Wi-Fi and BLE hybrid technologies. In the ecosystem, the data of the signal and the device were collected using the fingerprint method. Kalman Filter is used to reduce the noise on the obtained RSSI data and make it more stable. There are two main parts in this study. The first part, the NLLS is used to extract the estimated location, region and estimated path of the client by using the data collected from Wi-Fi and Beacon devices. The second part, KNN and SVM algorithms in machine learning are used to calculate the estimated area of the client. The accuracy scores were calculated for different training and test rates for each algorithm.

July 2021, 85 pages.

**Keywords:** indoor positioning, machine learning, hybrid positioning

# 1. GİRİŞ

Gelişen teknoloji ile birlikte konum-tabanlı hizmetlere olan ilgi ve yatırım gün geçtikçe artmaktadır. Hayatımızda sıkça kullandığımız birçok uygulama artık konum tabanlı hizmetleri kullanmakta, buna göre belirli hizmetler sunmakta, elde edilen konum bilgileri ile iş süreçlerini katkı sağlamayı amaçlamaktadır. Bu konum hizmetleri dış mekanda Küresel Konumlandırma Sistemi (Global Positioning System - GPS) veya baz istasyonu sinyalleri üzerinden sağlanmaktadır.

GPS sinyalleri dış mekan alanlarda konum tespit etmek için kullanıldığında yüksek performans sunmakla beraber, bu sinyallerinin karakteristik özelliklerinden dolayı iç mekanda konumun tespitini oldukça zorlaştırmaktadır. Çünkü bina içerisinde erişilen sinyaller bölgesel, geçici, küçük veya geniş alanlarda bulunabilir. Ayrıca sapma, yansıma, biçim bozulması, gürültü, görüş alanında olmama, zaman senkronizasyonu sağlayamama, çarpışma, gibi sinyal iletişim doğruluğunu etkileyebilecek sorunlarla karşılaşılmaktadır. Bu sebeple günümüzde kapalı alan konumlandırma sistemleri üzerine çalışmalar artarak düşük maliyetli çözüm arayışları devam etmektedir. Bu çözümler Wi-Fi, Bluetooth, ve Radyo Frekanslı Tanıma (Radio Frequency Identification - RFID) gibi kablosuz teknolojilere dayanmaktadır. Bu teknolojilerle yapılan iç mekan konumlandırma çalışmalarında temel prensip sinyal yayan ağ cihazlarına olan uzaklığın hesaplanmasıdır. Özellikle hemen hemen her binada karşılaşılabilecek, belli bir altyapıya sahip, düşük maliyetli ve orta genişlikte alanı kapsayan Wi-Fi ağlarını veya artık birçok akıllı cihazda yer alan Bluetooth sinyallerini kullanmak tasarımı kolaylaştıracak, maliyeti düşürecektir.

Bu tez çalışmasında bir ev ortamında bulunan antre ve oda içerisinde Bluetooth ve Wi-Fi sinyalleri kullanılarak iç mekan konumlandırma ortamı oluşturulmuştur. Oluşturulan bu ortamında 6 adet Beacon cihazı, 1 adet Wi-Fi erişim noktası ve 4 adet akıllı cihaz yer almaktadır. Bu ortam bir koordinat sistemi üzerine oturtulmuş ve buna göre akıllı cihazlar, Beacon cihazları ve Wi-Fi erişim noktası belirli noktalara sabitlenmiştir. RSSI (Received Signal Strength Indicator - Alınan Sinyal Gücü Göstergesi) verisi toplamak için oluşturulan alanlar belirlenmiş ve eşit ızgara alanlarına bölünmüştür. Bu cihazlardan alınan RSSI verileri Android işletim sisteminde kodlanan bir mobil uygulama aracılığı ile toplanmış, MongoDB Realm veritabınında saklanmıştır. Bu veriler sonrasında Kalman filtresinden geçirilip 2 ayrı yöntem

kullanılarak işlenmiştir. İlk bölümde Beacon cihazları ve Wi-Fi noktasından elde RSSI verileri Doğrusal Olmayan En Küçük Kareler Yöntemi ve Levenberg-Marquardt algoritması kullanarak istemcinin test ortamındaki tahmini noktası ve bölgesi hesaplanmıştır. Tahmini ve gerçek noktaların oluşturduğu yol çıkarılmış, bunlar arasında karşılaştırma yapılmış ve hata payı hesaplanmıştır. Diğer bölümde ise ilk bölüme ek olarak ortamda Bluetooth sinyali yayabilen akıllı cihazlardan elde edilen RSSI verileri de kullanılmıştır. Makine öğrenmesinde kullanılan Destek Vektör Makinesi (Support Vector Machine - SVM) ve K-En Yakın Komşuluk (K-Nearest Neighbor - KNN) algoritmaları kullanılarak istemcinin test ortamındaki tahmini alanına (oda veya antre) ait doğruluk oranları hesaplanmıştır. İlgili hesaplamada her 2 algoritma farklı eğitim ve test veri oranları ile çalıştırılmış, sonrasında her bir eğitim/test veri oranı arasındaki doğruluk oranları karşılaştırılmıştır.

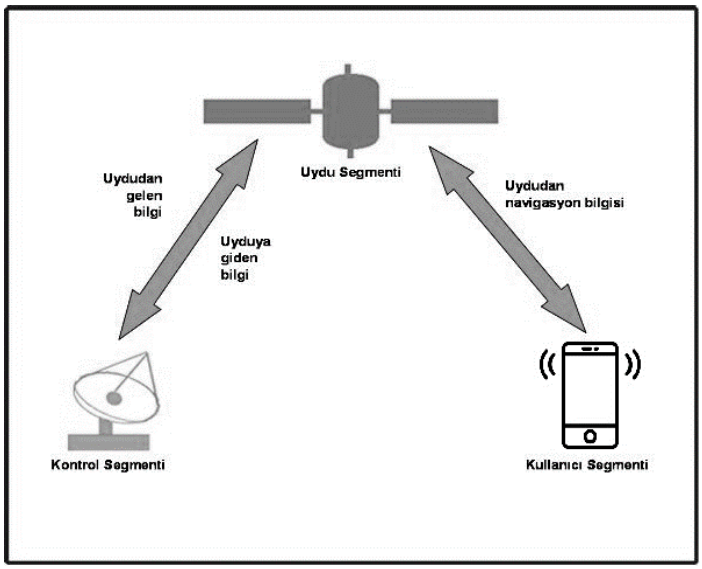
# 2. GENEL KISIMLAR

Konumlandırma sistemi bir nesnenin veya kişinin bir odada, binada veya dünyadaki konumunu ve yönünü belirleyen bir mekanizmadır. Bu bölümde birçok sistemlere yönelik kullanılan birçok teknoloji dış mekan ve iç mekan olmak üzere 2 ana başlık üzerinde incelenmiştir.

## 2.1. DIŞ MEKAN KONUMLANDIRMA YÖNTEMLERİ

Son yıllarda modern teknoloji cihazlarının sürekli yaygınlaşması, konum bilgilerinin önemini artırmıştır. Lokasyon bazlı hizmetlerin sayısının her geçen gün artması bunun en büyük nedenlerinden biri olarak gösterilebilir. Dış mekan konum belirleme hizmetlerini destekleyen en yaygın teknoloji, GPS'dir. Bu sistem ekvatora 55 derece eğimli yörüngelerde bulunan 31 aktif uyduya sahiptir. Uydular, dünya yüzeyinden yaklaşık 20.000 km uzaklıkta yörüngede dönmektedir ve günde 2 yörünge yapmaktadır. Yörüngeler, dünyanın çoğu yerinden her zaman altı uydu görünecek şekilde tasarlanmıştır.

GPS birçok karmaşık teknoloji kullanır, ancak çalışma prensibi olarak basittir. Esas olarak birden fazla uydudan konumlandırma sinyallerini alır ve konumu hesaplamak için üçgenleme tekniğini kullanmaktadır [1]. Şekil 2.1'de gösterildiği üzere uzay, kullanıcı ve kontrol segmenti olmak üzere üç ana bileşene sahiptir.




**Şekil 2.1:** GPS'in ana bileşenleri.

GPS alıcısı, her GPS uydusundan bir sinyal alır. Uydular, sinyallerin gönderildiği tam zamanı iletir. GPS, sinyalin iletildiği zamanı alındığı zamandan çıkararak her bir uydudan ne kadar uzakta olduğunu hesaplamaktadır. GPS alıcısı ayrıca, sinyallerini gönderdikleri anda uyduların gökyüzündeki kesin konumunu da belirleyebilmektedir. Dolayısıyla, üç uydudan gelen GPS sinyallerinin seyahat süresi ve gökyüzündeki kesin konumları göz önüne alındığında, GPS alıcısı konumunuzu üç boyutta (doğu, kuzey ve rakım) belirleyebilmektedir.

## 2.2. İÇ MEKAN KONUMLANDIRMA YÖNTEMLERİ

Kablosuz teknoloji tabanlı konum belirlemede konum tekniği ve algoritması için birçok farklı yöntem kullanılmaktadır. İç mekandaki pozisyonlar, restoran veya ofis gibi açık hava ortamlarının aksine, daha küçük kapsama ve daha ince bilgilere sahip olma eğilimindedir [2]. İç mekanda konum belirleme algoritması tasarımında göz önünde bulundurulması gereken en önemli faktör hareketliliktir. Bir ağ içerisinde kullanılan cihazlar sabit ve mobil olabildikleri gibi aktif sabit, pasif sabit, aktif mobil ve pasif mobil olabilmektedirler. İç mekan ağlarda konum belirleme amacıyla deterministik veya olasılıksal konum belirleme yöntemlerine başvurulabilir.

### 2.2.1. Üçgenleme Algoritmaları

Konum tespit işlemi bir bina içerisinde yer alan üç adet referans noktası olarak kabul edilen cihaza ait sinyal değeri göz önünde bulundurularak gerçekleştirilir. Bu amaçla konum belirleme işlemi gerçekleştirilmek istenilen alana her noktadan en az üç adet cihazın hedef noktaları kapsayacağı biçimde referans noktalar belirlenir. Belirlenen referans noktalara ait cihazların konumları bilindiği için hedefe ait konum tespiti yapma işlemi, hedefi kapsayan cihazların uzaklıkları kullanılarak gerçekleştirilir.

Mesafenin ölçülebilmesi için yöntem olarak Alınan Sinyal Gücü Göstergesi (Received Signal Strength Indication – RSSI), Varış Zamanı (Time of Arrival – ToA), Varış Zamanında Meydana Gelen Fark (Time Difference of Arrival – TDoA) gibi ölçüm tekniklerini kullanabilirler.

#### *2.2.1.1. Alınan Sinyal Gücü Göstergesi*

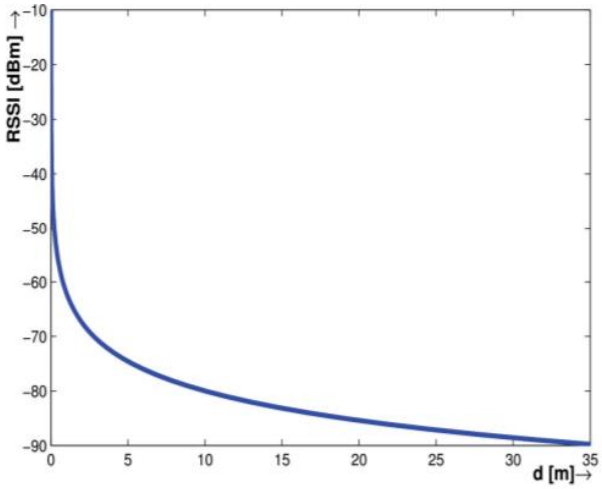
Alınan Sinyal Gücü Göstergesi (Received Signal Strength Indicator – RSSI), bir aygıtın herhangi bir erişim noktasından veya belirli bir yönlendiriciden gelen sinyalleri ne kadar iyi

duyduğunun, algıladığının ve alabildiğinin tahmini bir ölçümüdür. Diğer bir tanımla RSSI, alınan bir sinyalin bir istemci cihaza göreceli kalitesini ölçmek için kullanılan bir terimdir. RSSI değerinin mutlak değeri yoktur. IEEE 802.11 standardı, RSSI'nin 0 ila 255 arasında bir ölçekte olabileceğini ve her yonga seti üreticisinin kendi "RSSI_Max" değerini tanımlayabileceğini belirtir. Örneğin Cisco, 0 - 100 ölçeği kullanırken, Atheros 0 - 60 ölçeğini kullanır [3]. Alınan sinyal gücü, desibel veya logaritmik ölçekte $dBm$ olarak ölçülür. $dBm$ ve $RSSI$, her ikisi de aynı şeyi temsil eden farklı ölçü birimleridir. Aradaki fark, RSSI'nin göreceli bir endeks olması, $dBm$'nin ise mW (miliwatt) cinsinden güç seviyelerini temsil eden mutlak bir sayı olmasıdır. Sinyal gücü 0 $dBm$'ye ne kadar yakın ise o kadar güçlüdür. Sinyal güçlerine ait açıklamalara Tablo 2.1'de yer verilmiştir.

**Tablo 2.1:** Kabul edilebilir sinyal güçleri [3].

| Sinyal Gücü (dBm) | Sinyal Gücü Değerlendirmesi | Açıklama |
|---|---|---|
| -30 dBm | Mükemmel | Ulaşılabilir maksimum sinyal gücüne sahiptir. İstemci AP'den yalnızca birkaç metre uzakta olabilir. |
| -67 dBm | Çok iyi | Veri paketlerinin çok güvenilir ve zamanında teslim edilmesini gerektiren uygulamalar için minimum sinyal gücüne sahiptir. |
| -70 dBm | İyi | Güvenilir paket teslimi için minimum sinyal gücüne sahiptir. |
| -80 dBm | İyi değil | Temel bağlantı için minimum sinyal gücüne sahiptir. Paket teslimi güvenilmez olabilir. |
| -90 dBm | Kullanılamaz | Gürültü zeminine yaklaşıldığını gösterir. Herhangi bir işlevsellik pek olası değildir. |

RSSI aracılığıyla mesafe tahmini fikri, ideal durumda Alınan Sinyal Gücü (Received Signal Strength – RSS), Şekil 2.2'de gösterilen, 2 radyo cihazı arasındaki yolda iletilen gücün ve mesafenin bir fonksiyonu olduğu varsayımına dayanmaktadır [4].




**Şekil 2.2:** RSSI ve mesafe arasındaki ideal ilişki [4].

Denklem 2.1'de, binalar gibi küçük mesafelerde yaygın olarak kullanılan [5]' de önerilen yol kaybı modeli temsil edilmektedir. İlgili denklem içerisinde $Pr(d)$, $d$ $[mW]$ mesafesindeki RSS'dir. $Pr(d_0)$, $d_0$ $[mW]$ referans mesafesindeki RSS'dir. $\eta$, yol kaybı üssüdür. $d$ verici ile alıcı arasındaki metre cinsinden mesafesidir ve $d_0$, metre cinsinden referans mesafesidir.

$$\frac{P_r(d_0)}{P_r(d)} = (\frac{d}{d_0})^{\eta} \tag{2.1}$$

Denklem 2.6 'da yer alan mesafe ile Denklem 2.5' de yer alan $RSSI$ değeri arasındaki ilişki, Denklem 2.2 – Denklem 2.4 arasındaki formülasyonlarla elde edilebilir. $RSSI$ ve referans $RSSI_{d0}$ $dBm$ cinsindendir.

$$RSSI = 10\ log\frac{P}{0{,}001}[dBm] \tag{2.2}$$

$$\log P(d_0) = \log P(d) = \eta \log(\frac{d}{d_0})/10 \tag{2.3}$$

$$\frac{RSSI_{d0} - RSSI}{10} = \eta \log(\frac{d}{d_0}) \tag{2.4}$$

$$RSSI = RSSI_{d0} - 10\, n \log\left(\frac{d}{d_0}\right)[dBm] \tag{2.5}$$

$$d = d_0\ 10^{(RSSI_{d0} - RSSI)/10\eta} \tag{2.6}$$

Verici ve alıcı arasındaki mesafeyi elde etmek için RSSI kullanmak, Texas Instruments tarafından önerilen, kanal modeli olarak adlandırılan matematiksel bir işlev, Denklem 2.7'de gösterildiği gibi de uygulanabilir. Bu formülde Transmit Power ($T_x$) yer almaktadır.

$$RSSI = -(10 * n)log_{10}(d) + T_x \quad (2.7)$$

Burada $n$, sinyal yayılma sabiti veya üssüdür. Bu değer boş alanda 2, kapalı ortamlarda ise 4'e kadar değişebilmektedir. $d$, verici ile alıcı arasındaki metre cinsinden ölçülen mesafedir. $T_x$, mesafe 1 metre olduğunda kabul edilen referans RSSI değeridir.

#### *2.2.1.2. Varış Zamanı*

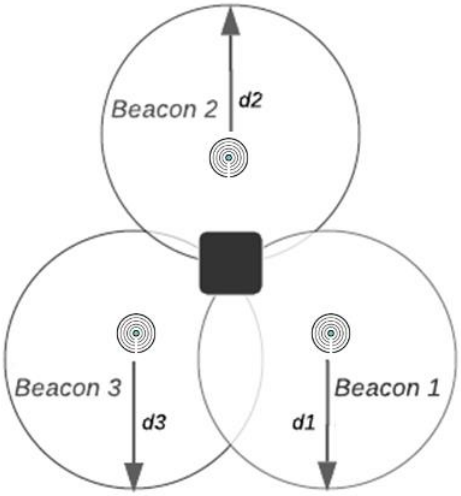
Varış Zamanı, GPS'de en çok kullanılan en basit ve en yaygın ölçüm tekniğidir. Bu yöntem, hedeften bir sinyalin tam olarak ne zaman gönderildiğini, sinyalin bir referans noktasına tam olarak ne zaman ulaştığı ve sinyalin hareket ettiği hızın (genellikle ışık hızı) bilinmesine dayanır.

$$d = c\ (t_{gelen} - t_{gönderilen}) \quad (2.8)$$

Denklem 2.8'de yer alan zamanlar bilindikten sonra, referans noktasına olan uzaklık bu denklem kullanılarak hesaplanabilir. İlgili mesafeyi kullanarak, hedefin olası konumlarının kümesi belirlenebilir. İki boyutta, bu denkleme sahip bir daire bulunmaktadır. Buradan da Denklem 2.9'de yer alan 2 nokta arasındaki uzaklık formülü ile hedefin tam konumu bulunabilir [6].

$$d = \sqrt{\left(x_{referans} - x\right)^2 + \left(y_{referans} - y\right)^2} \quad (2.9)$$

Aşağıda yer alan örnekte, üç cihaz ile çevrili bir hedef (siyah kare) yer almaktadır. $t_1$ zamanında, Beacon 1'den hedefe $t_2$'de alınan bir sinyal gönderilir. Hedef ve Beacon 1 arasındaki mesafe ($d_1$) hesaplanır ve olası konumların dairesi çizilir. Bu işlem, Beacon 2 ve Beacon 3 için tekrarlanır. Böylelikle Şekil 2.3'de gösterilen 2 daire daha elde edilir.




**Şekil 2.3:** Hedef konumun ToA tekniği kullanılarak hesaplandığı örnek.

### *2.2.1.3. Varış Zamanında Meydana Gelen Fark*

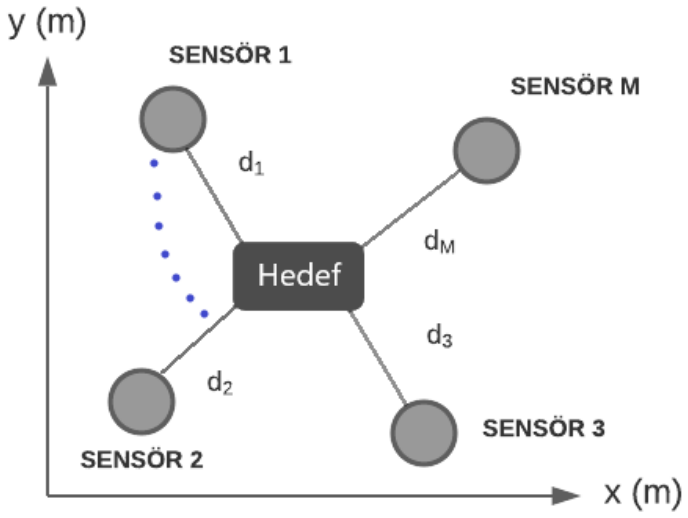
Varış Zamanında Meydana Gelen Fark ikinci en popüler menzil tekniğidir ve Varış Zamanı tekniğine kıyasla çok yönlüdür. Bu yöntem, sinyalin hedeften gönderildiği zamanı değil, yalnızca sinyalin alındığı zamanı ve sinyalin hareket ettiği hızın kullanılmasını gerektirir [6].

Sinyal 2 referans noktasından alındığında, varış süresindeki fark hedef ile 2 referans noktası arasındaki uzaklık farkını hesaplamak için kullanılabilir. Bu yönteme ait çalışma tekniği Denklem 2.10 ve Denklem 2.11'de yer almaktadır [7].

$$\Delta d = c\ (\Delta t) \tag{2.10}$$

$$\Delta d = \sqrt{(x_2 - x)^2 + (y_2 - y)^2} - \sqrt{(x_1 - x)^2 + (y_1 - y)^2} \tag{2.11}$$

Bu denklem bir hiperbol formuna dönüştürülebilir ve sonrasında hedefin konumu kesişme noktası bulunarak hesaplanabilir. Aşağıdaki Şekil 2.4'de yer alan örnekte, mavi ile belirtilen sensörlerle ile çevrili bir hedef (kaynak) yer almaktadır.




**Şekil 2.4:** Hedef konumun TDoA tekniği kullanılarak hesaplandığı örnek.

### 2.2.2. Üç Açılama Algoritmaları

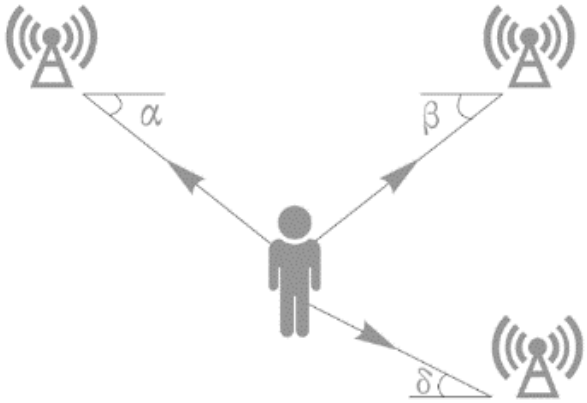
Bu yöntem mobil kullanıcı ve referans nokta arasında direk bir görüş alanı olduğu zaman kullanılmaktadır. Üç açılama temelli yöntemler hedef ve erişim noktalar arasındaki anten dizileri arasındaki açı farklarını göz önünde bulundurarak konum belirleme işlemini gerçekleştirirler.

Mesafenin ölçülebilmesi için Varış Açısı (Angle of Arrival – AoA) ve Varış Yönü (Direction of Arrival – DoA) gibi yöntemleri kullanabilirler.

#### *2.2.2.1. Açı Tabanlı Yöntem*

Bu yöntem, Şekil 2.5'de gösterildiği gibi belirli bir noktadan bir ya da daha fazla alıcıya ulaşan sinyallerin, alıcı antenleri ile yaptığı açıyı hesaplamaktadır. Yön belirlemek için yön duyarlılığı yüksek olan anten veya antenler gerekmektedir. Sonrasında belirli geometrik özelliklerden faydalanarak, kesişen 2 çizginin düğüm noktasının konumu kestirilebilir [8]. Bu tekniği kullanılarak gerçekleştirilen konum belirleme işlemlerinin doğruluğu, sinyal yayan cihazların birbirlerinin görüş hattı içerisinde olmaları ile orantılı olarak değişmektedir. Birbirlerinin görüş hattı içerisinde yer alan, güçlü sinyal yayıcı cihazlardan oluşan bir ağ kurmak yüksek maliyet

gerektirdiği için özellikle iç mekan ağlarda kullanılan bu teknik oldukça yüksek maliyetli bir yöntem olarak kabul edilir [9].



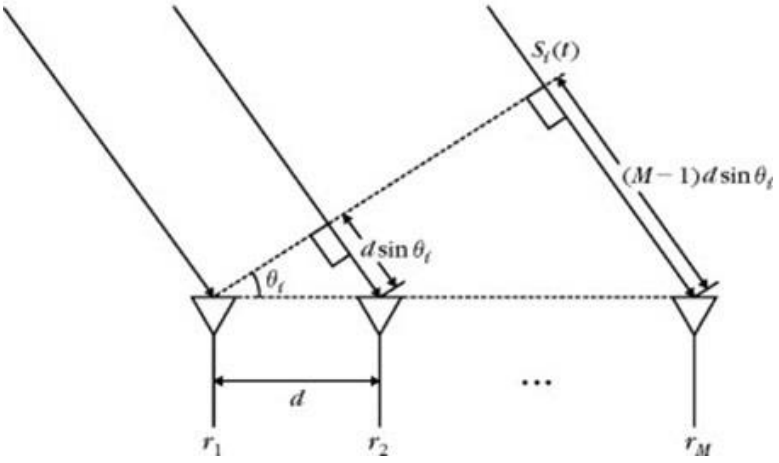

**Şekil 2.5:** Varış açısı yöntemi [9].

### *2.2.2.2. Varış Yönü*

Varış Yönü (Direction of Arrival – DoA) tahmini, bir sensör veya anten dizisine çarpan elektromanyetik veya akustik dalgalar formundaki yön bulma sinyallerinin tahminiyle ilgilidir. DoA tahmini, hem sivil hem de askeri uygulamalarda sinyal kaynaklarını bulmak ve izlemek için kullanılır.

Varış yönlerinin tahmini radar, sonar, sismik ve radyo sinyali işlemedeki uygulamaları nedeniyle büyük araştırma ilgisine sahiptir. Son 10 yılda yüksek çözünürlük performansları nedeniyle alt uzay yaklaşımları geliştirilmiştir. Bu algoritmalar arasında, varış yönlerinin tahmini, dizi anteninin sinyal işleme tekniğine dayanmaktadır [10].

Şekil 2.6'da gösterildiği gibi, $D$ sinyallerinin $\{\theta_i, i = 1, 2, \dots, D\}$, $\theta_i \in [-90\,°, 90\,°]$ açılarından $M$ sensörlerinin düzgün bir doğrusal dizisi üzerinde meydana geldiğini varsayılmaktadır. Ayrıca dizinin, çarpan sinyallerin düzlemsel olacağı şekilde herhangi bir kaynağın uzak alanında olduğu varsayılır. $M$ sensörüne gelen bir dalganın, sensör $m - 1$'e ulaşmak için kat edilen mesafeye kıyasla fazladan $d \sin \theta_i$ metre daha yol kat etmektedir [11].




**Şekil 2.6:** Varış yönü yöntemi [11].

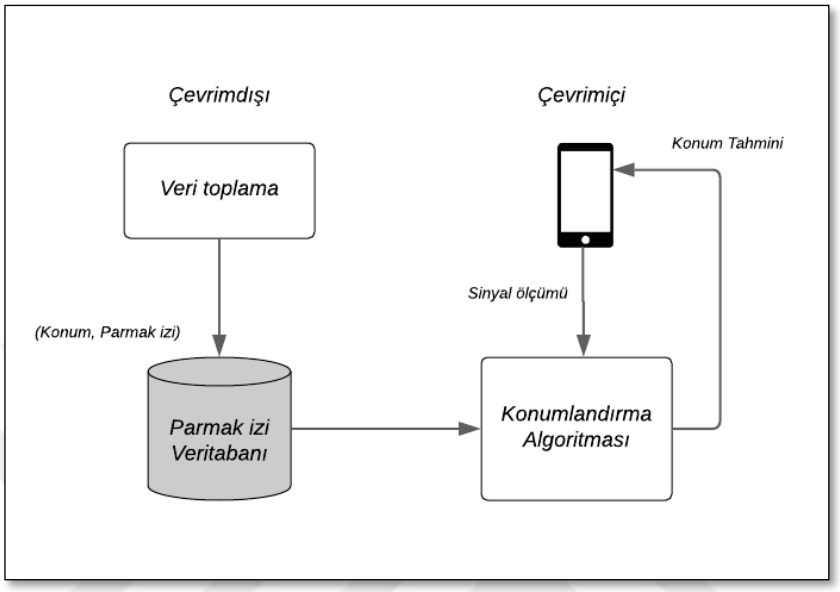
### 2.2.3. Sahne (Mekan) Analizi

Sahne analizi yöntemi konum bilgilerini saptayabilmek amacıyla bulunulan iç mekana ait özelliklerin konum belirleme işleminden önce analiz edilmesi temeline dayanır. Konum tespiti yapılmak istenilen iç mekan alt alanlara bölünür ve bu alt alanlara ait bir nitelik haritası çıkarılır. Elde edilen nitelik haritası konumu bulunmak istenilen hedefin sahip olduğu nitelikler ile karşılaştırılarak hedefin hangi alt alanın içerisinde olduğu kestirilir. Ancak nitelik haritasının doğru bir biçimde çıkartılabilmesi için ilgili iç mekan alanda birden çok kez ölçüm yapılması gerekmektedir. Aynı zamanda bina içerisinde yer alan kullanıcı hareketliliği de göz önünde bulundurulmalı; kullanıcı hareketliliğinin yoğun olduğu, kullanıcı hareketliliğinin olmadığı vb. çeşitli senaryolar için de ölçümler gerçekleştirilmelidir. Bir noktadan birden çok kez örneklem alınması; çevreye ait niteliklerin geniş ölçüde yansıtılması nedeniyle zaman ve açıya dayalı ölçüm tekniklerine göre daha başarılı sonuçlar elde edilir. Ancak bu yöntem için gerekli olan nitelik haritasını oluşturmak, ilgili nitelik haritasını saklamak ve konumu tespit edilmek istenilen her bir hedef için bu harita ile karşılaştırma yapmak maliyetlidir [12] [13].

#### *2.2.3.1 Parmak İzi Yöntemi*

Parmak izi tabanlı yöntem, ortamda var olan sinyal kaynaklarını kullanarak mobil cihazın konumunu sınıflandırma yöntemleri aracılığıyla tespit etme yöntemidir. Maliyetinin düşük ve uygulama alanının geniş olması sebebiyle parmak izi yöntemi iç ortamlarda daha çok tercih edilmektedir. Parmak izi tabanlı iç ortam konumlandırma sistemleri, ortamda var olan

sinyallerin kullanıldığı bir veri setinin oluşturulduğu çevrimdışı aşama ve konumlandırmanın gerçekleştirildiği çevrimiçi aşama olmak üzere 2 aşamadan oluşmaktadır [14]. Şekil 2.7'de bu aşamalar gösterilmiştir.




**Şekil 2.7:** Çevrimiçi ve çevrimdışı aşamalar [15].

## 2.3. İÇ MEKAN KONUMLANDIRMADA KULLANILAN TEKNOLOJİLER

İç mekan konumlandırma kavramı kapalı alanlarda insanların ve ya objelerin yerini belirleyen sistem olarak tanımlanabilmektedir. Günümüzde iç mekan konum belirleme farkındalığına olan ilgi hem akademik hem de endüstri alanlarında artmaktadır. İç mekanlarda konum tabanlı hizmetleri günlük hayatımızın çoğu zamanını ofis binalarından ulaşım tesislerine kadar farklı ve çeşitli iç mekanlarda geçirilmesi nedeniyle yüksek önem taşımaktadır. Örneğin, bir iç mekan navigasyon sistemi, ziyaretçilerini bir müzede yer alan karmaşık bir sergide rahatlıkla yönlendirebilir, kaybettiğiniz bir eşyanın yerini söyleyebilir veya ilk kez gitmiş olduğunuz bir hastanede ulaşmak istediğiniz polikliniğe en kısa rotayı gösterebilir. Başka bir örnek olarak, bir havaalanında yolcularına uçuşlarını ve biniş kapılarını hatırlatabilir, böylece uçuşlarını kaçırmalarını veya kalkışları geciktirmelerini engelleyebilir.

İç mekan konumlandırma için Wi-Fi, Bluetooth, RFID, Kızılötesi, Ultrason olmak üzere çeşitli kablosuz teknolojileri kullanmak mümkündür. Tablo 2.2'de bu kablosuz teknolojilere ilişkin belirli parametreler üzerinden karşılaştırmaları yer almaktadır.

**Tablo 2.2:** İç mekan konum belirleme teknolojileri.

| Teknoloji | Doğruluk (m) | Kapsama (m) | Enerji Tüketimi | Karmaşıklık | Maliyet |
|---|---|---|---|---|---|
| Wi-Fi | 1-5 | 20 - 50 | Yüksek | Düşük | Orta/Düşük |
| BLE | 1-2 | 1-3 | Düşük | Düşük | Düşük |
| Manyetik Alan | 2 | - | - | Orta | Düşük |
| RFID | 1-2 | 1 - 10 | Düşük | Düşük | Düşük |
| Ultrason | 0.3-1 | 2 - 10 | Düşük | Düşük | Orta |
| Kızılötesi | 1-2 | 1 - 5 | Düşük | Düşük | Orta/Düşük |

Önceki araştırmalarda, tek bir kablosuz teknolojiye dayanan iç mekan konumlandırma sistemlerinin geliştirilmesi için büyük bir çaba harcanmıştır. Bununla birlikte, bu tür teknolojilerin her birinin iç mekan konumlandırmayı desteklemenin bir aracı olarak belirli sınırlamaları bulunmaktadır. Bu gibi sınırlamalar iç mekan konumlandırmada bazı kablosuz teknolojilerin beraber kullanılabilirliği fikrini daha da ön plana çıkarmıştır.

Hibrit bir sistem bireysel olarak her bir teknolojinin güçlü yanlarını kullanarak daha iyi konumlandırma performansı elde etmek için kullanabilir. İç mekan konumlandırmada kullanılan teknolojilerinin hibrit olarak kullanılabilirliğini gözlemlemek için birçok çalışma yapılmıştır.

### 2.3.1. Wi-Fi ve Bluetooth ile Hibrit İç Mekan Konumlandırma

İç mekan konumlandırma için mevcut farklı öneriler arasında Wi-Fi ve Bluetooth yaygın olarak kullanılan 2 kablosuz teknolojidir. Sinyallerin çok fazla miktarda olması sebebiyle, Wi-Fi tabanlı iç mekan konumlandırma sistemleri genellikle parmak izi adı verilen sahne analizi tekniğini kullanmaktadır.

Parmak izi yöntemi, Wi-Fi radyo sinyal gücünü kullanır ve çevrimdışı ve çevrimiçi olarak adlandırılan 2 aşamadan oluşur. Çevrimdışı aşama her zaman çevrimiçi aşamadan önce gerçekleşir. Spesifik olarak, tespit edilebilen tüm Wi-Fi erişim noktalarından gelen sinyal kuvvetleri sabit, ve önceden seçilmiş iç mekan referans konumlarında toplanır. Her referans konumu için, parmak izi olarak $n$ boyutlu bir sinyal gücü vektörü elde edilir. Tüm $m$ referans konumlarının parmak izleri, iç mekan alanı için radyo haritası adı verilen bir veritabanı

oluşturur. Daha sonra, çevrimiçi konumlandırma aşamasında, bir kullanıcının konumu, mevcut konumda elde edilen n-boyutlu sinyal gücü vektörü esas alınarak tahmin edilir. Geçerli sinyal gücü vektörü, içindeki tüm parmak izleriyle karşılaştırılır [16].

Bununla birlikte, Bluetooth tabanlı iç mekan konumlandırma, konum tahmini için yakınlık analizi yöntemini kullanır. Bluetooth özelliği etkin bir cihazı tutan bir kullanıcı belirli bir etkin nokta aralığına girdiğinde, cihaz etkin noktayı (veya tersi) tanımlar ve karşılık gelen referans konumu, kullanıcının konumunun tahmini olarak döndürülür.

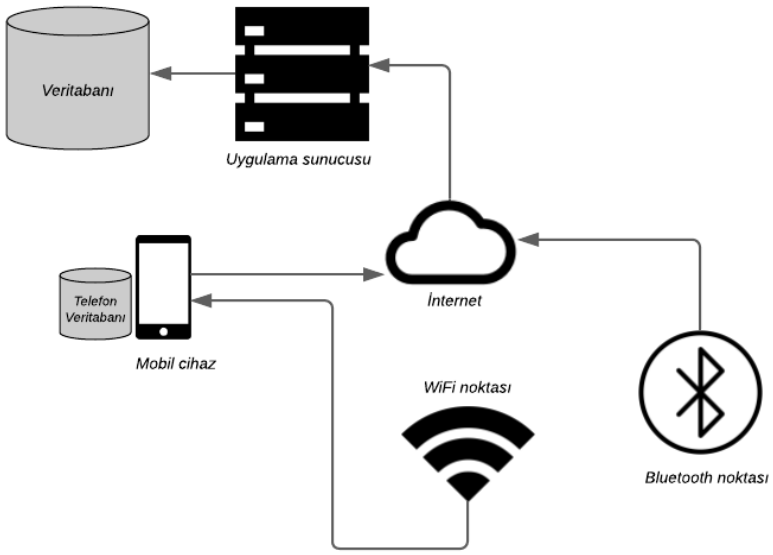
Wi-Fi ve Bluetooth'u bir konumlandırma sisteminde birleştirmek için 2 yaklaşım önerilmiştir. Bunlardan birincisi çevrimdışı fazda her referans konumunda hem Wi-Fi hem de Bluetooth sinyalleri için birleşik bir radyo haritası oluşturulmasına dayanmaktadır. Daha sonra, birleşik radyo haritası, kullanıcı pozisyonlarını tahmin etmek için çevrimiçi fazda kullanılır. Bu birleşik sahne analizi yaklaşımı, Bluetooth için ekstra çevrimdışı parmak izi koleksiyonu gerektirir.

Alternatif olarak, sahne analizi ve yakınlık analizi, tek bir konumlandırma sisteminde sırasıyla Wi-Fi ve Bluetooth'a uygulanabilmektedir. Wi-Fi içeren bir iç mekan alanı göz önüne alındığında, sınırlı sayıda Bluetooth etkin noktası, iç mekan alanını ayrık bölümlere bölmek için dağıtılır. Sonuç olarak, orijinal büyük radyo haritası, her biri Bluetooth etkin noktalarının açılmasının neden olduğu bir iç bölüme karşılık gelen küçük bölümlere ayrılmıştır. Bu yaklaşım çevrimiçi konum tahmininin hesaplama maliyetini düşürür. Fakat Wi-Fi ve Bluetooth arasındaki sinyal paraziti, birleşik bir radyo haritası kullanan konum tahminini etkileyebilmektedir.

Menzil sınırı olmayan teknikler, mobil terminalin kritik kör alanlardaki konumunun belirlenebilmesi için alternatif bir çözüm sunmaktadır. Bu çözümler çevrimdışı ve çevrimiçi şeklinde 2 aşamaya dayanmaktadır. Şekil 2.7'de gösterilen çevrimdışı aşamada, bulunan iç ortam boyunca veri toplanarak (site survey) bir parmak izi veritabanı oluşturulur. Konum tespiti seçilen metriğe göre en yakın parmak izi aranarak gerçekleştirilmektedir.

Hibrit iç mekan konumlandırma sistemi temel olarak genel müşteri - sunucu mimarisini kullanır. Bu hibrit iç mekan konumlandırma sisteminde Şekil 2.8'de gösterildiği gibi 4 bileşen (mobil cihazlar, bir uygulama sunucusu, Wi-Fi erişim noktaları ve Bluetooth noktaları) vardır. Sunucu ve mobil cihazlar, farklı mimari seçeneklerinde kullanılan ayrı veritabanı sistemlerine

sahiptir. Bu mimaride, sadece Wi-Fi tarama ve konum tahmini istemci cihazda gerçekleşir. İstemci, gerektiğinde sunucunun veritabanından Bluetooth tarafından okunan verileri alır [16].




**Şekil 2.8:** Wi-Fi ve Bluetooth hibrit konumlandırma mimari bileşenleri [16].

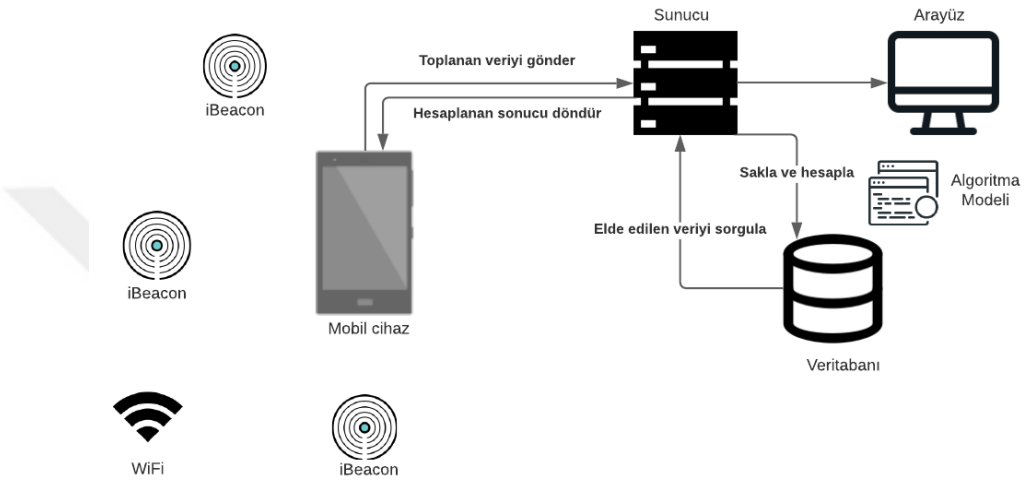
### 2.3.2. iBeacon ve Wi-Fi ile Hibrit İç Mekan Konumlandırma

Wi-Fi ve iBeacon iç mekan konumlandırması için Bluetooth Low Energy (BLE) teknolojisi kullanılmaktadır. İletişim teknolojilerinin gelişimi ve gelişmesiyle birlikte, hibrit sistemde BLE teknolojisini iç mekan konumlandırma alanında kullanılan Apple şirketinin 2013 yılında adını duyurduğu iBeacon adı verilen yeni bir teknoloji benimsenmiştir. iBeacon, hem Android hem de iOS cihazlar için kullanılabilen etkili ve daha az enerji tüketimi sunan platformlar arası bir teknolojidir.

İlgili hibrit iç konumlandırma sisteminde Wi-Fi ve iBeacon'un ayrı çalışmasını sağlamak ve daha sonra birleştirmek yerine iBeacon, Wi-Fi sistemine eklenti olarak kullanılmaktadır. Konum belirleme üç aşamadan oluşmaktadır. Bu aşamalar Şekil 2.9'da gösterilmiştir. İlk adım olan veri toplama 2 ana bileşen içermektedir [17]. İlki, binanın içindeki verilerin toplanmasıdır. Konumlandırma yöntemi RSSI (Received Signal Strength Indication)'ye dayandığından, konumu tahmin etmek için iBeacon cihazlarının ve Wi-Fi kablosuz erişim noktalarının RSSI değerleri kullanılmaktadır. Çevrimdışı aşamada, Wi-Fi erişim noktaların ve iBeacon cihazların RSSI parametreleri toplanır ve parmak izi olarak saklanır. İkincisi ise noktaların gerçek

yerlerinin toplanmasıdır. Sunucuda, veriler tüm RSSI parametreleri arasındaki gürültüler giderildikten sonra hesaplanmakta ve çevrimiçi aşamada kullanılmak üzere saklanmaktadır.

İkinci aşama, en yakın iBeacon cihazının seçimidir. Daha sonra belirli hesaplamalar sonucu çıkan veriler konumu belirlemek için çeşitli sınıflandırma algoritmalarında işlenmesidir. Üçüncü aşama ise tahmini konum noktası sonucunun sistem sunucusuna yüklenmesidir.




**Şekil 2.9:** RSSI'ın parmak izi metodu ile toplanması [17].

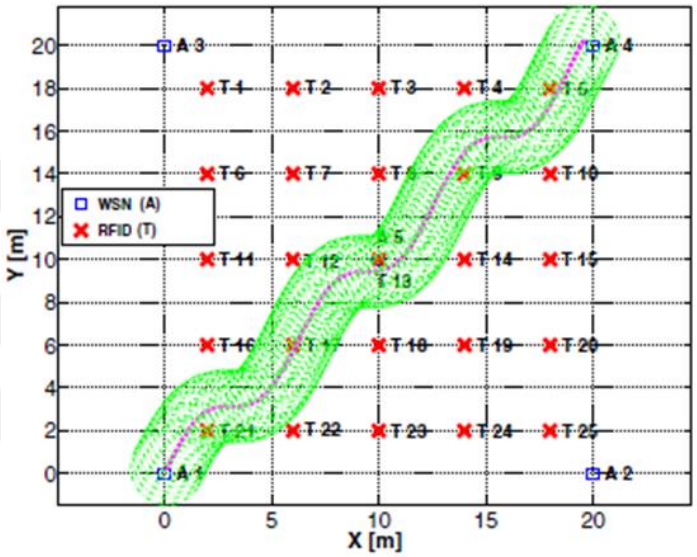
### 2.3.3. RFID ve Kablosuz Sensör Ağı ile Hibrit İç Mekan Konumlandırma

Kablosuz Sensör Ağı (Wireless Sensor Network – WSN) tabanlı konumlandırmaya yardımcı olmak için Radyo Frekanslı Tanıma (RFID) teknolojisi kullanılır. WSN - RFID hibrit karma konumlandırmada 2 yaklaşım önerilmektedir. Bu hibrit sistemde WSN hareketli düğümün pozisyonlarını belirleme konusunda öncü bir rol oynar, RFID bileşeni ise destekleyici bir rol oynar.

Yaklaşımlardan biri Genişletilmiş Kalman Filtresi (Extended Kalman Filter - EKF) algoritmasını, diğeri ise Partikül Filtresi (Particle Filter - PF) yaklaşımını kullanmaktadır. Her 2 yöntem de, genel olarak WSN - RFID hibrit yaklaşımının uygulanabilir olduğunu ve sert iç mekan koşullarında bile iyi konumlandırma tahmin yetenekleri sağladığını gösteren MATLAB simülasyonları ile karşılaştırılmıştır.

Örnek bir WSN - RFID hibrit topolojisi, Şekil 2.10 'da gösterilmiş olup, burada kareler WSN bağlantı düğümlerini ve çaprazları pasif etiketler olan RFID bağlantılarını temsil etmektedir.

Bu topolojide hareketli WSN düğümü ve bir RFID okuyucusu ile donatılmıştır, böylece hem komşu WSN bağlantı düğümleri hem de bağlantı RFID etiketleriyle iletişim kurabilir. Bu topolojide, RFID dağıtımı, çok ucuz olan ve herhangi bir güç kaynağına ihtiyaç duymayan pasif etiketlerden oluşur, bu bakımdan bu hibrit yaklaşımın maliyeti oldukça düşüktür.




**Şekil 2.10:** Hibrit WSN - RFID topolojisi [18].

Topolojide mor noktaların çevrelediği yol, hareketli düğümün gerçek yörüngesidir. Yeşil silindir alan, hareketli düğümde kurulu olan RFID okuyucusunun sorgulama alanını temsil etmektedir. RFID okuyucusunun çok yönlü bir antene sahip olduğunu ve sorgulama alanının yarıçapı r olan bir silindir olduğunu varsayılır.

Her RFID etiketi, yeşil silindir alanla ifade edilen kapsama alanının içinde veya dışında olmasına bağlı olarak mobil RFID okuyucusuna "1" veya "0" bilgisini sağlamaktadır. RFID gözlemini EKF denklemlerine entegre etmek için, RFID bilgisi mesafe tahminine çevrilir. Etiket, okuyucunun kapsama alanı içinde olduğunda, mobil düğümün konumunun, etiketin yarıçapı r ile ortalanan daire içinde eşit bir şekilde dağıldığını varsayılmaktadır.

Elde edilen bu bilgiler ve WSN uzaklık ölçümleri, EKF veya PF kullanılarak belirli matematik hesaplamalar yapılır. Sonrasında RSS uzaklık ölçümleri ile de bu hesaplamalar yapılır. Bu

işlemler MATLAB'da simüle edilerek hareketli düğümün iç mekanda konum tahminleri belirlenir.

Önerilen çözümler yeni donanım gerektirse de (yani bir RFID okuyucusu ve çevrede konuşlandırılan belirli sayıda sabit etiket), hesaplama karmaşıklığı yalnızca WSN konumlandırma sistemlerine göre çok fazla artmamıştır. Ekstra hesaplama miktarı, her pozisyon hesaplamasında okuyucu tarafından tespit edilen ortalama RFID cihazı sayısı ile orantılıdır. Dahası, simülasyon sonuçları hibrit algoritmaların sadece WSN ölçümlerine dayanan algoritmalardan daha yüksek doğruluk gösterdiğini kanıtlamıştır [18].

#### 2.3.4. UltraSound ve RFID ile Hibrit İç Mekan Konumlandırma

Bir diğer hibrit iç mekan konumlandırma sistemi ise dar bantlı UltraSound sistemlerinin bölgesel doğrulamasını, yüksek veri kapasitesine sahip aktif RF sistemleriyle birleştirilmesidir. Taşınabilir bir etiket, sabit bir ultrason vericisinden dar bir bant genişliğinde sinyal alarak odanın konumunu almaktadır. Elde edilen konum daha sonra RF üzerinden geri iletilir. Bu işlem ultrasonun yüksek doğruluğunu hareket halinde olan yüzlerce etiketin eş zamanlı olarak izlenmesini sağlayan geniş iletişim kapasitesine sahip RF sisteminin odanın tam konumunu bulması için birleştirmektedir.

İkinci alternatif ise ultrasonun bir RFID sistemine eklenti olarak yer almasıdır. RFID kendi pozisyonunu üçgenleme (trilateration) veya sinyal gücü ile sağlamaktadır. Bu durumda doğru odanın seçilebilmesi için ultrason vericilerinin yalnızca kritik odalara veya bölgelere eklenmelidir. Bununla birlikte bu konfigürasyonda ultrason sistemi, RFID sisteminin kendi pozisyonlarını iyileştirme konusunda yardımcı olabileceği ilave bilgiler sağlayabileceği ihtimalini de yaratmaktadır. Sonuç olarak, bu hibrit sistemin zaman gecikmesi ölçümüne dayanan önceki hibrit sistemlerden çok daha sağlam bir sistem olduğunu göstermiştir [19].

# 3. MALZEME VE YÖNTEM

## 3.1. KULLANILAN TEKNOLOJİLER

Bu tez çalışmasında Bluetooth cihazlarından alınan veriler Android işletim sisteminde Java dili ile kodlanan mobil uygulama aracılığı ile toplanılmış, toplanan bu veriler MongoDB Realm veritabanında saklanmıştır. Bu bölümde kullanılan bu teknolojilere ait özellikler incelenmiştir.

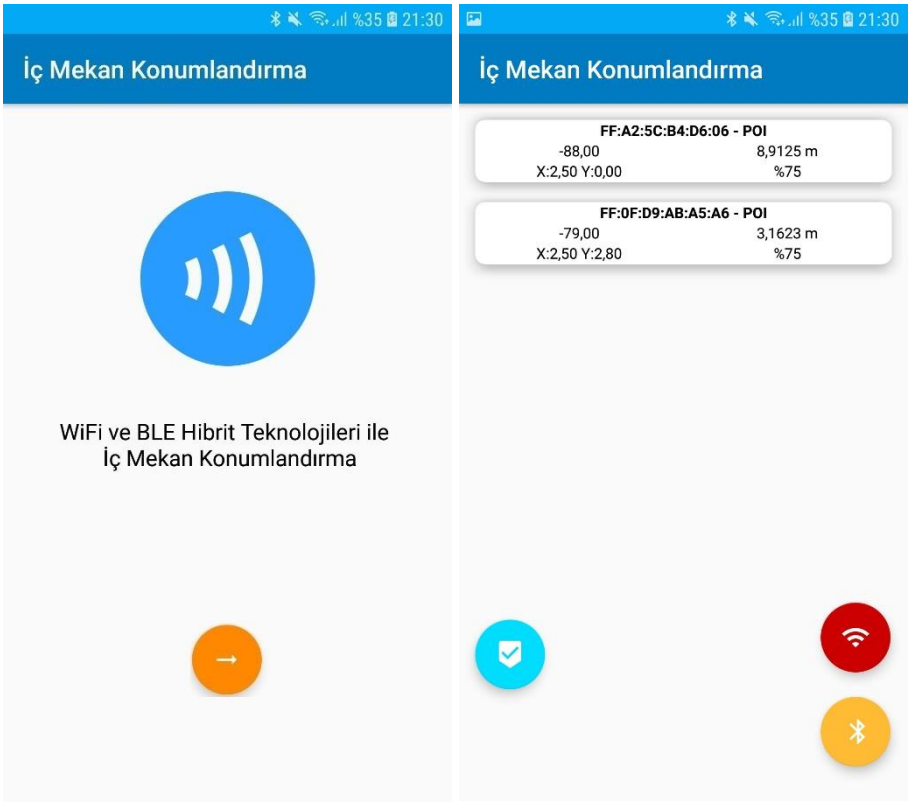
### 3.1.1. Android İşletim Sistemi

Android işletim sistemi mobil cihazlar için geliştirilmiş, Linux tabanlı, özgür, açık kaynak kodlu ve ücretsiz bir işletim sistemidir. Android işletim sisteminde uygulama geliştirme dili Java olup, son yıllarda Kotlin dilini de desteklemektedir. Günümüzde Android işletim sistemi kullanarak kodlanmış 1 milyondan fazla uygulama bulunmaktadır [20]. Tablo 3.1'de Android işletim sisteminin yayınlanan tüm versiyonları, kod adları ve yayın tarihleri verilmiştir.

**Tablo 3.1:** Android işletim sürümleri [20].

| Versiyon | Kod Adı | Yayın Tarihi |
|---|---|---|
| 1.0 | Android 1.0 | 23 Eylül 2008 |
| 1.1 | Android 1.1 | 9 Şubat 2009 |
| 2.3 - 2.3.6 | Gingerbread | 9 Şubat 2011 – 2 Eylül 2011 |
| 3.0 | Honeycomb | 22 Şubat 2011 |
| 4.1 - 4.2 - 4.3 | Jelly Bean | 9 Temmuz 2012 – 13 Kasım 2012 – 24 Temmuz 2013 |
| 5.0 - 5.1 | Lollipop | 3 Kasım 2014 - 9 Mart 2015 |
| 6.0 | Marshmallow | 5 Ekim 2015 |
| 7.0 - 7.1 | Nougat | 22 Ağustos 2016 – 4 Ekim 2016 |
| 8.0 – 8.1 | Oreo | 21 Ağustos 2017 – 5 Aralık 2017 |
| 9 | Pie | 6 Ağustos 2018 |
| 10 | 10 (Q) | 3 Eylül 2019 |
| 11 | 11 | 8 Eylül 2020 |

Bu tez için geliştirilen Android tabanlı mobil uygulamasına ait arayüzler Şekil 3.1'de gösterilmektedir. Uygulama Android'in 8.0 sürümünde yazılmış ve bu sürüme sahip, veri toplamak için kullanılan Samsung Galaxy S7 model mobil cihaz kullanılmıştır. Ayrıca uygulamanın minimum versiyonu 8.0 olup, derleme versiyonu ise 10 olarak belirlenmiştir.




**Şekil 3.1:** Mobil uygulamaya ait ekran görüntüleri.

### 3.1.2. MongoDB Realm Veritabanı

Realm, mobil işletim sistemleri (Android / iOS) için açık kaynaklı bir nesne veritabanı yönetim sistemidir. Realm veritabanı SQLite gibi veritabanı yönetimine bir alternatiftir. Realm Object Server ile verilen günlüklenmiş olana ait istemci tarafı veritabanları arasında 2 yönlü senkronizasyona izin verir. PostgreSQL gibi diğer veritabanı yönetim sistemleriyle entegrasyon için bir işletme lisansı ile birlikte hem bir geliştirici hem de ticari bir sürümü yayınlamıştır. Realm, 24 Nisan 2019 tarihinde MongoDB tarafından satın alınmıştır [21]. Realm veritabanını Android işletim sisteminde kullanabilmek için Java sınıflarının RealmObject sınıfından miras alması (inheritance) gerekir. Bu tez çalışmasında "Device" ve "Location" adında 2 sınıf

oluşturulmuş ve bu sınıflar RealmObject sınıfından miras almıştır. Bu sınıflara ait değişkenlerin özellikleri aşağıda verilen Tablo 3.2 ve Tablo 3.3'de yer almaktadır.

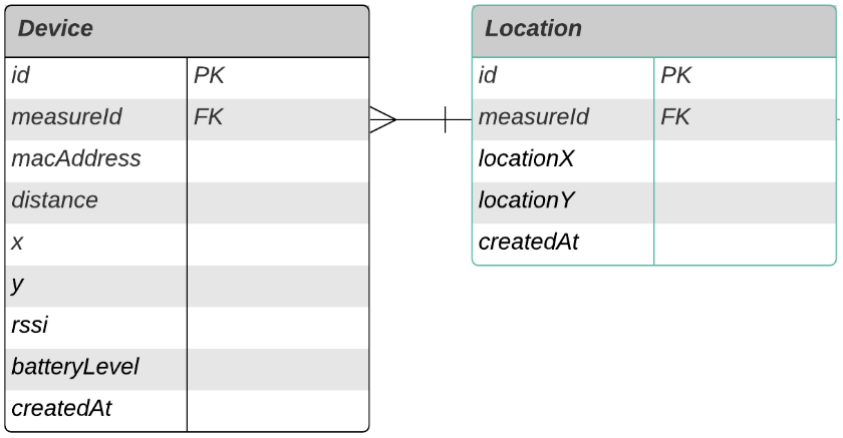
**Tablo 3.2:** Device sınıfı değişkenleri.

| Değişken Adı | Değişken Tipi | Açıklama |
|---|---|---|
| id | String | Birincil Anahtar (PK) |
| measureId | String | Ölçüme ait ID |
| macAddress | String | Cihazın MAC adresi |
| distance | Double | Cihazın istemciye uzaklığı |
| x | Double | Cihazın x koordinatındaki noktası |
| y | Double | Cihazın y koordinatındaki noktası |
| rssi | Double | Cihazın RSSI değeri |
| batteryLevel | Integer | Cihazın batarya seviyesi |
| createdAt | String | Cihazdan veri alınan zaman |

**Tablo 3.3:** Location sınıfı değişkenleri.

| Değişken Adı | Değişken Tipi | Açıklama |
|---|---|---|
| id | String | Birincil Anahtar (PK) |
| measureId | String | Ölçüme ait ID |
| locationX | Double | İstemcinin x koordinatındaki noktası |
| locationY | Double | İstemcinin y koordinatındaki noktası |
| createdAt | String | Oluşturulma zamanı |

Device sınıfı Beacon cihazları, Wi-Fi erişim noktası ve telefon, kulaklık vb. gibi cihazlara ait ölçüm sırasındaki verilerini, Location sınıfı ise Device sınıfından alınan verilerin, belirlenen koordinat sistemine göre tahmini noktalara ait verileri tutmaktadır. Device ve Location sınıflarına ait tablolar "measureId" kolonu ile birbirleriyle bağlıdır. Bu ilişkiyi gösteren varlık - ilişki diyagramı aşağıda Şekil 3.2'de verilmiştir.




**Şekil 3.2:** Varlık - ilişki diyagramı.

## 3.2. KULLANILAN SİNYAL ÇEŞİTLERİ

Bu bölümde iç mekanda belirli bir Nesnelerin İnterneti ekosistemi oluşturabilmek adına kullanılabilecek sinyal çeşitleri ve özellikleri analiz edilmiştir. Bu başlıkta çalışma kapsamında iç mekan konum belirleme amacıyla kullanılan Wi-Fi ve BLE'ye ait özellikler ayrıntılı olarak incelenmiştir.

### 3.2.1. Wi-Fi Temelli Konum Belirleme

Wi-Fi, IEEE kablosuz iletişim standardı 802.11'e dayanan en yaygın kullanılan kablosuz iletişim teknolojisidir. Hemen her binada erişim noktalarının varlığı, dizüstü bilgisayar, mobil cihazlar gibi pek çok günlük hayatta kullanılan cihazın Wi-Fi teknolojisini desteklemesi, cihazlara göre daha uzun mesafeye erişebilmeleri gibi sebebiyle Wi-Fi sinyalleri kapalı alanlarda konum belirleme işleminde kullanılabilecek temel teknolojilerden biridir.

Wi-Fi sinyallerinin toplanarak iç mekan konum belirlemede kullanılabilmesi amacıyla çalışmada test ortamı olarak kullanılan alan içerisinde yer alan erişim noktasına ait RSSI sinyalleri toplanmıştır. Tablo 3.4'de yer alan RSSI değerlerine göre Wi-Fi sinyal kalitesini göstermektedir. -49 $dBm$ ve üstünde elde edilen sinyaller kaliteli olarak kabul edilirken, -99 $dBm$ ve altında sinyal kalitesi çok düşük olduğu için haberleşme sağlanamadığı kabul edilmektedir.

**Tablo 3.4:** Wi-Fi sinyal kalitesi ve nitelikleri [22].

| Sinya Aralığı | Sinyal Kalitesi | Sinyal Göstergesi | Sinyal Niteliği |
|---|---|---|---|
| -49 dBm ve üstü | İyi |  | Sesli iletişime imkân verecek ölçüde güçlü sinyal elde edilmiştir. |
| -51 ve -79 dBm arası | Orta |  | İnternette gezinme, eposta gönderme gibi temel işlevler gerçekleştirilebilir. |
| -79 ve -99 dBm arası | Düşük |  | Bağlantı sağlansa da veri aktarımında zorluklar yaşanır. |
| -99 dBm ve altı | Çok Düşük |  | Sinyal alınan cihaza bağlantı sağlanması zorludur. |

Elde edilen RSSI değerleri, Serbest Uzay Yol Kaybı (Free Space Path Loss - FSPL) yöntemi ile kullanılarak istemci ve erişim noktası arasındaki mesafeyi hesaplama amacında kullanılmıştır.

Nokta kaynaktan uzaklaştıkça enerjinin daha geniş bir yüzeye dağılması sonucu; kürenin birim yüzey alanına düşen enerji azalmaktadır. Bu nedenle bir verici kaynaktan uzaklaştıkça elektromanyetik dalganın enerjisinde meydana gelen zayıflamaya Serbest Uzay Kaybı olarak tanımlanmaktadır. Antenden yayılan güç, serbest uzayda frekansın karesi ve uzaklık ile ters orantılı olarak azalmaktadır. Bu tez çalışmasında frekans ($f$) mHz cinsinden alınmıştır, bu bakımdan uzaklık ise metre cinsinden hesaplanmıştır. Vericiden d (kaynağa olan uzaklık) kadar uzaklıktaki bir noktada oluşan Serbest Uzay Kaybı ($L_{FSPL}$) formülü Denklem 3.1 ve 3.2'de yer almaktadır.

$$L_{FSPL} = -10\ log\left(\frac{\lambda}{4\pi d}\right)^2 \tag{3.1}$$

$$L_{FSPL} = 27.55 + 20log\ d + 20log\ f \tag{3.2}$$

### 3.2.2. Bluetooth Düşük Enerji Temelli Konum Belirleme

2013 yılında Apple tarafından geliştirilen iBeacon, Bluetooth Düşük Enerji (Bluetooh Low Energy, BLE) kablosuz teknolojisini kullanan kısa mesafeli, düşük tüketim gücüne sahip, düşük

maliyetli ve yakınlığa dayalı kablosuz bildirim sağlayan elektronik cihazlardır [23]. İlk olarak Apple tarafından tanıtılsa da Beacon cihazları hem iOS hem de Android işletim sistemine sahip mobil cihazlar ile kullanılabilmektedir.

BLE teknolojisi günümüzde oldukça yaygın kullanım alanlarına sahiptir. Havaalanları, alışveriş merkezleri, market, işyerleri, müzeler, tıbbi cihazlar, spor ve fitness cihazları, endüstriyel izleme sensörler, ev otomasyonları, toplu taşıma uygulamaları, uzaktan kumandalar, kablosuz fare ve klavye gibi bilgisayar çevre aygıtları kullanım alanlarına örnek olarak verilebilir.

Tüm BLE cihazları Genel Öznitelik Profili (Generic Attribute Profile - GATT) adı verilen bir yapıya sahiptir. Bu yapı profil ve kullanıcı verilerinin bir BLE bağlantısı üzerinden nasıl aktarılıp alınabileceği hakkında ayrıntılı olarak belirlemektedir.

GATT ve BLE bağlantısı ile ilgili en önemli nokta bu bağlantıların özel olmasıdır. Bir BLE çevre biriminin aynı anda yalnızca bir merkezi cihaza (cep telefonu gibi) bağlanabilir ve çevre birimi merkezi bir cihaza bağlandıktan sonra diğer cihazlar mevcut bağlantı kesilene kadar bu cihazı göremez veya bağlanamaz.

GATT'ta yer alan terimler ile ilgi açıklamalar aşağıda yer almaktadır.

- İstemci: GATT komutlarını ve isteklerini başlatan, isteklere gelen cevapları kabul eden cihazlar
- Sunucu: GATT komutlarını ve isteklerini alan, cevapları yollayan cihazlar
- Karakteristik (Characteristic): Client ve server arasında aktarılan verinin değeri.
- Servis: Benzer karakteristiklerin toplu sunulduğu alan. Örneğin batarya seviyesi, ısı değeri vb.
- Tanımlayıcı: Karakteristik hakkında bilgi. Örneğin ısı değeri olarak Celcius kullanılacaksa o karakteristikteki tanımlayıcıya "Celcius" yazılabilir.
- Belirteç: Servis, tanımlar ve karakteristiklere ait eşsiz bir UUID vardır. Bu UUID'lere belirteç adı verilir.

Beacon cihazları konumlandırıldıkları ortamdan sürekli Bluetooth sinyali yayarlar. Günümüzde gelişen Bluetooh teknolojisi ile sinyallerin ulaşabileceği mesafe oldukça artmıştır. Tablo 3.5'de Bluetooth sürümleriyle ilgili bazı parametreler özelinde karşılaştırmaya yer verilmiştir.

**Tablo 3.5:** Bluetooth teknolojilerinin karşılaştırması.

| Sinyal Aralığı | Uzaklık | Ağ Topolojisi | Maksimum Veri Oranı | Gecikme |
|---|---|---|---|---|
| Bluetooth 2.1 | 100 m'ye kadar | Piconet, Scatternet | 1 - 3 Mbps | < 100 msn |
| Bluetooth 4.0 (LE) | 100 m'ye kadar | Star-bus | 1 Mbps | < 6 msn |
| Bluetooth 5 (LE) | 200 m'ye kadar | Star-bus | 2 Mbps | < 3 msn |

## 3.3. KULLANILAN YÖNTEM VE ALGORİTMALAR

Bu bölümde Bluetooth cihazlarından veri toplama aşamasında ölçülen RSSI değerlerindeki gürültüyü gidermek için Kalman filtresi, istemci konumunun belirlemede Doğrusal Olmayan En Küçük Kareler Yöntemi (Non-linear Least Squares - NLLS) ve Levenberg - Marquardt (LM) algoritması, makine öğrenmesinde ise KNN ve SVM algoritmaları kullanılmıştır. Bu bölümde kullanılan bu yöntemlere ait özellikler incelenmiştir.

### 3.3.1. Kalman Filtresi

Kalman filtresi ilk olarak 1960 yılında Rudolf Kalman tarafından lineer sistemler üzerinde kullanılmak üzere önerilen, zaman içinde gözlemlenen ölçümler verilen bazı bilinmeyen değişkenlerin tahminlerini sağlayan bir algoritmadır. Kalman filtresi basit bir forma sahiptir ve hesaplama gücü düşüktür [24].

İdeal bir ortamda, RSSI değeri sadece 2 cihaz arasındaki mesafeye bağlıdır. Fakat RSSI değerleri çevresel faktörlerden büyük oranda etkilenir ve bunun sonucu olarak da yüksek seviyede gürültüye sahiptir. Bu gürültü çok yollu yansımalardan kaynaklanmaktadır. Örnek olarak çevredeki sinyaller, mobilyalar, eşyalar, duvarlar vb. gibi ortamdaki nesnelere karşı yansır [25]. Bu bakımdan RSSI değerlerindeki gürültüyü gidermek üzere Kalman filtresi kullanılmıştır.

Kalman filtresi, gürültülü ölçümlere dayalı olarak bazı gözlemlenmemiş değişkenlerin bir tahminini yapmaktadır. Ölçümlerin geçmişini hesaba kattığı için yinelemeli bir algoritmadır. Kalman filtresi doğrusal modelleri varsayar. Mevcut durumdan bir sonraki duruma geçiş ve durumdan ölçüme geçiş doğrusal dönüşümler olmalıdır. Bu tez çalışmasındada cihazlardan elde

edilen RSSI ölçümlerimize dayanarak gerçek RSSI değerini hesaplama işlemi gerçekleştirilmiştir. Geçiş modelinin genel formu Denklem 3.3'de yer almaktadır.

$$x_t = \mathrm{A}x_{\mathrm{t}-1} + \mathrm{B}u_{\mathrm{t}} + \in_t \tag{3.3}$$

RSSI verisi üzerinde filtreyi uygulamamız için, ilgili Bluetooth cihazının hareket etmediği varsayılır. Bu bakımdan aslında beklenen şey zamanla sabit bir RSSI sinyalidir ve geri kalan her şey gürültü olarak varsayılır. Bu yaklaşımı uygulamak için $u$ tamamen yok sayılır ve $A$ birim matris olarak kabul edilir. Böylece Denklem 3.4 elde edilir.

$$x_t = \mathrm{A}x_{\mathrm{t}-1} + \mathrm{B}u_{\mathrm{t}} + \in_t \approx x_{\mathrm{t}-1} + \in_t \tag{3.4}$$

Kalman filtresini uygulamanın ikinci adımı ise gözlem modelini tanımlamaktır. Belirli bir $x$ durumunu nasıl bir $z$ ölçümü ile sonuçlanacağını gösteren genel model Denklem 3.5'de yer almaktadır.

$$z_t = \mathrm{C}_t x_{\mathrm{t}} + \delta_t \tag{3.5}$$

Burada $C$ dönüşüm matrisi ve $\delta$ ise hatalı ölçümlerin neden olduğu gürültüdür. RSSI doğrudan modellendiğinden durum ve ölçümler eşittir. Bu, aşağıdaki azaltılmış ölçüm modeliyle sonuçlanır ve Denklem 3.6 elde edilir.

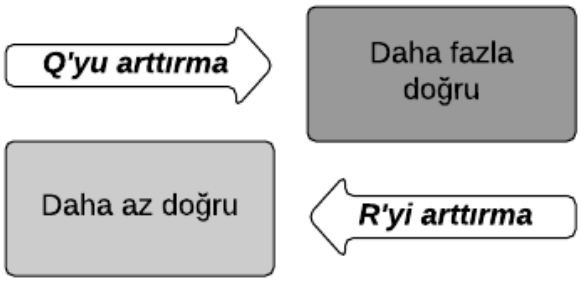
$$z_t = \mathrm{C}_t x_{\mathrm{t}} + \delta_t \approx x_{\mathrm{t}} + \delta_t \tag{3.6}$$

#### *3.3.1.1. Kalman filtresi için parametre seçimi*

Kalman filtresi özyinelemeli bir filtredir. Filtre hedefin durum vektörünü, duruma ait bir kovaryans matrisini, işlem gürültü kovaryans matrisini ($Q$) ve ölçüm gürültü kovaryans matrisini ($R$) alır. Filtre, durum vektörünü sabit bir zaman aralığı ile ilerletir. Önceden mevcut verilerden bir sonraki durumu ve sonraki durum kovaryans matrisini hesaplar. Bu adımlar sırasında, $Q$ ve $R$ matrisleri sabit girdiler olarak kullanılır. Bu nedenle, uygun bir Kalman filtresi tasarlamak için bu 2 parametrenin belirlenmesi gerekir. Filtrenin performansı kesinlikle bu parametrelerin doğru seçimine bağlıdır [26].

$Q$ ve $R$'yi düşünmenin temel bir yolu, tahmin (durum) denklemleri ile ölçüm (çıktı) denklemleri arasında ağırlıklandırma faktörleri olmalarıdır. Daha büyük bir $Q$ düşünmek, durum

denklemlerinde daha büyük belirsizliği dikkate almaya ve bu denklemlerin sonucuna daha az güvenmeye eşdeğerdir, bu da filtrenin ölçüm güncellemesiyle daha fazla düzeltmesi gerektiği anlamına gelir. Benzer şekilde, daha büyük bir $R$'nin dikkate alınması, ölçümde daha büyük belirsizliği dikkate almaya ve ölçüme daha az güvenmeye eşdeğerdir, bu da filtrenin ölçüm güncellemesiyle daha az düzeltmesi gerektiği anlamına gelir [27]. Bu olguyu detaylandıran bir şema Şekil 3.3'de gösterilmektedir.




**Şekil 3.3:** Gürültü kovaryans varsayımlarının filtreye etkisi.

Bu tez çalışmasında Kalman filtresini RSSI değerleri üzerinde kullanılacağı için ve bu sinyallerin çevresel faktörlerden etkilendiğini için ölçümlerle ilgili güvensizliğin daha baskın olduğu varsayılmıştır. Bu bakımdan kullanılan filtrede $R > Q$ olarak belirlenmiştir.

### 3.3.2. Doğrusal Olmayan En Küçük Kareler Yöntemi

Doğrusal Olmayan En Küçük Kareler yöntemi, gözlem sayısının bilinmeyen parametrelerin sayısından daha fazla olduğu doğrusal olmayan bir problemi çözmek için kullanılabilen bir optimizasyon tekniğidir [28]. Üç veya daha fazla referans noktası olduğunda, bu yöntem ile alıcının konumunu Denklem 3.7'de verilen şekilde çözmek için kullanılabilir.

$$r_i^2 = (x - p_i)^2 + (y - q_i)^2 \tag{3.7}$$

Alıcı nokta burada istemci, referans noktası ise cihazdır. Bu denklemde $r_i$, RSSI ve yol kaybı modeli kullanılarak bulunan $i$. konum ile alıcı arasındaki referans noktaları arasındaki mesafedir, $(x, y)$ istemcinin konumudur ve $(p_i, q_i)$ $i$. cihazın konumudur.

Doğrusal olmayan en küçük kareler, mevcut bilgileri kullanarak farklı koordinat kümelerini hesaplayarak ve ardından bu nokta arasındaki kareli hatayı referans noktalarına toplayarak bir konumu belirler [28]. Konumlandırma hatası formülü Denklem 3.8'de verilmiştir.

$$Hata = \sqrt{(x_i - x_{tahmini})^2 + \left(y_i - y_{tahmini}\right)^2} \tag{3.8}$$

Burada $i$ geçerli referans noktasıdır, $(x_i, y_i)$ referans noktasının konumudur ve $(x_{tahmini}, y_{tahmini})$ tahmini konumdur. Doğrusal Olmayan En Küçük Karelerin amacı, olabildiğince küçük veya bir eşik dahilinde olan kare mesafelerin toplamını bulmaktır [28].

### 3.3.3. Levenberg - Marquardt Algoritması

Kenneth Levenberg ve Donald Marquardt tarafından olarak geliştirilen Levenberg - Marquardt (LM) algoritması doğrusal olmayan bir fonksiyonu en aza indirme problemine sayısal bir çözüm sağlayan optimizasyon algoritmasıdır [29]. Levenberg - Marquardt algoritması, en yaygın kullanılan optimizasyon algoritmalardan biridir. Levenberg - Marquardt algoritmasının bir çözüm sağlamasına Doğrusal Olmayan En Küçük Kareler Minimizasyonu denir.

Newton algoritmalarından türetilerek elde edilen Levenberg - Marquardt algoritması, parametre güncelleme işlemlerini, bütün girdiler için oluşturulan hata vektörü ve Jacobian matrisi ile yapmaktadır. Bu algoritma bellek gibi sistem kaynaklarını diğer algoritmalara göre nazaran daha faza kullanmaktadır. Buna rağmen ağın eğitimi çok daha kısa sürede gerçekleşmektedir. Genelleme iyileşmeyi durdurduğunda eğitim sonlanmaktadır [30] [31]. LM algoritması güncellemesi Denklem 3.9'da verilmiştir.

$$\Delta w = (J^T J + \mu I)^{-1} J^T e \tag{3.9}$$

Denklem 3.9'da belirtilen w, ağırlık vektörü, $I$, birim matrisi, ve $\mu$, kombinasyon katsayısıdır. $J, [(P\ x\ n), N]$ boyutunda Jacobian matrisini, $e$, $[(P\ x\ n), 1]$ boyutunda hata vektörünü ifade eder. $P$, eğitim örnek sayısını, $n$, çıktı sayısını ve $N$, ağırlık sayısını gösterir [32].

### 3.3.4. K - En Yakın Komşuluk Algoritması

K - En Yakın Komşu (K - Nearest Neighbour - KNN) algoritması, 1967 yılında T. M. Cover ve P. E. Hart tarafından önerilen örnekleri benzerliklerine göre sınıflandıran mesafeye dayalı sınıflandırıcı olarak da bilinen denetimli bir öğrenme yöntemidir. KNN algoritması, sınıfları

belli olan bir örnek kümesindeki verilerden yararlanır. Örnek veri setine katılacak olan yeni verinin, mevcut verilere göre uzaklığı hesaplanıp, k sayıda yakın komşuluğuna bakılmaktadır.

KNN algoritmasında sınıflandırma işlemini yapmak için bir uzaklık ölçüm fonksiyonuna ihtiyaç duymaktadır. Probleme özgü olarak kullanılabilecek çok sayıda uzaklık ölçüm fonksiyon bulunmasına karşın temel fonksiyonlar Euclidean, Minkowski ve Manhattan fonksiyonlarıdır. $U$ uzaklığı göstermek üzere ilgili fonksiyonlar sırasıyla Denklem 3.10, Denklem 3.11 ve Denklem 3.12'de görülmektedir [33].

$$U = \sqrt[2]{\sum |x_{eğitim} - x_{test}|^2} \tag{3.10}$$

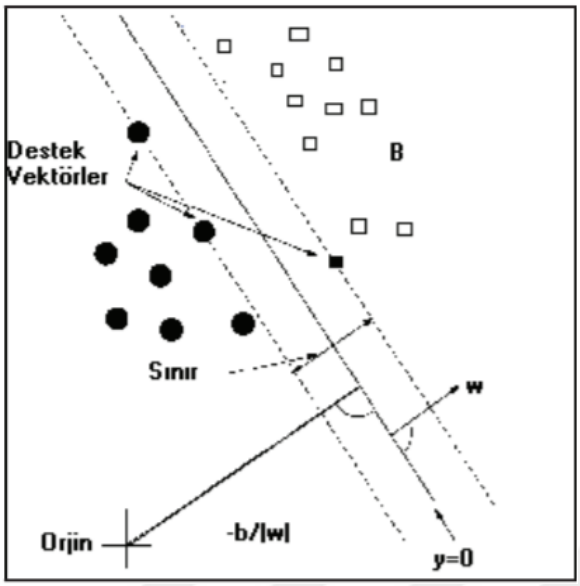
$$U = \sqrt[p]{\sum |x_{eğitim} - x_{test}|^p} \tag{3.11}$$

$$U = \sum |x_{eğitim} - x_{test}| \tag{3.12}$$

KNN algoritması eğitim ve test aşaması olmak üzere 2 ayrı faza sahiptir. KNN algoritması, verilerin sınıflandırılması için açıkça herhangi bir eğitim aşaması gerekmemektedir. Eğitim aşaması genellikle veri vektör koordinatlarının sınıf etiketi ile birlikte depolanmasını içerir. Sınıf etiketi genel olarak veri vektörü için bir tanımlayıcı olarak kullanılmaktadır. Bu, test aşamasında veri vektörlerini sınıflandırmak için kullanılır. Test için veri noktaları verildiğinde, KNN algoritmasının amacı yeni nokta için sınıf etiketini bulmaktır.

### 3.3.5. Destek Vektör Makinesi Algoritması

Destek Vektör Makineleri (Support Vector Machines - SVM) ilk kez 1995 yılında Vladimir Vapnik tarafından sınıflandırma ve regresyon tipi problem çözümleri için önerilen, güçlü istatistiksel teoriler üzerine kurulmuş bir makine öğrenmesi yöntemidir. Geleneksel makine öğrenmesi yöntemlerinde fazla sayıda eğitim verisinin gerekliliği, düşük yakınsama oranı, yerel minimuma takılma gibi problemlerle karşılaşılmaktadır. SVM, az sayıda veri içeren fakat yüksek boyutlu uygulamalarda da oldukça başarılıdır [34]. Şekil 3.4'de SVM'nin sınıflandırıcı yapısının çalışma prensibi yer almaktadır.




**Şekil 3.4:** SVM sınıflandırıcı yapısı [34].

SVM'nin çok büyük sayıda öz nitelik barındıran özellik alanlarında yüksek başarım sağlama potansiyeli bulunmaktadır. Bunun nedeni SVM'nin eğitim aşamasında, sınıflandırılmış vektör boyutunun geleneksel sınıflandırıcının üzerine çıkması ve büyük sınıflandırma problemlerinde verimli olmasıdır. Bu durum hata sınıflandırmasında da fayda sağlamaktadır. Ayrıca, bir SVM tabanlı sınıflandırıcının geleneksel sınıflandırıcılara kıyasla daha iyi genelleme özelliklerine sahip olduğunu gösteren çalışmalar mevcuttur. SVM, sınıflandırıcı eğitiminde yapısal yanlış sınıflandırma riskini en aza indirirken, geleneksel sınıflandırıcılar genellikle deneysel riskin en aza indirilmesi için eğitilmektedir [35].

SVM tekniği ikili bir sınıflandırıcı olarak geliştirilmiş olmasına rağmen çoklu sınıf ayrımında da kullanılmaktadır. Çoklu sınıfların SVM ile ayrıştırılmasında; $n$: $(x_i , y_i)$ formatında tanımlanmış eğitim verisini, $c$: toplam sınıf sayısını, $w$: iz düşüm için kullanılan parametreyi, $b$: taban değerini temsil etmek üzere $c$ adet ikili SVM modeli oluşturulmaktadır.

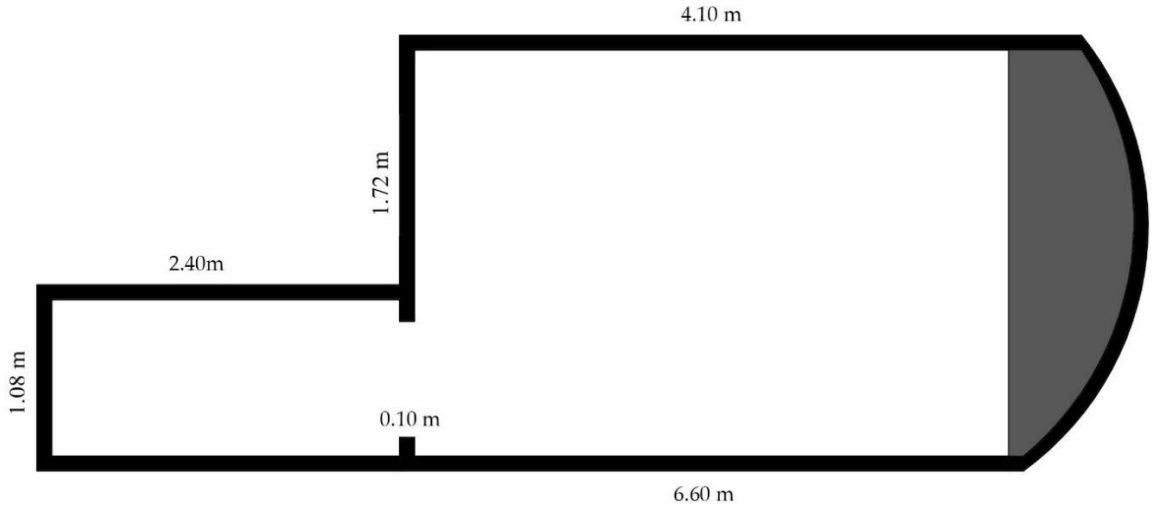
Gevşek değişkenler $\xi_i$ ve hata cezası $C$ ile gürültü dikkate alındığında verileri ayıran optimum hiper düzlem, aşağıdaki optimizasyon problemine bir çözüm olarak elde edilebilir [35]. İlgili işlemler Denklem 3.13 ve Denklem 3.14'de yer almaktadır.

$$min\ \frac{1}{2}\left|\left|w\right|\right|^2 + C\ \sum_{i=1}^{M} \xi_i \tag{3.13}$$

$$s.t.\ \begin{cases} y_i(x_i w^T + b) \geq 1 - \xi_i, & i = 1, \dots, M \\ \xi_i > 0, & i = 1, \dots, M \end{cases} \tag{3.14}$$

## 3.4. OLUŞTURULAN TEST ORTAMI

Bu tez çalışmasında iç mekan konumlandırma için belirlenen ev ortamında ölçüm alınmıştır. Şekil 3.5'de verilerin toplandığı alana ait plan çizimi yer almaktadır. Bu ölçüm alanında duvar kalınlığı ve gri renkte boyanan alanın eğri bir yapıya sahip olmasıyla birlikte içerisinde pencere bulunması sebebiyle ölçümde yer almamıştır, göz ardı edilmiştir.




**Şekil 3.5:** Verilerin toplandığı alana ait plan.

### 3.4.1. Ortamda Kullanılan Cihazlar

İç mekan konumlandırma ortamı oluşturabilmek adına test ortamında 2 tip senaryo üzerinden ölçüm gerçekleştirilmiştir. Planda sol en alt köşe orjin nokta olarak belirlenmiş olup, orjin noktasına göre cihazların her biri belirli koordinatlara sahiptir.

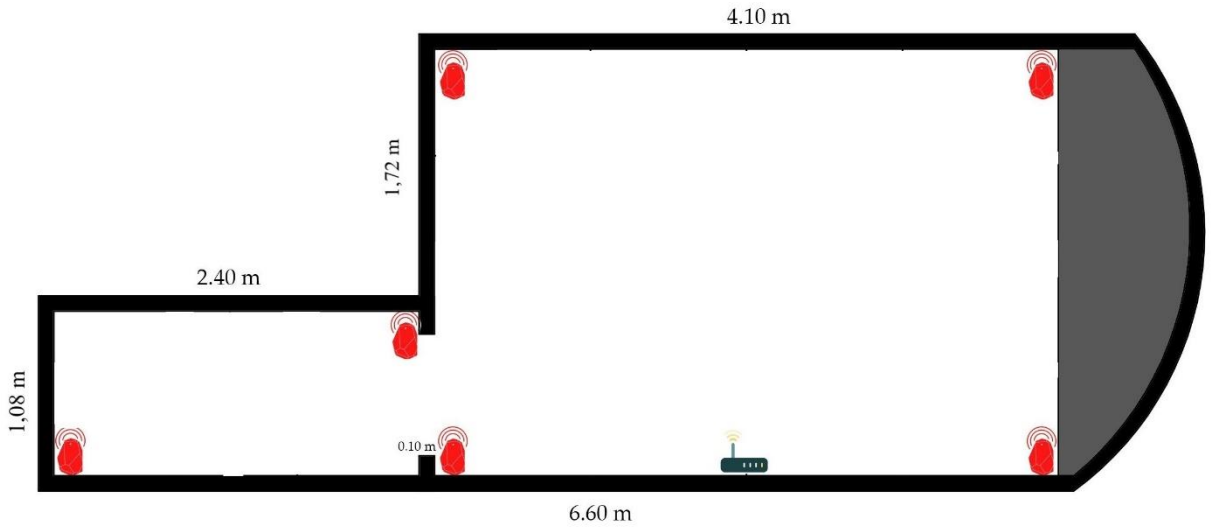
#### *3.4.1.1. Wi-Fi ve Beacon Cihazlarının Yerleşimi*

Test ortamında bulunan odada 1 adet Wi-Fi erişim noktası ve Bluetooth sinyalleri yayan 4 adet oda içerisinde, 2 adet ise antrede bulunan toplam 6 adet Beacon cihazı yerleştirilmiştir. Cihazların model bilgileri ve bulundukları konumlar Tablo 3.6'da gösterilmiştir.

**Tablo 3.6:** Test ortamında yer alan cihaz bilgileri.

| Cihaz Tipi | Cihaz Marka/Model | Desteklediği Teknolojiler | Bulunduğu Konum | Kapsama Alanı (m) | Bulunduğu Nokta (x,y) |
|---|---|---|---|---|---|
| Wi-Fi Erişim Noktası | Huawei HG255s | IEEE 802.11n, 802.11g, 802.11b | Oda | 70 | (4.55,0.0) |
| Beacon Cihazı | POI Beacon | Bluetooth 4.0 (BLE) | Antre | 70 | (0.0,0.0.0) |
| Beacon Cihazı | POI Beacon | Bluetooth 4.0 (BLE) | Antre | 70 | (2.4,1.08) |
| Beacon Cihazı | POI Beacon | Bluetooth 4.0 (BLE) | Oda | 70 | (2.5,0.0) |
| Beacon Cihazı | POI Beacon | Bluetooth 4.0 (BLE) | Oda | 70 | (2.5,2.8) |
| Beacon Cihazı | POI Beacon | Bluetooth 4.0 (BLE) | Oda | 70 | (6.6,0.0) |
| Beacon Cihazı | POI Beacon | Bluetooth 4.0 (BLE) | Oda | 70 | (6.6,2.8) |

Test ortamına yerleştirilen cihazların oda ve antre içerisinde yerleşimi Şekil 3.6'da gösterilmiştir.




**Şekil 3.6:** Verilerin toplandığı alana ait Wi-Fi ve BLE cihaz yerleşim planı.

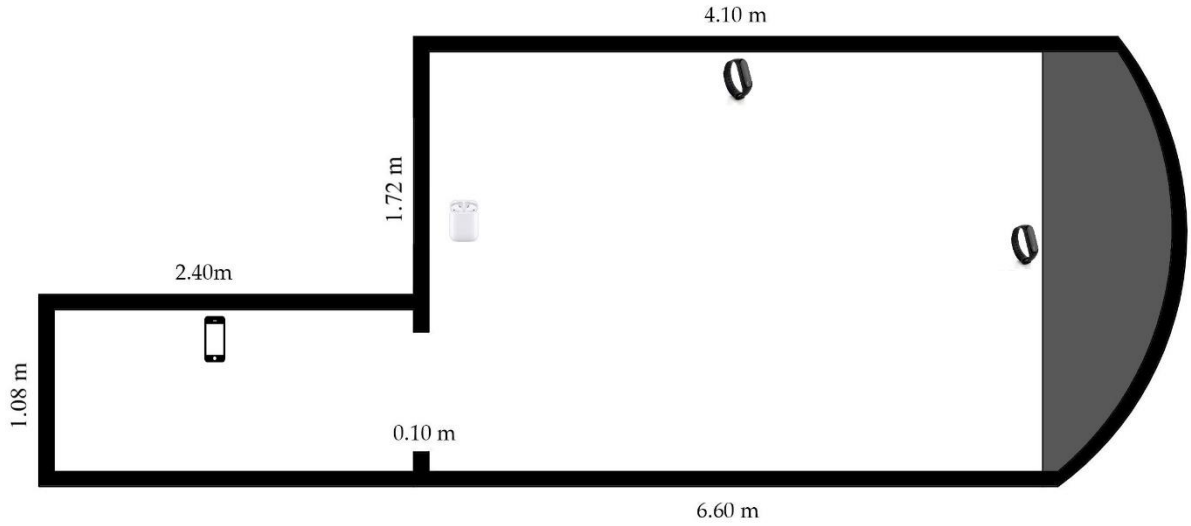
### *3.4.1.2. Akıllı Cihazların Yerleşimi*

Makine öğrenmesi ile yapılan ölçümlerde ayrıca test ortamında yer alan antrede bir adet akıllı telefon, odada ise 2 adet akıllı saat ve bir adet kablosuz kulaklık olmak üzere toplam 4 adet Bluetooth sinyali yayabilen akıllı cihaz yerleştirilmiştir. Cihazların model bilgileri ve bulundukları konumlar Tablo 3.7'de gösterilmiştir. Bu cihazlar BLE teknolojisini desteklemektedirler.

**Tablo 3.7:** Test ortamında yer alan Bluetooth akıllı cihaz bilgileri.

| Cihaz Tipi | Cihaz Marka/Model | Desteklediği Teknolojiler | Bulunduğu Konum | Kapsama Alanı (m) | Bulunduğu Nokta (x,y) |
|---|---|---|---|---|---|
| Akıllı Telefon | Apple iPhone SE 2020 | Bluetooth 5.0, A2DP, LE | Antre | yaklaşık 10 | (1.2,1.08) |
| Akıllı Saat | MI Band 2 | Bluetooth 4.0/4.2 | Antre | yaklaşık 10 | (4.55,2.8) |
| Akıllı Saat | MI Band 2 | Bluetooth 4.0/4.2 | Antre | yaklaşık 10 | (6.6,1.4) |
| Kablosuz Kulaklık | Apple Airpods 2.Nesil | Bluetooth 5.0 | Oda | yaklaşık 10 | (2.5,1.4) |

Test ortamına yerleştirilen akıllı cihazların oda ve antre içerisinde yerleşimi Şekil 3.7'de gösterilmiştir.



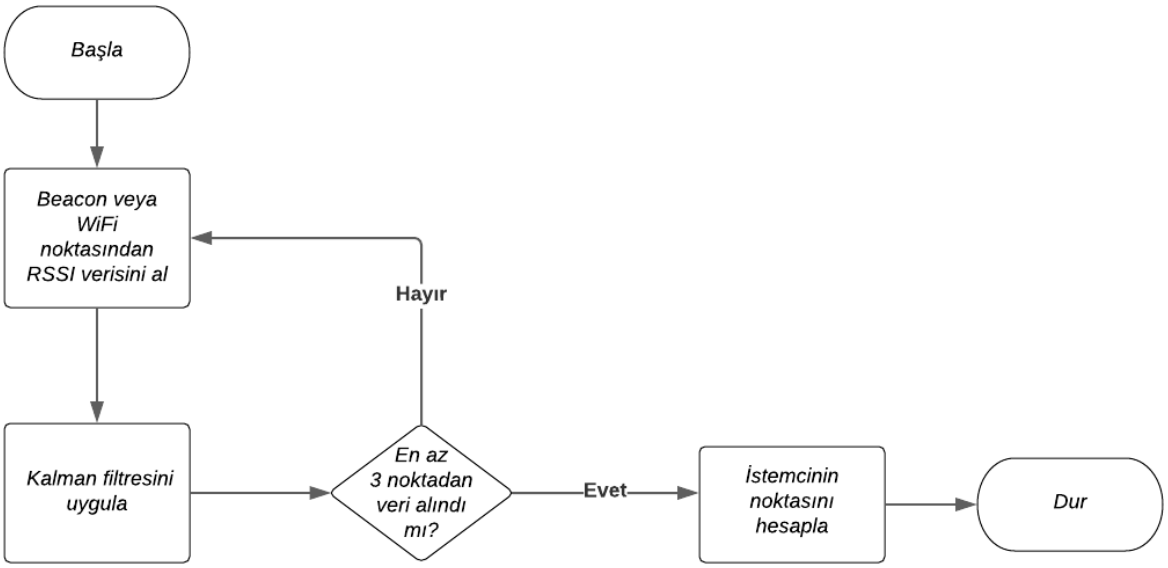

**Şekil 3.7:** Verilerin toplandığı alana ait akıllı cihazların yerleşim planı.

# 4. BULGULAR

İç mekan konumlandırma ortamı için oluşturulan test ortamında toplanan veriler 2 ayrı yöntem üzerinden sonuçlar elde edilmiştir. İlk bölümde Doğrusal Olmayan En Küçük Kareler Yöntemi ve Levenberg - Marquardt algoritması ile yapılan hesaplamalar ile elde edilen sonuçlar, ikinci bölümde ise makine öğrenmesi yöntemiyle KNN ve SVM algoritmalarıyla elde edilen sonuçlar ve değerlendirmeleri yer almaktadır.

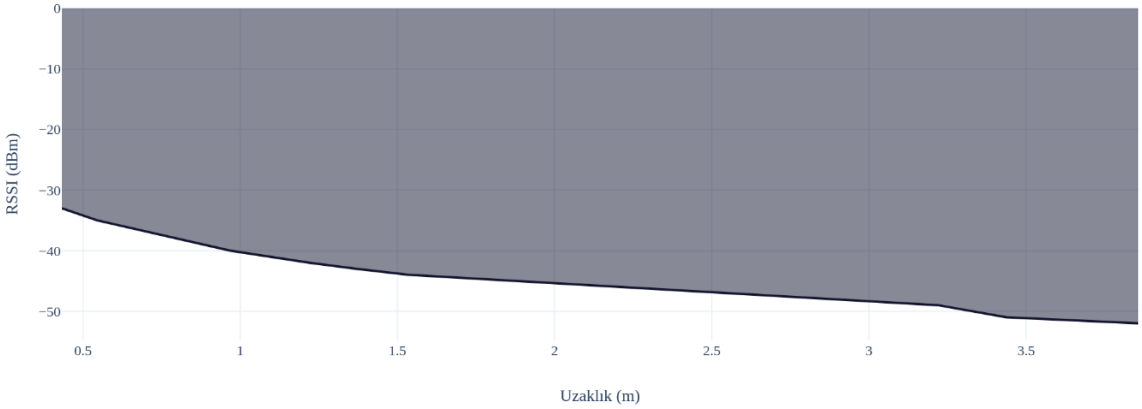
## 4.1. DOĞRUSAL OLMAYAN EN KÜÇÜK KARELER YÖNTEMİ İLE ELDEN EDİLEN SONUÇLAR

Wi-Fi ve Beacon cihazlarından toplanan verilerin Kalman filtresinden geçtikten sonra Doğrusal Olmayan En Küçük Kareler Yöntemi ve Levenberg - Marquardt algoritması kullanarak istemcinin konumunu noktasal ve bölgesel olarak tahmin etmeye yöneliktir. İstemcinin ölçüm alınan ortam içerisinde izlediği yol da çizilmiştir. Şekil 4.1'de işlem aşamasının akış diyagramı görülmektedir.



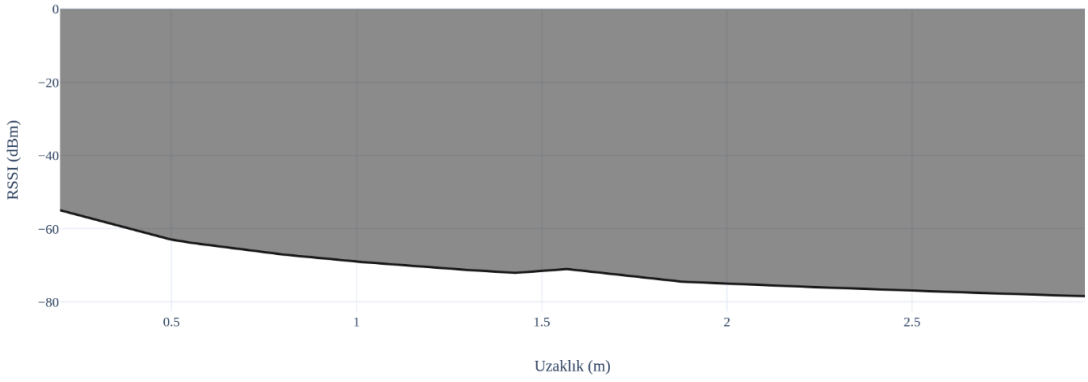

**Şekil 4.1:** Doğrusal Olmayan En Küçük Kareler yöntemine ait akış diyagramı

Wi-Fi erişim noktasının RSSI ve uzaklık ilişkisini yansıtan grafik Şekil 4.2'de verilmiştir. Wi-Fi noktasına olan uzaklık arttıkça elde edilen sinyal gücünün düştüğü yaklaşık 1.5 metre mesafesi aşıldığında daha düşük kalitede RSSI değeri ölçümlendiği gözlemlenmiştir.




**Şekil 4.2:** Wi-Fi noktasından elde edilen RSSI - uzaklık grafiği.

Beacon cihazlarına ait RSSI ve uzalık ilişkisini yansıtan grafik Şekil 4.3'de verilmiştir. Beacon noktasına olan uzaklık arttıkça elde edilen sinyal gücünün düştüğü ve daha düşük kalitede RSSI değeri ölçümlendiği gözlemlenmiştir.




**Şekil 4.3:** Beacon cihazlarından elde edilen RSSI - uzaklık değişim grafiği.

### 4.1.1. Rastgele Yörünge İle Elde Edilen Sonuçlar

Bu bölümde test ortamında rastgele bir yörünge üzerinde işaretlenen noktalardan istemcinin Wi-Fi noktası ve Beacon cihazlarından elde ettiği RSSI değerleri ve bu değerler kullanarak tahmini noktaları üzerinde 2 farklı senaryo üzerinden karşılaştırmaları yer almaktadır. Birinci

senaryoda test ortamı antrede 2 ve odada sekiz olmak üzere toplam 10 eşit ızgara alanlarına bölünmüştür. Antrede her bir ızgara parçası 1,344 $m^2$ , odada ise her bir ızgara parçası 1,435 $m^2$ olarak belirlenmiştir. İkinci senaryoda test ortamı antrede 9 ve odada 16 olmak üzere toplam 25 eşit ızgara alanlarına bölünmüştür. Antrede her bir ızgara parçası 0,288 $m^2$, odada ise her bir ızgara parçası 0,7175 $m^2$ olarak belirlenmiştir.

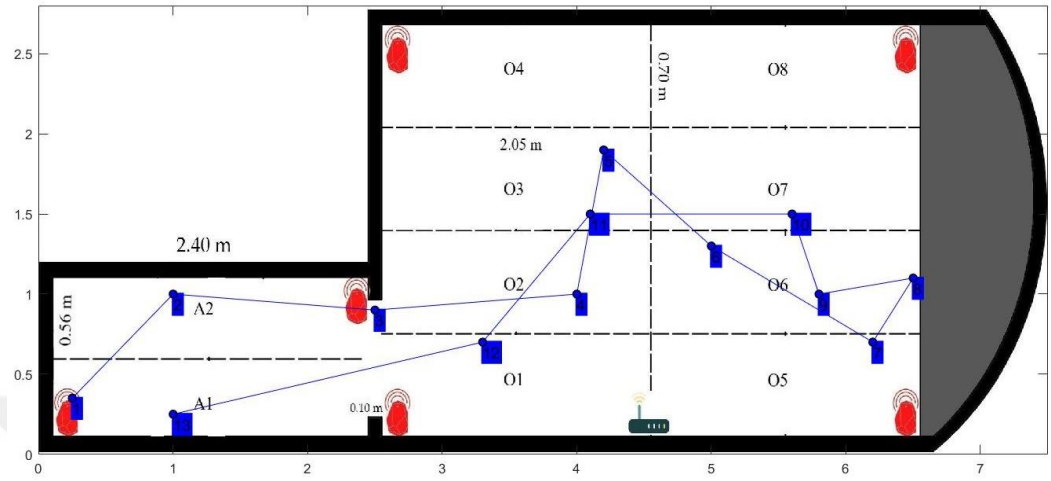
#### *4.1.1.1. 13 Noktalı Rastgele Yörünge*

Belirlenen ve işaretlenen 13 adet gerçek nokta ile Wi-Fi ve Beacon cihazlarından toplanan RSSI verileri kullanarak hesaplanan tahmini 13 adet nokta arasındaki karşılaştırma Tablo 4.1'de yer almaktadır. Konumlandırma hatası Denklem 3.8'de yer verilen denklem ile her bir referans noktası için hesaplanmış olup, tüm referanslar için ortalama hata 0,3533 m olarak hesaplanmıştır.

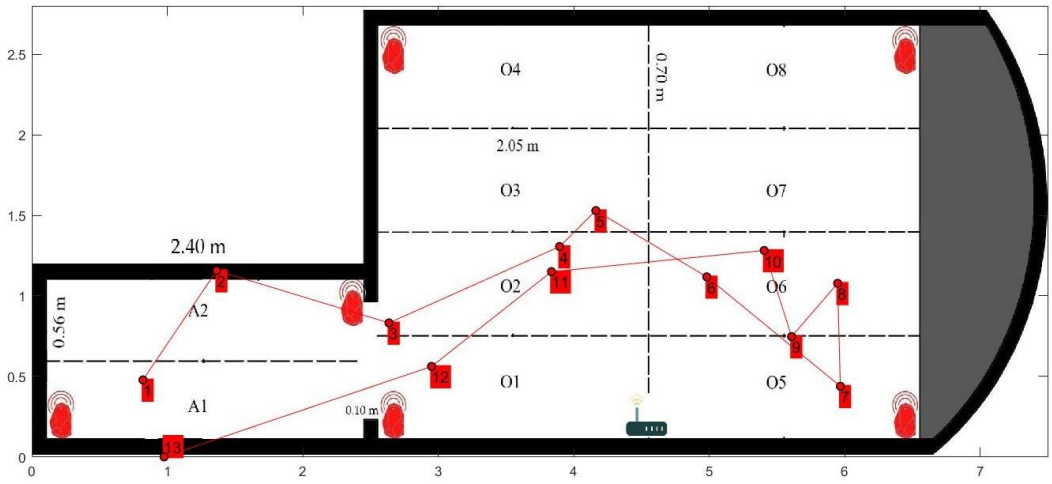
**Tablo 4.1:** 13 noktalı rastgele yörünge için nokta karşılaştırma tablosu.

| Referans Noktası | Gerçek Nokta (x) | Tahmini Nokta (x) | Gerçek Nokta (y) | Tahmini Nokta (y) | Hata (m) |
|---|---|---|---|---|---|
| 1 | 0,25 | 0,8189 | 0,35 | 0,4779 | 0,5831 |
| 2 | 1,00 | 1,3629 | 1,00 | 1,1574 | 0,3956 |
| 3 | 2,50 | 2,6347 | 0,90 | 0,8321 | 0,1508 |
| 4 | 4,00 | 3,8940 | 1,00 | 1,3065 | 0,3243 |
| 5 | 4,20 | 4,1614 | 1,90 | 1,5298 | 0,3722 |
| 6 | 5,00 | 4,9807 | 1,30 | 1,1183 | 0,1827 |
| 7 | 6,20 | 5,9662 | 0,70 | 0,4386 | 0,3507 |
| 8 | 6,50 | 5,9465 | 1,10 | 1,0780 | 0,5539 |
| 9 | 5,80 | 5,6065 | 1,00 | 0,7471 | 0,3184 |
| 10 | 5,60 | 5,4045 | 1,50 | 1,2821 | 0,2927 |
| 11 | 4,10 | 3,8341 | 1,50 | 1,1504 | 0,4392 |
| 12 | 3,30 | 2,9488 | 0,70 | 0,5616 | 0,3775 |
| 13 | 1,00 | 0,9746 | 0,25 | 0,000 | 0,2513 |

İstemcinin birinci senaryoda belirlenen ızgara parçaları üzerinden izlediği gerçek yol Şekil 4.4'de, tahmini yol ise Şekil 4.5'de yer almaktadır.

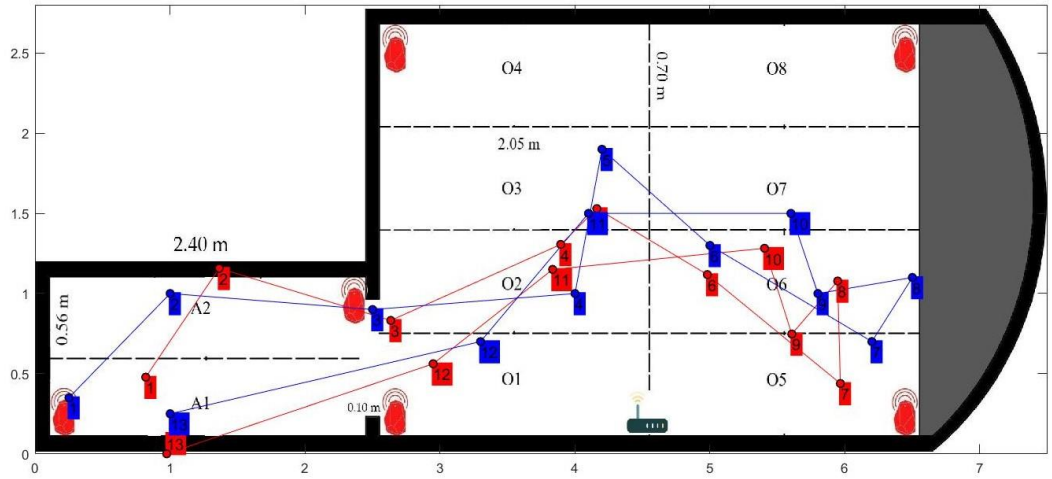



**Şekil 4.4:** 13 noktalı rastgele yörüngede senaryo 1 üzerinde istemcinin izlediği gerçek yol ve bölgeleri.



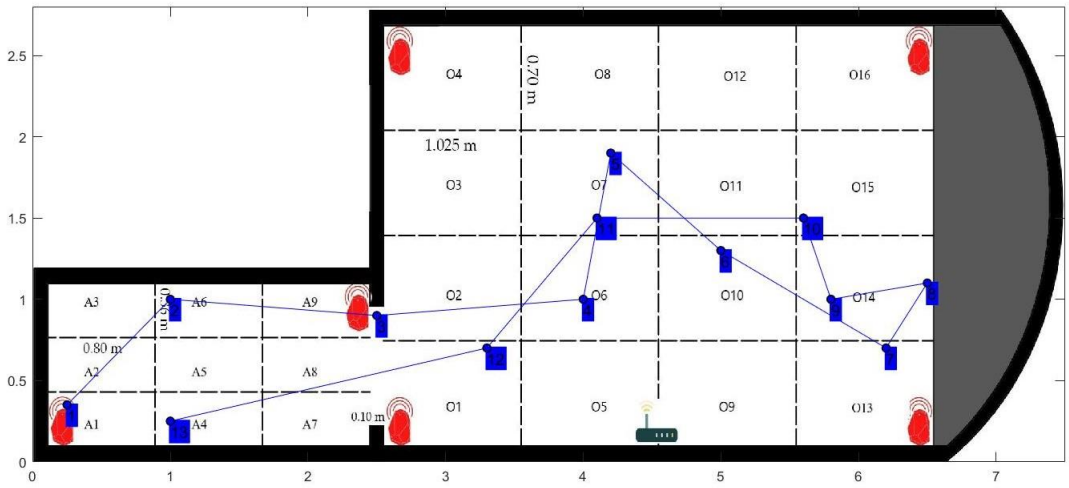

**Şekil 4.5:** 13 noktalı rastgele yörüngede senaryo 1 üzerinde istemcinin izlediği tahmini yol ve bölgeleri.

Şekil 4.6'da ise hem tahmini hem gerçek noktalarla istemcinin izlediği yollar yer almaktadır. Kırmızı renk ile belirtilen yol tahmini noktalarla istemcinin izlediği tahmini yolu, mavi renk ile belirtilen yol gerçek noktalarla istemcinin izlediği gerçek yolu temsil etmektedir.

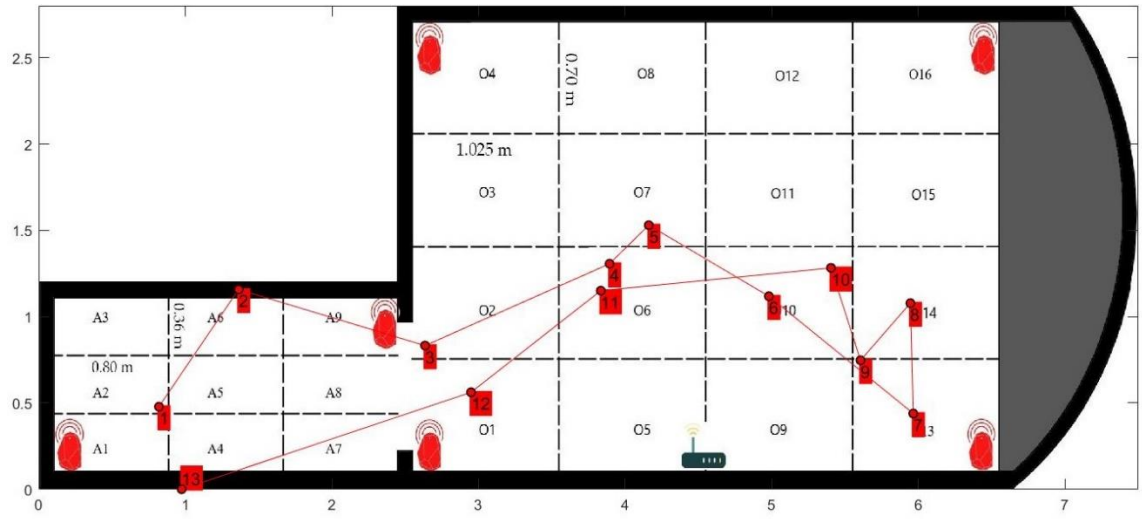



**Şekil 4.6:** 13 noktalı rastgele yörüngede senaryo 1 üzerinde istemcinin izlediği tahmini ve gerçek yol ve bölgeleri.

İstemcinin ikinci senaryoda belirlenen ızgara parçaları üzerinden izlediği gerçek yol Şekil 4.7'de, tahmini yol ise Şekil 4.8'de yer almaktadır.

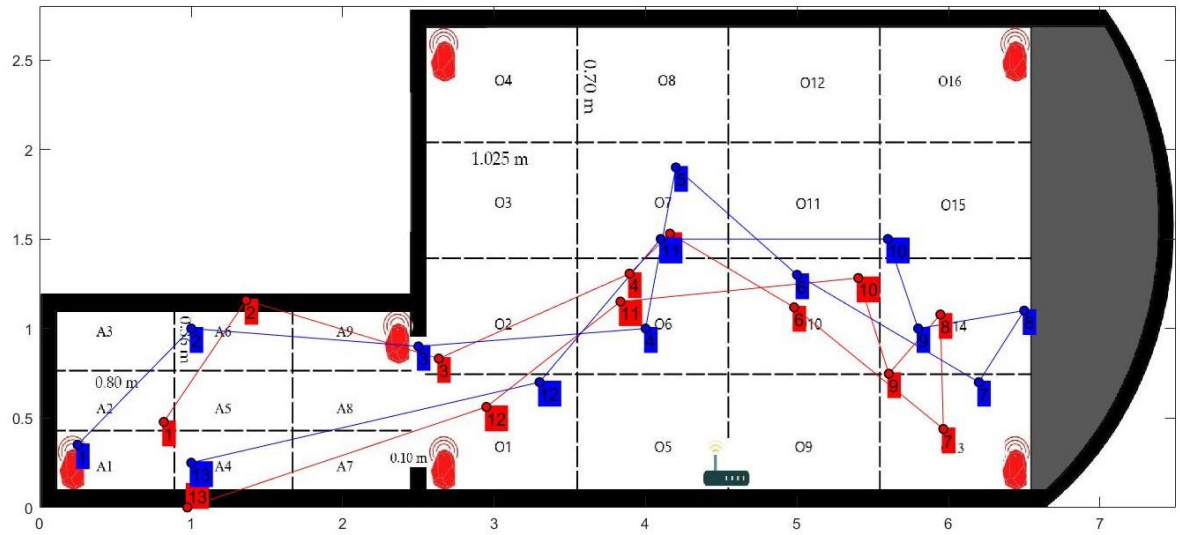



**Şekil 4.7:** 13 noktalı rastgele yörüngede senaryo 2 üzerinde istemcinin izlediği gerçek yol ve bölgeleri.




**Şekil 4.8:** 13 noktalı rastgele yörüngede senaryo 2 üzerinde istemcinin izlediği tahmini yol ve bölgeleri.

Şekil 4.9'da ise hem tahmini hem gerçek noktalarla istemcinin izlediği yollar yer almaktadır. Kırmızı renk ile belirtilen yol tahmini noktalarla istemcinin izlediği tahmini yolu, mavi renk ile belirtilen yol gerçek noktalarla istemcinin izlediği gerçek yolu temsil etmektedir.




**Şekil 4.9:** 13 noktalı rastgele yörüngede senaryo 2 üzerinde istemcinin izlediği tahmini ve gerçek yol ve bölgeleri.

Bu rastgele yörüngede birinci senaryo üzerinde elde edilen doğruluk oranı 13 bölgeden 11 bölgenin doğru hesaplanması ile %84,61, ikinci senaryoda elde edilen doğruluk oranı 13

bölgeden 10 bölgenin doğru hesaplanması ile %76,92'dir. Tablo 4.2'de gerçek ve tahmini bölgelerin karşılaştırılmasına yer verilmiştir. Birinci senaryoya göre 2,5 kat daha fazla alana bölünmüş olmasına rağmen doğruluk oranı %7,69 oranında azalma göstermiştir. Bunun nedeni ise ikinci senaryoda öznitelik sayısının birinci senaryoya göre fazla olması ve bununla birlikte hassasiyetin artmasıdır.

**Tablo 4.2:** 13 noktalı rastgele yörünge için bölge karşılaştırma tablosu.

| Referans Noktası | Gerçek Bölge (Senaryo 1) | Tahmini Bölge (Senaryo 1) | Gerçek Bölge (Senaryo 2) | Tahmini Bölge (Senaryo 2) |
|---|---|---|---|---|
| 1 | A1 | A1 | A1 | A2 |
| 2 | A2 | A2 | A6 | A6 |
| 3 | O2 | O2 | O2 | O2 |
| 4 | O2 | O2 | O6 | O6 |
| 5 | O3 | O3 | O7 | O7 |
| 6 | O6 | O6 | O10 | O10 |
| 7 | O5 | O5 | O13 | O13 |
| 8 | O6 | O6 | O14 | O14 |
| 9 | O6 | O6 | O14 | O14 |
| 10 | O7 | O6 | O15 | O10 |
| 11 | O3 | O2 | O7 | O6 |
| 12 | O1 | O1 | O1 | O1 |
| 13 | A1 | A1 | A4 | A4 |

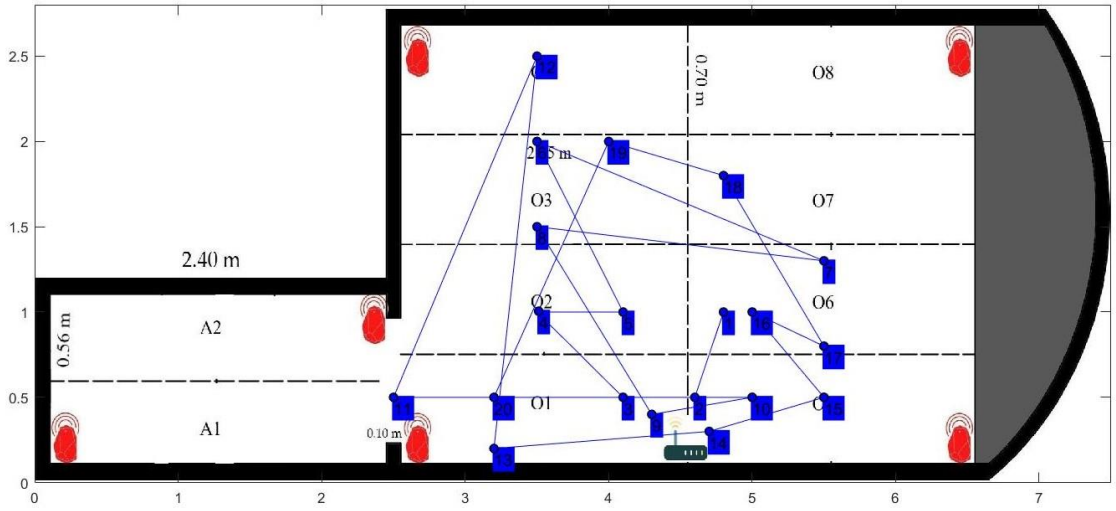
#### *4.1.1.2. 20 Noktalı Rastgele Yörünge*

Belirlenen ve işaretlenen 20 adet gerçek nokta ile Wi-Fi ve Beacon cihazlarından toplanan RSSI verileri kullanarak hesaplanan tahmini 20 adet nokta arasındaki karşılaştırma Tablo 4.3'de yer almaktadır. Konumlandırma hatası Denklem 3.8'de yer verilen denklem ile her bir referans noktası için hesaplanmış olup, tüm referanslar için ortalama hata 0,3459 m olarak hesaplanmıştır.

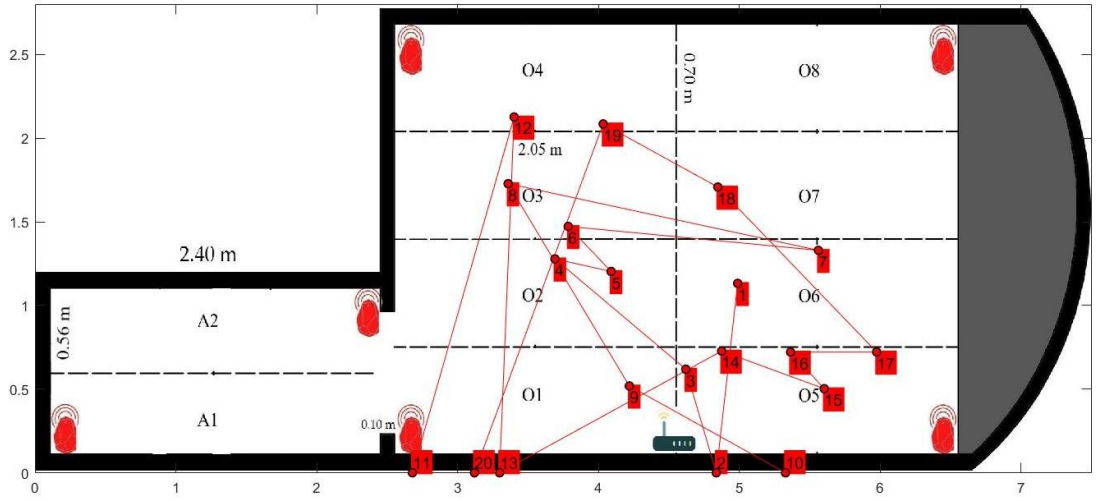
**Tablo 4.3:** 20 noktalı rastgele yörünge için nokta karşılaştırma tablosu.

| Referans Noktası | Gerçek Nokta (x) | Tahmini Nokta (x) | Gerçek Nokta (x) | Tahmini Nokta (y) | Hata (m) |
|---|---|---|---|---|---|
| 1 | 4,80 | 4,9871 | 1,00 | 1,1324 | 0,2292 |
| 2 | 4,60 | 4,8354 | 0,50 | 0,0000 | 0,5526 |
| 3 | 4,10 | 4,6190 | 0,50 | 0,6194 | 0,5326 |
| 4 | 3,50 | 3,6899 | 1,00 | 1,2788 | 0,3373 |
| 5 | 4,10 | 4,0884 | 1,00 | 1,2036 | 0,2039 |
| 6 | 3,50 | 3,7842 | 2,00 | 1,4729 | 0,5988 |
| 7 | 5,50 | 5,5603 | 1,30 | 1,2055 | 0,1121 |
| 8 | 3,50 | 3,3572 | 1,50 | 1,7285 | 0,2695 |
| 9 | 4,30 | 4,2177 | 0,40 | 0,5194 | 0,1450 |
| 10 | 5,00 | 5,3263 | 0,50 | 0,0000 | 0,5971 |
| 11 | 2,50 | 2,6777 | 0,50 | 0,0000 | 0,5306 |
| 12 | 3,50 | 3,3999 | 2,50 | 2,1267 | 0,3865 |
| 13 | 3,20 | 3,2968 | 0,20 | 0,0000 | 0,2222 |
| 14 | 4,70 | 4,873 | 0,30 | 0,7276 | 0,4613 |
| 15 | 5,50 | 5,6018 | 0,50 | 0,5027 | 0,1018 |
| 16 | 5,00 | 5,3626 | 1,00 | 0,7219 | 0,4569 |
| 17 | 5,50 | 5,9736 | 0,80 | 0,7222 | 0,4800 |
| 18 | 4,80 | 4,8459 | 1,80 | 1,7084 | 0,1025 |
| 19 | 4,00 | 4,0323 | 2,00 | 2,0856 | 0,0915 |
| 20 | 3,20 | 3,1187 | 0,50 | 0,0000 | 0,5066 |

İstemcinin birinci senaryoda belirlenen ızgara parçaları üzerinden izlediği gerçek yol Şekil 4.10'da, tahmini yol ise Şekil 4.11'de yer almaktadır.

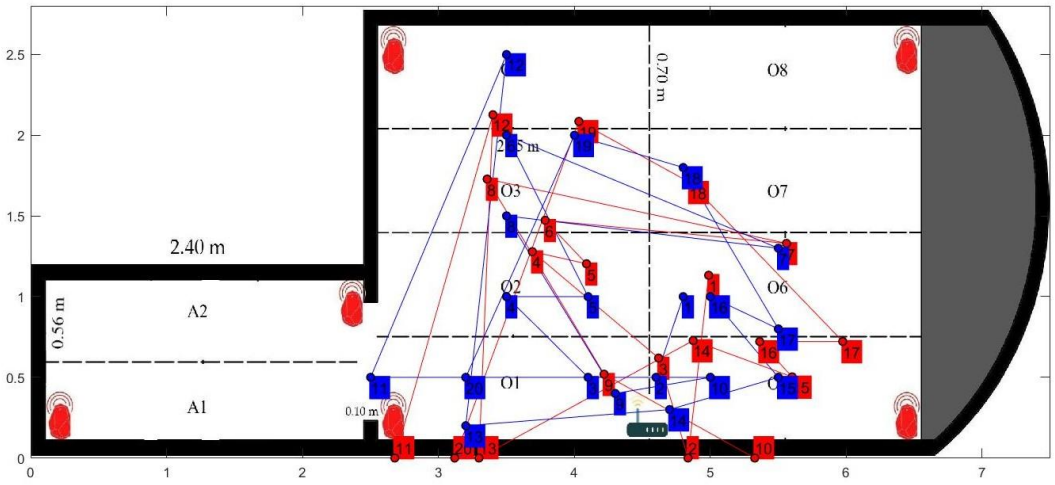



**Şekil 4.10:** 20 noktalı rastgele yörüngede senaryo 1 üzerinde istemcinin izlediği gerçek yol ve bölgeleri.



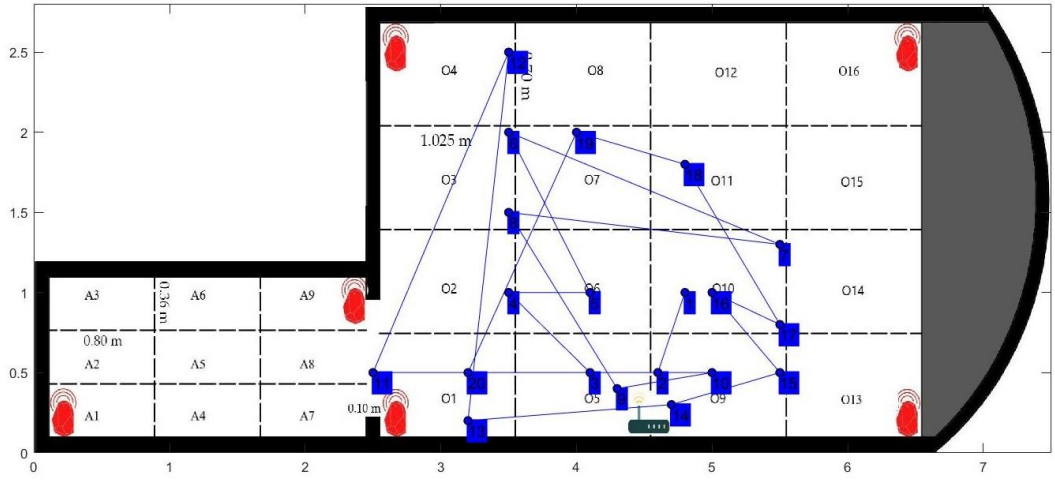

**Şekil 4.11:** 20 noktalı rastgele yörüngede senaryo 1 üzerinde istemcinin izlediği tahmini yol ve bölgeleri.

Şekil 4.12'de ise hem tahmini hem gerçek noktalarla istemcinin izlediği yollar yer almaktadır. Kırmızı renk ile belirtilen yol tahmini noktalarla istemcinin izlediği tahmini yolu, mavi renk ile belirtilen yol gerçek noktalarla istemcinin izlediği gerçek yolu temsil etmektedir.

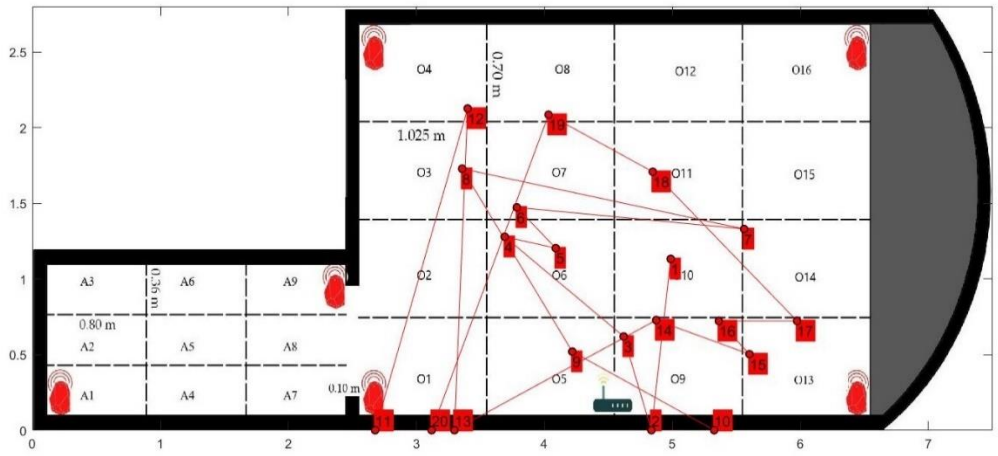



**Şekil 4.12:** 20 noktalı rastgele yörüngede senaryo 1 üzerinde istemcinin izlediği tahmini ve gerçek yol ve bölgeleri.

İstemcinin ikinci senaryoda belirlenen ızgara parçaları üzerinden izlediği gerçek yol Şekil 4.13'de, tahmini yol ise Şekil 4.14'de yer almaktadır.

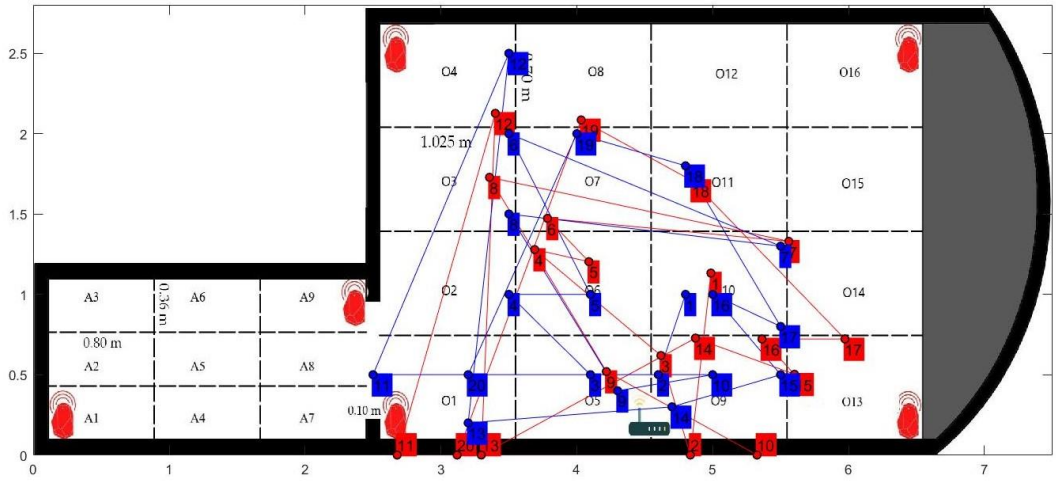



**Şekil 4.13**: 20 noktalı rastgele yörüngede senaryo 2 üzerinde istemcinin izlediği gerçek yol ve bölgeleri.




**Şekil 4.14:** 20 noktalı rastgele yörüngede senaryo 2 üzerinde istemcinin izlediği tahmini yol ve bölgeleri.

Şekil 4.15'de ise hem tahmini hem gerçek noktalarla istemcinin izlediği yollar yer almaktadır. Kırmızı renk ile belirtilen yol tahmini noktalarla istemcinin izlediği tahmini yolu, mavi renk ile belirtilen yol gerçek noktalarla istemcinin izlediği gerçek yolu temsil etmektedir.




**Şekil 4.15:** 20 noktalı rastgele yörüngede senaryo 2 üzerinde istemcinin izlediği tahmini ve gerçek yol ve bölgeleri.

Bu rastgele yörüngede birinci senaryo üzerinde elde edilen doğruluk oranı 20 bölgeden 16 bölgenin doğru hesaplanması ile %80,00, ikinci senaryoda elde edilen doğruluk oranı 20 bölgeden 13 bölgenin doğru hesaplanması ile %65,00'dir. Tablo 4.4'de gerçek ve tahmini bölgelerin karşılaştırılmasına yer verilmiştir. Birinci senaryoya göre 2,5 kat daha fazla alana

bölünmüş olmasına rağmen doğruluk oranı %15,00 oranında azalma göstermiştir. Bunun nedeni ilk örnekte açıklanmıştır.

**Tablo 4.4:** 20 noktalı rastgele yörünge için bölge karşılaştırma tablosu.

| Referans Noktası | Gerçek Bölge (Senaryo 1) | Tahmini Bölge (Senaryo 1) | Gerçek Bölge (Senaryo 2) | Tahmini Bölge (Senaryo 2) |
|---|---|---|---|---|
| 1 | O6 | O6 | O10 | O10 |
| 2 | O5 | O5 | O9 | O9 |
| 3 | O1 | O5 | O5 | O9 |
| 4 | O2 | O2 | O2 | O6 |
| 5 | O2 | O2 | O6 | O6 |
| 6 | O3 | O3 | O3 | O7 |
| 7 | O6 | O6 | O10 | O10 |
| 8 | O3 | O3 | O3 | O3 |
| 9 | O1 | O1 | O5 | O5 |
| 10 | O5 | O5 | O9 | O9 |
| 11 | O1 | O1 | O1 | O1 |
| 12 | O4 | O4 | O4 | O4 |
| 13 | O1 | O1 | O1 | O1 |
| 14 | O5 | O5 | O9 | O9 |
| 15 | O5 | O5 | O9 | O13 |
| 16 | O6 | O5 | O10 | O9 |
| 17 | O6 | O5 | O10 | O13 |
| 18 | O7 | O7 | O11 | O11 |
| 19 | O3 | O4 | O7 | O8 |
| 20 | O1 | O1 | O1 | O1 |

### 4.1.2. Belirlenmiş Yörünge İle Elde Edilen Sonuçlar

Bu bölümde test ortamında belirlenmiş yörünge üzerinde işaretlenen noktaların istemcinin Wi-Fi noktası ve Beacon cihazlarından elde ettiği RSSI değerleri ve bu değerler kullanarak tahmini noktaları üzerinde 2 farklı senaryo üzerinden karşılaştırmaları yer almaktadır. Birinci senaryoda test ortamı antre 2 ve oda 8 olmak üzere toplam 10 eşit ızgara alanlarına bölünmüştür. Antrede her bir ızgara parçası 1,344 $m^2$ , odada ise her bir ızgara parçası 1,435 $m^2$ olarak belirlenmiştir. İkinci senaryoda test ortamı antre 9 ve oda 16 olmak üzere toplam 25 eşit ızgara alanlarına bölünmüştür. Antrede her bir ızgara parçası 0,288 $m^2$, odada ise her bir ızgara parçası 0,7175 $m^2$ olarak belirlenmiştir.

#### *4.1.2.1. S Şeklindeki Yörünge*

Belirlenen ve işaretlenen S şeklindeki yörüngede belirlenen ve işaretlenen 13 adet gerçek nokta ile Wi-Fi ve Beacon cihazlarından toplanan RSSI verileri kullanarak hesaplanan tahmini 13 adet nokta arasındaki karşılaştırma Tablo 4.5'de yer almaktadır. Konumlandırma hatası Denklem 3.8'de yer verilen denklem ile her bir referans noktası için hesaplanmış olup, tüm referanslar için ortalama hata 0,2340 m olarak hesaplanmıştır.

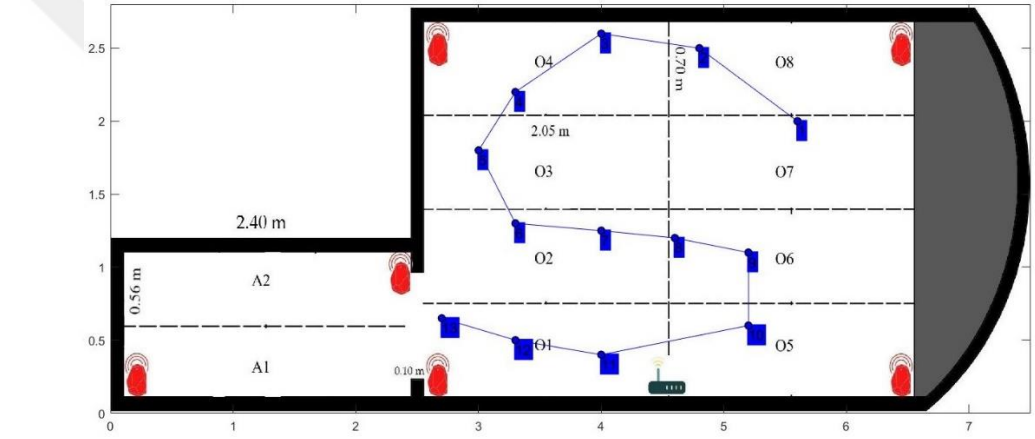
**Tablo 4.5:** S yörüngesi için nokta karşılaştırma tablosu.

| Referans Noktası | Gerçek Nokta (x) | Tahmini Nokta (x) | Gerçek Nokta (y) | Tahmini Nokta (y) | Hata (m) |
|---|---|---|---|---|---|
| 1 | 5,60 | 4,9931 | 2,00 | 1,9872 | 0,6070 |
| 2 | 4,80 | 4,7592 | 2,50 | 2,3364 | 0,1686 |
| 3 | 4,00 | 3,8694 | 2,60 | 2,2040 | 0,4170 |
| 4 | 3,30 | 3,3999 | 2,20 | 2,1267 | 0,1239 |
| 5 | 3,00 | 2,8111 | 1,80 | 1,6558 | 0,2376 |
| 6 | 3,30 | 3,4952 | 1,30 | 1,4836 | 0,2680 |
| 7 | 4,00 | 4,0255 | 1,25 | 1,4113 | 0,1633 |
| 8 | 4,60 | 4,7639 | 1,20 | 1,1692 | 0,1668 |
| 9 | 5,20 | 5,1766 | 1,10 | 0,9547 | 0,1472 |
| 10 | 5,20 | 5,0971 | 0,60 | 0,6184 | 0,1045 |

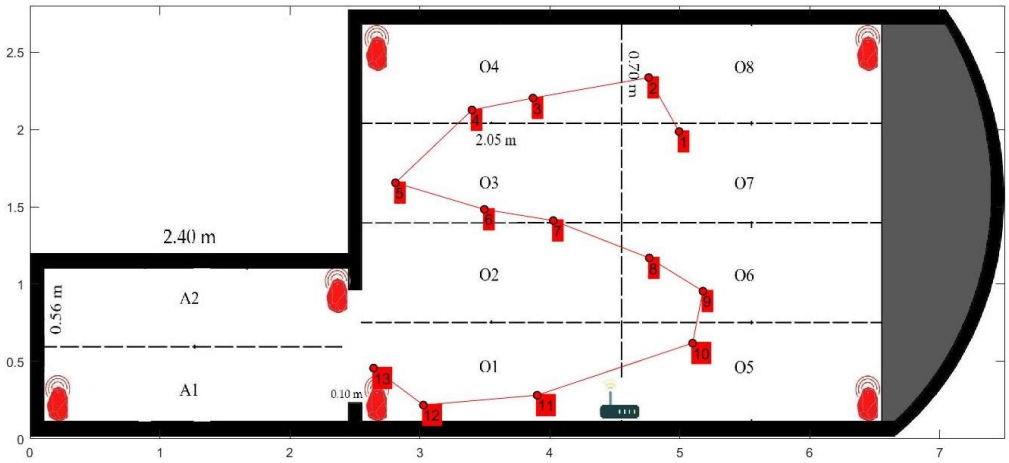
**Tablo 4.5 (devam):** S yörüngesi için nokta karşılaştırma tablosu.

| Referans Noktası | Gerçek Nokta (x) | Tahmini Nokta (x) | Gerçek Nokta (y) | Tahmini Nokta (y) | Hata (m) |
|---|---|---|---|---|---|
| 11 | 4,00 | 3,9016 | 0,40 | 0,2817 | 0,1539 |
| 12 | 3,00 | 3,0260 | 0,50 | 0,2180 | 0,2832 |
| 13 | 2,70 | 2,6430 | 0,65 | 0,4571 | 0,2011 |

İstemcinin birinci senaryoda belirlenen ızgara parçaları üzerinden izlediği gerçek yol Şekil 4.16'da, tahmini yol ise Şekil 4.17'de yer almaktadır.

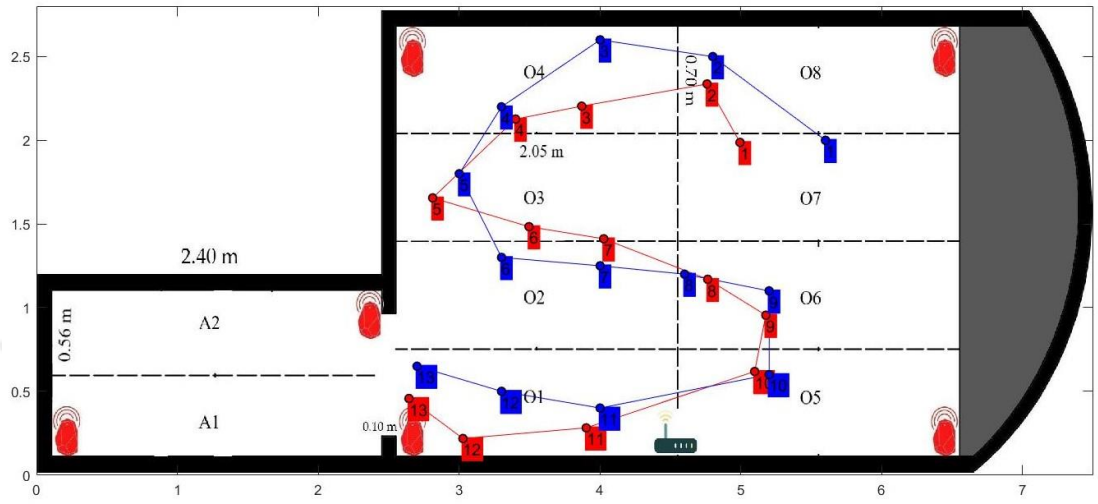



**Şekil 4.16:** S yörüngede senaryo 1 üzerinde istemcinin izlediği gerçek yol ve bölgeleri.



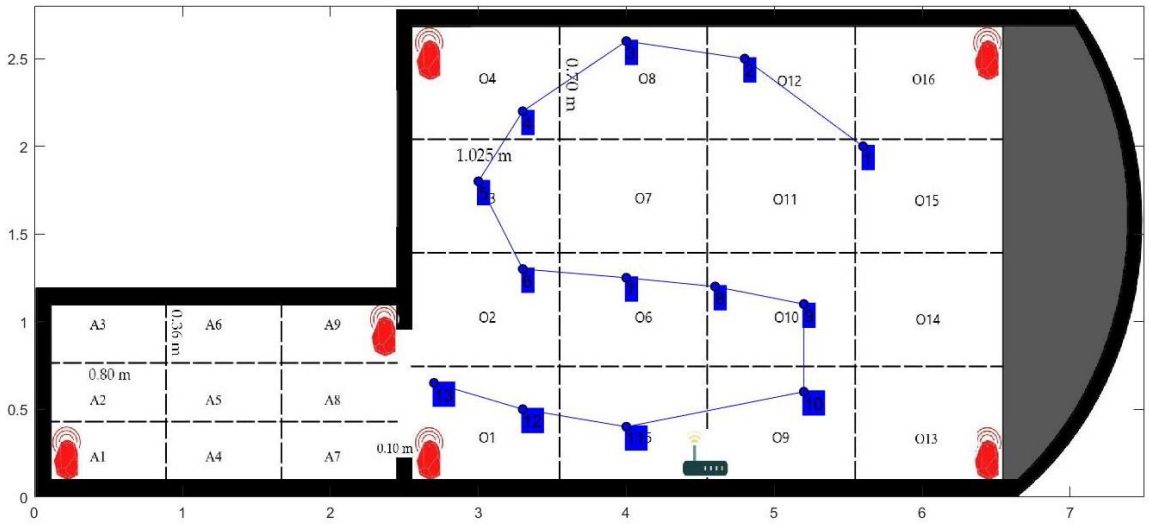

**Şekil 4.17:** S yörüngede senaryo 1 üzerinde istemcinin izlediği tahmini yol ve bölgeleri.

Şekil 4.18'de ise hem tahmini hem gerçek noktalarla istemcinin izlediği yollar yer almaktadır. Kırmızı renk ile belirtilen yol tahmini noktalarla istemcinin izlediği tahmini yolu, mavi renk ile belirtilen yol gerçek noktalarla istemcinin izlediği gerçek yolu temsil etmektedir.

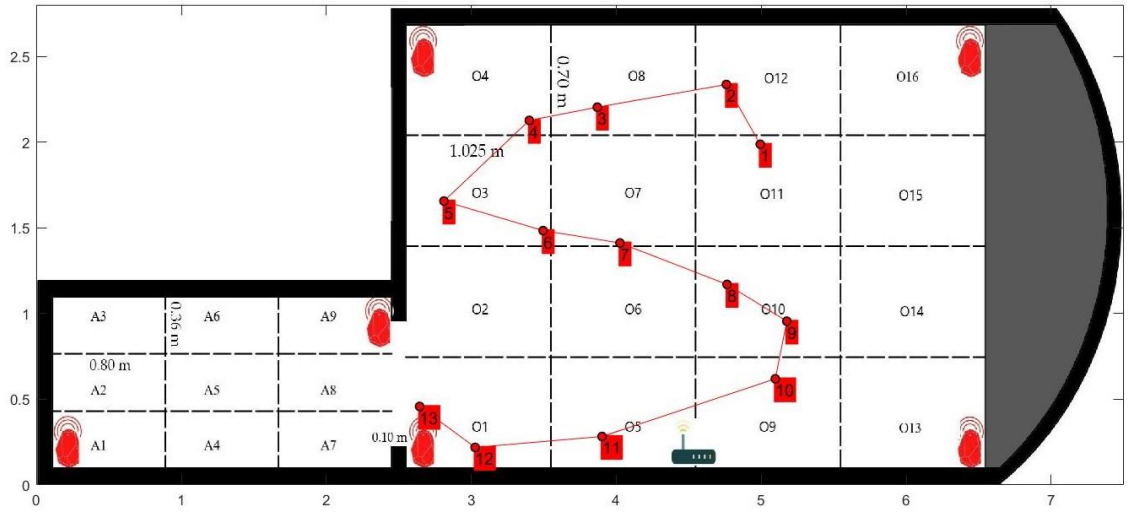



**Şekil 4.18:** S yörüngede senaryo 1 üzerinde istemcinin izlediği tahmini ve gerçek yol ve bölgeleri.

İstemcinin ikinci senaryoda belirlenen ızgara parçaları üzerinden izlediği gerçek yol Şekil 4.19'da, tahmini yol ise Şekil 4.20'de yer almaktadır.

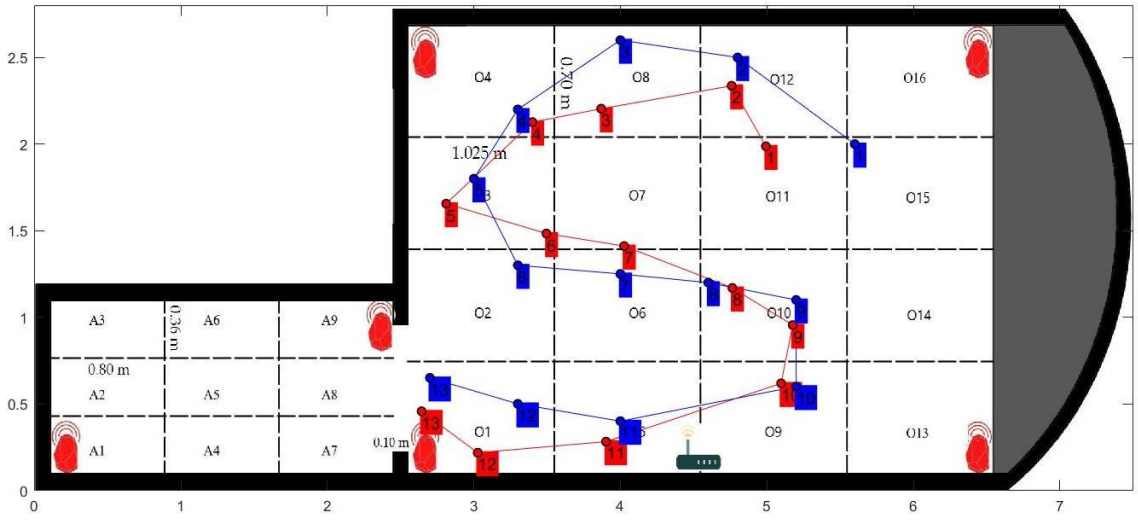



**Şekil 4.19:** S yörüngede senaryo 2 üzerinde istemcinin izlediği gerçek yol ve bölgeleri.




**Şekil 4.20:** S yörüngede senaryo 2 üzerinde istemcinin izlediği tahmini yol ve bölgeleri.

Şekil 4.21'de ise hem tahmini hem gerçek noktalarla istemcinin izlediği yollar yer almaktadır. Kırmızı renk ile belirtilen yol tahmini noktalarla istemcinin izlediği tahmini yolu, mavi renk ile belirtilen yol gerçek noktalarla istemcinin izlediği gerçek yolu temsil etmektedir.




**Şekil 4.21:** S yörüngede senaryo 2 üzerinde istemcinin izlediği tahmini ve gerçek yol ve bölgeleri.

S yörüngesinde birinci senaryo üzerinde elde edilen doğruluk oranı 13 bölgeden 11 bölgenin doğru hesaplanması ile %84,61, ikinci senaryo üzerinde elde edilen doğruluk oranı 13 bölgeden 10 bölgenin doğru hesaplanması ile %76,92'dir. Tablo 4.6'da gerçek ve tahmini bölgelerin

karşılaştırılmasına yer verilmiştir. Birinci senaryoya göre 2,5 kat daha fazla alana bölünmüş olmasına rağmen doğruluk oranı %7,69 oranında azalma göstermiştir. Bunun nedeni ilk örnekte açıklanmıştır.

**Tablo 4.6:** S yörüngesi için bölge karşılaştırma tablosu.

| Referans Noktası | Gerçek Bölge (Senaryo 1) | Tahmini Bölge (Senaryo 1) | Gerçek Bölge (Senaryo 2) | Tahmini Bölge (Senaryo 2) |
|---|---|---|---|---|
| 1 | O7 | O7 | O15 | O11 |
| 2 | O8 | O8 | O12 | O12 |
| 3 | O4 | O4 | O8 | O8 |
| 4 | O4 | O4 | O4 | O4 |
| 5 | O3 | O3 | O3 | O3 |
| 6 | O2 | O3 | O2 | O3 |
| 7 | O2 | O3 | O6 | O7 |
| 8 | O6 | O6 | O10 | O10 |
| 9 | O6 | O6 | O10 | O10 |
| 10 | O5 | O5 | O9 | O9 |
| 11 | O1 | O1 | O5 | O5 |
| 12 | O1 | O1 | O1 | O1 |
| 13 | O1 | O1 | O1 | O1 |

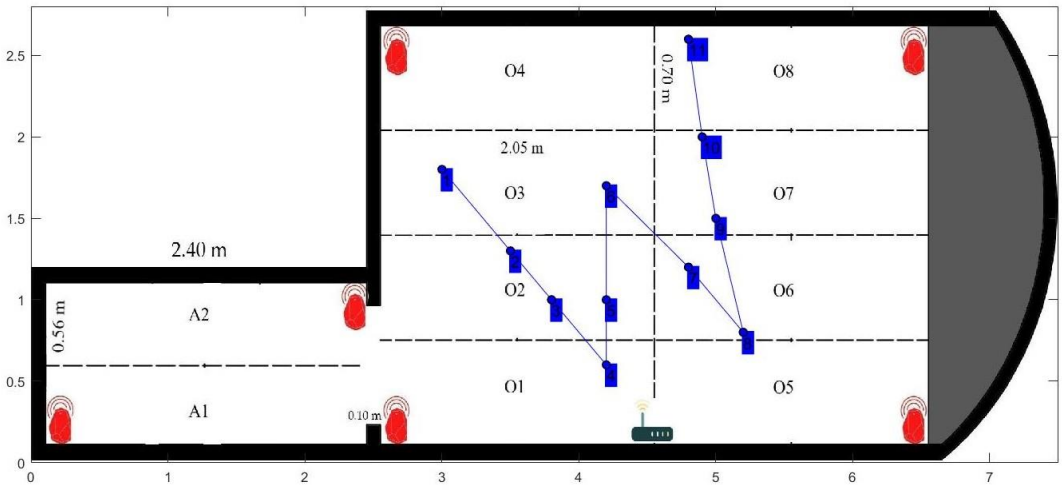
#### *4.1.2.2. W Şeklindeki Yörünge*

Belirlenen ve işaretlenen W şeklindeki yörüngede belirlenen ve işaretlenen 11 adet gerçek nokta ile Wi-Fi ve Beacon cihazlarından toplanan RSSI verileri kullanarak hesaplanan tahmini 11 adet nokta arasındaki karşılaştırma Tablo 4.7'de yer almaktadır. Konumlandırma hatası Denklem 3.8'de yer verilen denklem ile her bir referans noktası için hesaplanmış olup, tüm referanslar için ortalama hata 0,2886 m olarak hesaplanmıştır.

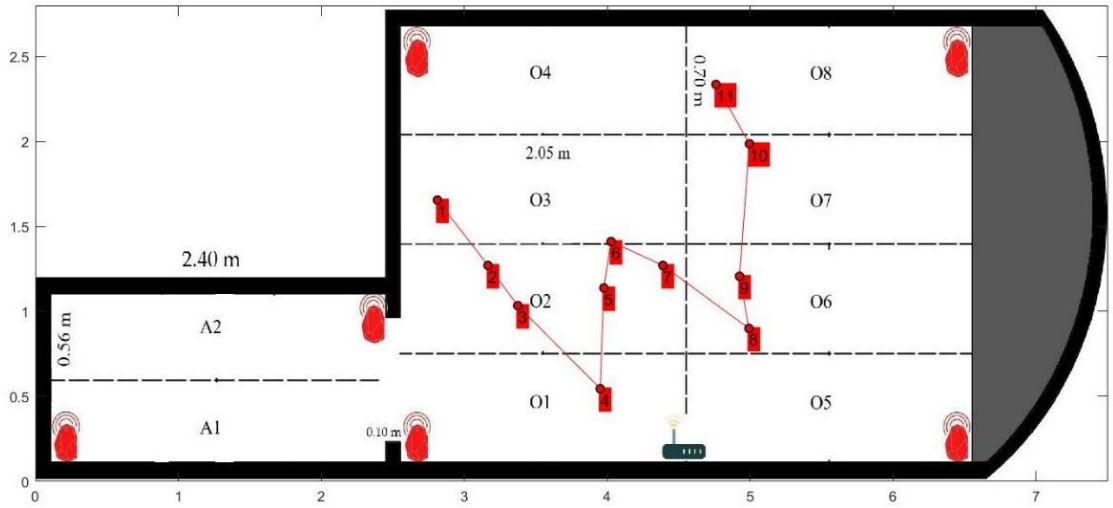
**Tablo 4.7:** W yörüngesi için nokta karşılaştırma tablosu.

| Referans Noktası | Gerçek Nokta (x) | Tahmini Nokta (x) | Gerçek Nokta (y) | Tahmini Nokta (y) | Hata (m) |
|---|---|---|---|---|---|
| 1 | 3,00 | 2,8111 | 1,80 | 1,6558 | 0,2376 |
| 2 | 3,50 | 3,1647 | 1,30 | 1,2709 | 0,3366 |
| 3 | 3,80 | 3,3727 | 1,00 | 1,0344 | 0,4287 |
| 4 | 4,20 | 3,9498 | 0,60 | 0,5446 | 0,2563 |
| 5 | 4,20 | 3,9749 | 1,00 | 1,1381 | 0,2641 |
| 6 | 4,20 | 4,0255 | 1,70 | 1,4113 | 0,3373 |
| 7 | 4,80 | 4,3882 | 1,20 | 1,2710 | 0,4179 |
| 8 | 5,20 | 4,9898 | 0,80 | 0,8996 | 0,2326 |
| 9 | 5,00 | 4,9247 | 1,50 | 1,2067 | 0,3028 |
| 10 | 4,90 | 4,9931 | 2,00 | 1,9872 | 0,0940 |
| 11 | 4,80 | 4,7592 | 2,60 | 2,3364 | 0,2667 |

İstemcinin birinci senaryoda belirlenen ızgara parçaları üzerinden izlediği gerçek yol Şekil 4.22'de, tahmini yol ise Şekil 4.23'de yer almaktadır.

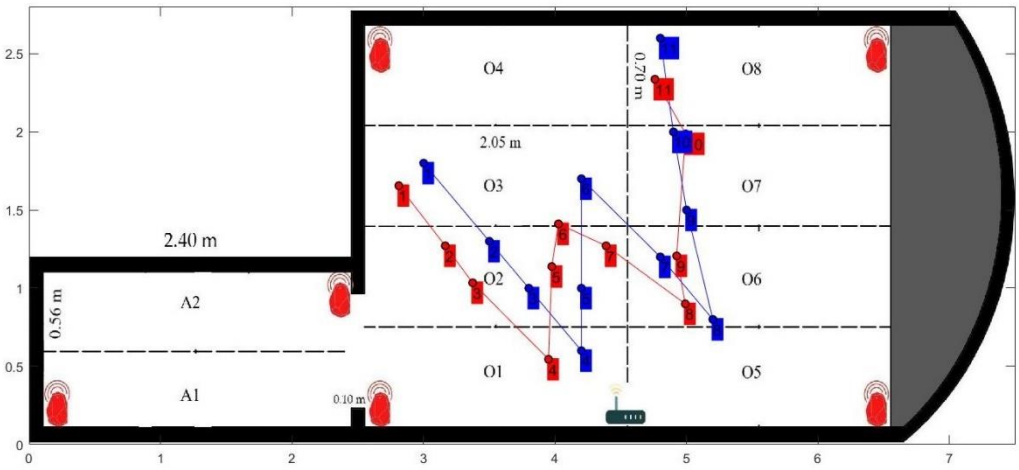



**Şekil 4.22:** W yörüngede senaryo 1 üzerinde istemcinin izlediği gerçek yol ve bölgeleri.



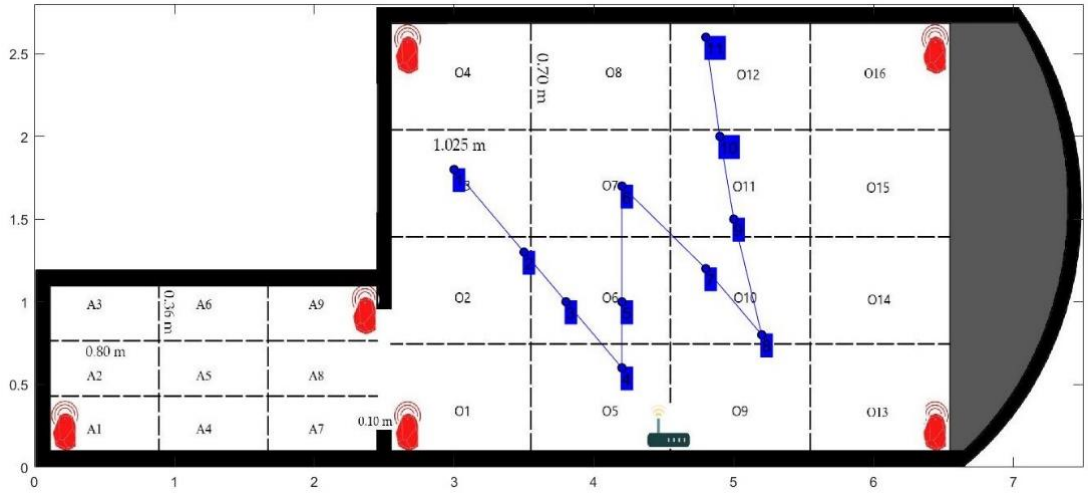

**Şekil 4.23:** W yörüngede senaryo 1 üzerinde istemcinin izlediği tahmini yol ve bölgeleri.

Şekil 4.24'de ise hem tahmini hem gerçek noktalarla istemcinin izlediği yollar yer almaktadır. Kırmızı renk ile belirtilen yol tahmini noktalarla istemcinin izlediği tahmini yolu, mavi renk ile belirtilen yol gerçek noktalarla istemcinin izlediği gerçek yolu temsil etmektedir.

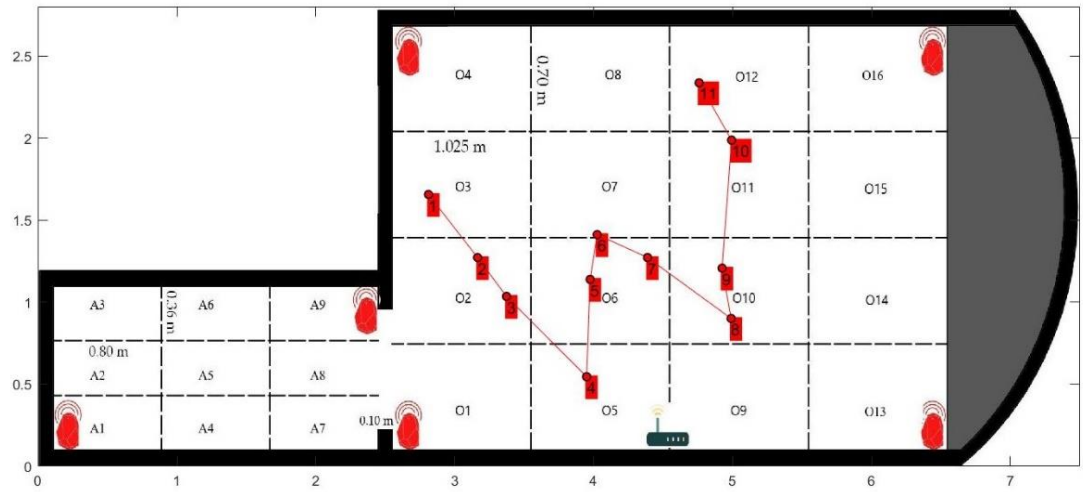



**Şekil 4.24:** W yörüngede senaryo 1 üzerinde istemcinin izlediği tahmini ve gerçek yol ve bölgeleri.

İstemcinin ikinci senaryoda belirlenen ızgara parçaları üzerinden izlediği gerçek yol Şekil 4.25'de, tahmini yol ise Şekil 4.26'da yer almaktadır.

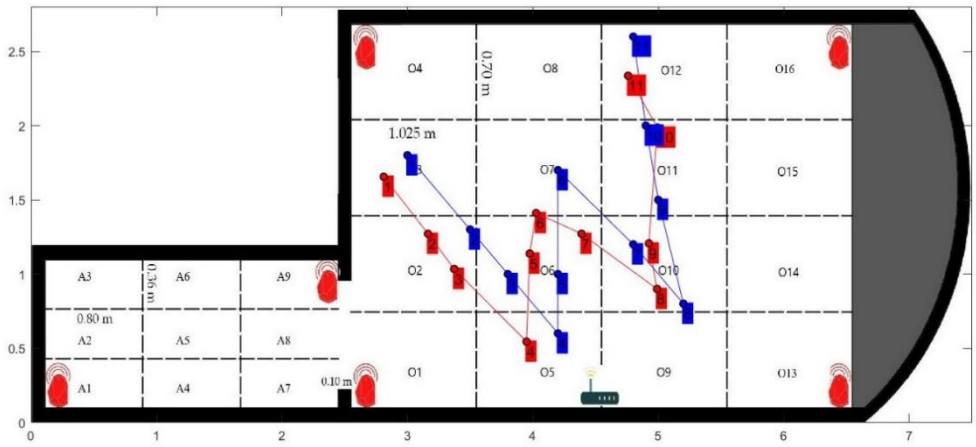



**Şekil 4.25:** W yörüngede senaryo 2 üzerinde istemcinin izlediği gerçek yol ve bölgeleri.




**Şekil 4.26:** W yörüngede senaryo 2 üzerinde istemcinin izlediği tahmini yol ve bölgeleri.

Şekil 4.27'de ise hem tahmini hem gerçek noktalarla istemcinin izlediği yollar yer almaktadır. Kırmızı renk ile belirtilen yol tahmini noktalarla istemcinin izlediği tahmini yolu, mavi renk ile belirtilen yol gerçek noktalarla istemcinin izlediği gerçek yolu temsil etmektedir.




**Şekil 4.27:** W yörüngede senaryo 2 üzerinde istemcinin izlediği tahmini ve gerçek yol ve bölgeleri.

Tablo 4.8'de W yörüngesinde birinci senaryo üzerinde elde edilen doğruluk oranı 11 bölgeden 9 bölgenin doğru hesaplanması ile %81,81, ikinci senaryo üzerinde elde edilen doğruluk oranı 11 bölgeden 8 bölgenin doğru hesaplanması ile %72,72'dir. Birinci senaryoya göre 2,5 kat daha fazla alana bölünmüş olmasına rağmen doğruluk oranı %9,09 oranında azalma göstermiştir. Bunun nedeni ilk örnekte açıklanmıştır.

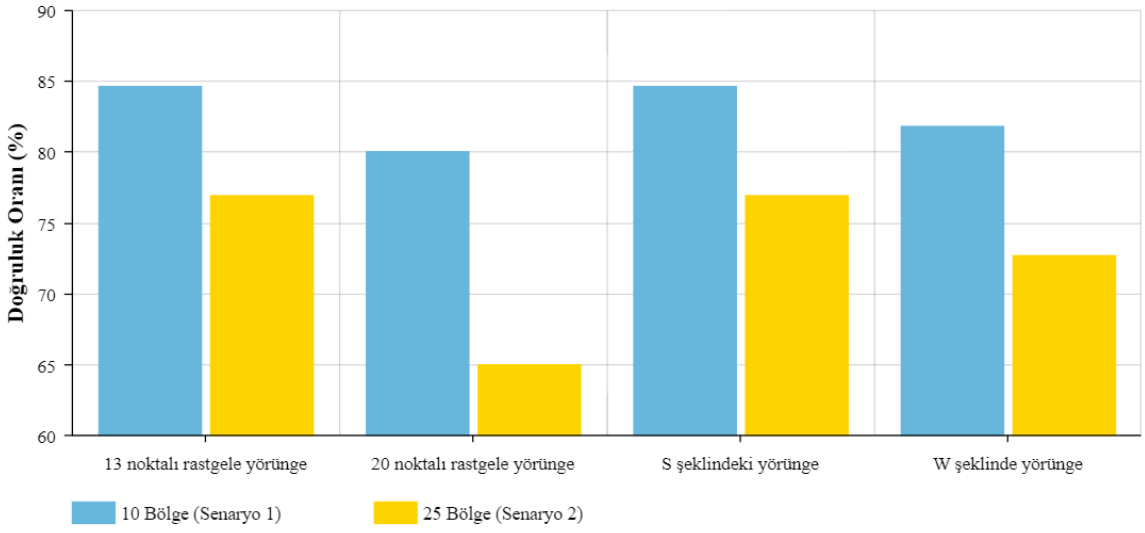
**Tablo 4.8:** W yörüngesi için bölge karşılaştırma tablosu

| Referans Noktası | Gerçek Bölge (Senaryo 1) | Tahmini Bölge (Senaryo 1) | Gerçek Bölge (Senaryo 2) | Tahmini Bölge (Senaryo 2) |
|---|---|---|---|---|
| 1 | O3 | O3 | O3 | O3 |
| 2 | O2 | O2 | O2 | O2 |
| 3 | O2 | O2 | O6 | O2 |
| 4 | O1 | O1 | O5 | O5 |
| 5 | O2 | O2 | O6 | O6 |
| 6 | O3 | O3 | O7 | O7 |
| 7 | O2 | O6 | O10 | O6 |
| 8 | O6 | O6 | O10 | O10 |
| 9 | O7 | O6 | O11 | O10 |
| 10 | O7 | O7 | O11 | O11 |
| 11 | O8 | O8 | O12 | O12 |

Bu yöntem sonucu elde edilen ortalama hata ve doğruluk oranlarını içeren özet sonuçları Tablo 4.9'da ve grafik Şekil 4.28'de yer almaktadır.

**Tablo 4.9:** Rastgele ve belirlenen yörüngeler için özet sonuç tablosu.

| Ölçüm Tipi | Hata (m) | Doğruluk Oranı (Senaryo 1) | Doğruluk Oranı (Senaryo 2) |
|---|---|---|---|
| 13 noktalı rastgele yörünge | 0,3533 | 84,61 | 76,92 |
| 20 noktalı rastgele yörünge | 0,3459 | 80,00 | 65,00 |
| S şeklindeki yörünge | 0,2340 | 84,61 | 76,92 |
| W şeklindeki yörünge | 0,2886 | 81,81 | 72,72 |
| Ortalama | 0,3054 | 82,75 | 72,89 |




**Şekil 4.28:** Rastgele ve belirlenen yörüngeler için doğruluk değişim grafiği.

## 4.2. MAKİNE ÖĞRENMESİYLE ELDE EDİLEN SONUÇLAR

Bu bölümde Beacon cihazlarından ve Wi-Fi erişim noktasından toplanan RSSI verilerinin makine öğrenmesi yöntemlerinde uzaklığa dayalı tahmin prensibini temel alan KNN ve SVM algoritmaları kullanarak istemcinin bulunduğu alanı (antre veya oda) tahmin etmesini içeren senaryolar ve sonuçları yer almaktadır. Bu kısımda yer alan testlerde toplam 822 adet RSSI verisi kullanılmıştır. Her iki algoritmada da belirlenen farklı eğitim ve test oranları için

doğruluk oranları hesaplanmıştır. Bu bölümdeki testlerde kullanılan RSSI verilerine ait anlık veritabanı görüntüsü Ek-1'de yer almaktadır. Bu görüntü Location tablosundan alınmıştır.

### 4.2.1. KNN Algoritması İle Elde Edilen Sonuçlar

Wi-Fi noktası ve Beacon cihazlarından toplanan verilerin KNN algoritmasında kullanılan Euclidean, Manhattan, ve Minkowski uzaklık ölçüm fonksiyonlarında ayrı ayrı doğruluk oranları hesaplanmıştır. En yüksek doğruluk oranı Manhattan ölçüm fonksiyonunda elde edilmiştir. KNN algoritmasında kullanılan değişkenler ve değerleri Tablo 4.10'da yer almaktadır. Elde edilen doğruluk oranları Tablo 4.11'da yer almaktadır.

**Tablo 4.10:** KNN algoritmasında kullanılan değişkenler.

| Parametre Adı | Parametre Açıklaması | Parametre Değeri |
|---|---|---|
| weights | Ağırlık | Tek tip (Uniform) |
| algorithm | Algoritma | Otomatik (Auto) |
| n_neighbors | Komşu - N | 5 |
| p | Minkowski metriği için güç | 1=Manhattan, 2=Euclidean, Keyfi değer=Minkowski |

**Tablo 4.11:** Wi-Fi ve Beacon için KNN algoritması ile elde edilen doğruluk oranları.

| Eğitim Oranı | Doğruluk Oranı |
|---|---|
| 0,9 | 90,08 |
| 0,8 | 89,82 |
| 0,7 | 88,93 |
| 0,6 | 88,42 |
| 0,5 | 87,64 |
| 0,4 | 86,76 |
| 0,3 | 86,06 |
| 0,2 | 85,28 |

Wi-Fi noktası, Beacon cihazları ve akıllı cihazlardan toplanan verilerde ise en yüksek doğruluk oranı yine Manhattan ölçüm fonksiyonunda elde edilmiştir. Elde edilen doğruluk oranları Tablo 4.12'de yer almaktadır.

**Tablo 4.12:** Wi-Fi ve Beacon ve BSD için KNN algoritması ile elde edilen doğruluk oranları.

| Eğitim Oranı | Doğruluk Oranı |
|---|---|
| 0,9 | 90,32 |
| 0,8 | 89,89 |
| 0,7 | 88,94 |
| 0,6 | 88,47 |
| 0,5 | 87,66 |
| 0,4 | 86,79 |
| 0,3 | 86,20 |
| 0,2 | 85,29 |

### 4.2.2. SVM Algoritması İle Elde Edilen Sonuçlar

Wi-Fi noktası ve Beacon cihazlarından toplanan verilerin SVM algoritmasında kullanılan birden farklı fonksiyon için ayrı ayrı doğruluk oranları hesaplanmıştır. En yüksek doğruluk oranı doğrusal (linear) fonksiyonunda elde edilmiştir. SVM algoritmasında kullanılan değişkenler ve değerleri Tablo 4.13'de yer almaktadır. Elde edilen doğruluk oranları Tablo 4.14'de yer almaktadır.

**Tablo 4.13:** SVM algoritmasında kullanılan değişkenler.

| Parametre Adı | Parametre Açıklaması | Parametre Değeri |
|---|---|---|
| C | Düzenlileştirme parametresi | 1 |
| tol | Durdurma kriteri için tolerans | 1e-3 |
| kernel | Çekirdek | linear, poly, rbf, sigmoid |

**Tablo 4.14:** Wi-Fi ve Beacon için SVM algoritması ile elde edilen doğruluk oranları.

| Eğitim Oranı | Doğruluk Oranı |
|---|---|
| 0,9 | 87,76 |
| 0,8 | 87,57 |
| 0,7 | 87,45 |
| 0,6 | 87,33 |
| 0,5 | 87,04 |
| 0,4 | 86,82 |
| 0,3 | 86,68 |
| 0,2 | 86,11 |

Wi-Fi noktası, Beacon cihazları ve akıllı cihazlardan toplanan verilerde ise en yüksek doğruluk oranı yine doğrusal (linear) fonksiyonunda elde edilmiştir. Elde edilen doğruluk oranları Tablo 4.15'de yer almaktadır.

**Tablo 4.15:** Wi-Fi ve Beacon ve BSD için SVM algoritması ile elde edilen doğruluk oranları.

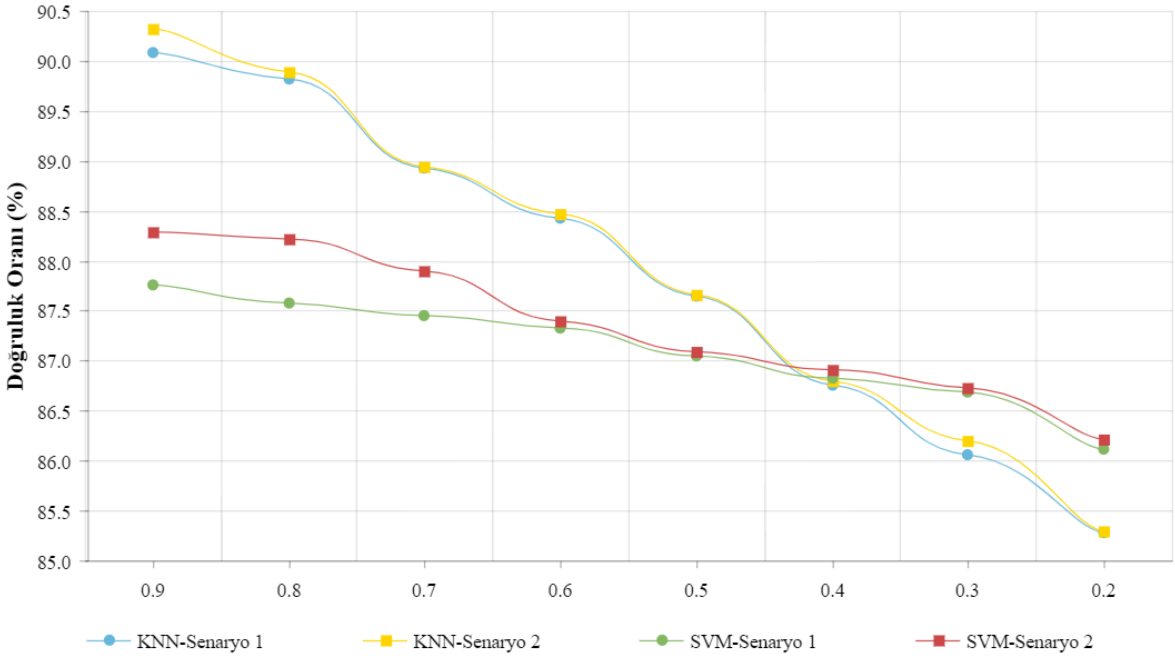
| Eğitim Oranı | Doğruluk Oranı |
|---|---|
| 0,9 | 88,29 |
| 0,8 | 88,22 |
| 0,7 | 87,90 |
| 0,6 | 87,40 |
| 0,5 | 87,09 |
| 0,4 | 86,91 |
| 0,3 | 86,73 |
| 0,2 | 86,21 |

Makine öğrenmesi yöntemiyle elde edilen ortalama doğruluk oranlarının eğitim oranlarına göre değişimlerini yansıtan özet Tablo 4.16 ve grafik Şekil 4.29'da yer almaktadır.

Senaryo 1, Wi-Fi ve BLE veri kombinasyonunu, Senaryo 2 ise Wi-Fi, BLE ve BSD veri kombinasyonunu içeren sonuçlar yer almaktadır.

**Tablo 4.16:** Makine öğrenmesi ile edilen özet sonuç tablosu.

| Algoritma | Ortalama Doğruluk Oranı (Senaryo 1) | Ortalama Doğruluk Oranı (Senaryo 2) |
|---|---|---|
| KNN Algoritması | 87,87 | 87,95 |
| SVM Algoritması | 87,10 | 87,34 |
| Ortalama (algoritma bazında) | 87,91 | 87,22 |




**Şekil 4.29:** Makine öğrenmesi ile edilen doğruluk oranlarının değişim grafiği.

İç mekan konumlandırma adına farklı teknolojilerin kullanılarak konum tespiti yapılması sıklıkla çalışılan bir konudur. Literatürde yer alan bazı çalışmalar incelenmiş ve bu tezde yapılan çalışmaşlarla doğruluk yüzdeleri karşılaştırılmıştır. Ali ve diğ. [36] tarafından Uzun Mesafe (Long Range - LoRa) teknolojisi kullanılarak gerçekleştirilmiş ve iç mekan konumlandırmada toplanan parmak izlerinin kullanımında bir çözüm olarak önerilen derin öğrenme yöntemi kullanılmıştır. 4 adet test senaryosunda ortalama %85 doğruluk oranı elde

edilmiştir. Bu çalışmada doğruluk oranının tez çalışmasındaki doğruluk oranlarına nazaran yüksek olması LoRa teknolojisinin Wi-Fi ve BLE'den daha kararlı olduğu ve çevresel değişikliklere karşı daha dayanıklı olması [37] ve buna bağlı olarak elde edilen sinyallerin daha az bozunma, sapma gibi sinyal iletişim doğruluğunu etkileyebilecek sorunlarla daha az etkilenmesiyle açıklanabilir.

Diğer yandan iç mekanda parmak izi konumlandırma sistemleri için yörünge gizlilik koruma yaklaşımı başlıkları altında gerçekleştirilen çalışmalar da yer almaktadır. Bu çalışmalarda gerçek yörüngenin gizliliğini korumak amacıyla sahte yörüngeler oluşturulmakta ve bu yörüngelerin gerçek yörüngelerle benzerlikleri karşılaştırılmaktadır. Konstantinidis ve diğ. [38] ait çalışmada Wi-Fi sinyal haritaları ve Zamansal Vektör Haritası (Temporal Vector Map - TVM) kullanarak %87, Li ve diğ. [39] ait çalışmada Wi-Fi parmak izi yöntemi kullanarak %80 ~ %85 ve Wang ve diğ. [40] ait çalışmada yine Wi-Fi parmak izi yöntemi kullanarak %85 doğruluk oranını elde edilmiştir.

# 5. TARTIŞMA VE SONUÇ

İç mekan konumlandırma ortamı oluşturmak için bu tez çalışmasında bir ev ortamında bulunan antre ve oda kullanılmıştır. Bu ortamda 6 adet Beacon cihazı, 1 adet Wi-Fi erişim noktası ve 4 adet akıllı cihaz yer almaktadır. Bu ortam bir koordinat sistemi üzerine oturtulmuş ve buna göre akıllı cihazlar, Beacon cihazları ve Wi-Fi erişim noktası belirli noktalara sabitlenmiştir. Bu cihazlardan alınan RSSI parmak izi verileri Android işletim sisteminde kodlanan bir mobil uygulama aracılığı ile toplanmış, MongoDB Realm veritabınında saklanmıştır. Parmak izi yöntemide çevrimdışı eğitim aşaması olarak adlandırılan bu aşamada farklı zaman dilimlerinde gerçekleştirilen veri toplamalar sonucunda 822 adet veri içeren veri kümesi elde edilmiştir. Elde edilen veriler üzerinde yer alan gürültüyü azaltmak amacıyla elde edilen Kalman filtresi iç mekan konum belirleme problemine uyarlanarak kullanılmıştır.

Bu veriler 2 ayrı yöntem üzerinde kullanılarak 2 ayrı bölümde incelenmiştir. İlk bölümde Doğrusal Olmayan En Küçük Kareler Yöntemi ve Levenberg - Marquardt algoritması kullanarak elde edilen sonuçlar istemcinin test ortamı içerisindeki tahmini konumu, yolu ve bölgeleri çıkarmaya yöneliktir. RSSI verisi toplamak için oluşturulan alanlar belirlenmiş ve bu alanlar içerisinde ızgara alanlarına bölünmüştür. İki ayrı senaryo üzerinde çalışılan bu yöntemde, önce test ortamı antrede 2 ve odada sekiz olmak üzere toplam 10 bölgeye bölünmüştür. Antrede her bir ızgara parçası 1,344 $m^2$ , odada ise her bir ızgara parçası 1,435 $m^2$ olarak belirlenmiştir. Bu senaryoda ortalama doğruluk oranı %82,75 olarak hesaplanmıştır. İkinci senaryoda ise, test ortamı antre 9 ve oda 16 olmak üzere toplam 25 bölgeye bölünmüştür. Antrede her bir ızgara parçası 0,288 $m^2$, odada ise her bir ızgara parçası 0,7175 $m^2$ olarak belirlenmiştir. Birinci senaryoya göre 2,5 kat daha fazla alana bölünmüş olmasına rağmen ortalama doğruluk oranı %9,86 azalma göstermiş ve ortalama doğruluk oranı %72,89 olarak hesaplanmıştır. Bu yöntemde senaryo bağımsız olarak ortalama hata 0,3054 $m$ olarak hesaplanmıştır.

Dış mekandan farklı olarak, iç mekan farklı bir anlamsal konum ve yörünge hissine sahip olabilmektedir. Bunun nedeni iç mekanlarda yer alan alanlarda sinyalin daha fazla bozulmaya veya daha fazla gürültü içerisinde olma ihtimalinin daha yüksek olmasıyla açıklanabilmektedir. Bu ihtimal aynı zamanda istemcinin iç mekan konumundaki yerini tahmin etmeyi ve tahmindeki doğruluk oranını etkileyebilmektedir.

İkinci bölümde ise makine öğrenmesi yöntemiyle KNN ve SVM algoritmalarıyla elde edilen hesaplamaların sonucu yer almaktadır. Elde edilen sonuçlar incelendiğinde her 2 algoritmanın da en yüksek doğruluk oranına %90'lık kısmının eğitim olarak sınıflandırıldığı durumda erişildiği ve en iyi doğruluk oranına KNN algoritmasında erişildiği görülmüştür. Ayrıca her iki algoritmanın doğruluk oranlarında BSD'nin test ortamına katılımı ile bir iyileşme olduğu gözlemlenmiştir. Bu iyileşme BSD'nin iç mekan konumlandırmada yardımcı bir rol oynayabileceğini göstermektedir.

Tez çalışması literatürde yer alan diğer çalışmalarla karşılaştırılmıştır. Karşılaştırılan çalışmalarda doğruluk oranları %80 - %87 aralığında olup, bu tez çalışmasında ilk kısımda elde edilen doğruluk oranı ortalama %72 - %83, ikinci kısımda elde edilen doğruluk değerleri ise ortalama %87 - %88 aralığındadır. Elde edilen doğruluk oranları, karşılaştırılan diğer çalışmaların doğruluk oranlarına oldukça yakın ve tutarlı değerlerin olduğu görülmüştür.

# KAYNAKLAR


[1] S. Watson, «Introduction to Global Positioning Systems (GPS),» U.S. Army Corps of Engineers / NOAA Coastal Services Center Training Partnership, USA.

[2] H. Ramadhan, Y. Yustiawan ve J. Kwon, «Applying Movement Constraints to BLE RSSI-Based Indoor Positioning for Extracting Valid Semantic Trajectories,» *Sensors,* cilt 20, no. 2, 2020.

[3] «Understanding RSSI,» MetaGeek, [Çevrimiçi]. Available: https://www.metageek.com/training/resources/understanding-rssi.html. [Erişildi: 12 Aralık 2020].

[4] B. Miraslov ve M. Simek, «Adaptive Distance Estimation Based on RSSI in 802.15.4 Network,» *Radioengineering,* cilt 22, pp. 1162-1168, Aralık 2013.

[5] J. KANG, D. KIM ve Y. KIM, «RSS self-calibration protocol for WSN localization,» %1 içinde *The 2nd International Symposium on Wireless Pervasive Computing ISWPC '07*, San Juan (Puerto Rico), 2007.

[6] B. O'Keefe, «ECE Senior Capstone Project 2017 Tech Notes: Finding location with time of arrival and time difference of arrival techniques,» 2017. [Çevrimiçi]. Available: https://sites.tufts.edu/eeseniordesignhandbook/files/2017/05/FireBrick_OKeefe_F1.pdf. [Erişildi: 14 Aralık 2020].

[7] J. Apolinario, H. Yazdanpanah, A. Nascimento ve M. Campos, *A Data-Selective LS Solutıon To TDoA-Based Source Localization,* IEEE Dataport, 2019.

[8] B. Ozdemir, S. Alcay, C. O. Yigit ve A. Ceylan, «Kapalı Mekânlarda Uygulanan Konum Belirleme Yöntemleri ve Karşılaştırılması,» %1 içinde *Harita ve Kadastro Mühendisleri Odası, 7. Mühendislik Ölçmeleri STB Komisyonu*, Çorum, 2014.

[9] «MINEW,» Shenzhen Minew Technologies Co, [Çevrimiçi]. Available: https://en.minewtech.com/news/company-2020-09-18-01.html. [Erişildi: 12 Aralık 2020].

[10] Z. Wei ve X. Xiaoli, «Analysis and Simulation of the Direction of Arrival Estimation Algorithm of Spatial Signal,» %1 içinde *The Eighth International Conference on Electronic Measurement and Instruments*, Xian, 2007.

[11] M. David, C. Boucherea, F. Vargas ve E. Rogerio, «CHAPTER 2 - Signal Parameter Estimation for the Localization Problem,» %1 içinde *Position Location Techniques and Applications*, Academic Press, 2009, pp. 23-65.

[12] B. Cook, G. Buckberry, I. Scowcroft, J. Mitchell ve T. Allen, «Location by Scene Analysis of Wi-Fi Characteristics,» *Relation,* cilt 10(1.119), no. 6216, 2009.

[13] A. Papapostolou ve H. Chaouchi, «Scene analysis indoor positioning enhancements,» *Annales des télécommunications,* cilt 66, pp. 591-533, 10 2011.

[14] A. M. Zarca, «A Study of Fingerprint-based Methods for Training Phase in Wi-Fi Indoor Positioning Systems.,» *International Journal of Computer Systems,* cilt IV, no. 7, 2017.

[15] Z. Xiao, H. Wen, A. Markham, N. Trigoni, P. Blunsom ve J. Frolik, «Non-Line-of-Sight Identification and Mitigation Using Received Signal Strength,» *IEEE Transactions on Wireless Communications,* cilt 14, no. 3, p. 1689–1702, Mart 2015.

[16] A. Baniukevic, C. Jensen ve H. Lu, «Indoor Positioning With Wi-Fi and Bluetooth: Architecture and Performance,» %1 içinde *2013 IEEE 14th International Conference on Mobile Data Management*, Milan, 2013.

[17] J.-S. Leu, C.-C. Chiu ve J.-C. Hsu, «Implementation and analysis of Hybrid Wireless Indoor Positioning with iBeacon and Wi-Fi,» %1 içinde *2016 8tInternational Congress on Ultra Modern Telecommunications and Control Systems and Workshops (ICUMT)*, Lisbon, 2016.

[18] Z. Xiong, F. Sottile, M. A. Spirito ve R. Garello, «Hybrid Indoor Positioning Approaches Based on WSN and RFID,» %1 içinde *2011 4th IFIP International Conference on New Technologies, Mobility and Security*, Paris, 2011.

[19] S. Holm, «Hybrid ultrasound-RFID indoor positioning: Combining the best of both worlds,» %1 içinde *2009 IEEE International Conference on RFID*, Orlando, FL, 2009.

[20] «Android Geliştirme için Kurulum,» Google Inc., [Çevrimiçi]. Available: https://source.android.com/setup/start/build-numbers. [Erişildi: 22 Kasım 2020].

[21] «MongoDB,» Wikipedia, [Çevrimiçi]. Available: https://en.wikipedia.org/wiki/MongoDB. [Erişildi: 2 Ocak 2021].

[22] A. T. Samsudin, M. S. Saharedan, S. N. Yahya, M. S. Ishak ve S. S. Said, «Improved wi-fi signal quality indicator using wi-fi performance observation,» *Asia Pacific J. Contemp. Educ. Commun. Technology*, cilt 3, no. 2, 2017.

[23] Apple Inc., [Çevrimiçi]. Available: https://developer.apple.com/ibeacon/. [Erişildi: 17 Ocak 2021].

[24] Y. Kim ve H. Bang, Introduction to Kalman Filter and Its Applications, Daejeon: Korea Advanced Institute of Science and Technology, 2018.

[25] W. Bulten, A. C. Van Rossum ve W. F. G. Haselager, «Human SLAM, Indoor Localisation of Devices and Users,» %1 içinde *2016 IEEE First International Conference on Internet-of-Things Design and Implementation (IoTDI)*, Berlin, 2016.

[26] A. Atasoy ve A. G. Gelen, «A New Method for Kalman Filter Tuning,» %1 içinde *2018 International Conference on Artificial Intelligence and Data Processing (IDAP)*, Malatya, 2018.

[27] M. B. Rhudy, R. A. Salguero ve K. Holappa, «A Kalman filtering tutorial for undergraduate students,» *International Journal of Computer Science & Engineering Survey*, cilt 8, no. 1, pp. 1-18, 2017.

[28] S. Sadowski ve P. Spachos, «Optimization of BLE beacon density for RSSI-based indoor localization,» %1 içinde *2019 IEEE International Conference on Communications Workshops (ICC Workshops)*, 2019.

[29] H. Yu ve B. M. Wilamowski, «Levenberg-marquardt training,» %1 içinde *Industrial electronics handbook*, cilt V, 2011.

[30] D. Marquardt, «An Algorithm for LeastSquares Estimation of Nonlinear Parameters,» *SIAM Journal on Applied Mathematics*, cilt XI, no. 2, pp. 431-441, 1963.

[31] M. Hagan ve M. M. B., «Training feedforward networks with the Marquardt algorithm,» *IEEE Transactions on Neural Networks*, cilt V, no. 6, pp. 989-993, 1994.

[32] M. A. Çavuşlu, Y. Becerikli ve C. Karakuzu, «Levenberg – Marquardt Algoritması ile YSA Eğitiminin Donanımsal Gerçeklenmesi,» *TBV Bilgisayar Bilimleri ve Mühendisliği Dergisi,*, cilt 5, pp. 31-38, 2012.

[33] L. Fausett, Fundamentals of neural networks - architectures, algorithms, and applications, Prentice- hall, 1994.

[34] N. Güner ve E. Çomak, «Mühendislik Öğrencilerinin Matematik I Derslerindeki Başarısının Destek Vektör Makineleri Kullanılarak Tahmin Edilmesi,» *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi,* cilt 17, no. 2, pp. 87-96, 2011.

[35] W. A. ve Y. B.-S, «Support vector machine in machine condition monitoring and fault diagnosis,» *Mechanical Systems and Signal Processing*, cilt 21, no. 6, pp. 2560-2574, 2007.

[36] I. Ali, A. Muis ve R. Sari, «A Deep Learning Model Implementation Based On RSSI Fıngerprinting for Lora-Based Indoor Localization,» *EUREKA: Physics and Engineering*, no. 1, pp. 40-59, 2021.

[37] B. Islam, M. T. Islam, J. Kaur ve S. Nirjon, «LoRaIn: Making a Case for LoRa in Indoor Localization,» %1 içinde *2019 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, Kyoto, Japan, 2019.

[38] A. Konstantinidis, G. Chatzimilioudis, D. Zeinalipour-Yazti, P. Mpeis, N. Pelekis ve Y. Theodoridis, «Privacy-Preserving Indoor Localization on Smartphones,» *IEEE Transactions on Knowledge and Data Engineering*, cilt 27, no. 11, pp. 3042-3055, 2015.

[39] H. Li, L. Sun, H. Zhu, X. Lu ve X. Cheng, «Achieving privacy preservation in WiFi fingerprint-based localization,» %1 içinde *IEEE INFOCOM 2014 - IEEE Conference on Computer Communications*, Toronto, Canada, 2014.

[40] Y. Wang, M. Huang, J. Q. ve J. Ma, «DP3: A Differential Privacy-Based Privacy-Preserving Indoor Localization Mechanism,» *IEEE Communications Letters*, cilt 22, no. 12, pp. 2547-2550, 2018.

# EKLER

## EK 1. ANLIK VERİTABANI GÖRÜNTÜSÜ


```
{
  "Location":
  [
  {
      "id": "6de62b4c-ef83-4d87-b838-02faeb3416ca",
      "measureId": "8d44ba43-0315-4eba-bbe6-7d90282de31b",
      "locationX": 3.3726807968314136,
      "locationY": 1.0344157020208338,
      "area": "O2",
      "createdAt": "28-03-2021 11:41:20"
    },
  {
      "id": "e6ae6f91-2c07-42e2-bf4d-12ab8723078f",
      "measureId": "01559890-c1c2-4048-8dd4-eec1107768a5",
      "locationX": 4.9246750019113215,
      "locationY": 1.2066524963759722,
      "area": "O10",
      "createdAt": "28-03-2021 11:49:00"
    },
  {
      "id": "52a6e7c9-1783-4734-86fb-1582d5d6548c",
      "measureId": "675348a4-2f23-4a4b-bc23-3466f5cd4732",
      "locationX": 2.8110871033880924,
      "locationY": 1.655788739003141,
      "area": "O3",
      "createdAt": "28-03-2021 11:40:17"
    },
  {
      "id": "a0661ca5-f1cc-4b22-9797-2ee7007274ad",
      "measureId": "75a9d9e2-0015-4c3b-8a7f-2cefe1f2019c",
      "locationX": 3.1647489555611124,
      "locationY": 1.2709439245472676,
      "area": "O2",
      "createdAt": "28-03-2021 11:41:07"
    },
  {
      "id": "58b982d9-12d7-4181-a34a-9afe86a6d84e",
      "measureId": "636122f3-a615-48a2-9747-cf50c7a63b3e",
      "locationX": 3.974903865597894,
      "locationY": 1.1380931242118983,
      "area": "O6",
      "createdAt": "28-03-2021 11:44:55"
    },
  {
      "id": "75d0f71c-9ce8-4220-a4a5-6a75eb3ccc8d",
      "measureId": "35ca8a9d-0b93-4ffb-a0a1-5292e00ab279",
      "locationX": 4.025517534957916,
      "locationY": 1.4113426739254387,
```

```
      "area": "O7",
      "createdAt": "28-03-2021 11:45:55"
    },
  {
      "id": "ac2cbc9a-9160-4502-b7b0-3d2c172da919",
      "measureId": "361a33a3-00b2-4f3e-8834-81b5ca8d8e8b",
      "locationX": 4.993087347744834,
      "locationY": 1.9871865026476694,
      "area": "O11",
      "createdAt": "28-03-2021 11:51:54"
    },
  {
      "id": "637d842b-2951-4c25-bd9e-d84ab1509abd",
      "measureId": "554d35e5-f0b9-4e5d-9cb6-dd73232a03de",
      "locationX": 4.759176972638222,
      "locationY": 2.3364480115098147,
      "area": "O12",
      "createdAt": "28-03-2021 11:52:34"
    },
  {
      "id": "8f3e95ef-71e2-4108-8ab9-0d41784a0c3c",
      "measureId": "02b7cf9b-af69-44d9-9695-fee615d8b006",
      "locationX": 4.388223122237824,
      "locationY": 1.2710120610367466,
      "area": "O6",
      "createdAt": "28-03-2021 11:46:55"
    },
  {
      "id": "bebf4af8-e489-4f6e-8de2-4ff15a8ef372",
      "measureId": "f14f9ae3-5f29-4f97-9374-68b20e52c415",
      "locationX": 3.949791165593566,
      "locationY": 0.5446324785494631,
      "area": "O5",
      "createdAt": "28-03-2021 11:43:59"
    },
  {
      "id": "0a0c5df6-e930-4626-9bd8-7b75a351dc48",
      "measureId": "cc2ee847-c3e8-4cfe-8290-717e04f251cb",
      "locationX": 4.989818350180401,
      "locationY": 0.8995901288671938,
      "area": "O10",
      "createdAt": "28-03-2021 11:48:00"
    }

  ]
}
```