



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



RADYO DALGALARINDAN ALINAN SİNYAL
GÜÇ GÖSTERGESİ (RSSI) DEĞERİ İLE
KONUM BELİRLEME DOĞRULUĞUNUN
İNCELENMESİ

SEYİT ALİ GÜLBAĞ

YÜKSEK LİSANS TEZİ

Harita Mühendisliği Anabilim Dalı

Ocak-2024
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Seyit Ali GÜLBAĞ tarafından hazırlanan “Radyo Dalgalarından Alınan Sinyal Güç Göstergesi (RSSI) Değeri ile Konum Belirleme Doğruluğunun İncelenmesi” adlı tez çalışması 17/01/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Harita Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Semih EKERCİN
(Antalya Bilim Üniversitesi)

.....

Danışman

Prof. Dr. Ekrem TUŞAT
(Konya Teknik Üniversitesi)

.....

Üye

Prof. Dr. Ekrem TUŞAT
(Konya Teknik Üniversitesi)

.....

Üye

Doç. Dr. Akif DURDU
(Konya Teknik Üniversitesi)

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Seyit Ali GÜLBAĞ

Tarih:26.12.2023

ÖZET**YÜKSEK LİSANS TEZİ****RADYO DALGALARINDAN ALINAN SİNYAL GÜÇ GÖSTERGESİ (RSSI)
DEĞERİ İLE KONUM BELİRLEME DOĞRULUĞUNUN İNCELENMESİ****Seyit Ali GÜLBAĞ****Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Harita Mühendisliği Anabilim Dalı****Danışman: Prof. Dr. Ekrem TUŞAT****2024, 133 Sayfa****Jüri
Prof. Dr. Semih EKERCİN
Prof. Dr. Ekrem TUŞAT
Doç. Dr. Akif DURDU**

ABD tarafından GPS'in geliştirilmesi ve sivil kullanıma açılması birlikte, dünya genelinde konum belirleme sistemlerine sahip olmanın stratejik ve ticari önemi birçok ülke tarafından fark edilmiştir. Bu durum, günümüzde bölgesel veya küresel çapta faaliyet gösteren çeşitli uydu tabanlı konum belirleme sistemlerinin ortaya çıkmasına ve kullanımının artmasına neden olmuştur. Fakat bu sistemlerinin en büyük dezavantajı konum belirlenirken uydu ile yeryüzünde bulunan kullanıcı arasında görüş açıklığı bulunması gerekliliğidir. Yani bu sistemler kullanılırken uydular ile yeryüzünde bulunan alıcı arasında bulunan bir engel (ağaç, duvar vs.) sistemin kullanımını büyük ölçüde engelleyebilmektedir. Bu nedenle, yeraltı ve kapalı alanlarda konum belirleme ihtiyacını karşılamak amacıyla alternatif sistemler ve yöntemler geliştirilmektedir. Bu yöntemlerden biri de RSSI değeri ile konum belirlemedir. Bu çalışma ile RSSI değeri ve makine öğrenmesi algoritmaları kullanılarak kapalı mekanlarda konum belirleme ve elde edilen konumun doğruluğunun incelenerek artırılması yönünde araştırmalar yapılmıştır.

Çalışmada konum belirleme yöntemi olarak Trilaterasyon ve Parmak İzi (ing:Fingerprint) yöntemleri kullanılmıştır. Trilaterasyon yönteminin en büyük dezavantajı olan referans noktaların yerleşim geometrisinin hesaplanan konum doğruluğuna etkisi sebebi ile çalışmada kullanılan referans RF verici istasyonları deney sahasına iki farklı geometride yerleştirilmiştir. Her iki geometri için deney sahasına homojen olarak yayılan noktalarda RSSI ve konum değerleri ölçülmüş olup makine öğrenmesi tabanlı regresyon modelleri için eğitim verisi toplanarak veri setleri oluşturulmuştur. Ayrıca toplanan bu eğitim verilerinde RSSI değerleri 10 epok ölçülerek istatistiksel yöntemler ile filtrelemeye tabi tutulmuştur. Bu sayede çevresel etkilerden dolayı hatalı olabilecek RSSI ölçümleri elemine edilmeye çalışılmıştır. Bu eğitim verileri ile eğitilen modellerin geliştirilen bir algoritma ile hiper parametre optimizasyonu sağlanarak eğitim verisine uyumu artırılmaya çalışılmıştır. Bu sayede çalışmada kullanılan her bir modelden en yüksek performansın alınması amaçlanmıştır. Parametreleri ayarlanan modellerden en yüksek doğruluğa sahip olanları seçilmiş ve hazırlanan mobil uygulamaya eklenerek uygulama sahasında her iki geometri için gerçek zamanlı testler yapılmıştır. Testler sonucunda elde edilen mesafe ve konum değerleri için EKK yöntemi ile dengeleme yapılarak elde edilen konum doğruluğunun artırılmasına yönelik yöntemler araştırılmıştır. Sonuç olarak elde edilen en yüksek konum doğruluğu değerlerini veren yöntem seçilerek uygulama sahası için RSSI ile konum belirlemeye yönelik sistemin parametreleri önerilmiştir.

Seçilen çalışma sahasının gerçek dünya koşullarına benzer şekilde kapalı, görüş açısının kısıtlı ve fiziki engeller içermesi sebebiyle, geliştirilen yöntemin gerçek uygulama alanlarında da başarıyla uygulanabileceği düşünülmektedir.

Anahtar Kelimeler: RSSI, LoRa, GNSS, Regresyon, Parmakizi, Makine Öğrenmesi.

ABSTRACT**MS THESIS****INVESTIGATION OF POSITIONING ACCURACY BASED ON RECEIVED
SIGNAL STRENGTH INDICATOR (RSSI) VALUES FROM RADIO WAVES****Seyit Ali GÜLBAĞ****Konya Technical University
Institute of Graduate Studies
Department of Geomatics Engineering****Advisor: Prof. Dr. Ekrem TUŞAT****2024, 133 Pages****Jury
Prof. Dr. Semih EKERCİN
Prof. Dr. Ekrem TUŞAT
Assoc.Prof. Dr. Akif DURDU**

With the development and civilian deployment of GPS by the United States, many countries around the world have realized the strategic and commercial importance of having positioning systems. This has led to the emergence and increased use of various satellite-based position systems operating on a regional or global scale. However, the biggest disadvantage of these systems is the need for a clear line of sight between the satellite and the user on the ground. In other words, when using these systems, an obstacle (tree, wall, etc.) between the satellites and the receiver on the ground can greatly hinder the use of the system. For this reason, alternative systems and methods are being developed to meet the need for positioning in underground and confined spaces. One of these methods is positioning with RSSI. In this study, experiments have been carried out to determine the location in confined spaces using RSSI value and machine learning algorithms and to examine and improve the accuracy of the obtained position.

In the study, Trilateration and Fingerprint methods were used as positioning methods. Due to the biggest disadvantage of the trilateration method, which is the effect of the placement geometry of the reference points on the calculated position accuracy, the reference RF transmitter stations used in the study were placed in two different geometries in the experimental field. For both geometries, RSSI and coordinate values were measured at points spread homogeneously over the experimental field and training data were collected and data sets were created for machine learning based regression models. In addition, RSSI values were measured with 10 epoch measurements and filtered with statistical methods. In this way, RSSI measurements that may be inaccurate due to environmental effects were tried to be eliminated. The models trained with this training data were hyper parameter optimized with an algorithm developed to increase the fit to the training data. In this way, it is aimed to obtain the highest performance from each model used in the study. The models with the highest accuracy were selected from the models whose parameters were adjusted and added to the prepared mobile application and real-time tests were performed for both geometries in the application area. For the distance and coordinate values obtained as a result of the tests, methods to increase the position accuracy obtained by balancing with the EKK method were investigated. As a result, the method that gives the highest position accuracy values is selected and the parameters of the system for positioning with RSSI are proposed for the application area.

It is thought that the developed method can be successfully applied in real application areas since the selected study area is closed, has limited visibility and physical obstacles similar to real world conditions.

Keywords: RSSI, LoRa, GNSS, Regression, Fingerprint, Machine Learning.

ÖNSÖZ

Konum belirleme uygulamaları, belirlenen konum doğruluğunun artırılması veya bu alanda teorik ve teknik anlamda geliştirme sağlamak Harita Mühendisliği disiplinin temel görevlerinden biridir. GNSS'in kapalı alanlarda konum belirlemede etkin olamayışı sebebi ile bu alanda birçok çalışma yapılmıştır. Yapılan bu çalışmalar incelendiğinde özellikle RF dalgaları ile konum belirlenmesi yönünde teknik anlamda Harita Mühendisliğinin disiplinin diğer mühendislik disiplinlerine nazaran daha az çalışma çıkardığı görülmektedir. Elbette ki bu konunun yüksek oranda elektronik ve yazılım bilgisi gerektirmesi, bu konunun Elektronik Mühendisliği ve Bilgisayar Bilimleri gibi disiplinler tarafından daha çok çalışılmasının temel sebeplerindendir. Bu alanda yapılan çalışmalara mesleğimiz adına katkı sunmamı sağlayacak bu proje konusunu bana önerdiği, bu alanda yaptığım deneylerde destek veren ve yol gösteren değerli hocam sayın Prof. Dr. Ekrem TUŞAT'a sonsuz teşekkürü borç bilirim. Ayrıca benim bugünlere gelmeme vesile olan eğitimim konusunda her türlü fedakarlığı yapan ve beni destekleyen anne, babama ve yaptığım çalışmalarda beni her zaman destekleyen sevgili eşime teşekkür ederim.

Seyit Ali GÜLBAĞ
KONYA-2024

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
ŞEKİLLER VE ÇİZELGELER LİSTESİ	ix
Şekiller Listesi	ix
Çizelgeler Listesi	x
SİMGELER VE KISALTMALAR.....	xiii
1. GİRİŞ.....	1
2. KAYNAK ARAŞTIRMASI	4
3. KONUM BELİRLEMEDE KULLANILAN YÖNTEMLER.....	8
3.1. Radyo Dalgaları	9
3.1.1. Radyo frekans bantları	10
3.1.2. Modülasyon	13
3.1.2.1. Modülasyonun gereği	13
3.1.2.2. LoRa (Long Range-Uzun Menzil)	14
3.2. Radyo Dalgaları ile Konum Belirleme	15
3.2.1. Açıl ölçüm yöntemleri ile konum belirleme	16
3.2.1.1. Varış açısı ölçümü (Angle of Arrival – AOA)	16
3.2.1.2. Mesafe belirleme yöntemleri	17
3.2.2.1. Varış zamanı ölçümü (Time of Arrival, TOA)	17
3.2.2.2. Varış zamanı farkı ölçümü (Time Difference of Arrival, TDOA)	18
3.3. RSSI ile Konum Belirleme	19
3.3.1. Alınan sinyal güç göstergesi (RSSI)	20
3.3.2. RSSI değerinin mesafeye dönüştürülmesi	21
3.3.2.1. Yol kaybı modeli	22
3.3.2.1.1. Friis denklemleri	22
3.3.2.1.2. Polinom katsayıları.....	23
3.3.2.2. Makine öğrenmesi yöntemleri	25
3.3.2.3. Hibrit yöntemler.....	25
3.3.3. RSSI değerinin açı bilgisine dönüştürülmesi.....	26
4. MAKİNE ÖĞRENMESİ MODELLERİ.....	27
4.1. Makine Öğrenmesinde Temel Kavramlar.....	29
4.2. Regresyon Modelleri.....	31
4.2.1. Bagging regresyon modeli	32
4.2.2. Random Forest regresyon modeli	37
4.2.3. SVR regresyon modeli.....	38

4.2.4. Gradient Boosting regresyon modeli	42
4.2.5. XGB regresyon modeli	43
4.2.6. K-En Yakın Komşu regresyon modeli.....	45
5. KONUM HESAPLAMA YÖNTEMLERİ	48
5.1. Trilaterasyon (Üçgenleştirme) Yöntemi	48
5.1.1. Ters matris yöntemi ile çözüm.....	51
5.1.2. Cramer kuralı ile çözüm	51
5.2. Triangülasyon (Üçgenleme) Yöntemi	52
5.3. Multilaterasyon yöntemi	54
5.4. Parmak İzi Yöntemi	55
5.5. Karma Yöntemler	58
6. MATERYAL VE YÖNTEM.....	59
6.1. Donanım.....	59
6.2. Yazılım.....	66
6.3. Yöntem.....	73
6.3.1. Uygulama Sahası	74
6.3.2. Verilerin toplanması ve filtrelenmesi	76
6.3.2.1. Standart Sapma	78
6.3.2.2. IQR (Çeyrekler açıklığı)	78
6.3.2.3. Z Skoru Yöntemi	79
6.3.2.4. Modifiyeli Z Skor Yöntemi	80
6.3.3.Regresyon analizi.....	81
6.3.3.1.Regresyon modellerinin oluşturulması	82
6.3.3.2. Modellerin değerlendirilmesinde kullanılan metrikler	86
6.3.3.2.1. R^2 analizi.....	86
6.3.3.2.2. RMSE (Root Mean Squared Error- Karesel Ortalama Hatanın Kökü)	87
6.3.3.2.3. MAE (Mean Absolute Error- Ortalama Mutlak Hata)	88
6.3.4.Test verilerinin ayrılması	89
6.3.5. Hiper parametre optimizasyonun yapılması ve model seçimi	90
7. UYGULAMA	98
7.1. EKK Uygulanması	100
7.2. Uygulama Sonuçları	103
7.2.1. Uygulama 1 için istatistiksel sonuçlar	104
7.2.2. Uygulama 2 için istatistiksel sonuçlar	115
8. SONUÇ ve ÖNERİLER	126
8.1. Öneriler	128
KAYNAKLAR	130

ŞEKİLLER VE ÇİZELGELER LİSTESİ

Şekiller Listesi

Şekil 3.1. Bir anten tarafından yayılan radyo dalgaları (Chetvorno, 2015).....	9
Şekil 3.2. Radyo dalgalarında dalga boyu, dalga yüksekliği ve frekans gösterimi (Karaahmet, 2008).	10
Şekil 3.3. Dünya üzerinde tahsis edilen ISM bandlarının frekans aralığı (Tell, 2023). .	13
Şekil 3.4. Modülasyonlu radyo dalgaları (Berserkerus, 2008).	14
Şekil 3.5. Varış Açısı Ölçümü (Minew, 2020).	16
Şekil 4.1. Makine öğrenmesi modellerinin sınıflandırılması	28
Şekil 4.2. İş yerinde çalışanların yaş ve tecrübelerinin saçılım diyagramı.....	35
Şekil 4.3. İş yerinde çalışanların yaş ve tecrübelerinin bölümlendirilmesi.	35
Şekil 4.4. Verilen örnek için kullanılan ağaç diyagramı.	36
Şekil 4.5. SVR Regresyon modelinde rbf çekirdek fonksiyonu kullanılarak ayrılan hiper düzlemler (Géron, 2019).	39
Şekil 5.1. Trilaterasyon yöntemi.....	49
Şekil 5.2. Triangulation yöntemi.	53
Şekil 5.3. Tek istasyon ile Parmak izi yöntemi kullanılarak konum belirleme.	56
Şekil 5.4. İki istasyon ile Parmak İzi yöntemi.	57
Şekil 6.1. Çalışmada kullanılan E22-900T30D model numaralı RF modülü.....	59
Şekil 6.2. Ebyte RF modülünün bilgisayar bağlantısında kullanılan UART köprüsü.....	60
Şekil 6.3. Çalışmada kullanılan anten	62
Şekil 6.4. ESP32 ve Ebyte RF Modülü bağlantı şeması.....	64
Şekil 6.5. Uygulamada kullanılan ve vericilerden yayınlanan sinyalleri alan istasyon ..	65
Şekil 6.6. Uygulamada kullanılan ve sinyal gönderen verici istasyon	65
Şekil 6.7. RF modülünün parametrelerinin ayarlanmasında kullanılan uygulama.....	66
Şekil 6.8. Android işletim sistemi için geliştirilen konum belirleme uygulaması.....	70
Şekil 6.9. Geliştirilen konum belirleme uygulamasında ölçümün yapılması.	71
Şekil 6.10. Geliştirilen konum belirleme uygulaması ölçüm sonuçlarının görüntülenmesi	72
Şekil 6.11. Uygulama sahası.....	74
Şekil 6.12. Uygulama sahasında K26(soldaki resim) ve K24(sağdaki resim) adı verilen koridorlar.	74
Şekil 6.13. Uygulama sahasında Orta Alan adı verilen kısım.	75
Şekil 6.14. Uygulama 1 için verici istasyonların yerleşimi.....	75
Şekil 6.15. Uygulama 2 için verici istasyonların yerleşimi	75
Şekil 6.16. IQR ile veri gurubunun parçalara ayrılması	78
Şekil 6.17. Çalışma sahasının yöntem 1'göre 3 farklı alana ayrılması.	83
Şekil 6.18. Regresyon modellerinde aşırı öğrenme, öğrenememe, ideal öğrenme	93

Çizelgeler Listesi

Çizelge 3.1. ITU radyo spektrum bantlarının sınıflandırılması (ITU, 2010).	11
Çizelge 4.1. Bir işyerinde çalışanların yaş ve tecrübeye göre aldıkları maaşlar.	34
Çizelge 5.1. Tek istasyondan yapılan RSSI ölçümleri.	56
Çizelge 5.2. İki istasyondan yapılan RSSI ölçümleri.	57
Çizelge 6.1. Çalışmada kullanılan antenin özellikleri (EOTH, 2023).	62
Çizelge 6.2. Eğitim ve test verisi için yapılan ölçümler.	76
Çizelge 6.3. Uygulama sahasında bir noktada yapılan RSSI ve mesafe ölçümleri.	77
Çizelge 6.4. Filtreleme sonucu elde edilen RSSI değerleri.	81
Çizelge 6.5. Mesafe belirlemede kullanılan regresyon modellerinin kullandığı veri yapısı.	84
Çizelge 6.6. Mesafe belirlemede kullanılan regresyon modelinin kullandığı veri yapısı.	85
Çizelge 6.7. Ölçüm yapılan alanı belirlemede kullanılan regresyon modellerinin kullandığı veri yapısı.	85
Çizelge 6.8. Parmak izi yöntemi için makine modellerinin eğitiminde kullanılan veri yapısı.	86
Çizelge 6.9. Varsayılan parametreler ile elde edilen model performansları.	92
Çizelge 6.10. Hiper parametre ayarlaması sonrası model performansları.	92
Çizelge 6.11. Uygulama 1’de mesafe tahmini için seçilen modeller ve kullanılan veri adları.	95
Çizelge 6.12. Uygulama 1’de parmak izi yöntemi için seçilen modeller ve kullanılan veri adları.	96
Çizelge 6.13. Uygulama 2’de mesafe tahmini için seçilen modeller ve kullanılan veri adları.	96
Çizelge 6.14. Uygulama 2’de parmak izi yöntemi için seçilen modeller ve kullanılan veri adları.	97
Çizelge 6.15. Modellerin, öğrenememe, aşırı öğrenme ve ideal öğrenme durumları için örnek sonuç.	97
Çizelge 7.1. RSSI değerinin mesafeye dönüştürülmesinde kullanılan Polinom denklemleri sonuçları.	99
Çizelge 7.2. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.	105
Çizelge 7.3. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.	105
Çizelge 7.4. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.	106
Çizelge 7.5. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.	106
Çizelge 7.6. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.	107
Çizelge 7.7. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.	107
Çizelge 7.8. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.	108
Çizelge 7.9. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.	108

Çizelge 7. 10. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.....	109
Çizelge 7.11. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.....	109
Çizelge 7. 12. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.	110
Çizelge 7.13. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.....	110
Çizelge 7.14. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.....	111
Çizelge 7.15. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.	111
Çizelge 7.16. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.....	112
Çizelge 7.17. Parmak izi yöntemine göre elde edilen konum doğruluklarına ilişkin istatistiksel sonuçlar.....	112
Çizelge 7.18. Uygulama 1 için yapılan değerlendirmede belirlenen yöntemler ve hesaplanan skorları.	113
Çizelge 7.19. Trilaterasyon ile belirlenen konumların Öklid uzunluğuna göre belirlenmiş ortalama hataları.	114
Çizelge 7.20. Parmak izi yöntemi ile belirlenen konumların Öklid uzunluğuna göre belirlenmiş ortalama hataları.	114
Çizelge 7.21. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.....	115
Çizelge 7.22. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.	115
Çizelge 7.23. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.....	116
Çizelge 7.24. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.....	116
Çizelge 7.25. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.	117
Çizelge 7.26. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.....	117
Çizelge 7.27. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.....	118
Çizelge 7.28. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.	118
Çizelge 7.29. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.....	119
Çizelge 7.30. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.....	119
Çizelge 7.31. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.	120
Çizelge 7.32. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.....	120
Çizelge 7.33. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.....	121
Çizelge 7.34. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.	121

Çizelge 7.35. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.....	122
Çizelge 7.36. Parmak izi yöntemine göre elde edilen konum doğruluklarına ilişkin istatistiksel sonuçlar.....	122
Çizelge 7.37. Uygulama 2 için yapılan değerlendirmede belirlenen yöntemler ve hesaplanan skorları.	123
Çizelge 7.38. Trilaterasyon ile belirlenen konumların Öklid uzunluğuna göre belirlenmiş ortalama hataları.	124
Çizelge 7.39. Parmak izi yöntemi ile belirlenen konumların Öklid uzunluğuna göre belirlenmiş ortalama hataları.	124



SİMGELER VE KISALTMALAR

Simgeler

λ :	Dalga boyu
kb:	Kilobayt
Hz:	Hertz
GHz:	Gigahertz
dBm:	Desibel Miliwatt
dB:	Desibel
c:	Işık Hızı
C:	Celsius derece
f:	Frekans
d:	İki istasyon arasındaki mesafe(m)
m:	Metre
km:	Kilometre

Kısaltmalar

Ar-Ge:	Araştırma-Geliştirme
AOA:	Angle of Arrival (Varış Açısı)
BLE:	Bluetooth Low Energy (Bluetooth Düşük Enerji)
DF:	Direction Finding (Yön Bulma)
EKK:	En Küçük Kareler
GNSS:	Global Navigation Satellite Systems (Küresel Konum Belirleme Sistemleri)
IMU:	Internal Measurement Unit (İç Ölçüm Birimi)
IOT:	Internet of Things (Nesnelerin İnterneti)
ISM:	Industrial Scientific Medical (Endüstri, Bilimsel, Sağlık)
ITU:	The International Telecommunication Union (Uluslararası Telekomünikasyon Birliği)
KOH:	Karesel Ortalama Hata
LBS:	Location Based Systems (Yer Bazlı Konum Belirleme Sistemleri)
MAE:	Mean Absolute Error(Ortalama Mutlak Hata)
MZS:	Modifiyeli Z Skoru
RF:	Radyo Frekans
RBF:	Radial Basis Function (Radyal Temel Fonksiyonu)
RFID:	Radio Frequency Identification (Radyo Frekans Kimlik Tanıma)
RMSE:	Root Mean Squared Error(Karesel Ortalama Hata)
RSS:	The Received Signal Strenght (Alınan Sinyal Gücü)
RSSI:	The Received Signal Strenght Indicator (Alınan Sinyal Güç Göstergesi)
SNR:	Signal-to-Noise Ratio (Sinyal-Gürültü Oranı)
STDS:	Standart Sapma
SS-FSK:	Spread Spectrum Frequency Shift Keying
SVR:	Support Vector Regression
TDOA:	Time Difference of Arrival (Varış Zamanı Farkı)
TOA:	Time of Arrival (Varış Zamanı)
UHF:	Ultra High Frequency (Ultra Yüksek Frekans)
ULP:	Ultra Low Power(Ultra Düşük Güç)
VHF:	Very High Frequency (Çok Yüksek Frekans)
Wi-Fi:	Wireless Fidelity (Kablosuz Bağlantı)
YSA:	Yapay Sinir Ağı
ZS:	Z Skoru

1. GİRİŞ

Kablosuz iletişim, kullanım kolaylığı ve sunduğu avantajlar nedeniyle günümüzde vazgeçilmez bir hale gelmiştir. Teknolojinin gelişmesi ile birlikte, kablosuz iletişim donanımların da önemli ilerlemeler kaydedilmiştir. Günümüzde bu teknolojiler artık sadece iletişim amaçlı değil, veri toplama, uzaktan kontrol, IOT (ing: Internet Of Things- Nesnelerin İnterneti), akıllı şehirler, askeri uygulamalar gibi birçok alanda kullanılmaktadır.

Kablosuz iletişim teknolojilerinde en çok tercih edilen yöntemlerden olan radyo dalgaları birçok mühendislik disiplininin hizmet alanı içerisinde dolaylı veya doğrudan kendine yer edinmiştir. Bu mühendislik dallarından biri olan Harita Mühendisliği disiplini ise radyo dalgaları çok önemli bir yere sahiptir. Günümüzde yüksek doğrulukla konum belirleme ve bunu sağlayacak yöntemlerin araştırılması Harita Mühendisliğinin temel amaçlarından biridir. Bu amaca hizmet eden Küresel Konum Belirleme Sistemleri (ing:Global Navigation Satellite Systems - GNSS) ise yeryüzü üzerinde konum belirlemede en çok kullanılan sistem olup, bu sistemin kullandığı temel teknolojilerden birini de radyo dalgaları oluşturmaktadır.

GNSS, alıcısı olan bir kullanıcının herhangi bir zamanda, dünyanın herhangi bir yerinde, küresel bir koordinat sisteminde konumunu belirlemesine olanak sağlayan uydu ölçme sistemleridir (Kahveci ve Yıldız, 2017). Sistemin temel işleyişi, alıcı ile uydular arasında yapılan kod-faz ölçümleri sonucu hesaplanan mesafeler ve bu mesafelerin, ölçü yapılan uyduların ölçü anındaki koordinatları ile birlikte kullanılmasıyla konumun hesaplanmasına dayanır. Ancak GNSS sistemlerinin en büyük dezavantajlarından biri, uydu ile alıcı arasında doğrudan bir görüş hattının olması gerekliliğidir. Bu durum, GNSS sistemlerinin kapalı alanlarda ve yer altı çalışmalarında etkin bir şekilde kullanılamaması yol açmaktadır. Bu sebep ile kapalı alanlarda konum belirleme ihtiyacını gidermek için GNSS alternatif oluşturacak konumlandırma sistemleri geliştirilmektedir. Bugüne kadar bu alanda birçok çalışma yapılmış, yöntemler önerilmiş ve donanımlar geliştirilmiştir. Fakat hala GNSS kadar hızlı, yüksek doğruluklu, birim kullanıcı maliyeti düşük ve geniş kesime hitap edecek bir yöntem bulunamamıştır. Bu durum, kapalı mekanlarda konumlandırma sistemlerinin geliştirilmesi ve iyileştirilmesi için sürekli bir motivasyon kaynağı olmuştur.

Öte yandan kapalı mekân konumlandırma sistemleri, kullanıcıların konumlarının belirlenmesi ve yönlendirilmesi, üretim ve lojistik faaliyetlerinin yapıldığı otonom

tesislerde faaliyetlerin aksamadan hızlı ve ucuz maliyetlerle gerçekleştirilmesi için çok önemli bir konuyu oluşturmaktadır. Günümüzde bu konuda geliştirilen sistemler genellikle kablosuz ağ teknolojileri, sinyal işleme, görüntü işleme ve sensörlerden yararlanmaktadır. Özellikle Endüstri 4.0 ile gelişen otonom üretim tesisleri veya evlerimizde kullanılan temizlik robotları gibi cihazlar konum belirlemek için donatıldıkları sensörleri kullanmaktadır. Ancak bu aygıtların içinde barındırdıkları sensörler, topladıkları veriyi ortam haritasına dönüştürecek ve kullanacak yazılım ile işlemci gibi bileşenler, bu cihazların maliyetini önemli derecede arttırmaktadır. Bu sebep ile kapalı mekanlarda konum belirlenmesi, doğruluğunun artırılması ve tüm bunların düşük maliyetlerle yapılması için bu alanda Ar-Ge yapan ticari, bilimsel kuruluşlar ve bireysel araştırmacıların çalışmaları devam etmektedir. Bu kesimler, mevcut sensörleri ve yazılımları geliştirmeye, yeni teknolojiler geliştirmeye ve maliyetleri düşürmeye çalışmaktadırlar. Yapılan son çalışmalar ile özellikle yapay zeka tabanlı yöntemler ve derin öğrenme tekniklerinin kullanılabilirliğinin artmasının, konum belirleme doğruluğunun ve maliyetlerinin önemli ölçüde azaltmaya yardımcı olacağı düşünülmektedir. Böylece gelecekte evlerimizdeki ve endüstriyel tesisler gibi kapalı mekanların tamamında konum belirleme ihtiyacı daha uygun fiyatlı ve yüksek doğrulukta karşılanabilmesi amaçlanmaktadır.

Burada belirtilmesi gereken bir diğer önemli konu GNSS sistemleri günümüzde birçok alanda hayatımızın vazgeçilmez bir parçası haline geldiği daha önce belirtilmiştir. Fakat bu sistemlerin yönetimi üretildikleri ülkelere ait olması, sadece ticari amaçla kullanılmamaları ve ait oldukları ülkelerin çıkarlarına hizmet etmesi sebebi ile bu sistemlere sahip olmayan ülkelerin kendi alternatif konum belirleme sistemlerini geliştirilmesi gerekliliğini ortaya koymaktadır. Yapılan bu ve bunun gibi çalışmalar ile edinilen tecrübeler sayesinde Küresel veya Bölgesel Konum Belirleme Sistemine sahip olmayan ülkelerin kendi ulusal konum belirleme sistemlerini geliştirme ve işletme kabiliyetleri artacaktır. Böylelikle söz konusu ülkeler kendi askeri, ticari ve sivil alanlardaki ihtiyaçlarını küresel sistemlere bağımlı olmadan karşılayabileceklerdir.

Bu motivasyonlardan yola çıkılarak yapılan bu çalışmada Alınan Sinyal Güç Göstergesi (ing:Received Signal Strength Indicator - RSSI) değeri kullanılarak kapalı alanlarda konum belirlenmesine yönelik donanım ve yazılımdan oluşan bir sistem geliştirilmiştir. RSSI değeri ile mesafe arasında ters orantı olması, onu konum belirlemede kullanılır kılmakta olup ayrıca bu teknolojiye erişimin düşük maliyetli olması bu yöntemin çalışmada tercih edilmesindeki en önemli etken olmuştur.

Yapılan çalışma gerek dnya kořullarına uygun olabilecek yani alıcı ve verici RF istasyonlarının arasında grřn kısıtlı olduėu veya hi grř olmayan, arada kalın duvarların bulunduėu, grř aıklıėının bulunduėu yerlerde de yine fiziki engellerin olduėu bir alanda gerekleřtirilmiřtir. Geliřtirilen sistemde gerek zamanlı konum belirleme yapılabilmekte olup ayrıca farklı makine ėrenmesi tabanlı regresyon ve sınıflandırma modelleri kullanılarak bu modellerinin konum belirlemedeki bařarısı ve referans verici istasyonlarının yerleřim geometrisinin konum belirlemeye etkisi de incelenmiřtir. Bunlara ek olarak tasarlanan sistemin maliyeti hesaplanmış ve elde ettiėi konum doėruluėuna iliřkin istatikselsunulaarak kullanılabirliėi ynnde fikir verilmeye alıřılmıřtır.



2. KAYNAK ARAŞTIRMASI

GNSS sistemlerinin kapalı alanlarda yüksek hatalarla konum belirlemesi veya hiç sinyal alamaması, kapalı mekanlarda konum tespiti imkanını kısıtlamaktadır. Bu da kapalı mekanlarda konum belirlemenin alternatif yöntemlerine ve sistemlerine duyulan ihtiyacı artırmıştır. Bu çalışmanın da konusu olan RSSI ile kapalı mekanlarda konum belirlemeye yönelik yapılan akademik çalışmalardan bazıları aşağıda verilmektedir.

Bahl ve Padmanabhan (2000) Microsoft Şirketinde, 43.5 m × 22.5 m büyüklüğünde bir alanda 2.4 GHz ISM bandında çalışan radyo frekans (RF) tabanlı sisteme dayalı iç mekan konum belirleme sistemini kurmuşlardır. Sistem, belirtilen konumda RF RSSI verisini toplar ve sinyal gücü bilgilerini kullanarak ampirik, radyo yayılım modeli ve teorik sinyal gücü haritaları, en yakın komşu algoritması, doğrusal regresyon modeli kullanarak konum belirlenmiştir. Ampirik yöntemin en başarılı sonuçları verdiği belirtilerek ± 1.92 m (%25 yüzdelik dilim medyan değeri), ± 2.94 m (%50 yüzdelik dilim medyan değeri) ve ± 4.69 m (%75 yüzdelik dilin medyan değeri) konum doğruluğunun elde edildiği bildirilmiştir.

Karaca (2008) yaptığı Konum Belirleme ve Paket Takibi adlı çalışmasında sinyal şiddeti ölçümüne dayalı bir paket takip sistemi geliştirmiştir. Radyo dalgası sinyal şiddeti ile uzaklık arasındaki bağıntının kullanıldığı sistemde, izlenecek paket üzerine düşük güçlü ve pille çalışabilen bir radyo vericisi yerleştirilerek önceden belirlenmiş noktalara yerleştirilen alıcılarla paketten gelen sinyal şiddetleri ölçülmüştür. Tüm alıcıların yaptığı ölçümler tek merkezde toplanarak paketin konumunun hesaplandığı belirtilmiştir. Geliştirilen sistemin işletim ve kuruluş maliyetinin düşüklüğü, personel, araç, hammadde ve ürün gibi her şeye uygulanabilir olması, konum belirleme duyarlılığının sınırlı olmasına rağmen, özellikle büyük yerleşkeye sahip fabrikalarda kullanımını avantajlı kılmakta olduğu belirtilmektedir. Çalışma sonucunda en iyi konum tahmini $\pm 1,5$ metre hata ile, en kötü konum tahmininin ise $\pm 6,5$ metre hata içerdiği ortalama konum doğruluğunu ise ± 3.52 metre olarak belirtilmiştir. Geliştirilen sistem yardımıyla, işgücü ve zamandan büyük oranda tasarruf sağlanacağı belirtilmektedir.

Varshney ve diğ. (2016) yaptıkları çalışmada kapalı alanlarda Wi-Fi ve BLE teknolojisi ile kapalı mekân konumlandırma sistemi geliştirmişlerdir. Çalışmada Android işletim sisteminde çalışan ve gerçek zamanlı konum belirleyebilen bir uygulama geliştirildiği belirtilerek Wi-Fi için mobil telefona entegreli Wi-Fi alıcısı kullanılırken BLE için Beacon donanımlarının kullanıldığı belirtilmiştir. Bu donanımlar kullanılarak

tasarlanan deneyde Wi-Fi için uygulama en iyi sinyale sahip 3 Wi-Fi modeminden alınan sinyali işlendiği, ölçülen RSSI değerinin Güç Yayılım Modeli ile mesafeye çevrildiği ve trilaterasyon kullanılarak alıcı koordinatlarının hesaplandığı bildirilmektedir. Deney sonucuna göre x koordinatının %77.59 ve y koordinatının %88.41 doğrulukta belirlenebildiği yapılan çalışmada sunulmuştur. BLE için yapılan deneyde ise ölçülen RSSI değerlerine göre en yüksek değere sahip 7 istasyon seçildiği, bu istasyonlarda alınan RSSI değerlerinin zamanla değiştiği belirtilerek ortalama konum doğruluğu x koordinatı için %89.10 ve y koordinatı için %73.30 olduğu yapılan belirtilmiştir. Çalışmada Beaconlardan alınan sinyaller ile saçma sonuçların çıktığı ve hiç konumun tespit edilemediği ayrıca belirtilmiştir.

Saray (2017) yılında yapmış olduğu çalışmasında radyo dalgaları kullanılarak yeraltı maden ocaklarında çalışan madencilere ait konumların izlenebilmesini amaçlamıştır. Hazırlanan uygulamanın RF sinyali ile madenciye ait bilgileri yayınlayan gezici modül geziciden gelen madenci bilgisini ve RSSI bilgisini toplayan referans alıcı modül ve referans alıcıdan gelen bilgileri bilgisayara aktaran merkez alıcıdan oluşmakta olduğu belirtilmiştir. Uygulamada madencilerden gelen bilgiler bilgisayar üzerinde bulunan ve C# programlama dili ile hazırlanan uygulama üzerinden takip edilmekte olup merkez alıcıya uzaklıkları ölçülmektedir. Açık, kapalı ve yer altında yapılan ölçümlerinin deneysel sonuçlarına göre (Ölçülen en yüksek mesafe 15 m);

- Açık alanda yapılan ölçümlerin sonucunda en düşük %1.453 en yüksek %25.610 hata,
- Kapalı alanda gerçekleştirilen deneylerde en düşük %0.229 en yüksek %13.116 hata,
- Yer altında gerçekleştirilen deneyler sonucunda en düşük %0.644 en yüksek %22.311 hata içerdiği hesaplanmıştır.

Özdemir (2020) Wi-Fi modemlerinden alınan RSS değeri ile parmak izi konum belirleme yönteminin gerçek koşullarda uygulandığı ve konum doğrulukları için çeşitli kriterler dikkate alınarak analiz edildiğini belirten bir çalışma yapmıştır. Çalışmada kullanılan en yakın komşu yöntemin kalibrasyon nokta sıklığına göre değiştiğini, birden çok noktadan aday nokta konumunun hesabında ağırlıkların göz önüne alınması gerektiği, ancak komşu sayısının seçiminde sabit bir değer yerine dinamik bir değer kullanılmasının farklı tipte kapalı mekânlar için daha uygun olacağını, radyo haritasında boş kalan kısımlar için enterpolasyon yöntemleri ile doldurulmasının konum doğruluğuna fayda sağlayacağını belirtmiştir. Ayrıca çalışmada elde edilen konum doğruluğunun farklı

deney sahalarında da incelenmesi gerektiği ve farklı deney sahalarının konum doğruluğuna etkisinin ayrıca incelenmesi gerekliliğini de belirtmiştir. Çalışmada Çizelge 3.9 ile bildirilen sonuçlar incelendiğinde en iyi konum doğruluğu değerinin (2.kat uygulama sahasında Ağırlıklandırılmış KNN yöntemi ve komşu sayısı=5 parametreleri için) ± 2.29 metre olarak bulunduğu görülmektedir.

Tekbaş ve diğ. (2020) tarafından yapılan çalışmada Digi firmasının üretmiş olduğu Zigbee RF haberleşme modülleri arasındaki sinyallerin RSSI değeri ölçülerek parmak izi tabanlı algoritma geliştirilmiş ve kapalı ortamlarda konum tespiti yapıldığı belirtilmiştir. Söz konusu uygulamada kullanılan alan (5m x 8 m) üzerinde konum belirlenirken alanda bulunan ofis malzemeleri boşaltılmış rastgele 25 noktada 5 saniye boyunca 10 adet RSSI ölçümü yapılarak 3 katmanlı YSA (Yapay Sinir Ağı) için veri toplanarak makine eğitilmiştir. Sonrasında aynı ofise eşyalar yerleştirilerek ve insan hareketliliği sağlanmış ve aynı noktalardan 10 adet RSSI ölçümü sağlanarak RSSI değerlerinin kalibre edildiği bir veri seti hazırlanmış olup ortalama ± 24.2 cm konum doğruluğu elde edildiği belirtilmiştir.

Alsmadi ve diğ. (2021) tarafından yapılan çalışma ile iç ortamdaki nesnelerin yerini en az hata ile bulmayı amaçlayan bir Filtrelenmiş RSSI ve İşaret Ağırlığı (ing:Filtered RSSI and Beacon Weight-FRBW) adlı algoritmanın geliştirildiği belirtilmiştir. Söz konusu çalışmada RSSI ölçümü sırasında ölçümü yapılan RSSI değerlerini Kalman Filtreleme sürecine tabi tutulduğu belirtilmiştir. Beacon içerisinde gömülü bilgi işlem modeli ile mesafe tahminin yapılabilirdiği belirtilmiş fakat bunun yüksek hata içerdiği bu sebep ile geliştirilen FRBW algoritması ile bu hatanın minimize edildiği belirtilmiştir. FRBW algoritması ile belirlenen konumun ham RSSI değeri ile belirlenen konuma göre çok daha iyi sonuçlar ortaya koyduğu yapılan deney sonuçları ile yapılan çalışmada gösterilmiştir.

Ramirez ve diğ. (2021) tarafından yapılan iç mekân konumlandırma için BLE (Bluetooth Low Energy) RSSI ölçümü uygulamasında düşük enerji ile çalışan bluetooth aygıtlarının yayınlamış olduğu sinyalin gücünün (RSSI) ölçülmesi ve kalman filtrelemeden yararlanılarak aynı katta ve açık görüş alanında bulunan aygıtlarla 10 metrelik bir mesafede ± 10 cm'ye varan bir doğrulukla mesafe bilgisi elde edildiği belirtilmektedir. Fakat görüş alanının olmadığı ve bluetooth aygıtları arasında engeller bulunması halinde ölçülen mesafe doğruluğunun metre mertebesine çıktığı ifade edilmektedir.

Yaman ve diğ. (2021) Bluetooth 4.0 teknolojisi ile çalışan 3 adet verici 1 adet alıcıdan oluşan ve bluetooth sinyallerinin RSSI ölçümünü yapabilen elektronik kartlardan oluşan bir sistem tasarımı kurmuşlardır. Sistemde vericilerden gelen sinyallerden ölçülen RSSI metriği Eşitlik 2.1'deki denklem ile uzunluk birimine çevrilmiştir. Sonrasında iki boyutlu trilaterasyon ile konum tespiti sağlanmıştır.

$$Uzunluk = 10^{\frac{rssi-rssi_1}{-10+n}} \quad (2.1)$$

Bu denklemde $rssi_1$, bir metre mesafede ölçülen sabit RSSI değerini, n ise ortam değişkenini ifade etmekte olup çalışmada n değeri 20 olarak kabul edilmiştir. Yapılan çalışmada sistem maliyeti belirtilmiş ayrıca elde edilen sonuçların literatürde belirtilen ürünler gibi performans gösterdiği belirtilmektedir.

Yapılan kaynak araştırması sonucu çalışmaların çoğunluğunda yapılan deneylerin küçük alanlarda veya kullanılan donanımların birbirini gördüğü alanlarda yapıldığı görülmüştür. Bu sebep ile bu çalışmada hem çalışma alanı olabildiğince büyük seçilmiş hem de görüş açıklığının kısmen veya hiç olmadığı durumlarda elde edilebilecek konum doğruluğu ortaya konulmaya çalışılmıştır.

3. KONUM BELİRLEMEDE KULLANILAN YÖNTEMLER

Konum belirleme amaçlı geliştirilen uydu bazlı sistemlerin tarihçesi 1960'lı yıllara dayanmakta olup GPS sisteminin gönderilen ilk uydusunun konumlandırma denemeleri 1978'de yapılmıştır. Sistemin 1980'lerde sivil kullanıma açılması ve 1990'larda tam olarak işler hale gelmesinden günümüze kadar gelişimi devam etmiştir. Sistemin öneminin anlaşılması ile beraber diğer ülkeler tarafından ülke çıkarları gözetilerek kendi konum belirleme sistemlerinin kurulması amacı ile Glonass ve Galileo gibi küresel konum belirleme sistemleri geliştirilmiştir. Öte yandan bilim adamları ve araştırmacılar tarafından, bu sistemlere alternatif veya önemli eksikliklerin giderilmesi amacı ile yeni konum belirleme teknolojileri üzerinde araştırmalar devam etmektedir. Bu araştırmaların en yoğun olduğu alan GNSS'in konum belirlemede yeterli olamadığı kapalı alanlarda konum belirlemeye yardımcı olacak teknolojiler ve yöntemlerin belirlenmesidir. Bu kapsamda birçok yöntem ve teknoloji geliştirilmiş olup her birinin kendine has avantaj ve dezavantajları bulunmaktadır. Konum belirlemede kullanılan bu teknolojilerden bazıları;


- **Radyo Dalgaları:** Bluetooth, Wi-Fi, hücresel şebekeler veya RFID (ing:Radio Frequency Identification-Radyo Frekans Kimlik Tanıma)'den gelen sinyallerin kullanılarak konum veya mesafe tayinine dayanan sistemlerdir. Wi-Fi, Bluetooth gibi kablosuz ağ teknolojilerinin yaygınlaşmasıyla konum belirleme yöntemleri bu alanda da çeşitlenmiştir. Radyo Dalgaları aynı zamanda GNSS sistemlerinin konum belirlemede kullandığı temel teknolojilerden biridir.
- **Akustik Dalgalar:** Bu teknolojiye ses dalgalarının havada seyahat etme süresi kullanılarak konum tespiti yapılır. Donanımdan yayılan ses dalgalarının çevredeki sensörlere ulaşma sürelerinin ses hızı ile çarpılması ile mesafe tespiti gerçekleştirilir. Bu mesafe kullanılarak ortam haritası çıkarılabilir veya trilaterasyon ile konum hesabı yapılabilir.
- **Manyetik Alan:** Dünya'nın manyetik alan haritası bilindiği için manyetik alan sensörü verileriyle konum tayini yapılabilir. Bu yöntemde ortama konumlandırılan bir donanım ile manyetik alan kaynaklarının şiddeti ve yönü ölçülerek konum tespiti yapılabilir.
- **Kızılötesi:** Kızılötesi kameralar çevredeki nesnelerin kızılötesi yansımalarını kullanarak konum belirlenebilmektedir.

- **Görüntü İşleme:** Çevredeki yapılar, tabelalar vb. nesnelerin görüntüleri kullanılarak, nesnelerin konumları bilgisinden yararlanılarak konum tespiti yapılabilmektedir.
- **IMU (ing:Inertial Measurement Unit - Ataletsel Ölçüm Ünitesi):** IMU sensörleri konumlandırılan cihazın hareketlerini, ivmelenmelerini ve yön değişimlerini ölçerek konum tayininde kullanılmaktadır. Özellikle kapalı alanlarda ve GNSS sinyallerine erişimin zor olduğu ortamlarda IMU teknolojisi konum belirlemede etkin bir şekilde kullanılabilir. IMU teknolojisi aynı zamanda Fotogrametride de kullanılan temel teknolojiler arasında yer almaktadır.

3.1. Radyo Dalgaları

Elektromanyetik spektrum içinde radyo dalgaları en uzun dalga boylarına sahiptir. Frekans aralığı 30 Hz'den 300 GHz'e kadar olan bu dalgalarda, dalga boyları 10.000 km ile 1 mm arasında değişiklik gösterebilmektedir.


Radyo dalgalarının yayılması, ivmeli yüklü parçacıkların, yani elektronların etkileşimi ile gerçekleşir. Yapay olarak bunu sağlamak için zamana göre değiştirilen elektrik akımları metal bir iletkeni uygulanır. Bu amaçla üretilen metal iletkenlere anten denilmektedir. Antene uygulanan bu elektrik akımları antende bulunan elektronların ileri geri hareket etmelerine sebep olur. Bu hareket sonucu oluşan salınım ile antenden radyo dalgaları yayılmaktadır. Yayılan bu radyo dalgaları alıcı istasyona ait bir antene çarptıkça antendeki elektronları ileri geri hareket etmesini sağlar. Böylelikle alıcı istasyon bu ileri geri hareketleri salınıma çevirerek gönderilen mesaj alınmış olur. Şekil 3.1 ile radyo dalgalarının yayılım şekli gösterilmekte olup bu yayılım türü kullanılan antene göre değişiklik gösterebilmektedir.



Şekil 3.1. Bir anten tarafından yayılan radyo dalgaları (URL-3).

Radyo dalgalarının hızı, yayıldığı maddesel ortamın özelliklerine göre değişiklik gösterebilmekle beraber boş uzayda ışık hızında hareket etmektedir. Yapılan ölçümlere göre radyo dalgasının boşluktaki yayılma hızı 299,792,458 m/s'dir. Radyo dalgalarında dalga boyu terimi bir dalga döngüsünde ardışık tepe ve dip noktaları arasındaki mesafeyi ifade etmekte olup yaygın olarak lamda (λ) harfi ile gösterilmektedir. Bir noktadan birim zamanda geçen tam dalga sayısı ise o radyo dalgasının frekansını ifade eder ve birimi hertz'dir.

Dalga boyu ile frekans arasındaki ilişki ters orantılıdır. Yani yüksek frekanslı radyo dalgaları yüksek enerjiye ve kısa dalga boyuna, düşük frekanslı radyo dalgaları ise düşük enerjiye ve uzun dalga boyuna sahiptir. Frekans büyüdükçe radyo dalgasının cisimlere nüfuz oranı artarak daha fazla engelden geçebilirken taşıdığı bilgide bununla orantılı olarak artmaktadır.



Şekil 3.2. Radyo dalgalarında dalga boyu, dalga yüksekliği ve frekans gösterimi (URL-9).

3.1.1. Radyo frekans bandları

Farklı kullanıcılar arasında paraziti önlemek için, radyo frekans bandlarının üretimi ve iletimi, uluslararası bir kuruluş olan Uluslararası Telekomünikasyon Birliği (ITU) tarafından koordine edilen ulusal yasalarla sıkı bir şekilde düzenlenmektedir (URL-2). Ülkemizde de ITU, Bilgi Teknolojileri ve İletişim Kurumu ile koordineli çalışmaktadır. Radyo spektrumunun (RF bandları) farklı bölümleri, ITU tarafından farklı radyo iletim teknolojileri ve uygulamaları için tahsis edilmiştir.

Çizelge 3.1. ITU radyo spektrum bantlarının sınıflandırılması (URL-8,URL-16).

Grup Adı	Kısaltma	Frekans ve Dalga Boyu	Kullanım Alanları
Aşırı düşük frekans	ELF	3–30 Hz 100.000–10.000 km	Denizaltılarla iletişim.
Süper düşük frekans	SLF	30–300 Hz 10.000–1.000 km	Denizaltılarla iletişim.
Ultra düşük frekans	ULF	300–3.000 Hz 1.000–100 km	Denizaltı ve madenlerle iletişim.
Çok düşük frekans	VLF	3–30 kHz 100–10 km	Navigasyon, zaman sinyalleri, denizaltı iletişimi, kablosuz kalp atış hızı monitörleri, jeofizik.
Düşük frekans	LF	30–300 kHz 10–1 km	Navigasyon, zaman sinyalleri, AM uzun dalga yayını (Avrupa ve Asya'nın bazı bölgeleri), amatör radyo.
Orta frekans	MF	300–3.000 kHz 1.000–100 m	AM (orta dalga) yayınları, amatör radyo, çığ işaretleri.
Yüksek frekans	HF	3–30 MHz 100–10 m	Kısa dalga yayınları, vatandaşlar bant radyosu, amatör radyo ve ufuk üstü havacılık iletişimi, ufuk üstü radar, otomatik bağlantı kurma (ALE) / yakın dikey insidanslı skywave (NVIS) radyo iletişimi, deniz ve mobil radyo telefonu.
Çok yüksek frekans	VHF	30–300 MHz 10–1 m	FM, televizyon yayınları, görüş hattı yerden uçağa ve uçaktan uçağa iletişim, kara mobil ve deniz mobil iletişim, amatör radyo, hava durumu radyosu.
Ultra yüksek frekans	UHF	300–3.000 MHz 1–0,1 m	Televizyon yayınları, mikrodalga fırın, mikrodalga cihazlar/haberleşme, radyo astronomi cep telefonları, kablosuz LAN, Bluetooth, ZigBee, GPS ve kara mobil gibi iki yönlü telsizler, FRS ve GMRS telsizleri, amatör telsiz, uydu telsiz, Uzaktan kumanda Sistemleri, ADSB.
Süper yüksek frekans	SHF	3–30 GHz 100–10 mm	Radyo astronomi, mikrodalga cihazlar/iletişim, kablosuz LAN, DSRC, en modern radarlar, iletişim uyduları, kablolu ve uydu televizyon yayıncılığı, DBS, amatör radyo, uydu radyosu.
Aşırı yüksek frekans	EHF	30–300 GHz 10–1 mm	Radyo astronomi, yüksek frekanslı mikrodalga radyo rölesi, mikrodalga uzaktan algılama, amatör radyo, yönlendirilmiş enerji silahı, milimetre dalga tarayıcı, Kablosuz Lan 802.11ad.


Çizelge 3.1’de belirtildiği üzere radyo frekanslarının ve dalga boylarının türüne boyutuna göre farklı kullanım alanları mevcuttur. Buradaki temel ilişki radyo dalgalarının frekans arttıkça ve dalga boyu küçüldükçe iletişim hattındaki engellerden daha az yansıma ile geçebilmekte ve birim zamanda taşınan bilgi boyutu kapasitesi artmaktadır. Tam tersi bir durumda ise yani dalga boyu arttıkça ve frekans değeri azaldıkça birim

zamanda taşınan bilgi miktarı kapasitesi azalmakta ve radyo dalgaları daha fazla yansımaya maruz kalmaktadır. Ayrıca dalga boyu ile o radyo dalgasını yaymak veya almak için kullanılan anten boyutu değişmektedir. Dalga boyu ve frekans arasındaki matematiksel ilişki Eşitlik 3.1’de verilmiştir. Burada λ dalga boyunu, c ışık hızını (299,792,458 m/s) f ise frekansı temsil etmektedir.

$$\lambda = \frac{c}{f} \quad (3.1)$$

Çizelge 3.1’de belirtilen frekans bantlarını kullanmak için ayrıca lisanslara ve izinlere ihtiyaç duyulmaktadır. Bu bantlar dışında herhangi bir izin veya lisans gerektirmeden sivil kullanıcıların kullanabileceği ve ISM (ing:Industrial Scientific Medical) bandları olarak adlandırılan bir RF frekans bandı mevcuttur. Bu band telekomünikasyondaki uygulamalar hariç, endüstriyel, bilimsel ve tıbbi amaçlar için uluslararası olarak ayrılmış radyo spektrumunun bölümlerinden oluşmakta olup ISM bandlarının kullanımı, kablosuz ağlar, bluetooth, RFID, NFC, uzaktan kumanda, telsiz telefon, mikrodalga fırın gibi pek çok teknoloji için önemlidir. Şekil 3.3 ile ISM Bandının uluslararası olarak kullanılan genel frekansları mevcuttur. Fakat ülkeler kendi yasal düzenlemelerine göre bu bandların kullanımını sınırlandırabilir veya değiştirebilmektedir. Bu çalışmada ISM bandını (868-915 MHz) kullanan RF modülleri tercih edilmiştir. Bu bandın tercih edilmesindeki sebepler;

- Herhangi bir kullanım izni veya lisans gerektirmemesi,
- Dünya çapında birçok farklı alanda kullanılıyor olması, bu sebep ile bu bandı kullanan RF modülünün teminin kolay olması,
- Maliyet açısından diğer cihazlara nazaran oldukça uygun olması,
- Birçok alanda kullanılıyor olması sebebi ile kullanımı ve programlanması yönünde örnek kaynak bulundurmasıdır.



Şekil 3.3. Dünya üzerinde tahsis edilen ISM bandlarının frekans aralığı (URL-15).

3.1.2. Modülasyon


Modülasyon kavramı bir taşıyıcı sinyal ile bilgi sinyalinin birleştirilmesine denir. Bu yöntem günümüzde en çok kablosuz iletişimde kullanılmaktadır. Yöntem başta radyo yayıncılığının yapıldığı antenli yayınlar için geliştirilmiş olsa da günümüzde kablolu, kablosuz iletişimlerde kullanılmaktadır. Düşük frekanslı dalgaların (örneğin ses) çok uzak mesafelere gönderilmesi çok zordur. Bu sebep ile düşük frekanslı dalgaların yüksek frekanslı taşıyıcı dalgalara entegre edilerek uzak mesafelere gönderilmesi için modülasyon yöntemi geliştirilmiştir. Gönderilen bu dalgalardan bilgi verisinin ayrıştırılmasına ise modülasyon çözümü denir. Bu yöntemin geliştirilmesi ile farklı modülasyon teknikleri ortaya çıkmıştır. Bu teknikler sayesinde gönderilmek istenen verinin gönderildiği ortamın durumuna gönderilmek istenen mesafeye, gönderilmek istenen verinin türü ve boyutuna göre farklı modülasyon teknikleri kullanılabilir. Günümüzde LoRa modülasyonu popülerlik kazanarak en çok kullanılan modülasyon tekniklerinden biri olmuştur.

3.1.2.1. Modülasyonun gereği

Kablosuz haberleşmede veya radyo yayıncılığında ses, görüntü veya herhangi bir verinin bir anten yardımıyla elektromanyetik dalga olarak alıcılara ulaştırılması temel amaçtır. Ses dalgalarının uzak mesafelere gönderilmesi yapısı itibari ile yüksek dalga boyuna ve düşük frekanslı yapıda olması sebebi ile zordur. Ayrıca elektromanyetik yayın

yapan antenlerin boyutu veya türü ile gönderebildiği elektromanyetik dalgaların arasında matematiksel bir ilişki vardır.

Herhangi bir ses veya görüntü elektrik sinyallerine dönüştürüldüğünde anten yardımı ile olduğu gibi yayınlanamaz. Çünkü yayın yapan veya alıcı işlevi gören bir antenin boyutu aldığı veya gönderdiği radyo dalgasının boyutu ve frekansı ile doğrudan ilişkilidir. Örnek verilecek olursa bir şarkının ses sinyallerinin radyo verici anteninden doğrudan yayınlandığını ele alalım şarkının içerisinde sesler ince ve kalın olarak sürekli değişebilmektedir. Buna göre gönderilen ses dalgasının boyutu ve frekansı da sürekli değişecektir. Bu durum yayın yapan veya alan antenin boyutu veya türünün de bu yayında sürekli değişmesi gerektiği anlamına gelir. Bu sebep ile yayıncılıkta veya kablosuz haberleşmede yayınlanan elektromanyetik dalgaların sabit frekans ve dalga boyutunda gönderilmesi gerekmektedir. Bu durumda modülasyon tekniği ile ses sinyali taşıyıcı bir radyo dalgası üzerine entegre edilerek basitlikle hem çok daha uzun mesafelere hem de sabit antenlerle gönderilebilmektedir. Bu sebeplerden dolayı modülasyon iletişim teknolojisinin en önemli parçalarındandır.



Şekil 3.4. Modülasyonlu radyo dalgaları (URL-1).

3.1.2.2. LoRa (Long Range-Uzun Menzil)

Teknolojinin gelişmesi ile akıllı şehirler, akıllı evler, akıllı sulama sistemleri vb. akıllı cihazlar pazarı hızla büyümektedir. Nesnelerin interneti kavramı (Internet of Things, IOT) bu noktada ortaya çıkmıştır. Az önce bahsedilen akıllı sistemlerin her biri bir yönetici bilgisayar tarafından yönetilmesi veya koordine edilmesi gerekmektedir. Akıllı cihazların, sensörlerin vb. donanımların merkez bilgisayarı ile haberleşme gereksinimi artık kablolarla değil kablosuz iletişim araçları ile sağlanmaya

çalışılmaktadır. Bu sayede hem bakım onarım hem de büyük bir kablo karmaşasının hem de görüntü kirliliğinin önüne geçilmektedir. Bu durumda en önemli sorun bu donanımların verileri uzak mesafeye güvenilir ve düşük güç ile tüketimi ile göndermesi ve almasıdır. Bu soruna cevap verilebilmesi amacı ile teknoloji firmaları Ar-Ge çalışmalarına büyük kaynaklar ayırmıştır. Bu çalışmalar sonucunda birçok farklı haberleşme teknolojisi geliştirilmiştir. Bunların başında LoRa teknolojisi gelmektedir. LoRa isim olarak, Long Range(Uzun Mesafe) kelimelerinin ilk hecelerinden oluşur. Alternatiflerine nazaran düşük boyuttaki verileri çok daha uzak mesafelere düşük güç tüketimi ile radyo frekansları kullanarak gerçekleştiren bir telekomünikasyon teknolojisi olarak ortaya çıkması onu daha ön plana taşımıştır. Fransa’da 2012 yılında geliştirilen bu teknoloji, 2015’te kurulan Semtech firması tarafından satın alınmıştır.

Lora haberleşme teknolojisinde kullanılan modülasyon türü Spread Spectrum Frequency Shift Keying (SS-FSK) modülasyonudur. SS-FSK, geniş bantlı frekans değişimli anahtarlama (FSK) modülasyonunun yayılma spektrum (SS) tekniği kullanılarak uygulanmasıdır. Bu sayede Lora haberleşmesinde spektrum verimliliği artırılırken, sinyal gürültü oranı iyileştirilmektedir. Lora modülasyonunda veri, farklı frekans bantlarında yayılarak iletilir. Alıcı tarafında bu farklı frekanslardaki sinyaller toplanarak orijinal veri geri elde edilir. Böylece haberleşmede gerekli güç düşürülürken, iletim mesafesi artırılabilir.

Günümüzde LoRa, bir iletişim teknolojisinden daha çok bir kablosuz iletişim ekosistemi halini almıştır. Bu ekosistem içerisinde kablosuz ağlar, veri istasyonları, RF modülleri, modülasyon çipleri ve yazılımlar gibi birçok teknolojiyi barındırmaktadır.

Yapılan çalışmada uzak mesafe iletişimi, düşük güç tüketimi ve alternatiflerine nazaran maliyet açısından daha uygun olması sebebi ile LoRa teknolojisini kullanan radyo frekans modülleri kullanılmıştır.

3.2. Radyo Dalgaları ile Konum Belirleme

Radyo dalgaları ile konum belirlenirken genellikle uydu sistemleri veya baz istasyonları tarafından sağlanan sinyaller kullanılır. Burada istasyonlardan gelen radyo sinyali hem bilgi taşıyabilmekte hem de o sinyalin seyahat süresi, geliş yönü veya gücü ölçülerek mesafe ve konum tespitinde kullanılabilir. Radyo sinyallerinin ışık hızında seyahat etmesi sinyalin seyahat süresinin ölçülmesini zorlaştırmasına karşın uydu bazlı sistemlerde hızlı, yüksek doğrulukta ve küresel ölçekte ölçümler yapmaya olanak

tanımlanmaktadır. Hava koşullarından az etkilenmesi, geniş kapsama alanı sağlaması ve maliyetinin düşük olması radyo dalgalarının konum belirlemedeki en büyük avantajlarıdır. Fakat çevresel engellerden yansımaya maruz kalmaları, elektriksel veya manyetik alanlarda bozulmaya uğraması radyo dalgalarının en büyük dezavantajlarıdır.


Radyo dalgaları ile konum belirlenirken genellikle alıcı ve verici istasyon arasındaki mesafe veya açı tespiti sağlanır. Sonrasında geriden kestirme gibi teknikler ile koordinat hesaplaması yapılabilmektedir. Fakat RSSI değeri hem geliş açısının belirlenmesinde hem mesafeye çevrilerek trilaterasyon gibi tekniklerle koordinat hesabında hem de parmak izi algoritmaları ile doğrudan koordinat tahminlerinin yapılabilmesinde kullanılabilmektedir.

3.2.1. Açı ölçüm yöntemleri ile konum belirleme

Radyo dalgaları ile konum belirleme yöntemleri, sinyalin varış açısının belirlenmesine dayanır. Fakat varış açısının tespiti için özel donanımlar gerekmekte olup sinyal yansımalarından dolayı yanlış açı belirlenebilmesi en büyük dezavantajlarıdır.

3.2.1.1. Varış açısı ölçümü (Angle of Arrival – AOA)

Bu yöntemde en az 2 alıcı istasyon kullanılır. Bir verici istasyondan sinyal yayınlandığında, her alıcı istasyon, sinyalin geliş açısını ölçer. Alıcılar, sinyalin kendilerine geldiği açıya göre bir çember çizerler ve iki alıcının çizdiği çemberlerin kesişim noktası, vericinin konumunu gösterir. Daha yüksek doğruluk elde etmek için üç veya daha fazla alıcı kullanılabilir.



Şekil 3.5. Varış Açısı Ölçümü (URL-12).

AOA ölçüm değerleri ile konum belirleme sisteminde kullanılacak antenlerin özel üretim ve maliyetli olması bu sistemin en büyük dezavantajıdır. Ayrıca sinyallerin seyahat süresince izledikleri yolda yansımalarla maruz kalmaları yine bu yöntemin dezavantajlarından biridir.

3.2.2. Mesafe belirleme yöntemleri

Radyo dalgaları ile konum belirlemede mesafe değerinin kullanılması halinde mesafe değerinin doğruluğu hesaplanacak konumun doğruluğunu direk olarak etki etmektedir. Bu sebep ile mesafenin belirlenmesi için birçok farklı yöntem ve teknoloji geliştirilmiştir. Bu yöntemlerin çoğunluğu RF sinyallerinin seyahat süresi baz alınarak mesafe belirlemede olup bunu yapabilen donanımların maliyetleri de oldukça yüksek olmaktadır. Bu yöntemlerin başlıcaları şunlardır;

- Varış zamanı ölçümü
- Varış zamanı farkı ölçümü
- RSSI ile mesafe belirlemedir.

3.2.2.1. Varış zamanı ölçümü (Time of Arrival, TOA)

Varış zamanının ölçülmesi ile konum belirleme yönteminde alıcı ve verici donanımı arasındaki mesafe, verici istasyondan gönderilen mesajın alıcı istasyona ulaşma süresinin sinyalin ortamdaki yayılım hızı ile çarpılması esasına dayanmaktadır. Burada mesafe hesaplanmasında kullanılan matematiksel bağıntı Eşitlik 3.2 ile verilmiştir.

$$d = c * \Delta t \quad (3.2)$$

Eşitlik 3.2’de d mesafeyi, c ışık hızını (ses dalgaları kullanılıyorsa ses dalgaları yayılım hızını) ve ΔT ise sinyalin alıcıya ulaştığı zaman ile vericiden çıkış zamanı arasındaki farkı ifade etmektedir.

Bu yöntemin uygulanması için ölçülen zaman farkının yüksek hassasiyette ve doğrulukta olması gerekmektedir. Radyo dalgaları için örnek verilecek olursa ölçülebilen zaman farkı hassasiyeti 1 mikrosaniye olması durumunda ölçülebilen en düşük uzaklık yaklaşık 300 m olacaktır. Zaman farkının 1 nanosaniye olması durumunda ise ölçülen en

düşük uzaklık 0.30 m olacaktır. Bu sebep ile bu yöntemde kullanılacak ve zamanı ölçecek donanımlar yüksek maliyetlere sebep olmaktadır.

Günümüzde kullanılan GNSS konum belirleme sistemlerinde yüksek zaman duyarlılığına sahip atomik saatler bulunmaktadır. Bu sayede GNSS sistemleri ile yüksek doğrulukta konum tespiti yapılabilmektedir. Atom saatlerinin genel çalışma prensibi atomların birim zamandaki yapmış oldukları titreşim düzeylerinin kullanılarak zamanın ölçülmesi esasına dayanır. Buradaki titreşim sayısı atomlar için özel olup çevresel koşullardan hemen hemen hiç etkilenmemektedirler.

Bu yöntem ile mesafe belirleme ve belirlenen mesafe kullanılarak konum hesaplama uydu bazlı konum belirleme sistemlerinin temelini oluşturmaktadır. Sistemin uzay bölümünü uydular ve içerdikleri atomik saatler oluşturmaktadır. Bu saatler sayesinde uydu ile alıcı arasındaki mesafe hassas ve yüksek doğrulukla belirlenebilmektedir.

3.2.2.2. Varış zamanı farkı ölçümü (Time Difference of Arrival, TDOA)

Bu yöntemde, bir referans verici istasyonundan yayılan sinyalin farklı konumda bulunan iki veya daha fazla alıcı istasyondan alınma sürelerinin farklılıklarını kullanarak alıcı istasyonlar arasındaki mesafenin belirlenmesi için kullanılabilir. Bu farklılıklar, her alıcı ve verici istasyon uzaklığının farklı olması durumunda ortaya çıkmaktadır. Bu yöntemin kullanılabilmesi için en az iki alıcı ve bir verici istasyonun bulunması gerekmektedir. Konum hesaplamalarında kullanılacak mesafe bilgisinin belirlenmesi için TDOA kullanırken, Eşitlik 3.3 ile verilen matematiksel bağıntı ile gerekli hesaplamalar yapılabilmektedir.

$$TDOA_{AB} = (t_B - t_A) * c \quad (3.3)$$

Bu bağıntıda $TDOA_{AB}$, iki alıcı istasyon arası mesafeyi, t_A , A alıcısının sinyalin alındığı zamanı, t_B , B alıcısının sinyali aldığı zamanı ve c ise sinyalin yayılım hızını temsil eder. Eşitlik 3.3 ile üç veya daha fazla noktadan gezici alıcıya olan mesafe belirlenmesi ve sonrasında trilaterasyon gibi teknikler ile gezici alıcının koordinatları hesaplanabilir. Burada gezici alıcı ile ifade edilen istasyon sahada konumu belirlenecek noktalarda ölçüm yapan istasyondur.

TDOA, genellikle yer tabanlı veya cep telefonu konumlandırma sistemlerinde, genellikle GPS, GLONASS, Galileo ve diğer GNSS sistemleri ile birlikte kullanılmaktadır. TDOA ve TOA yöntemlerinin birbirine göre bazı avantaj ve dezavantajları bulunmaktadır. Bunlar;

- TDOA zaman farklarından kaynaklanan çok daha küçük ölçekli değişiklikleri ölçme yeteneğine sahip olması sebebi ile özellikle yakın mesafe bulunan noktaların konumlarını belirlerken faydalı olabilmektedir.
- TDOA yönteminde sinyal doğrudan hedefe gitmeden yansıma, engellemeler veya farklı yollar aracılığı ile gitmesi durumuna daha dirençlidir. Bu nedenle TDOA, özellikle yoğun yerleşim alanlarında daha iyi performans gösterebilmektedir. Öte yandan uzak mesafelerde ve açık alanlarda TOA daha yüksek doğruluk sağlamaktadır.
- TDOA, en az 3 istasyon ile konum belirlenebilmektedir. TOA, istasyon sayısı en az 2'dir. Bu sebep ile TOA sistem maliyeti daha düşüktür.
- Zaman senkronizasyonu gerektirmemesi TOA'yı daha basit uygulanabilirliğini sağlamaktadır. TDOA için istasyonlar arasındaki zaman senkronizasyonunun çok iyi ayarlanması gerekmektedir. Bu durumda istasyon sayısının artması ile daha karmaşık bir kurulum ve işletme zorluğu vardır.

3.3. RSSI ile Konum Belirleme

RSSI ile konum belirleme son yıllarda kablosuz haberleşme donanımlarının çevremizde yaygınlaşması ve kapalı mekanlarda GNSS'nin etkin kullanılamayışı ile daha çok önem kazanmıştır. Burada RSSI değerinin RF modüllerinden, Wi-Fi modemlerinden ve BLE donanımlarından günümüzde rahatlıkla elde edilebilmektedir. Fakat elde edilen bu değer mesafeye ve koordinat bilgisine dönüştürülmesinde birçok sorunla karşılaşmaktadır.

Yapılan çalışmalar ile RSSI değerinden elde edilen konum bilgisinin doğruluğunun artırılması için farklı yöntemler denenmiştir. Yol kaybı (ing:Path loss) modelleri, parmak izi (ing:fingerprinting) yöntemi ve trilaterasyon gibi teknikler RSSI verilerinin konum verisine dönüştürülmesinde kullanılmıştır. Ancak bu yöntemlerin her biri kendi zorluklarını barındırmaktadır. Yol kaybı modelleri ortamın değişkenlik göstermesinden, parmak izi yöntemi ise referans noktalarının yoğun olarak kullanılması

gerekliliğinden dolayı kısıtlamalar içermektedir. Trilaterasyon ise gereken minimum istasyon sayısının veya uygun geometrinin sağlanamadığı kapalı ortamlarda yetersiz kalmaktadır.

Yukarıda bahsedilen yöntemlerin temelinde RSSI verisinin mesafe veya açıya dönüştürülmesi vardır. Bahsedilen yöntemler ile bu dönüşüm yapılabilmektedir fakat asıl önemli nokta elde edilen mesafe ve açı değerinin doğruluğunun artırılması gerekliliğidir. Yapılan bu çalışmada RSSI değerinden konum belirlenmesi dışında bunu yaparken farklı makine öğrenimi algoritmalarının kullanımı ve performanslarının gözlemlenmesi, bunların parametre ayarlamalarının yapılması, verilerin ön işleme tabi tutulması ve EKK (En Küçük Kareler) gibi tekniklerle elde edilen konum doğruluğunun artırılmasına yönelik araştırmalar da yapılmıştır.

3.3.1. Alınan sinyal güç göstergesi (RSSI)

RSSI, kablosuz iletişim teknolojilerinde sinyalin gücünü ölçmek için kullanılan bir metriktir. RSSI, sinyalin bir alıcı cihaza ulaştığında ne kadar güçlü veya zayıf olduğunu belirlemede kullanılmaktadır. Kablosuz ağlarda RSSI, genellikle dBm (desibel milivat) cinsinden ifade edilmekte olup düşük bir değer zayıf sinyali temsil etmektedir. Örneğin, -60 dBm RSSI değeri, daha güçlü bir sinyali temsil ederken, -90 dBm RSSI değeri daha zayıf bir sinyali temsil eder.

RSSI değeri kablosuz iletişimi sağlayan donanımlar arasındaki mesafe ile ters orantılı olarak değişmektedir. Yani cihazlar arasındaki mesafe arttıkça RSSI değerinin düşmesi beklenir. Fakat bu değer, sinyalin gücünün yanı sıra çevresel etmenlerden de oldukça etkilenmektedir. Ortamda bulunan duvarlar, mobilya ve diğer fiziki engeller sinyali zayıflatırken, metal yapılar veya elektronik cihazlar sinyali tamamen bloke edebilmektedir. Bu sebeple aynı mesafedeki iki cihaz arasında RSSI değerleri farklı olabilmektedir.

RSSI, kablosuz iletişimde sinyal gücünü izlemek ve değerlendirmek için ortaya çıkmışsa da mesafeye göre değişimi onu mesafe ve konum belirlemede kullanır kılmıştır. Ayrıca özel antenlerin sinyalin yönüne göre almış oldukları RSSI değerindeki değişimle de sinyal varış açısı tespit edilebilmektedir. Yani RSSI değeri hem mesafe belirlenmesinde hem de sinyal varış açısının belirlenmesinde kullanılabilir.

Burada belirtilmesi gereken önemli bir husus, RSSI metriği bize sadece sinyal gücü hakkında bilgi vermektedir. Ancak sinyalin kalitesini veya gürültü seviyelerini

değerlendirmede herhangi bir bilgi vermemektedir. Bu durum için farklı parametrelerden de destek alınması gerektiği unutulmamalıdır. Özellikle SNR (ing:Signal to Noise Ratio – Sinyal Gürültü Oranı), iletişim kalitesini daha ayrıntılı bir şekilde değerlendirmek için kullanılabilecek yöntemlerdendir.

RSSI değerinin dBm olarak ölçülebildiği daha önce belirtilmiştir. Fakat günümüzde bazı cihazlar RSSI değerini 0-255 arasında bir değer olarak kullanıcıya gösterir. RSSI değeri, farklı cihazlar ve farklı üreticiler tarafından farklı şekillerde ölçülebilir ve gösterilebilmektedir. Burada RSSI değerinin gösterim biçimi bakımından standartlaştırılmış bir ilişki bulunmamaktadır. Fakat RSSI değerinin 0 ile 255 arasında verilmesinin nedenlerinden biri, bu aralığın 8 bitlik bir sayıyı temsil etmesidir ve 8 bitlik bir sayı, 0 ile 255 arasında 256 farklı değer alabilmektedir. Bu da RSSI değerinin daha kolay saklanması ve işlenmesi için kullanışlı bir formatı ve alınan sinyal gücünün ölçülebildiği daha geniş bir çözünürlük sunmaktadır. Zira dBm olarak RSSI değeri donanımsal olarak değişiklik gösterse de -120 dBm ile 0 dBm arasında ölçülebilmektedir.

Bu çalışmada kullanılan RF modülleri RSSI değerini 0 ile 255 arasında bir değer olarak alınan mesajın ekine yerleştirmektedir. Bu yönüyle ek olarak RSSI değerinin hesaplanmasında karmaşık formüller ve algoritmalar kullanılmasına gerek duyulmamıştır.

3.3.2. RSSI değerinin mesafeye dönüştürülmesi

RSSI değeri mesafe ile ters orantılı oluşu onu mesafe belirlenmesinde kullanılabilecek yöntemler arasında yer almasını sağlamaktadır. Burada en önemli husus RSSI değerinin mesafe değerine dönüştürülmesi sonucu ortaya çıkan mesafenin doğruluğudur. Çünkü bu doğruluk sonrasında hesaplanacak koordinatın doğruluğuna doğrudan etki yapmaktadır. Buradaki dönüşüm için farklı alternatifler mevcuttur. Bunlardan bazıları şunlardır;

- Yol Kaybı Modelleri (ing:Path Loss Models)
- Makine Öğrenmesi Yöntemleri
- Hibrit Yöntemler

3.3.2.1. Yol kaybı modeli

Yol kaybı modeli, iletim ortamında sinyalin gücünün mesafeye bağlı olarak azalmasını ifade eden bir modeldir. Bu modele göre farklı mesafe aralıklarında ölçülen RSSI değerleri kullanılarak, mesafeye bağlı sinyal gücü azalmasını tanımlayan denklemler geliştirilmektedir. En yaygın kullanılan yol kaybı modelleri Friis ve polinom denklemleridir.

3.3.2.1.1. Friis denklemleri

Friis Denklemleri, kablosuz iletişimde sinyal gücü ve uzaklık arasındaki ilişkiyi açıklamak için temel bir matematiksel model sunmaktadır. Bu model serbest boşlukta sinyalin nasıl yayıldığını tanımlamakta olup teorik bir denklem olarak kabul edilmektedir. Bu sebep ile bu model gerçek dünya koşullarını tam olarak yansıtmayabilmektedir. Çünkü çevresel etkenler, yansımalar, engeller ve sinyal gücünü etkileyen diğer faktörler bu denklemde göz ardı edilmektedir. Boşlukta alıcı ve verici istasyon arasında sağlanan iletişimde d kadar mesafede alıcı istasyondan alınan sinyal gücü Eşitlik 3.4’de verilen Friis eşitliği ile ifade edilmektedir (Friis, 1946).

$$P_r = P_t G_t G_r \left(\frac{\lambda}{4\pi d} \right)^2 \quad (3.4)$$

$$P_r = P_t G_t G_r \left(\frac{\lambda}{4\pi d} \right)^2 L \quad (3.5)$$

Eşitlik 3.4’de P_t verici tarafından yayılan sinyal gücünü ifade eder. P_r vericiden gelen dalganın alınan sinyal gücünü ifade eder. G_t ve G_r verici ve alıcı antenlerin kazanç değerini ifade etmektedir. Bu değerler donanımları üreten firmalar tarafından verilmektedir. Lamda λ sinyalin dalga boyunu, d ise alıcı ve verici istasyonlar arası mesafeyi ifade etmektedir. Mesafenin belirlenebilmesi için Eşitlik 3.5 yeniden düzenlenerek d parametresi yalnız bırakılır ve Eşitlik 3.6 ile verilen matematiksel bağıntı elde edilir.

$$d = \sqrt{\frac{P_t G_t G_r \lambda^2}{4\pi^2 P_r L}} \quad (3.6)$$

Bu düzenleme ile mesafenin doğrudan ölçülmesi için kullanılan bir denklem ortaya çıkmış olur ve RSSI değerlerinden mesafe hesaplanması çok daha rahat bir şekilde gerçekleştirilebilir.

Eşitlik 3.4'e L yol kaybı faktörü eklenirse, Eşitlik 3.5'deki denklem oluşur ve çevresel etkiler denkleme dahil edilir. Ancak, çevresel etkilerin sinyal gücüne etkisi çoğu zaman sistematik olmamakta olup L yol kaybı parametresi ile çevresel etkiler denkleme dahil edilsede, çevresel etmenlerin yoğun olduğu bir ölçüm ortamında bu parametre yeterli olmayabilmektedir. Bu sebeple gerçek dünya koşullarında RSSI değeri ölçümü sonucunda hesaplanan mesafe değeri ile gerçek değer arasındaki hata oranı çoğu zaman yüksek olmaktadır. İstenen konum belirleme doğruluğunun ve hassasiyetinin yüksek olmasına ihtiyaç duyulduğu durumlarda, bu sebeplerden ötürü Friis denklemi yeterli olmamaktadır.

3.3.2.1.2. Polinom katsayıları

RSSI değerleri ile mesafe arasındaki ilişkinin ters orantılı olduğu, fakat bu orantının genellikle doğrusal bir ilişki sunmadığı, bunun başlıca sebebinin RSSI değerinin sadece mesafeye bağımlı olarak değişmemekte olduğu, çevresel etmenlerden de oldukça fazla etkilendiği daha önce belirtilmiştir. Bu nedenle, polinomlar gibi daha karmaşık fonksiyonlar kullanmak, RSSI ve mesafe arasındaki ilişkiyi daha iyi yakalamak için kullanılabilecek yöntemlerin başında gelmektedir.

Polinom denklemleri kullanarak RSSI 'den mesafe belirlenmesi yönteminde RSSI değerlerini ve bunların ölçüldüğü mesafe değerini kullanarak bir polinom eğrisi denkleminde ait katsayılar hesaplanır. Bu katsayılar ile verilen bir RSSI değerinin mesafe karşılığı hesaplanabilmektedir. RSSI değerinin çevresel etkilerden de oldukça etkilenebilmesi sebebi ile kullanılan polinom eğrisine ait denklemin derecesinin belirlenmesi oldukça önemlidir. Çünkü polinom denkleminin derecesi, RSSI değerleri ve mesafe değerleri arasındaki ilişkinin karmaşıklığını daha iyi temsil etmede veya daha kötü temsil etme yönünden farklı sonuçlar doğurabilmektedir. Daha yüksek dereceli bir polinom, daha karmaşık ilişkiler daha iyi yakalanabilir, ancak bu durum aynı zamanda aşırı uyum sorunlarına da yol açabilmektedir. Kullanılacak polinom denkleminin derecesine çalışmanın yapılacağı sahadan toplanacak veriler ile hesaplanan sonuçlara göre karar verilmesi en mantıklı çözüm olacaktır. Yapılan deneylere göre seçilen polinom derecesi

ve polinom katsayılarının farklı çalışma sahalarında aynı sonuçları vermeyebileceği de unutulmamalıdır.

Eşitlik 3.7, 3.8 ve 3.9'da sırası ile birinci, ikinci ve üçüncü derece polinom denklemleri verilmiştir. RSSI değerleri ve bu değerlerin ölçüldüğü mesafe değerleri yardımı ile bu polinomlara ait a, b, c ve d polinom katsayıları hesaplanabilmektedir.

$$y = ax + b \quad (3.7)$$

$$y = ax^2 + bx + c \quad (3.8)$$

$$y = ax^3 + bx^2 + cx + d \quad (3.9)$$

Bu eşitliklerden 3.8 için yani ikinci derece bir polinomun katsayılarının hesaplanmasına yönelik yapılacak matematiksel işlemler aşağıda sunulmuştur. RSSI ile mesafe arasında veya birbirine bağımlı iki değişken arasındaki ilişkinin belirlenmesinde sadece ikinci derece polinomların yeterli olmayabileceği farklı derecedeki polinomlarla da test yapılması gerekliliği unutulmamalıdır. Buna göre ikinci derece polinom için aşağıda verilen eşitlikler farklı derecedeki polinom denklemleri için küçük değişikliklerle kolayca geliştirilebilmektedir.

Eşitlik 3.8 ile verilen denklemdeki x bilinmeyenleri RSSI değerlerini, y bilinmeyeni ise mesafe olarak kabul edilerek A ve Y matrisleri Eşitlik 3.10 ve 3.11'deki gibi oluşturulabilir.

$$A = \begin{bmatrix} 1 & RSSI & RSSI^2 & \dots & RSSI^n \\ \vdots & \vdots & \vdots & \dots & \vdots \\ 1 & RSSI & RSSI^2 & \dots & RSSI^n \end{bmatrix} \quad (3.10)$$

$$Y = \begin{bmatrix} mesafe \\ \vdots \\ mesafe \end{bmatrix} \quad (3.11)$$

Eşitlik 3.10 ve 3.11'de verilen matrislerde her satırda denklem katsayılarını belirlemek için kullanılan RSSI ve bunların ölçüldüğü mesafe değerleri ifade edilmektedir. Ayrıca A matrisinde belirtilen $RSSI^n$ ifadesinde n katsayıları hesaplanan polinomun derecesini ifade etmektedir. Daha sonra A matrisinin transpozesi alınarak aşağıda verilen eşitlikler yardımı ile polinom denklemine ait katsayılar hesaplanabilmektedir.

$$N = A^T A \quad (3.12)$$

$$n = A^T Y \quad (3.13)$$

$$X = N^{-1} n \quad (3.14)$$

Sonuç olarak hesaplanan $\underline{X}$ matrisinin elemanları polinom denkleminin katsayılarını verir. Eşitlik 3.15’de ikinci dereceden bir polinomun katsayılarının sıralaması gösterilmektedir.

$$X = \begin{bmatrix} d \\ c \\ b \\ a \end{bmatrix} \quad (3.15)$$

3.3.2.2. Makine öğrenmesi yöntemleri

Günümüzde bilgisayar biliminin gelişmesi ile derin öğrenme teknikleri de gelişmiştir. Bu alanda yapılan algoritmalar ile ölçülen RSSI verileri ve bunların ölçüldükleri mesafe veya koordinatlar makine modeline öğretilerek daha sonrasında ölçülen bir RSSI değeri için mesafe ve koordinat hesaplanması sağlanabilmektedir.

Derin öğrenme algoritmaları, karmaşık veri setlerindeki örüntüleri daha etkili bir şekilde öğrenme yeteneği ile bilinmektedirler. Bu durumda, kablosuz iletişim ortamlarında oluşan gürültüyü azaltarak ve sinyal deformasyonunu düzelterek daha doğru konum tahminleri yapılmasına olanak tanımaktadır. Bu çalışmada makine öğrenmesi tabanlı regresyon algoritmaları kullanılmış olup bu algoritmalarla ilişkin daha detaylı bilgi 4 numaralı bölümde verilmiştir.

3.3.2.3. Hibrit yöntemler

Hibrit yöntemler, RSSI verisinden mesafe verisi elde edilmesinde birden fazla yöntemi birleştirerek daha hassas ve doğru sonuçlar elde etmeyi amaçlar. Örneğin, RSSI değerleri hem YSA hem de regresyon modelleri kullanılarak mesafeye dönüştürülebilir. Böylelikle bu iki yöntemin sonuçları birleştirilerek bu yöntemlerin güçlü ve zayıf yönleri en iyi şekilde kullanılabilir. Fakat her veri türü ya da deney sahası için sonuçları doğrudan iyileştirebileceği söylenemez.

3.3.3. RSSI değerinin açı bilgisine dönüştürülmesi

RSS değeri, alıcı anten tarafından alınan sinyalin gücünü ifade ettiği ve ölçülen değerinde sinyal gücündeki değişimleri yansıttığı daha önce belirtilmiştir. Farklı açılardan ve mesafedeki kaynaklardan gelen sinyallerin RSSI değerleri farklı olması, bu değerlerden sinyalin geldiği yönün tahmin edilmesini mümkün kılmaktadır. RSSI değerinin mesafeye çevrilmesi ile konum tespitinin yapılabileceği gibi sinyalin geliş açısının tespiti ile de konum tespiti yapılabilmektedir.

Bu amaçla radyo dalgalarından yararlanılarak açı tespit edilmesine yönelik iki farklı yaklaşım önerilebilir. Bunlar RSSI değişimine göre açı belirlenmesi ve faz farkı ölçümüne göre açı belirlenmesi olarak ifade edilebilir. Her iki yöntemde birden fazla anten kullanımı ya da alıcı antenin döndürüldüğü bir mekanizma ile yapılabilir. Daha detaylı açıklanacak olunursa anten sayısının bir adet olduğu durumda anten dönebilen bir mekanizma yardımı ile belirli periyotlarda döndürülür. Sinyal gücündeki değişim bu dönme işlemi sırasında takip edilerek en yüksek RSSI değerinin ölçüldüğü açı sinyalin geliş açısı olarak kabul edilir. Faz farkı ölçüm yönteminde ise aynı işlem geçerlidir. Farklı olan kısım ise gelen sinyalin RSSI değeri yerine fazı ölçülerek fazdaki değişimler yardımı ile açı tespit edilmesidir.

Anten sayısının birden fazla olduğu durumda da anten yönleri farklı yönlere bakacak şekilde sabitlenir. Bu antenlerden gelen sinyallerin RSSI değerleri karşılaştırılır ve en yüksek değere sahip antenin yönü sinyalin geliş yönü olarak kabul edilir. Faz farkında ile açı tespitinde ise her anten, aynı sinyali farklı bir noktadan alır ve aynı sinyali aldıkları halde sinyal fazında farklılık olması sebebi ile bu farktan yararlanılarak sinyalin geliş açısı tespit edilebilir. Bu yöntemin en büyük dezavantajı anten sayısı arttığı için kullanılan RF modülünün de sayısının artması gerekebilir. Çünkü piyasada bulunan RF modüllerinin çoğunluğu tek antenli yapıda bulunmaktadır. Bu durumda maliyetleri ve enerji tüketimini arttırmaktadır. Ayrıca kullanılacak anten sayısı sınırlı olacağı için tespit edilen sinyalin geliş açısının doğruluğu da bununla orantılı olarak sınırlıdır.


4. MAKİNE ÖĞRENMESİ MODELLERİ

Makine öğrenmesi, bilgisayar algoritmalarının insanlardan bağımsız verileri öğrenmesi, analizler yapması, bunlara göre kararlar vermesi, bu verilerden yeni veriler türetmesi olarak tanımlanabilir. Makine öğrenmesi, temel olarak, Denetimli, Denetimsiz ve Destekleyici öğrenme olmak üzere üç ana kategoriye ayrılabilir (Russel ve Norvig, 2010). Bunlar;

- Denetimli Öğrenme (ing:Supervised Learning): Denetimli öğrenmede, etiketlenmiş verilerle çalışılır. Makine modeli, girdi verilerini (RSSI, sıcaklık, nem vb. eğitim verilerini) ve bu verilere karşılık gelen çıktıları öğrenmeye çalışmaktadır. Örneğin RSSI verisinden mesafe tahmin edilmesi, bir e-postanın spam olup olmadığını tahmin edilmesi veya bir hastanın laboratuvar sonuçlarına dayanarak kanser olup olmadığını belirlemek gibi durumlar için kullanılabilir. Bu öğrenme yöntemi, genellikle sınıflandırma ve regresyon problemlerinde kullanılmaktadır.
- Denetimsiz Öğrenme (ing:Unsupervised Learning): Denetimsiz öğrenmede, etiketlenmemiş verilerle çalışılmakta olup bu öğrenme yönteminde verilerin içerdiği doğal yapılar keşfedilmeye çalışılmaktadır. Bu yöntem, veri kümesindeki benzer özelliklere sahip örnekleri gruplamak için kullanılan kümeleme veya veri boyutunu azaltmak için kullanılan boyut indirgeme gibi durumlar için kullanılabilir. Denetimsiz öğrenme, genellikle veri ön işleme, veri analizi ve özellik çıkarımı gibi durumlarda oldukça yaygın olarak kullanılmaktadır.
- Destekleyici Öğrenme (ing:Reinforcement Learning): Destekleyici öğrenme, genellikle karmaşık, öngörülemeyen ve karar verme yeteneği gerektiren durumlarda kullanılır. Örneğin, pekiştirmeli öğrenme modeli bir strateji oyununda kullanılabilir. Burada model, oyun üzerindeki mevcut duruma dayanarak bir hamle seçer. Hamle yapıldıktan sonra, oyun yeni bir duruma geçer ve model, oyunun sonucunda kazanmaya yönelik puan almaya çalışır. Burada oyun süresince yaptığı hamlelere göre puanlandırma yapılarak sürekli bir öğrenme işlevi yerine getirilmektedir.

Makine öğrenmesi modellerinin projelerde kullanılabilir hale gelmesi için izlenmesi gereken bir süreç vardır. Bu süreç için bir sıralama yapılacak olunursa;

- Projede makine öğrenmesi modellerinin yapması istenen işlevin belirlenmesi,
- Amaçlanan işleve göre makine modelleri seçilmesi (regresyon, sınıflandırma algoritmaları, pekiştirmeli öğrenen modeller gibi),
- Bu amaca yönelik verilerin toplanması,
- Makine modellerinin eğitilmesi,
- Modellerin test edilmesi ve değerlendirilmesi
- Model performansları yeterli değilse hiper parametre optimizasyonların yapılması şeklinde olabilir.



Şekil 4.1. Makine öğrenmesi modellerinin sınıflandırılması

Şekil 4.1’de makine öğrenmesi modellerinin genel sınıflandırması ve bu sınıflar altında sıklıkla kullanılan bazı algoritmalar sunulmuştur. Bu şekil incelendiğinde bazı algoritmaların hem regresyon hem de sınıflandırma kategorilerinde yer aldığı görülmektedir. Bunun sebebi bazı algoritmaların hem sayısal tahminlerde hem de karar verme süreçlerinde başarılı sonuçlar vermesidir. Her bir modelin ve tekniğin ne zaman ve nasıl kullanılacağı, uygulamanın gereksinimlerine ve kullanılacak verilere bağlıdır.

4.1. Makine Öğrenmesinde Temel Kavramlar

İlerleyen bölümlerde makine öğrenmesinde sıklıkla tercih edilen ve bu çalışmada kullanılan denetimli makine öğrenmesi modellerinden regresyon modelleri hakkında bilgi verilmeye çalışılmıştır. Bu anlatımların daha net anlaşılabilmesi için öncesinde bazı kavramlar hakkında bilgi verilmesi gerekmektedir. Bu kavramlar aşağıda verilmiştir.

Veri seti: Makine öğrenmesinde kullanılacak verilerin toplandığı verilerin bütününe verilen isimdir. Veri kümesindeki verilerin niteliği ve miktarı modelin başarısını etkilemektedir. Örneğin yapılan bu çalışmada veri seti, istasyonlardan gelen RSSI değerlerinden ve bu değerlerin ölçüldüğü doğrusal mesafe ve koordinat değerlerinden oluşmaktadır.

Bağımsız değişken: Tahmin edilmek istenen değişkene etki eden değişkenlerdir. Model eğitim sonrasında tahmin için modele bu değişken verilir ve çıktısı bağımlı değişkeni ifade etmektedir. Yapılan bu çalışmada ölçülen RSSI değeri bağımsız değişken olarak kullanılmıştır.

Bağımlı değişken: Tahmin edilmek istenen değişkendir. Bağımsız değişkene ya da değişkenlere bağlı olarak değişmektedir. Bu çalışmada mesafe veya iki boyutlu koordinat bağımlı değişken olarak kullanılmıştır.

Eğitim verisi: Modelin eğitilmesinde kullanılan ve hem bağımsız hem bağımlı değişken değerlerini içeren veri kümesine verilen isimdir. Modelin performansı doğrudan bu veri setinin içerdiği veri miktarı ve boyutu ile ilişkilidir.

Test verisi: Modelin eğitilmesi sonucunda performansını değerlendirmede kullanılacak veri setidir. Bu veri seti içerisinde yer alan bağımsız değişkenlerin eğitim verilerinin içerdiği değerlerin geneline homojen olarak yayılmış olması modelin genel performansı hakkında daha doğru bilgi verecektir. Bu veri setinde yer alan bağımsız değişkenlerin karşılığı olan bağımlı değişkenlerin bilinmesi de gerekmektedir. Bu sayede tahmin sonuçlarının doğruluğu ve performansı çeşitli metrikler kullanılarak

hesaplanabilmektedir. Bu sebeplerden dolayı test verisi de en az eğitim verisi kadar önemlidir. Çünkü modelin gerçek senaryolarda kullanıldığında ortaya çıkacak sonuçlar doğrudan bu veriler ile testi sonucunda gösterdiği performansını yansıtacaktır.

Hiper parametre optimizasyonu: Hiper parametre optimizasyonu modelin performansını etkileyen parametrelerin en iyi değerlerinin bulunmaya çalışıldığı süreç olarak ifade edilebilmektedir. Regresyon modellerinden farklı veri türleri, veri boyutları veya veri çeşitleri ile çalışarak bu verileri anlamlandırması, modellemesi ve tahminler üretmesi beklenmektedir. Modellerin kullandığı, varsayılan parametreler ile veri setindeki ilişki en iyi düzeyde her zaman yakalanamaz. Bunun için modelin veriler arasındaki ilişkiyi daha iyi anlayabilmesi, eğitim ve test verilerine göre uygun parametrelerin belirlenmesi süreçleri geliştirilmiştir. Bu süreçlere hiper parametre optimizasyonu adı verilmektedir. Makine öğrenmesi modelleri kullanılırken özellikle regresyon problemlerinde modeller kullanılırken hiper parametre optimizasyonunun yapılması bu çalışmada önerilmektedir.

Günümüzde hiper parametre optimizasyonu için birçok algoritma geliştirilmiştir. Yapılan çalışmada başta bu algoritmalar kullanılarak model performansları gözlemlenmeye çalışılmış, fakat bu algoritmaların kullandığı zaman ve getirdiği performans artışı verimli olmaması sebebi ile çalışmada kullanılan makine öğrenmesi modellerine özel bir hiper parametre optimizasyonunu sağlayan algoritma geliştirilmiştir. Bu algoritma modellerin en çok kullanılan ve model performansına en çok etki eden parametreleri test verilerine göre en iyi sonucu verecek şekilde geliştirilmiştir. Bu algoritmanın sonuçlarına göre en iyi performansı gösteren modeller farklı bir test verisine tabi tutularak performansları gözlemlenmiştir (Daha fazla detay için Bölüm 6.3.5'e bakınız).

Aşırı öğrenme (ing:Overfitting): Aşırı öğrenme aslında modelin eğitim verilerini ezberleyerek tahmin için eğitim verisi dışında veri sunulduğunda yüksek hatalı sonuçlar vermesi durumu olarak adlandırılabilir. Modellerin eğitim verisini aşırı öğrenip öğrenmediğinin ve genelleştirme yeteneğinin olup olmadığının tespit edilmesi gerekmektedir.

Öğrenememe (ing:Underfitting): Öğrenememe, bir makine öğrenimi modelinin eğitim verilerini yetersiz bir şekilde öğrenmesi ve genelleştirme yeteneğinin düşük olması durumunu ifade eder. Başka bir deyişle, model, veri setindeki veriler arasındaki ilişkiyi ve örüntüyü yakalamakta zorlanarak eğitimde kullanılan verilerle yapılan testlerde dahi iyi performans sergileyememe durumu olarak ifade edilebilir.

Genelleştirme: Modelin eğitim dışı yeni verileri doğru bir şekilde tahmin edebilme yeteneği olarak ifade edilen kavramdır. Genelleştirmenin iyi olması modelin daha önce görmediği veriler içinde iyi sonuçlar verebileceği anlamına gelmektedir.

4.2. Regresyon Modelleri

Regresyon modelleri, bağımsız değişkenlerin (örneğin RSSI değerleri) bağımlı değişkenler (örneğin mesafe değerleri) üzerindeki etkisini modellemek için makine öğrenmesi tabanlı en ideal yöntemlerdendir. Bu modellerin eğitim verileri ile eğitilerek veriler arasındaki ilişkileri öğrenmesi sağlanarak sonrasında eğitilen bu modellere yeni girdiler verildiğinde çıktıları tahmin etmek mümkün olmaktadır.

Bu modeller, genellikle mevcut verileri kullanarak yeni sayısal bir değer üretmek için kullanılır. Örneğin, bir evin fiyatı tahmin edilmek istendiğinde bağımsız değişkenler evin özellikleri (örneğin, evin büyüklüğü, yılı, konumu vb.) ve bağımlı değişken evin fiyatı olur. Regresyon modeli, evin özelliklerini ve fiyatını içeren eğitim verileriyle eğitilir. Model eğitildikten sonra, yeni bir evin özelliklerini modele girebilir ve model, evin fiyatını tahmin edebilmektedir. Başka bir örnek verilecek olunursa bir seçimde adayların politikalarının seçmen kitlesi üzerinde, yapacağı değişiklikler ve oy oranlarına etkisini anlamak için regresyon analizi kullanabilir. Bu durumda, bağımsız değişkenler farklı türdeki seçim vaatleri (örneğin vergilerin azaltılması, mühendislik projelerinin yapılması söylemleri vb.) ve bağımlı değişken için ise bu vaatlerin hitap ettiği seçmen kitlesi büyüklüğü olabilir. Regresyon modeli, seçim vaatleri ve hitap edilen seçmen kitlesi büyüklüğünü içeren eğitim verileriyle eğitilir. Model eğitildikten sonra, yeni bir seçim vaadi senaryosu modele girildiğinde model, bu vaadin oy oranındaki artışı ya da azalışı tahmin edebilecektir.

Sonuç olarak, regresyon modelleri, veriler arasındaki ilişkileri anlamak ve gelecekteki sayısal değerleri tahmin etmek için güçlü ve esnek araçlardır. Regresyon modellerinin doğru bir şekilde uygulanabilmesi ve yüksek doğruluklu tahminler için, verilerin doğru bir şekilde toplanması, ön işlemeye tabi tutulması ve hazırlanması gerekmektedir. Bu çalışmada Şekil 4.1’de belirtilen regresyon modellerinden bazıları kullanılarak RSSI değeri ile mesafe ve koordinat tahminleri yapılmıştır. Kullanılan regresyon modelleri aşağıda verilmiş olup söz konusu modellerin nasıl seçildiğine ilişkin bilgi 7. Bölümde bildirilmektedir.

- SVR Regresyon Modeli

- Random Forest Regresyon Modeli
- Bagging Regresyon Modeli
- Gradient Regresyon Modeli
- XGB Regresyon Modeli
- K-En Yakın Komşu Regresyon Modeli

4.2.1. Bagging regresyon modeli

Bagging yöntemi, Leo Breiman (1928-2005) tarafından 1994 yılında önerilmiş ve 1996 yılında geliştirilmiş bir teknik olup Bagging kelimesi "Bootstrap Aggregating" kelimelerinin kısaltılması ile oluşmaktadır. Bagging regresyon modeli, tek başına bir makine öğrenmesi algoritması değildir. Bu yöntem daha çok topluluk makine öğrenmesi algoritması olup karar karar ağaçları, doğrusal regresyon, destek vektör regresyon modelleri gibi regresyon algoritmalarını temel model olarak kullanarak tahmin yapmaktadır. Bu teknik temel aldığı veya tanımlanan regresyon modellerinin zayıf öğrenme yeteneklerini arttırmayı, aşırı öğrenmeyi azaltarak modellerin performansını geliştirmeyi amaçlamaktadır. Bu sayede, tek bir regresyon modeline göre daha yüksek bir doğruluk elde edebilmektedir.

Bagging yöntemi iki aşamadan oluşmakta olup bunlar Bootstrap ve Aggregating olarak isimlendirilmiştir. Bu aşamalardan Bootstrap, veri kümesinden rastgele örnekler çekerek yeni veri kümeleri oluşturulur. Bu veri kümeleri, temel regresyon modellerinin eğitilmesi için kullanılır. Aggregating ise birden çok modelin tahminlerini birleştirme işlemidir.

Bu çalışmada Bagging yöntemi için Karar Ağacı (ing: Decision Tree) regresyon algoritması temel alınmıştır. Bu sebep ile Bagging yönteminden önce temel model olarak kullandığı karar ağaç yapısı hakkında bilgi verilmesi gerekmektedir.

Karar ağaçlarını kullanan regresyon modelleri veri setlerini alt veri kümelerine ayırır. Bu ayrımı yaparken de olabildiğince saf yani hedef değişkenin ortalamasına yakın değerler içeren alt kümeler halinde bölmek için en iyi özelliği ve değeri bulmaya çalışan bir algoritma kullanılmaktadır. Bu algoritma, her düğümde (veri setindeki özelliklerin bölüldüğü noktada) hata fonksiyonunu (örneğin, karesel ortalama hata) en aza indiren özelliği ve değeri seçmektedir. Bu şekilde her yaprak düğümü (özelliklerin bölüldüğü son kısım), hedef değişkenin ortalamasını tahmin etmek için kullanılan bir alt veri kümesini temsil etmektedir. Karar ağacı regresyonunun matematiksel temeli, entropi ve

bilgi kazancı kavramlarına dayanmaktadır. Entropi, bir veri kümesinin sahip olduğu rastgelelik veya belirsizlik derecesini ölçer. Bilgi kazancı ise bir veri kümesini bölmenin entropiyi ne kadar azalttığını gösterir. Karar ağacı algoritması, bilgi kazancını maksimize eden özellikleri ve değerleri seçerek veri kümesini bölmeye çalışmaktadır.

$$H(S) = - \sum_{i=1}^n p_i \log_2 p_i \quad (4.1)$$

Claude E. Shannon (1916-2001) tarafından tanımlan Entropi Eşitlik 4.1’de verilen formüle göre hesaplanır (Gray, 1990). Burada, S bir düğümü, n sınıf sayısını, p_i ise i’nci sınıfın olasılığını gösterir. Burada sınıf kavramı, bir veri kümesindeki benzer özelliklere sahip örneklerin bir alt kümesi olarak ifade edilmektedir. Örneğin, bir sınıf, bir çiçeğin türü, yaprak genişliği ya da arabanın motor hacmi gibi özellikleri olabilmektedir. Bir veri kümesinde, birçok farklı sınıf olabilir ve her sınıf, veri kümesindeki benzer özelliklere sahip örneklerin bir alt kümesini temsil etmektedir.

Entropi, 0 ile 1 arasında değer almakta olup 0 ise, düğümde tek bir sınıf olduğu ve saflığın en yüksek olduğu anlaşılır. Eğer Entropi 1 ise, düğümde tüm sınıflar eşit oranda dağıtıldığı ve saflığın en düşük seviyede olduğu yani veri kümesinin karışıklığının en fazla olduğu anlaşılmaktadır. Bir düğümü bölmenin bilgi kazancı, bölmeden önceki entropi ile bölmeden sonraki entropinin farkı olarak hesaplanır. Bölmeden sonraki entropi, alt düğümlerin entropilerinin ağırlıklı ortalamasına eşit olup burada bahsedilen Ağırlık kavramı alt düğümlerdeki örnek sayısının oransal ifadesidir.

$$G(S, A) = H(S) - \sum_{v \in \text{Values}(A)} H(S_v) \frac{|S_v|}{|S|} \quad (4.2)$$


Bilgi kazancı, Eşitlik 4.2’deki formülle hesaplanır (Quinlan, 1979). Burada, $G(S, A)$ bir düğümü A özniteliğine göre bölmenin bilgi kazancını, $\text{Values}(A)$, A özniteliğinin alabileceği değerleri, S_v , A özniteliğinin v değerine sahip olan örnekleri, |S| ise toplam örnek sayısını gösterir. Bir karar ağacı oluştururken, her düğümde veri setindeki tüm öznitelikler arasından bilgi kazancını maksimize eden öznitelik seçilir. Bu şekilde, ağacın derinliğini ve dallanma sayısı azaltılmış olmaktadır. Karar ağacının

çıktısı, problem regresyon ise yaprak düğümlerindeki bağımlı değişkenin ortalaması, problem sınıflandırma ise yaprak düğümlerindeki en çok oy alan sınıftır.

Buraya kadar karar ağacı yapısında bir veri setinin alt veri kümelerine nasıl ayrıldığı ve nasıl tahmin yaptığı hakkında bilgi verilmeye çalışılmıştır. Bu işleyiş bir işyerinde çalışanların yaş, tecrübe ve maaş verileri kullanılarak eğitilen karar ağacı modeli ve maaş tahmin etme süreci örneği ile anlatılmaya çalışılacaktır. Bu örnekte kullanılan veri Çizelge 4.1’de verilmiştir.


Çizelge 4.1. Bir işyerinde çalışanların yaş ve tecrübeye göre aldıkları maaşlar.

Yaş	Tecrübe (Yıl)	Maaş
21	1	₺10,000.00
27	5	₺12,000.00
21	1	₺10,000.00
41	10	₺15,000.00
26	3	₺10,500.00
46	20	₺20,000.00
42	15	₺18,000.00
39	10	₺16,000.00
50	25	₺25,000.00
25	3	₺10,500.00
44	20	₺20,000.00
42	17	₺18,000.00
33	8	₺16,000.00
36	11	₺17,000.00
42	15	₺20,000.00
43	12	₺19,000.00
32	8	₺15,000.00
47	14	₺20,000.00
45	18	₺20,000.00



Şekil 4.2. İş yerinde çalışanların yaş ve tecrübelerinin saçılım diyagramı.


Çizelge 4.1'deki veriler, saçılım diyagramı ile Şekil 4.2'de gösterilmiştir. Çizelgedeki veriler alt veri kümelerine bölündüğünde Şekil 4.3'deki gibi bir görünüm oluşur.



Şekil 4.3. İş yerinde çalışanların yaş ve tecrübelerinin bölümlendirilmesi.

Yaşı 42 ve 10 yıllık tecrübeye sahip bir çalışan için maaş tahmini yapılmak istendiğinde karar ağacının ilgili veriyi bulundurduğu yaprakların tahminlerinin ortalaması alınır. Şekil 4.3'de gösterilen karar ağacında 40 ile 43 yaş arasında ve 14 yıldan az tecrübeye sahip olan 15000 ve 19000 TL maaş alan iki çalışanın bulunduğu yaprak (kırmızı ile işaretli kısım) görülmektedir. Model bu maaşlarının bulunduğu yaprakların

ortalaması alır ve tahmin sonucu olan 17000 TL değerini çıktı olarak verir. Bu yapı Şekil 4.4’de verilen ağaç diyagramı olarak da gösterilebilir.



Şekil 4.4. Verilen örnek için kullanılan ağaç diyagramı.

Karar ağaç yapılarının işleyiş şekli anlatıldığına göre Bagging yönteminin temel çalışma prensibi hakkında daha detaylı bilgi verilebilir. Bu tekniğin çalışma şekli veri setinden tekrarlı örneklemeler alarak farklı alt veri kümeleri oluşturulur. Sonrasında oluşturulan her alt veri kümesi üzerinde öğrenme algoritması kullanılarak farklı öğrenciler (tahminciler) eğitilir. Burada “öğrenciler” terimi, Bagging tekniği içerisinde bulunan farklı regresyon modellerini veya tanımlanan regresyon modelini temsil etmektedir. Sonrasında her bir öğrencinin eğitilmesi tamamlandığında, tahmin için yeni veriler modele sunulur ve bu öğrencilerin yaptıkları tahminlerin ortalaması çıktı olarak sunulur.

Ayrıca Bagging regresyon modeli, temel regresyon modellerini bağımsız olarak eğitebilmektedir. Bu sayede her bir alt veri kümesi için ayrı bir işlemcinin kullanılması mümkün olup eğitim süresi oldukça kısalmaktadır. Bu durumda Bagging yöntemini büyük veri kümeleri için daha kullanışlı bir model haline getirmektedir. Bagging regresyon modelinin tahmininde kullanılan temel matematiksel Eşitlik 4.3’de verilmiştir (Breiman, 1996).

$$\hat{f}_{BR}(x) = \frac{1}{B} \sum_{b=1}^B T_b(x) \quad (4.3)$$

Burada, $\hat{f}_{BR}(x)$ bagging regresyon modelinin tahmini, B temel regresyon modeli sayısı, $T_b(x)$ ise b numaralı temel regresyon modelinin tahmini anlamına gelir. Temel regresyon modelleri, herhangi bir doğrusal ya da doğrusal olmayan regresyon modeli olabilmektedir.

4.2.2. Random Forest regresyon modeli

Random Forest, tek bir karar ağacı yerine çok sayıda karar ağacının bir araya getirilmesi prensibine dayanan, sınıflandırma ve regresyon için kullanılan güçlü bir makine öğrenmesi yöntemidir. Türkçede rastgele ormanlar anlamına gelmektedir.

Random Forest yöntemi aslında Bagging yönteminin geliştirilmiş hali olup 2001 yılında Leo Breiman tarafından tanımlanmıştır. Breiman, öncelikle tekli karar ağaçları üzerine yapılan çalışmaları incelenmiştir. Daha sonra birden fazla karar ağacının eğitimi ve sonuçlarının birleştirilmesi üzerine deneyler yaparak ilk denemelerde elde edilen başarılı sonuçlar üzerine yöntemin geliştirme çalışmaları hız kazanmıştır. Yöntemle ilgili ilk makale 2001 yılında yayınlanmıştır. Takip eden yıllarda Random Forest üzerine pek çok çalışma yapılarak yöntemin teorik alt yapısı oluşturulmuş ve algoritmaları geliştirilmiştir.

Random Forest yönteminin avantajları arasında, yüksek doğruluk, az parametre ayarı, eksik verilere karşı dayanıklılık, değişken önemini belirleme gibi özellikler sayılabilir. Dezavantajları arasında ise, yüksek hesaplama maliyeti, karmaşık model yapısı, yorumlama zorluğu gibi faktörler sayılabilmektedir.

Random Forest regresyon modelinin matematiksel temeli, çok sayıda karar ağacının oluşturulması ve bunların ortalamasının alınması esasına dayanmaktadır. Her karar ağacı, eğitim verilerinden rastgele seçilen bir örneklem üzerine kurulur ve her bir bölünme noktasında rastgele seçilen bir alt küme değişkenleri arasından en iyi bölünme kriteri belirlenir. Bu aynı zamanda Bagging tekniğinden en önemli farkını ifade etmektedir. Yani burada veri setini alt veri kümelerine ayırmanın yanında verileri özniteliklerine göre de ayırmaktadır. Bu şekilde, karar ağaçları arasındaki korelasyon azaltılır ve varyans düşürülebilmektedir. Tahmin aşamasında veri, tüm ağaçlara verilerek her ağaçtan ayrı bir tahmin elde edilir. Random Forest, her bir ağacın hata oranını hesaplar ve tahmin yaparken de bu hataları ağırlık olarak kullanmaktadır. Böylece, daha başarılı olan ağaçların tahminleri sonuca daha fazla etki etmektedir. Bu durum, Random Forest'ın Bagging tekniğinden diğer bir farkıdır.

Random Forest verileri alt veri kümelerine bölme işlemi Bagging yönteminde olduğu gibi Entropi ve Bilgi kazancı yöntemleri ile yapmaktadır. Burada kullanılan matematiksel eşitlikler önceki bölümde verilen 4.1 ve 4.2 eşitlikleri ile aynıdır. Matematiksel olarak, Random Forest regresyon modelindeki kullanılan temel matematiksel Eşitlik 4.4’de verilmiştir.

$$\hat{f}_{RF}(x) = \frac{1}{B} \sum_{b=1}^B T_b(x) \quad (4.4)$$

Bu eşitlikte, B oluşturulan karar ağacı sayısı, $T_b(x)$ ise b’ninci karar ağacının x noktasındaki tahminini olarak ifade eder. Random Forest regresyon modelinin genelleştirme hatası, karar ağaçlarının gücü ve korelasyonu ile ilişkilidir. Genelleştirme hatası ise Eşitlik 4.5’deki gibi ifade edilebilir (URL-17).

$$Err_{RF} = \bar{\rho}\sigma^2 + \bar{\epsilon}^2 \quad (4.5)$$


Burada, $\bar{\rho}$ karar ağaçlarının ortalama korelasyonu, σ^2 karar ağaçlarının varyansı, $\bar{\epsilon}^2$ ise karar ağaçlarının karesel ortalama hatası şeklinde ifade edilmektedir. Random forest regresyon modelinin performansını artırmak için, karar ağaçlarının gücünü artırmak ve korelasyonlarını azaltmak gerekir. Bu amaçla, karar ağaçlarının derinliği, bölünmede kullanılan değişken sayısı ve örneklem büyüklüğü gibi parametreler ayarlanması gerekir (URL-17).

4.2.3. SVR regresyon modeli

SVR, destek vektör makinelerinin regresyon problemlerine uygulanmasıyla elde edilen bir makine öğrenmesi algoritması olup Support Vector Regression kelimelerinin ilk harflerinden oluşmaktadır. Destek Vektör Makineleri yöntemi ilk olarak 1992 yılında Vapnik ve Chervonenkis tarafından ortaya atılmış olup 1995 yılında Boser, Guyon ve Vapnik tarafından çekirdek fonksiyonları kullanılarak geliştirilmiştir. SVR modeli ise 1997 yılında Vapnik, Cortes ve Smola tarafından geliştirilmiş olup 1998 yılında Drucker, Burges, Kaufman, Smola ve Vapnik tarafından iyileştirilmeler yapılmıştır. Başta

sınıflandırma problemleri için geliştirilen algoritma, regresyon uygulamalarına uyarlanarak yapılan deneylerde de başarılı olduğunu kanıtlamıştır.

SVR'nin temel fikri, verileri boyutlar arasında en iyi şekilde ayıran bir fonksiyonu bulmak esasına dayanmaktadır. SVR bunu yaparken, veriler arasındaki doğrusal olmayan ilişkileri de dikkate alabilecek bir fonksiyon seçmektedir. Bu işlemi Kernel adı verilen çekirdek fonksiyonları kullanılarak gerçekleştirilmektedir. Çekirdek fonksiyonları, verileri yüksek boyutlu uzaya dönüştürmek için kullanılır ve bu dönüşüm, veriler arasındaki ilişkileri daha iyi yakalamada faydalı olmaktadır. Bu şekilde eşlenmiş veriler üzerinde bu yöntemler bir hiper düzlem bulunmaya çalışılmaktadır. Sonrasında bu hiper düzlem, verileri iki sınıfa ayıracak şekilde konumlandırılır. Şekil 4.5'de koyu siyah çizgi ile bu durum gösterilmektedir. Ancak, burada önemli olan nokta, bu hiper düzlemin verileri mümkün olduğunca iyi ayırmaya çalışırken, bazı verileri hata payı olarak kabul edilmesidir. Bu hata payı, ϵ ile Şekil 4.5'de gösterilmiştir. Bu parametre, modelin tahminlerinin gerçek değerlerden ne kadar sapabileceğini belirlemektedir. ϵ değeri büyükse, model tahminlerinde daha fazla hata payı kabul etmektedir. Eğer ϵ değeri küçükse, model tahminlerinde bu sefer daha az hata payı kabul etmektedir. Bu sebep ile ϵ değeri, modelin hassasiyetini ve doğruluğunu doğrudan etkileyen parametrelerdendir.



Şekil 4.5. SVR Regresyon modelinde rbf çekirdek fonksiyonu kullanılarak ayrılan hiper düzlemler (Géron, 2019).

SVR, en iyi hiper düzlemi bulmak için iki tür hiper düzlemi kullanmakta olup bunlar;

- Destek vektör hiper düzlemi (SVH),

- Marjinal hiper düzlemidir (MH).

SVH, verilere en yakın olan hiper düzlemi ifade eder ve tahminlerin çoğunu bu hiper düzlem kullanarak yapılmaktadır. MH ise, hata payını minimize etmek için kullanılır ve verilerin bir kısmını bu hiper düzlem üzerine yerleştirilmektedir (Şekil 4.5’de SVH, dıştaki iki siyah çizgi, MH ise ortadaki siyah çizgidir.).

SVR modelinin kullandığı temel matematiksel denklemleri aşağıda yer alan eşitliklerde verilmiştir.

$$x_i, y_i \quad i = 1, 2, 3, \dots, n \quad (4.6)$$

Veri noktaları Eşitlik 4.6 ile ifade edilir burada x bağımsız değişkeni y ise bağımlı değişkeni ifade eder.

$$f(x) = w^T \Phi(x) + b \quad (4.7)$$

Regresyon hattı için genel denklem Eşitlik 4.7’de gösterilmiştir. Burada w ağırlık vektörü, b sapma terimi ve $\phi(x)$ çekirdek fonksiyonunu ifade eder (Cortes ve Vapnik, 1995). SVR de 4 farklı çekirdek fonksiyonu kullanılmakta olup bunlardan en yaygın kullanılanı ve özellikle doğrusal olmayan ilişkilerde başarılı sonuçlar veren RBF (ing: Radial Basis Function - Radyal Bazlı Fonksiyon) fonksiyonudur. Yapılan bu çalışmada da RBF çekirdek fonksiyonunun kullanıldığı SVR regresyon modeli en başarılı sonuçları vermiştir.

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (4.8)$$

Burada x_i ve x_j , girdi vektörleridir. Bu vektörler, regresyon yapmak istenen veri noktalarının özelliklerini temsil eder. Örneğin, RSSI ile mesafe tahmini için x_i ve x_j vektörleri, 1. istasyondan alınan RSSI değeri 2. İstasyondan alından RSSI değeri gibi özellikleri içerir. γ , RBF çekirdek fonksiyonunun genişliği veya ölçeği olarak adlandırılan bir parametredir. Bu parametre, çekirdek fonksiyonunun şeklini kontrol eder. γ değeri büyükse, çekirdek fonksiyonu dar bir şekil alır ve sadece çok yakın olan veri noktalarını etkiler. γ değeri küçükse, çekirdek fonksiyonu geniş bir şekil alır ve daha uzak olan veri

noktalarını da etkiler. γ değeri, SVR Regresyon modelini eğitirken seçilir (Vapnik ve diğ., 1997).

$\|x_i - x_j\|^2$ ifadesi ise, iki girdi vektörü arasındaki Öklid uzaklığının karesidir. Bu terim, iki veri noktasının ne kadar benzer veya farklı olduğunu ölçer. Öklid uzaklığı, Eşitlik 4.9'da verilen formül ile hesaplanır.

$$\|x_i - x_j\|^2 = \sum_{k=1}^m (x_{ik} - x_{jk})^2 \quad (4.9)$$

Bu denklemde m , girdi vektörlerinin boyutudur. Örneğin, mesafe tahmini için kullanılan RSSI değeri 4 istasyondan gelen değerleri girdi verisi olarak sunulursa bu değer 4 olur. SVR modelindeki regresyon fonksiyonu ise Eşitlik 4.10 ile gösterilmiştir. Bu fonksiyon ile veri noktalarına en iyi uyan eğri veya yüzey belirlenir (Vapnik ve diğ., 1997).

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x) + b \quad (4.10)$$

Burada α_i, α_i^* Lagrange çarpanları ve $K(x_i, x)$ çekirdek fonksiyonunun değeridir. Eşitlikte verilen b değeri ise Eşitlik 4.11 ile verilen denklem yardımı ile hesaplanır (Vapnik ve diğ., 1997).

$$b = y_k - \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x_k) \quad (4.11)$$

Yapılan deneylerde de görüldüğü üzere SVR regresyon modeli az sayıda veri ile dahi RSSI ile mesafe arasında bulunan ilişkiyi başarılı bir şekilde modelleyebilmektedir. Fakat bölgesel modellemelerde yani modellenecek veriler arasındaki ilişkinin karmaşıklığı azaldığında daha küçük veri kümeleri ile çalışıldığında tahmin etme performansının çalışmada kullanılan diğer regresyon modellerine göre daha az olduğu gözlemlenmiştir.

4.2.4. Gradient Boosting regresyon modeli

Gradient Boosting regresyonu, aşamalı öğrenme yöntemidir. Bu yöntem, bir dizi basit regresyon modellerini birleştirerek daha karmaşık ve doğrusal olmayan veri kümeleri üzerinde daha iyi performans elde etmeye çalışan bir aşamalı öğrenme tekniğidir.

Modelin çalışma prensibi, ilk olarak, veri seti test ve eğitim verileri olarak ayrılır ve bu veriler kullanılarak temel bir model oluşturulur. Bu temel model yaptığı tahminlerde veri setinin ortalaması veya medyanı gibi temel istatistik yöntemleri kullanarak ya da basit yapıda olan karar ağaçları ile tahmin yapan bir modeldir. Sonrasında bu modelin tahminleri ile gerçek değerler arasındaki hata hesaplanır. Hesaplanan hata değerleri, bir sonraki modelin odaklanacağı alanı temsil etmektedir. Bir sonraki aşamada, bu hata değerlerine odaklanan bir zayıf öğrenici eğitilir. Bu öğrenici ile önceki modelin hataları düzeltilmeye çalışılır. Her modelin katkısı, kayıp fonksiyonunun gradyanını takip ederek belirlenir. Gradyan, bir fonksiyonun değişim oranını gösteren bir vektördür. Gradyan artırma yöntemi, bir fonksiyonun minimum veya maksimum değerine ulaşmak için gradyanın tersi veya aynı yönüne doğru adım atmayı içerir. Gradient Boosting regresyon modelinde, kayıp fonksiyonunun gradyanı, modelin hatalarını azaltmak için kullanılır. Gradyan, kayıp fonksiyonunun minimuma gittiği yönü gösterir. Bu adımlar belirli bir iterasyon sayısına veya belirli bir hata düzeltme düzeyine ulaşılan kadar tekrarlanır. Her iterasyon, modelin daha iyi performans göstermesini sağlamak için önceki modellerin hatalarını düzeltmeye odaklanır. Sonuç tahmini, belirlenen iterasyon sayısına ulaşıldığında tüm modellerin ağırlıklı toplamı kullanılarak yapılır.

Gradient Boosting regresyonu, 1999 yılında Jerome Friedman tarafından geliştirilmiştir. Friedman, 2001 yılında yayınladığı bir makalede, bu yöntemin teorik temellerini ve uygulamalarını anlatmıştır. Friedman, bu yöntemi, stokastik gradyan artırma (ing: Stochastic Gradient Boosting) olarak adlandırmıştır. Bu yöntem ile her iterasyonda eğitim verisine rastgele bir alt küme seçerek, modelin çeşitliliğini artırmayı ve aşırı öğrenmenin azaltılması amaçlanmıştır. Gradient Boosting regresyon modelinin temel matematiksel denklemleri aşağıda yer alan eşitlikler ile ifade edilmektedir.

$$L(y, F(x)) \quad (4.12)$$

Eşitlik 4.12 ile hedef fonksiyon tanımlanır. Bu fonksiyona göre y gerçek hedef değerleri, $F(x)$ tahmin edici fonksiyonu, L ise kayıp fonksiyonunu (ing:loss function) temsil etmektedir (Friedman, 2001).

$$F(x) = \sum_{m=0}^M \gamma_m h_m(x) \quad (4.13)$$

Eşitlik 4.13 ile tahmin edici fonksiyon tanımlanmaktadır. Buna göre $h_m(x)$ zayıf tahmin edicileri, γ_m ise onların ağırlıklarını temsil eder. M ise tahmin edici sayısını belirtir (Friedman, 2001).

$$\gamma_m = \operatorname{argmin} \gamma \sum_{i=1}^n L(y_i, F_{m-1}(x_i) + \gamma h_m(x_i)) \quad (4.14)$$

Eşitlik 4.14 ile Gradyan iniş denklemi tanımlanmaktadır. Bu denkleme göre, γ_m , m 'inci tahmin edicinin ağırlığını bulmak için kullanılan bir optimizasyon denklemini ifade etmektedir. $F_{m-1}(x_i)$ ise önceki tahmin edicilerin toplamını temsil eder (Friedman, 2001).

$$r_{im} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F(x)=F_{m-1}(x)} \quad (4.15)$$

Eşitlik 4.15 ile hata fonksiyonu denklemi tanımlanmaktadır. Buna göre r_{im} , i 'inci veri noktasının m 'inci tahmin edicinin hata fonksiyonunu temsil etmekte olup bu fonksiyon, kayıp fonksiyonunun türevi ile hesaplanır (Friedman, 2001).

4.2.5. XGB regresyon modeli

XGB regresyon yöntemi, Tianqi Chen adlı bir doktora öğrencisi tarafından başlatılan ve DMLC (ing:Distributed Machine Learning Community) adlı bir topluluk tarafından geliştirilen açık kaynak projesi olan XGBoost kütüphanesinin bir parçasıdır. XGBoost ismi, eXtreme Gradient Boosting kelimelerinin kısaltılması ile oluşmuş olup temelinde, Gradient Boosting regresyon yöntemini kullanarak çok sayıda karar ağacını birleştirir.

XGBoost, Gradient Boosting yöntemini optimize ederek, veri setinin karmaşıklığını yakalayabilen, aşırı uyuma karşı dirençli olan, hızlı, ölçeklenebilir ve yüksek performanslı bir regresyon algoritması sunmayı amaçlamaktadır. Bu algoritma, paralel hesaplama, ağaç budama (karar ağaçlarının boyutunu ve karmaşıklığını azaltmak), önbellek farkındalığı (modelin bellek erişimini ve veri aktarımının optimize edilmesi), ayrık veri optimizasyonu gibi birçok özellik kullanarak, model eğitimi hızlandırır ve büyük veri setleri ile çalışabilmesine olanak tanımaktadır. XGBoost, farklı hata fonksiyonları, düzenlileştirme terimleri, ağaç parametreleri, örnekleme yöntemleri gibi birçok seçeneği ayrıca sunmakta olup bu seçenekler, modeli farklı veri setleri ve problemlere göre uyarlamak için kullanılabilir.

XGBoost yönteminin en büyük dezavantajı parametre optimizasyonun zor olmasıdır. Bunun en büyük sebebi ise, çok sayıda parametre içermesi ve bu parametrelerin optimal değerlerini bulmak için deneme-yanılma yöntemi kullanılmasıdır. Bu süreç özellikle büyük veri setlerinde oldukça fazla zaman almaktadır (Chen ve Guestrin, 2016).

XGBoost, Gradient Boosting yöntemini aşağıda verilen yöntemler ile geliştirmektedir (Chen ve Guestrin, 2016).

- XGB regresyonu, hata fonksiyonuna, ağaçların yaprak sayısı ve yaprak değerleri ile ilgili iki düzenlileştirme terimi eklenir. Bu terimler, ağaçların aşırı büyümesini ve aşırı uyumunu engelleyerek, modelin genelleştirme yeteneğini arttırmaktadır.
- XGB regresyonu, veri setindeki aykırı değerleri ve eksik değerleri daha iyi işleyebilmek için, ağırlıklı niceliksel tayin adlı bir yöntem kullanmaktadır. Bu yöntem, veri setini, eşit ağırlıklı parçalara bölmek için optimal eşik değerleri bularak ağaçların dallanmasında daha etkili ve verimli bir bölünme kriteri sağlamaktadır.
- XGB regresyonu, her ağaç oluşturulurken, veri setinin sütunlarını rastgele seçerek, kolonyal evrim adlı bir yöntem uygulamaktadır. Bu yöntem, modelin çeşitliliğini artırarak, aşırı uyumu azaltmakta olup modelin hızını ve bellek kullanımını da iyileştirmektedir.

XGB regresyon modelinin Gradient Boosting yönteminden farklı olarak kullandığı matematiksel denklemler aşağıda yer alan eşitlikler ile verilmiştir.

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), f_k \in F \quad (4.16)$$

Burada $\hat{y}_i$ i'nci örnek için tahmin edilen değer, K topluluktaki ağaç sayısı, f_k k'nci ağaç fonksiyonu ve F ağaç fonksiyonlarının uzayını ifade etmektedir (Chen ve Guestrin, 2016). XGB regresyonunda, ağaç yapısı, eşit ağırlıklı parçalara bölünmüş veri setini kullanarak oluşturulur. Bu parçalar, ağırlıklı niceliksel tayin adlı bir yöntem ile bulunur. Bu ağaç yapısının temel matematiksel denklemi Eşitlik 4.17'de verilmiştir.

$$f_k(x) = w_{q(x)}, q: R^m \rightarrow T \quad (4.17)$$

Burada, $f_k(x)$ k'nci karar ağacı fonksiyonunu, x bağımsız girdi değişkenlerini, $w_{q(x)}$ x'in gittiği yaprağın değerini, $q(x)$ x'in gittiği yaprağın indeksi, m bağımsız girdi değişkeni sayısını, T ağacın yaprak sayısını ifade etmektedir (Chen ve Guestrin, 2016).

4.2.6. K-En Yakın Komşu regresyon modeli

K-En Yakın Komşu (ing:K-Nearest Neighbors) regresyon modeli, makine öğrenmesinin denetimli öğrenme alt dalında yer alan regresyon veya sınıflandırma problemlerine çözüm sunan bir yöntemdir. Bu yöntemin temel çalışma prensibi, veri集中的 her veri noktasının değerini, en yakın komşularının değerlerinin ortalaması olarak tahmin etme esasına dayanmaktadır. En yakın komşuları ya da diğer bir deyişle veri集中的 benzer özelliklere sahip veri noktalarını bulmak için bir mesafe ölçütü kullanır. Buradaki mesafe ölçütü ile iki veri noktası arasındaki uzaklığı hesaplayarak noktanın yakınlık derecesi belirlenir. Burada kullanılan temel matematiksel denklem Eşitlik 4.18 ile verilmiştir (URL-13).

$$\hat{y} = \frac{1}{K} \sum_{i=1}^K y_i \quad (4.18)$$

Eşitlik 4.18'e göre, $\hat{y}$ bağımlı değişkenin tahmini değerini, K seçilen komşu sayısını, y_i en yakın komşuların bağımlı değişken değerlerini ifade etmektedir. En yakın komşuların yakınlık derecesinin tespiti için algoritmalarda en fazla tercih edilen

yöntemler Öklid mesafesi, Minkowski mesafesi ve Manhattan mesafesidir. Bu yöntemlerden Öklid mesafesi iki nokta arasındaki en kısa doğrusal uzaklığı temsil eder. Birçok mühendislik dalında yaygın olarak kullanılmaktadır. Matematiksel formülü Eşitlik 4.19 ile verilmiştir.

$$d(x, y) = \sqrt{\sum_{i=1}^t (x_i - y_i)^2} \quad (4.19)$$

Eşitlik 4.19’da verilen değerlerden x yeni bir veri noktasını, y ise eğitim verisindeki her bir veri noktasını temsil etmektedir. Bu eşitlik de t değeri ise veri noktalarının özellik sayısını ifade eder.

Mesafe belirlemede kullanılan bir diğer yöntem olan Manhattan mesafesi, iki nokta arasındaki yatay ve dikey uzaklıkların toplamıdır. Bu, şehir içi ulaşımında kullanılan bir mesafe ölçütüdür. Manhattan mesafesi Eşitlik 4.20’de verilen formül ile hesaplanır.

$$d(x, y) = \sum_{i=1}^t |x_i - y_i| \quad (4.20)$$

Manhattan mesafesinin avantajı, hesaplamasının kolay olmasıdır. Özellikle, yüksek boyutlu veri setleri için, Manhattan mesafesi, Öklid mesafesine göre daha hızlı ve daha verimli hesaplanabilir. Manhattan mesafesinin dezavantajı ise, iki nokta arasındaki en kısa doğrusal uzaklığı vermemesidir. Buda bazı regresyon hesaplamalarında yüksek hatalı tahminler yapmasına sebep olurken bazı durumda da Öklid mesafesi yöntemine göre daha başarılı tahminler yapılmasını sağlamaktadır.

Bir diğer mesafe hesaplama yöntemi olan Minkowski mesafe hesaplama yöntemi aslında Öklid ve Manhattan yöntemlerinin genelleştirilmiş bir halidir. Bu mesafe ölçütü, bir parametre olan p değerine göre değişmekte olup p=2 olduğunda Öklid mesafesi, p=1 olduğunda ise Manhattan mesafesi elde edilebilmektedir. Genel matematiksel eşitliği Eşitlik 4.21 ile aşağıda verilmektedir.

$$d(x, y) = \left(\sum_{i=1}^t |y_i - x_i|^p \right)^{\frac{1}{p}} \quad (4.21)$$

Minkowski mesafesinin avantajı, farklı p değerleri ile farklı uzaklık ölçütleri elde edilebilmesidir. Bu, veri setinin yapısına veya dağılımına göre en uygun mesafe ölçütünü seçmeyi sağlar. Buradaki p değeri, veri setinin özelliklerine veya modelin performansına göre değişebilir. Uygun p değerini seçmek için, farklı p değerlerine göre modelin performansını ölçmek ve en iyi sonucu veren p değerini bulmak gerekmektedir. Bu işlem içinde algoritmalarda ayrıca hiper parametre optimizasyon yöntemi ile en uygun değerin belirlenmesi ihtiyacını doğurmaktadır.

Sonuç olarak K-En Yakın Komşu regresyon modeli tahmin edilmek istenen bağımlı değişkenin eğitim verisi içerisinde yukarıda bahsedilen mesafe hesaplama yöntemlerine göre k sayıda en yakın değerleri bulur ve bunlara karşılık gelen bağımlı değişkenlerin aritmetik ortalamalarını çıktı olarak vermektedir. Bu yöntemin avantajları basit ve anlaşılması kolay olması, aşırı uyuma karşı dirençli olması ve veri setinin yapısına veya dağılımına göre herhangi bir varsayım yapmamasıdır. Bazı dezavantajları ise büyük veri setleri için hesaplama için kullanılan zaman ve işlemci gücü yüksektir, yüksek boyutlu veri setleri için doğruluk performansı düşebilmektedir, uygun k değerini seçmek zordur, çünkü çok küçük veya çok büyük k değerleri yanlış tahminlere yol açabilmektedir. Çok küçük k değeri, modelin veri setindeki gürültü veya sapmalara duyarlı olmasına ve aşırı uyum yapmasına neden olabilmektedir.

5. KONUM HESAPLAMA YÖNTEMLERİ


Konum belirleme, bir nesnenin veya kişinin nerede olduğunu tespit etme işlemidir. Konum belirleme, farklı amaçlar için farklı yöntemler kullanılarak yapılabilir. Örneğin GNSS ile konum tespitinde uydular ile alıcı arasındaki mesafeyi ölçerek trilaterasyon yöntemi ile konum hesaplanırken yersel ölçme aletleri ile bu işlem hem açı hem mesafe ölçerek jeodezik temel ödev formülleri ile yapılabilir. Buradaki en önemli kısım hesaplamada kullanılan mesafe, açı ve referans noktanın konum değerlerinin doğruluğudur. Bu veriler hesaplanan konumun doğruluğuna en büyük etkiyi yapan bileşenlerdir. Geliştirilen yöntemler ile bu verileri kullanarak konumu bilinmeyen noktanın konumlarının hesaplanmasını mümkün kılmakta olup her yöntemin kendine has avantajı veya dezavantajı bulunmaktadır.

Temel olarak bu yöntemlerin en önemli veri kaynağı referans noktaları ve konumu belirlenecek nokta arasındaki mesafe, açı ve hız bilgisidir. Bu bilgileri kullanarak konum hesaplamada kullanılan yöntemlerden bazıları şunlardır;

- Trilaterasyon Yöntemi,
- Triangulation Yöntemi,
- Multilaterasyon Yöntemi,
- Karma Yöntemler ve
- Parmak İzi Yöntemidir.

5.1. Trilaterasyon (Üçgenleştirme) Yöntemi

Trilaterasyon yönteminde konum belirlenebilmesi için koordinatı bilinen en az 3 referans noktası ile konumu bilinmeyen gezici istasyon arasındaki **mesafenin** belirlenmesi gerekir. Bu yöntem, geometri bilgisine dayanır ve geometrik şekilleri, özellikle daireleri ve küreleri, kullanarak nesnenin konumunu hesaplar.



Şekil 5.1. Trilaterasyon yöntemi.

Şekil 5.1’de 1, 2 ve 3 numaralı noktalar konumları bilinen referans noktalarını A ile verilen nokta ise konumu belirlenmek istenen noktayı temsil etmektedir. Konumları bilinen noktaların koordinatları y_i , x_i ile belirtilmiş ve A noktasına olan uzaklıkları r_i ile ifade edilmiştir. Burada i sırası ile 1, 2 ve 3 numaralı noktaları ifade etmektedir. Koordinatı bilinmeyen A konumu için koordinatlarda y_A , x_A olarak ifade edilmektedir. Buna göre r_i değerinin hesaplanmasında kullanılan temel formül Eşitlik 5.1 ile verilmiştir.

$$(x_i - x_A)^2 + (y_i - y_A)^2 = r_i^2 \quad (5.1)$$

Eşitlik 5.1’de i yerine sırası ile nokta numaraları girilerek denklem açılırsa Eşitlik 5.2, 5.3 ve 5.4 elde edilir.

$$x_1^2 - 2x_1x_A + x_A^2 + y_1^2 - 2y_1y_A + y_A^2 = r_1^2 \quad (5.2)$$

$$x_2^2 - 2x_2x_A + x_A^2 + y_2^2 - 2y_2y_A + y_A^2 = r_2^2 \quad (5.3)$$

$$x_3^2 - 2x_3x_A + x_A^2 + y_3^2 - 2y_3y_A + y_A^2 = r_3^2 \quad (5.4)$$

Eşitlik 5.2’den ve Eşitlik 5.3’den Eşitlik 5.4 sırası ile çıkarılarak bilinenler ve bilinmeyenler taraflara ayrılıp eşitlikler tekrar düzenlendiğinde Eşitlik 5.5 ve 5.6 elde edilir.

$$2x_A(x_3 - x_1) + 2y_A(y_3 - y_1) = x_3^2 - x_1^2 + y_3^2 - y_1^2 + r_1^2 - r_3^2 \quad (5.5)$$

$$2x_A(x_3 - x_2) + 2y_A(y_3 - y_2) = x_3^2 - x_2^2 + y_3^2 - y_2^2 + r_2^2 - r_3^2 \quad (5.6)$$

Bu denklemler matris biçiminde yazıldığında ise Eşitlik 5.7 oluşur.

$$2 \begin{vmatrix} x_3 - x_1 & y_3 - y_1 \\ x_3 - x_2 & y_3 - y_2 \end{vmatrix} \begin{vmatrix} x_A \\ y_A \end{vmatrix} = \begin{vmatrix} x_3^2 - x_1^2 + y_3^2 - y_1^2 + r_1^2 - r_3^2 \\ x_3^2 - x_2^2 + y_3^2 - y_2^2 + r_2^2 - r_3^2 \end{vmatrix} \quad (5.7)$$

Eşitlik 5.7 Ters matris veya Cramer kuralı ile çözülerek bilinmeyen A noktasına ait koordinatlar bulunabilir. Hesaplamalarda kullanılan r_i değeri yani referans noktalar ile konumu bilinmeyen nokta arasında ölçülen veya hesaplanan mesafe değeri genellikle bir miktar hata içermektedir. Bu hata bazı durumlarda kaba bazı durumlarda ise ölçme aletinin kalibrasyonunun bozuk olması veya ölçme doğruluğunun ya da inceliğinin sınırlı olmasından kaynaklanabilmektedir. Bu durumda da Eşitlik 5.7 Ters matris veya Cramer kuralı ile çözülmesi sonucu hesaplanan konum, A noktasının gerçek konum değerinin yakınında ya da uzağında bir nokta olabilmektedir.

Eşitlik 5.7’de görüldüğü üzere A noktasına ait koordinatların hesaplanmasını içeren çözüm 3 referans noktasına olan mesafenin girdi olarak kullanılması ile çözülmektedir. Yapılan bu çalışmada 4 adet verici istasyonu kullanıldığı için buradaki denklemin 4 istasyondan alınan veriye göre güncelleştirilmesi ya da mevcut 4 noktayı 3 nokta olacak şekilde farklı kombinasyonlara göre ayırarak koordinatların ayrı ayrı hesaplanması ve bulunan koordinat değerlerinin ortalaması alınarak A noktasının koordinatlarının hesaplanması mümkündür.

Trilaterasyon ile konum hesaplamalarında referans istasyon ile konumu belirlenecek nokta arasında ölçülen mesafenin doğruluğu hesaplanan konumun doğruluğunu doğrudan etkilemektedir. Fakat mesafenin azda olsa hatalı ölçüldüğü durumlarda en az mesafenin doğruluğu kadar referans istasyonlarının yerleşim geometrisi hesaplanacak konum doğruluğunu etkilemektedir. Bu sebep ile özellikle kapalı mekân konum belirleme sistemlerinde trilaterasyon ile konum hesaplamalarının yapılması planlandığı takdirde referans istasyonların yerleşim geometrisinin buna göre ayarlanması gerekmektedir.

5.1.1. Ters matris yöntemi ile çözüm

Ters matris yöntemi, lineer cebirde kullanılan bir yöntemdir. Bu yöntem, bir matrisin tersini bulmak ve bu tersi kullanarak lineer denklem sistemlerini çözmek için kullanılmaktadır. Eşitlik 5.7’de verilen matrisin ters matris yöntemi ile çözülmesi için matris sırası ile A, B ve X matrislerine bölünür. Buna göre Eşitlik 5.7’deki matrisin bölünmesi sonucu A matrisi Eşitlik 5.8’de, B matrisi Eşitlik 5.9’da ve X bilinmeyenler matrisi Eşitlik 5.10’da verilmiştir.

$$A = \begin{vmatrix} 2(x_3 - x_1) & 2(y_3 - y_1) \\ 2(x_3 - x_2) & 2(y_3 - y_2) \end{vmatrix} \quad (5.8)$$

$$B = \begin{vmatrix} x_3^2 - x_1^2 + y_3^2 - y_1^2 + r_1^2 - r_3^2 \\ x_3^2 - x_2^2 + y_3^2 - y_2^2 + r_2^2 - r_3^2 \end{vmatrix} \quad (5.9)$$

$$X = A^{-1} * B \quad (5.10)$$

$$X = \begin{vmatrix} x_A \\ y_A \end{vmatrix} \quad (5.11)$$

Eşitlik 5.11 ile hesaplanan X matrisinin elemanları sırası ile A noktasının koordinat değerlerini içermektedir.

5.1.2. Cramer kuralı ile çözüm

Cramer kuralı ile çözüm yöntemi, lineer cebirde kullanılan bir yöntemdir. Bu yöntem, bir matrisin determinantını kullanarak lineer denklem sistemlerini çözmek için kullanılır. Eşitlik 5.7’de belirtilen matrisler yeniden düzenlenerek A, B, C matrisleri oluşturulur.

$$A = \begin{vmatrix} 2(x_3 - x_1) & 2(y_3 - y_1) \\ 2(x_3 - x_2) & 2(y_3 - y_2) \end{vmatrix} \quad (5.12)$$

$$B = \begin{bmatrix} x_3^2 - x_1^2 + y_3^2 - y_1^2 + r_1^2 - r_3^2 & 2(y_3 - y_1) \\ x_3^2 - x_2^2 + y_3^2 - y_2^2 + r_2^2 - r_3^2 & 2(y_3 - y_2) \end{bmatrix} \quad (5.13)$$

$$C = \begin{vmatrix} 2(x_3 - x_1) & x_3^2 - x_1^2 + y_3^2 - y_1^2 + r_1^2 - r_3^2 \\ 2(x_3 - x_2) & x_3^2 - x_2^2 + y_3^2 - y_2^2 + r_2^2 - r_3^2 \end{vmatrix} \quad (5.14)$$

Oluşturulan matrislerin sırası ile Δ_1 , Δ_2 ve Δ_3 determinantı hesaplanır. Hesaplanan determinantlar Eşitlik 5.15 ve 5.16'da kullanılarak $\underline{A}$ noktasına ait bilinmeyen koordinatlar hesaplanmaktadır.

$$x_A = \Delta_2 / \Delta_1 \quad (5.15)$$

$$y_A = \Delta_3 / \Delta_1 \quad (5.16)$$

5.2. Triangülasyon (Üçgenleme) Yöntemi

Triangülasyon yöntemi, bir nesnenin konumunu belirlemek için iki veya daha fazla referans noktasına yapılan gözlemle ya da referans noktalarından konumu belirlenecek noktaya yapılan gözlem sonucu, gözlem hatlarının açısı kullanılarak konum belirlemede kullanılan yöntemdir verilen genel addır. Bu yöntemde, trilaterasyon yönteminden farklı olarak, referans noktalarından konum belirlenecek noktaya olan mesafelerin değil aradaki gözlem hattının açısının ölçülmesi veya hesaplanması gerekmektedir.

Triangülasyon yönteminin temel çalışma prensibi konumu belirlenecek olan noktanın konumunu belirlemek için, koordinatları bilinen en az iki veya daha fazla referans noktasına ihtiyaç vardır. Her referans noktasından konumu belirlenecek noktaya olan açı ya da bu noktadan referans noktalarına olan gözlem hattının açısı belirlenir. Bu açılar, nesnenin referans noktalarına olan yönünü belirler. Sonrasında bu açılar kullanılarak, nesnenin konumunu veren üçgen veya üçgenler oluşturulur. Bu üçgenin köşeleri referans noktaları, kenarları ise nesnenin referans noktalarına olan mesafelerdir. Bu bilgilerden faydalanılarak aşağıda yer alan matematiksel eşitlikler yardımı ile konum hesabı gerçekleştirilebilir.


Hesaplama işlemi için referans noktalarının koordinatları (y_1, x_1) , (y_2, x_2) ve konumu belirlenecek noktanın(A) koordinatları (y_A, x_A) olarak tanımlanır. A noktasına referans noktalarından yapılan gözlem ile ölçülen semt (kuzey yönü ile yaptığı açı) açıları θ_1 , θ_2 olarak, bunun tam tersi olan A noktasından referans noktalarına yapılan gözlem sonucu ölçülen semt açıları θ_3 , θ_4 olarak tanımlanır. Tanımlanan açılara ait matematiksel eşitlikler aşağıdaki formüller ile tanımlanabilir.

$$\theta_1 = \arctan\left(\frac{y_A - y_1}{x_A - x_1}\right) \quad (5.17)$$

$$\theta_2 = \arctan\left(\frac{y_A - y_2}{x_A - x_2}\right) \quad (5.18)$$

$$\theta_3 = \arctan\left(\frac{y_2 - y_A}{x_2 - x_A}\right) \quad (5.19)$$

$$\theta_4 = \arctan\left(\frac{y_1 - y_A}{x_1 - x_A}\right) \quad (5.20)$$



Şekil 5.2. Triangulation yöntemi.

Şekil 5.2’de verilen Triangulation yöntemine ait ölçülen açılar her iki durum içinde verilmiştir. Eşitlik 5.17, 5.18, 5.19 ve 5.20’deki denklemler Bölüm 5.1’deki gibi düzenlendiğinde ve Cramer kuralına göre çözüm yapıldığında 1 ve 2 numaralı noktalardan A noktasına gözlem yapılan uygulama için A noktasının koordinatları Eşitlik 5.21 ve 5.22 ile hesaplanabilir.

$$y_A = \frac{(y_1 \tan \theta_2 - y_2 \tan \theta_1) + (x_2 - x_1) \tan \theta_2 \tan \theta_1}{\tan \theta_2 - \tan \theta_1} \quad (5.21)$$

$$x_A = \frac{(y_1 - y_2) + x_2 \tan \theta_2 - x_1 \tan \theta_1}{\tan \theta_2 - \tan \theta_1} \quad (5.22)$$

Tam tersi durumda yani A noktasından 1 ve 2 numaralı noktalara gözlem yapılan uygulama için A noktasının koordinatları Eşitlik 5.23 ve 5.24 ile hesaplanabilir.

$$y_A = \frac{(y_1 \tan \theta_4 - y_2 \tan \theta_3) - (x_2 - x_1) \tan \theta_4 \tan \theta_3}{\tan \theta_4 - \tan \theta_3} \quad (5.23)$$

$$x_A = \frac{(y_1 - y_2) + x_2 \tan \theta_4 - x_1 \tan \theta_3}{\tan \theta_4 - \tan \theta_3} \quad (5.24)$$

Bu yöntem her ne kadar daha az nokta ile konum tespiti gerçekleştirebilse de en büyük dezavantajı istasyon sayısının yükselmesi ile yapılacak hesaplamaların daha karmaşık bir hal almasıdır.

5.3. Multilaterasyon yöntemi

Multilaterasyon yöntemi, bir veya daha fazla nesnenin konumlarını belirlemek için kullanılan bir yöntemdir. Bu yöntem, bir veya birden fazla sinyal vericisinin ve dört veya daha fazla sinyal alıcısının kullanılması ile çalışmaktadır. Bu yöntemde sinyal vericisi olarak sinyal üreten ve yayınlayan aktif vericiler veya başka bir kaynaktan gelen sinyalleri yansıtan veya tekrarlayan pasif vericileri kullanılabilir. Sinyal alıcıları ise, vericilerden gelen sinyalleri almak ve işlemek için kullanılan donanımlardan oluşmaktadır.

Multilaterasyon yönteminin temel prensibi, vericilerden yayınlanan sinyalin alıcılara ulaşma süreleri veya süre farklarının mesafeye çevrilmesi esasına dayanmaktadır. Burada bahsedilen mesafe belirlemede kullanılan yöntemler TOA, TDOA vs. gibi yöntemlerdir. Bu yöntemler ile belirlenen mesafeler veya mesafe farkları, nesnenin hiperbolik eğriler, küreler veya daireler üzerindeki yerlerini belirlemede kullanılır. Sonrasında, bu eğrilerin, kürelerin veya dairelerin kesişim noktası, konumu belirlenecek noktanın koordinatlarını vermektedir.

Multilaterasyon yöntemi, trilaterasyon yöntemine benzemekte olup farklı olarak daha fazla referans istasyonuna ihtiyaç duyulmaktadır. Trilaterasyon yönteminde, en az üç referans istasyonu kullanılırken Multilaterasyon yönteminde, en az dört referans istasyonu kullanımı gerekmektedir. Bu şekilde trilaterasyon yöntemine göre daha doğru ve daha esnek sonuçlar verebilmektedir. Bu yöntemin avantajları arasında radar sistemlerine göre daha düşük maliyetli, daha esnek ve daha doğru konum belirleme imkânı sunması sayılabilir. Ayrıca, bu yöntem ile takibi yapılan hedeflerin yükseklik, hız ve kimlik gibi ek bilgileri de hesaplanabilmektedir. Bu özelliği ile bu yöntem günümüzde havayolu taşımacılığında etkin bir biçimde kullanılmaktadır. Bu yöntemin dezavantajları arasında ise alıcıların doğru konumlandırılması ve senkronize edilmesi,


sinyallerin yayılma hızının ve yolunun sabit olmaması ve zamanlayıcıların kalibre edilmesi gibi sorunlar sayılabilmektedir.

5.4. Parmak İzi Yöntemi

Önceki bölümlerde belirtilen konum belirleme yöntemleri çoğunlukla açı ve mesafe bilgisini kullanarak referans istasyonlarına dayalı olarak konumun hesaplandığı yöntemlerdir. Günümüz teknolojisinin gelişmesi ile regresyon modelleri, yapay sinir ağları gibi algoritmalar kullanılarak Parmak İzi yöntemi ile, bir nesnenin veya kişinin konumunu belirlemek mümkündür. Bu yöntemde önceden toplanmış veriler ve bunların konum bilgilerini içeren veri tabanlarından yararlanılmaktadır. Bu veri tabanları, kapalı alanlarda farklı noktalardan ölçülen sinyal gücü ve bu verinin ölçüldüğü konum bilgisini içermektedir. Bu bilgiler makine öğrenmesi tabanlı regresyon modellerine veya yapay sinir ağları gibi algoritmalara eğitim verisi olarak sunulur ve bu modeller eğitilerek ölçülen yeni bir RF sinyali ile modeldeki veriler kullanılarak en uygun eşleşmeyi bulmaya çalışır. Bulduğu en yakın ilişkiye göre ölçülen sinyalin koordinatları kullanıcıya sunulur.

Bu yöntemin en büyük avantajı sinyal alınan referans istasyon sayısına bir sınırlama getirmemesidir. Eğer yeterli sayıda eğitim noktası var ise tek bir istasyonla dahi bu yöntemin çalışması mümkündür. Fakat referans istasyon sayısının çoğalması ile belirlenen konum doğruluğu arasındaki ilişkinin doğru orantılı olması sebebi ile tek istasyon ile elde edilebilecek konum doğruluğu da sınırlıdır. Bu durum RSSI ile parmak izi yöntemi kullanarak konum belirlemeye yönelik hazırlanan örnek uygulama üzerinden anlatılacaktır.

Bilindiği üzere RSSI değeri ile mesafe arasında ters orantılı bir ilişki söz konusudur. Şekil 5.3 ile verilen uygulama senaryosunda V23 RF verici istasyonunu ifade etmektedir. Gezici RF istasyonu ile bu istasyondan 5 metre uzaklıktaki 1, 2, 3, 4 ve 5 numaralı noktalarda RSSI ölçümü ve bulundukları koordinatlar lokal koordinat sisteminde ölçülmüştür. Buna göre ortam koşulları değişmediği ve arada engel olmadığı bir durumda RSSI ölçümünde bu noktaların tamamında eşit değerler ölçülmüş olup ölçüm sonuçları Çizelge 5.1’de verilmiştir.




Şekil 5.3. Tek istasyon ile Parmak izi yöntemi kullanılarak konum belirleme.

Çizelge 5.1. Tek istasyondan yapılan RSSI ölçümleri.

Nokta Adı	Y(m)	X(m)	Ölçülen RSSI Değeri
			V23
1	16.235	107.699	248
2	15.283	109.837	248
3	6.382	107.587	248
4	7.529	110.095	248
5	6.739	108.885	248

Parmak izi yöntemi ile Random Forest regresyon modelinin bu çizelgeye göre 1, 2, 3 ve 4 numaralı noktalar ile eğitimi gerçekleştirilmiştir. Sonrasında eğitilen modelden 5 numaralı nokta için ölçülen 248 RSSI değeri için koordinat tahmini yapması istendiğinde modelin yaptığı tahminin bu noktaların ağırlık merkezinde bir konuma sahip olduğu ($T = Y=11.237, X=108.848$), fakat gerçek konumunun 3 ve 4 numaralı noktaya daha yakın olduğu bilinmektedir. Buna göre yapılan örnek uygulama Şekil 5.4'deki gibi bir yapıya göre revize edilerek V24 adında bir adet daha verici istasyonu eklendiğinde ve aynı noktalardan RSSI ölçümü yapılarak eğitim için kullanılan veri seti oluşturulduğunda bu veri seti Çizelge 5.2'deki gibi olmaktadır.



Şekil 5.4. İki istasyon ile Parmak İzi yöntemi.

Çizelge 5.2. İki istasyondan yapılan RSSI ölçümleri.

Nokta Adı	Y(m)	X(m)	Ölçülen RSSI Değeri	
			V23	V24
1	16.235	107.699	248	238
2	15.283	109.837	248	236
3	6.382	107.587	248	250
4	7.529	110.095	248	242
5	6.739	108.885	248	245

Çizelge 5.2 ile verilen noktalardan 1, 2, 3 ve 4 numaralı noktalara ait veriler ile eğitilen Random Forest regresyon modeline 5 numaralı nokta için tahmin yapması istendiğinde yaptığı koordinat tahmini 5 numaralı noktaya daha yakın koordinat değeri ($T1=7.491$, $X=109.123$) olarak elde edilmiştir. Bu örnek uygulamada da görüldüğü üzere parmak izi yöntemi ile konum belirlemede referans istasyon sayısının artışının koordinat tahminine doğrudan ciddi miktarda etki etmektedir.

Ayrıca bir verici istasyonuna 25 metre mesafede ölçülen RSSI değeri ile arada engel bulunulan durumda 8 metre mesafede ölçülen RSSI değeri birbirine yakın sonuçlar olabilmektedir. Eğitilen modelin bu durumu bilmemesi sebebi ile yaptığı tahmine göre konum doğruluğu yine düşük olmaktadır. Bu sebep ile bu yöntem ile konum belirlenirken çalışma sahasının farklı konumlarına yayılmış referans istasyonları kullanılması konum doğruluğunu oldukça arttıracaktır.

Bu yöntemin diğer bir avantajı da ölçülen sinyal özelliklerine göre doğrudan konum tahmini yapabilmesidir. Yani ölçülen sinyali mesafe veya açı gibi parametrelere dönüştürmeden veya trilaterasyon, triangülasyon gibi yöntemleri kullanmadan doğrudan konumu belirlemesidir. Bu durum da konumun daha fazla hata kaynağına (mesafe ve

açıya dönüşümde oluşabilecek hatalar veya trilaterasyon gibi yöntemlerde ortaya çıkan geometrinin yetersizliği gibi hatalar) maruz kalmadan belirlenmesine yol açmaktadır.

5.5. Karma Yöntemler

Bu yöntemler, önceki bölümlerde belirtilen yöntemlerin birleşimi veya farklı veri kaynaklarından yararlanarak konum belirlemeyi amaçlamakta olup bu yöntemler diğer yöntemlerin eksiklik veya dezavantajlı durumlarını ortadan kaldırılarak konum belirlemede doğruluk, güvenilirlik ve kapsama alanını artırmak için kullanılır. Örneğin, GPS, Wi-Fi, hücresel ağ, ivmeölçer, pusula gibi farklı sensör ve vericilerden gelen verileri birleştirerek konum belirleyen akıllı telefonlar bu yöntemin kullanımına örnek olarak verilebilir.

6. MATERYAL VE YÖNTEM

Bu çalışmada RSSI ile kapalı mekanlarda konum belirlemeye yönelik donanım ve yazılım geliştirilerek konum belirleme ve doğruluğun artırılmasına için deneyler yapılmıştır. RSSI değerleri, ortamın fiziksel özellikleri, sinyal yansımaları, engeller, gürültü ve parazit gibi faktörlerden etkilenmektedir. Bu nedenle, RSSI ile konum belirleme için donanım seçimi, geliştirilmesi, donanım ile verilerin toplanması ve verilerin filtrelenmesi için en uygun yöntemler araştırılmıştır. Veriler toplanırken ön işlemeye tabi tutularak istatistiksel yöntemler ile filtrelemeler yapılmış, filtrelenen verilerin mesafeye dönüştürülmesi için makine öğrenmesi tabanlı çeşitli regresyon algoritmaları kullanılmış olup bu yöntemlerden en başarılı olanları seçilmiştir. Başarılı bulunan yöntemler kullanılarak test ölçümlerinde elde edilen RSSI ile hem Trilaterasyon ve EKK (En Küçük Kareler) yöntemleriyle hem de parmak izi yöntemi ile koordinat belirlemesi yapılmıştır. Bu kapsamda kullanılan veya geliştirilen donanım, yazılım ve istatistiksel yöntemlere ilişkin detaylı bilgi sonraki bölümlerde verilmektedir.

6.1. Donanım

Yapılan çalışmada RSSI verisinin toplanması için günümüzde IOT alanında sıklıkla kullanılmakta olan LoRa modülasyonunu kullanan ve EBYTE firması tarafından geliştirilen E22-900T30D RF modülü tercih edilmiştir.



Şekil 6.1. Çalışmada kullanılan E22-900T30D model numaralı RF modülü.

E22-900T30D, yeni nesil LoRa yayılım spektrum teknolojisini, SX1262 çipini ve iletişim protokolü olarak da UART seri haberleşme protokolünü kullanmaktadır. Bu modül ISM bandı olan 850.125MHz~930.125MHz frekans aralığında çalışabilen (varsayılan 868.125MHz olarak ayarlı) ve sinyal çıkış gücü 30dBm'ye kadar çıkabilen yüksek güçlü bir vericiye sahiptir. Modül uzun mesafeli, düşük güç tüketimi ve yüksek hassasiyetli kablosuz iletişim sağlamak için tasarlanmıştır. Fabrika testlerine göre yerden yüksekliği 2 metre ve arada engel bulunmadığı alanlarda 10 km'ye kadar iletişim menzili sunduğu bildirilmektedir (URL-4). Modül çeşitli paket boyutlarında veri gönderim ayarına, kanal parametre ayarına, güç ayarına, iletim modu ayarına, uyku modu özelliği gibi birçok farklı özelliğe sahiptir. Ebyte RF modüllerinin bu özelliklerinin kullanımını sağlayan parametreleri ayarlamak için bilgisayar bağlantısında kullanılan dananım Şekil 6.2 ile verilmiştir.

Kullanılan RF modülü, TTL seviyesinde çıkış sağlamaktadır. Yani Modül üzerinde bulunan TX ve RX pinlere 0V ila 0.8V arasında bir voltaj gönderdiğinde, bunun düşük (0) sinyal olduğunu, 2V ila 5V arasında bir voltaj gönderdiğinde ise bunun yüksek (1) sinyal olduğunu anlayan bir mantık sistemine sahiptir. Modülün temel çalışma gerilimi ise 3.3V'dur. Modülün tercih edilmesindeki temel etkenler;

- Yüksek iletişim menzili,
- Veri gönderim hızının yüksek olması,
- İletişimdeki parazitleri en düşük seviyede tutan gömülü yazılıma sahip olması,
- Şifreli iletişim sağlama imkânı sunması,
- RSSI değerinin ölçümünü yine içerisinde yer alan gömülü yazılım ile yaparak gelen mesajın arkasına otomatik ekleyebilmesi,
- Düşük enerji tüketimine sahip olmasıdır.



Şekil 6.2. Ebyte RF modülünün bilgisayar bağlantısında kullanılan UART köprüsü.

RSSI ölçümünde RF modülünde kullanılan antenin, alınan veya gönderilen sinyalin iletişim menzilinde ve ölçülen RSSI değerine etkisi önemlidir. Çünkü alınan

sinyal gücü, antenin kazancı, yönlülüğü, polarizasyonu, bant genişliği ve eşleşmesi gibi özellikler tarafından etkilenmektedir. Bu kapsamda çalışmada kullanılan RF modülü için kullanılan anten seçiminde bazı faktörler göz önünde bulundurularak anten seçimi yapılmıştır. Bu faktörler aşağıda verilmiştir.

- Antenin kazancı, iletim mesafesini ve sinyal kalitesini artırmak için yüksek olmalıdır. Ancak, yüksek kazançlı antenler genellikle belirli bir yönde odaklanma özelliğine sahiptir. Bu da antenin doğru yönde hizalanması gerektiği anlamına gelir. Bu sebep ile bu tarz antenler RSSI ile sinyal geliş açısının tespitinde daha etkili olabilmektedir.
- Antenin polarizasyonu, RF modülünün polarizasyonu ile aynı olmalıdır. Polarizasyon, radyo dalgasının elektrik alanının yönüdür. Farklı polarizasyonlara sahip antenler arasındaki iletişim, sinyal kaybına neden olabilmektedir.
- Antenin bant genişliği, LoRa modülünün bant genişliğiyle uyumlu olmalıdır. Bant genişliği, antenin çalışabileceği frekans aralığıdır. Dar bant genişliğine sahip antenler, sinyal bozulmasına ve performans düşüşüne neden olabilir.

Bu faktörler ve maliyet göz önünde bulundurularak çalışmada kullanım için seçilen anten Şekil 6.3’de verilmiş olup üretici firma tarafından bilgi sayfasında iletilen özellikleri ise Çizelge 6.1 ile verilmiştir. Yapılan ölçümler sırasında bu anten ile yapılan RSSI ölçümlerinde aynı noktada antenin yönü değiştirildiğinde alınan RSSI değerinin de değiştiği görülmüştür. Bu sebep ile çalışma sırasında anten için sabit bir yön belirlenmiş olup yapılan tüm ölçümlerde bu yön korunmuştur.



Şekil 6.3. Çalışmada kullanılan anten (URL-5).

Çizelge 6.1. Çalışmada kullanılan antenin özellikleri (URL-5).


Özellik Adı	Değer
Çalışma Frekansı	868 ~ 915 MHz
Sinyal Kazancı	12 dBi
Polarizasyon	Dikey
Empedans	50 ohm
Çalışma Sıcaklığı	-40 ~ + 85 C
Boyut	27 cm

Çalışmada kullanılan RF modülü ve kullanılan anten ile iletişimin sağlanması için bir kontrolcüye ihtiyaç duyulmaktadır. Bu aşamada yapılacak iletişim için gönderilen verinin oluşturulması veya alınan verinin kullanıcıya aktarılabilmesi için kontrolcü kartı olan ESP32 kartı kullanılmıştır. ESP32, ESP8266'nın geliştirilmiş bir versiyonu olup Espressif Systems tarafından üretilen çok yönlü özellikler sunan güçlü bir mikrodenetleyici çipine sahiptir. Bu kartın başlıca özellikleri şunlardır.

- Wi-Fi ve Bluetooth 4.2 kablosuz iletişim donanımlarını içerisinde barındırır. Bu sayede Bluetooth donanımı ile RF modülünden alınan sinyaller ve RSSI değerleri akıllı telefon ve tabletler için geliştirilen Android tabanlı uygulamaya anlık gönderilebilmektedir. Bu sayede geliştirilen uygulama ile makine öğrenmesi ve diğer konum belirleme hesaplamaları yapılarak kullanıcıya mesafe ve koordinat gibi bilgiler gerçek zamanlı olarak sunulmaktadır.


- Tensilica Xtensa Çift çekirdekli 32-bit LX6 mikro işlemcisine (160 veya 240 MHz'de çalışan) sahiptir. Bu işlemci, yüksek performanslı uygulamalar için uygun olup ayrıca, düşük güç tüketimi için ULP (Ultra Düşük Güç, ing: Ultra Low Power) çekirdeği de bulunmaktadır (URL-7).
- Kart 448 kb ROM ve 520 kb SRAM belleğe sahiptir. Ayrıca, harici belleklerle de uyumludur (URL-7).
- SPI, UART, I2C, I2S gibi iletişim protokollerini desteklemektedir. Bu sayede uygulamada kullanılan RF modülü ile rahatlıkla kullanılabilir.
- Derin uyku, hafif uyku, dinamik frekans ölçeklendirme gibi güç tasarrufu modlarına sahiptir. Derin uyku modunda, 5 uA gibi çok düşük miktarda akım çekmektedir. Bu sayede bu kart ile beraber kullanılan RF modülü ile ve 4000 mAh taşınabilir güç kaynakları ile yapılan uygulamada tek şarjda 36 saate kadar çalışabilmektedir.
- Bu kartın programlanması için C, C++, MicroPython, Lua, JavaScript gibi diller kullanılabilir. Bu dillerin her birinin kendine has avantaj ve dezavantajları vardır. Hazırlanacak uygulamalar da uygun olan programlama dili seçilerek yüksek kullanılabilirlik sunmaktadır.

Çalışmada kullanılan donanımların çalışması için kullanılacak enerji, 4000 mAh güç kapasiteli ve 3.6 V çıkış gerilimine sahip taşınabilir güç kaynaklarından sağlanmıştır. Kullanılan donanımlar 10 cm × 10 cm büyüklüğünde bakır plaketler üzerinde Renzo Michitangi tarafından Github platformunda paylaşılan bağlantı şeması kullanılarak birleştirilmiştir.




Şekil 6.4. ESP32 ve Ebyte RF Modülü bağlantı şeması (URL-11).

Söz konusu şema (Şekil 6.4) referans alınarak iki farklı devre geliştirilmiştir. Bunlardan biri sinyal gönderen verici istasyonların olduğu devre diğeri ise vericilerden gelen sinyali alarak gerçek zamanlı olarak akıllı telefondaki uygulamaya gönderen devredir. Temelde her iki devrede aynı şema kullanılarak geliştirilmiştir. Fakat alıcı istasyon olarak kullanılacak devreye ek olarak RGB led eklenmiştir. Bu led istasyonun sinyal alıp almaması durumuna göre kırmızı ve yeşil olarak yanmaktadır. Uygulama için toplamda 4 adet verici istasyon olarak görev yapacak devre, 1 adet alıcı istasyon olarak görev yapacak devre olmak üzere 5 adet donanım geliştirilmiştir. Bakır plaket üzerinde geliştirilen bu donanımlardan alıcı olarak görev yapan istasyon Şekil 6.5’de ve verici istasyon Şekil 6.6’da gösterilmektedir. Geliştirilen donanımların adet maliyeti yaklaşık 25 Amerikan doları (16.11.2023 tarihi için) olmak üzere uygulamada kullanılan tüm donanımlar için yaklaşık maliyet 125 Amerikan dolarıdır.




Şekil 6.5. Uygulamada kullanılan ve vericilerden yayınlanan sinyalleri alan istasyon.



Şekil 6.6. Uygulamada kullanılan ve sinyal gönderen verici istasyon.

6.2. Yazılım

RF modülünün parametre ayarlarında yapılmak istenen değişiklikler Şekil 6.2 ile gösterilen usb UART köprüsü ve modülün üretici firması tarafından geliştirilen RF_Setting(E22-E90(SL)) V2.0 adlı uygulama ile yapılabilmektedir. Şekil 6.7 ile bu uygulama ve çalışmada kullanılan parametreleri belirtilmektedir.



Şekil 6.7. RF modülünün parametrelerinin ayarlanmasında kullanılan uygulama (URL-11).

Şekil 6.7’de verilen uygulamada kullanılan bu parametreler ve bunlara ait açıklamalar aşağıda verilmiştir.

Baud Rate: Bu parametre, UART iletişim hızını belirlemektedir. Çalışmada kullanılan RF modülü, 1200 bps ile 115200 bps arasında değişen sekiz farklı baud rate değerini desteklemektedir. Baud rate, veri aktarımının ne kadar hızlı olduğunu gösterir. Baud rate ne kadar yüksek olursa, veri aktarımı o kadar hızlı olur. Ancak, baud rate ile air rate arasında bir denge kurmak gerekir. Aksi takdirde veri kayıpları ve iletişim hataları ile karşılaşılabilir.

Air Rate: Bu parametre, saniyede iletilen bit sayısını ifade etmektedir. Çalışmada kullanılan RF modülü, 0.3 kbps ile 62.5 kbps arasında değişen sekiz farklı aktarım hızını desteklemektedir. Air rate ne kadar düşük olursa, veri iletimi o kadar yavaş olur, ancak aynı zamanda iletilen sinyalin gürültü ve parazitlere karşı dayanıklılığı da o kadar fazla olmaktadır. Bu nedenle, air rate değerini seçerken, iletim mesafesi, ortam koşulları ve uygulama gereksinimleri gibi faktörlerini dikkate almak gerekir.

Packet Size: Bu parametre, her bir veri paketinin boyutunu belirlemektedir. Çalışmada kullanılan RF modülü, 32, 64, 128 ve 240 byte paket boyutlarını desteklemektedir. Paket boyutu, veri aktarımının verimliliği ve güvenliği üzerinde etkilidir. Paket boyutu ne kadar küçük olursa, veri aktarımı o kadar verimli olur. Ancak, paket boyutu ne kadar büyük olursa, veri aktarımı o kadar güvenli olur.

Transmit Power: Bu parametre, RF modülünün veri gönderirken kullandığı gücü belirler. Çalışmada kullanılan RF modülü, 21 dBm ila 30 dBm arasında değişen 4 farklı güç değerini desteklemektedir. Güç, veri iletiminin menzili ve kalitesi üzerinde etkilidir. Güç ne kadar yüksek olursa, iletim mesafesi ve kalitesi o kadar iyi olmaktadır. Ancak, güç değeri arttıkça modülün enerji tüketimi ve ısı üretimi de o kadar fazla olmaktadır.

Channel RSSI: Bu parametre, modülün çalıştığı kanalın alınan sinyal gücünün (RSSI) ölçülüp ölçülmeyeceğini belirlemektedir.

Key: Bu parametre, modülün veri şifreleme anahtarını belirler. Çalışmada kullanılan RF modülü, 0 ila 255 arasında değişen 256 farklı anahtar değerini desteklemektedir. Bu özellik sayesinde şifreli haberleşme ve çevredeki diğer IOT cihazlarının haberleşmesinden etkilenmemek mümkündür.

Packet RSSI: Bu parametre, modülün her bir veri paketini aldıktan sonra RSSI değerini ölçüp ölçmeyeceği belirlemektedir. Çalışmada bu parametre aktif hale getirilerek gelen sinyalin gücü otomatik bir şekilde ölçülmesi sağlanmıştır.

Address: Bu parametre, modülün veri alışverişinde kullandığı adresi belirler. Bu parametre, veri iletiminin güvenliği ve ayırımı üzerinde etkili olmaktadır.

Channel: Bu parametre, modülün çalıştığı kanalı belirler. Çalışmada kullanılan RF modülü, 850 MHz ila 930 MHz arasında değişen 80 farklı kanal değerini desteklemektedir.

Relay: Bu parametre, modülün tekrarlayıcı (repeater) ağ modunda çalışıp çalışmadığını belirler. Bu özellik daha çok iletişim menzilinin artırılmasında kullanılmaktadır.

LBT: Bu parametre, modülün dinle-önce-gönder (ing:listen-before-talk) fonksiyonunu etkinleştirip etkinleştirmedini belirler. Dinle-önce-gönder fonksiyonu, modülün veri göndermeden önce kanalın boş olup olmadığını kontrol etmesini sağlamaktadır. Kanal boş ise, veri gönderilir, dolu ise veri gönderme ertelenmektedir. Bu sayede veri kaybı en aza indirilebilir.

WOR Role: Bu parametre, modülün çalışma rolünü belirlemektedir. Bu parametre modülün, alıcı, verici veya hem alıcı hem verici rolünde çalışmasını

sağlamaktadır. Bu parametre, veri iletiminin yönlendirilmesi ve ayrımı üzerinde etkilidir. Normal rol modunda, modül sadece belirli bir adrese sahip olan verileri almakta veya göndermektedir. Yayın rol modunda, modül tüm verileri almakta veya göndermektedir. Çoklu noktaya rol modunda, modül birden fazla adrese sahip olan verileri almakta veya göndermektedir.

WOR Cycle: Bu parametre, modülün uyku-önce-dinle fonksiyonunun çalışma döngüsünü belirlemekte olup, modülün enerji tüketimi ve veri alımı üzerinde etkili olmaktadır. Döngü değeri, modülün uyku modunda kalma süresini belirlemekte olup döngü değeri ne kadar büyük olursa, modül o kadar uzun süre uyku modunda kalır. Ancak, modül uyku modundayken veri alamayacağı unutulmamalıdır.

Tran Mode: Bu parametre, modülün veri iletim modunu belirlemektedir. Modülün, bu parametresi “Normal” veya “Fixed” olarak ayarlanabilmektedir. Şeffaf modda, modül verileri olduğu gibi gönderip veya almaktadır. Fixed modda ise, modül verileri LoRa protokolüne göre kodlar ve sadece belirtilen adres ve kanaldan veri alır veya gönderir.

Parity: Bu parametre, modülün UART iletişimde kullandığı parite bitini belirler. Parite biti, verilerin doğruluğunu kontrol etmek için kullanılmaktadır.

Bu değerlerden air rate ve packet size değerleri ne kadar düşük olursa iletişim menzili o kadar yüksek ve sinyalin parazitlerden etkilenme oranı o kadar düşük olmaktadır. Yapılan çalışmada RF modüllerinin göndereceği veri boyutu çok küçük olması sebebi ile bu parametreler en düşük seviyede tutulmuş olup veri kaybı yaşanmasının önüne geçilmiştir.

Çalışmada parametreleri ayarlanan RF modülü hazırlanan devredeki yuvasına takıldıktan sonra bu modülün kullanılabilmesi için ESP32 kartının bu modüle gönderilecek veriyi iletmesi veya gelen veriyi alması gerekmektedir. Bunun için ESP 32 kartının ayrıca programlanması ve iletişim sağlanan pinlerin karta bildirilmesi gerekmektedir. ESP 32 kartları Arduino IDE, PlatformIO, VS Code, Eclipse gibi IDE (Entegre Geliştirme Ortamı, ing: Integrated Development Environment)’ler ile programlanabilmektedir. Bu uygulamalardan Arduino IDE, Arduino kartlarını programlamak için geliştirilen açık kaynak kodlu bir yazılım geliştirme ortamıdır. Ayrıca C ve C++ dillerini kullanarak kod yazmaya, derlemeye ve kontrolcü kartlarına yüklemeye olanak tanımaktadır. Fakat Arduino IDE her ne kadar Arduino kartları için geliştirilmiş bir IDE olsa da açık kaynaklı yapısı sayesinde ESP32 ve diğer birçok kontrolcü kartlarını programlamada günümüzde aktif olarak kullanılmaktadır.

Yapılan çalışmada kullanıcı arayüzü kolaylığı ve geniş kütüphane kaynağına sahip olması sebebi ile Arduino IDE (versiyon:2.2.1) uygulaması tercih edilerek ESP 32 kartları programlanmıştır. Bu kapsamda C programlama dili kullanılarak bu çalışma için iki adet program geliştirilmiştir. Bu programlardan verici RF istasyonları için geliştirilen program verici istasyonların belirli bir zamansal periyotta yayın yapmasını sağlamaktadır. Uygulamada her verici için farklı bir istasyon adı tanımlanmış olup bunlar sırası ile V23, V24, V25 ve V26'dır. Vericilere geliştirilen bu uygulama yüklenirken sadece istasyon kimlik adı değiştirilerek yüklenmektedir. Bu verici istasyonlar kimlik adlarını kullanarak yayın yapmaktadırlar. Bu sayede alıcı istasyon aldığı sinyalin hangi vericiye ait olduğu tespit etmektedir. Uygulama yüklendikten sonra verici istasyonlar arasında veri gönderimi için bir zaman senkronizasyonu yapılması gerekmektedir. Çünkü alıcı istasyona 4 vericiden aynı anda veya çok düşük zaman aralıklarında (200 ms ve daha düşük aralıklar) veri geldiğinde alıcı modül tüm verileri işleyememektedir. Senkronizasyon işlemi şu şekilde yapılmaktadır.

- Vericilere enerji verildikten sonra V23 ve V24 istasyonlar üzerinde bulunan ESP32 kartındaki dahili mavi led yanması beklenir. Led yandıktan sonra bu kartlardaki reset tuşuna aynı anda basılır.
- Sonrasında bu istasyonlar üzerinde bulunan dahili led tekrar yanar ve söndüğünde diğer iki istasyonda ki reset tuşlarına aynı anda basılır. Bu sayede zaman senkronizasyonu yapılarak istasyonlardan iki tanesi veri yayını yaparken diğer ikisi uyku modunda çalışmaktadır.

Arduino ile geliştirilen diğer uygulama alıcı istasyon için geliştirilmiştir. Bu uygulama vericilerden gelen sinyalin geldiği istasyon kimliğini ve sinyalin ölçülen RSSI değerini, ESP32 üzerinde dahili olarak bulunan Bluetooth'u kullanılarak akıllı telefona gönderilmesini sağlamaktadır. Ayrıca sinyalin olup olmaması durumuna göre alıcı üzerinde bulunan RGB ledi kırmızı ya da yeşil olarak yakmaktadır.

Alıcı istasyonun toplayarak Bluetooth ile gönderdiği veriler akıllı telefonda bulunan ve Android işletim sistemi üzerinde çalışan uygulama ile alınır. Bu uygulama Android Studio (Sürüm: Android Studio Flamingo 2022.2.1 Patch 2) yazılım geliştirme platformunda java yazılım dili kullanılarak geliştirilmiştir. Konum belirlemeye yönelik tüm hesaplamalar, verilerin kaydedilmesi, makine öğrenmesi modelleri ile mesafe tahminlerinin yapılması ve parmak izi yöntemi ile koordinat belirlenmesi gibi işlemlerin tamamı bu uygulama içerisinde yapılır. Bu uygulamada kullanılan yazılım dili java olmasına karşın çalışmada kullanılan makine öğrenmesi modelleri Python programlama dili ile çalışabilmektedir. Bu sorunun çözümü için Chaquo adı verilen bir kütüphane kullanılarak Python kodları ile yazılan makine öğrenmesi algoritmaları Android Studio içerisinde kullanılabilmektedir.

Şekil 6.8. Android işletim sistemi için geliştirilen konum belirleme uygulaması.

Uygulama açıldığında Şekil 6.8'deki gibi bir arayüz kullanıcıyı karşılar. Bu ekranda bağlantı, veri akışı, veri ölçümü ve sonuçların tamamı görüntülenebilmektedir. ESP32 kontrolcü kartında dahili olarak bulunan Bluetooth donanımının MAC (Media Access Control) adresi vardır. Geliştirilen uygulamada verilen adres uygulama ile

varsayılan olarak gelmekte olup farklı bir cihaza bağlanmak istediğinde o cihazın MAC adresi eski adresin yerine girilerek bağlan butonuna basmak yeterlidir. Bağlantı sağlandığında Bağlı cihaz adı ve cihazın anlık olarak gönderdiği veriler uygulamanın üst kısmında bulunan “Bağlı Cihaz:” ve “Alınan Veri:” kısmında görüntülenecektir. Bu şekilde uygulama ölçüm yapmaya hazır hale gelmiş olup “Başlat” butonuna basıldığında ölçümlere başlanmış olacaktır. Bağlantı sağlanan ve ölçümlere başlanan bir uygulama arayüzü Şekil 6.9 ile verilmiştir.

RSSI ile Konum Belirleme

MAC Adresi: D4:D4:DA:5E:03:C2 Bağlantıyı Kes

Bağlanılan Cihaz: ESP32_ALICI_BT

Eğitim Verisi Toplama Modu ☐ Alınan Veri: V23 242

İptal Ölçüm Durumu: %70

Alınan RSSI	Belirlenen Mesafe
V23:(10) 242	V23:
V24:(10) 188	V24:
V25:(4) 234	V25:
V26:(4) 230	V26:

Bulunulan Bölge:

Belirlenen Koordinatlar

☒ Trilaterasyon ☐ Parmak İzi

Dosya Adı: Test ölçüm 30122023

Nokta Adı: 1

Y:

X:

Kaydet

Şekil 6.9. Geliştirilen konum belirleme uygulamasında ölçümün yapılması.

Şekil 6.9’da başlanılan bir ölçüm gösterilmektedir. Gösterilen ölçüm durumu %70 olup anlık olarak istasyonlardan alınan sinyalin son RSSI değeri ve o istasyondan toplam kaç veri alındığı “Alınan RSSI” kısmında gösterilmektedir. Uygulama her vericiden 10 adet RSSI ölçüm verisi alındığında ölçüm oranı 100’e tamamlanacak olup alınan RSSI değerleri için filtreleme yapılarak belirlenen RSSI değerleri Şekil 6.10’da olduğu gibi “Alınan RSSI” kısmında kullanıcıya bildirilecektir.

RSSI ölçümü tamamlanmasına müteakiben önceden belirlenen ve eğitilen makine modelleri kullanılarak mesafe ve parmak izi yöntemine göre koordinat belirlenir. Burada

her iki yöntem ile hesaplanan koordinatlar alt kısmında yer alan kutular (Trilaterasyon veya Parmak izi) işaretlenerek istenen yöntemin koordinatının görüntülenmesi sağlanır. Son olarak belirlenen koordinatlar ve nokta adı, “Dosya Adı:” kısmında girilen iş adı kullanılarak .txt dosya biçiminde kaydet butonu kullanılarak kayıt edilir. Kayıtların tutulduğu yer dosya adı kısmının yanında bulunan klasör işaretli buton kullanılarak görüntülenebilmektedir. Tamamlanmış bir ölçüm sonucunu gösteren uygulama ekranı Şekil 6.10’daki gibidir.

The screenshot displays the 'RSSI ile Konum Belirleme' (RSSI Location Determination) application interface. At the top, the MAC address is 'D4:D4:DA:5E:03:C2' with a 'Bağlantıyı Kes' (Disconnect) button. The connected device is 'ESP32_ALICI_BT'. The 'Eğitim Verisi Toplama Modu' (Training Data Collection Mode) is turned off, and the received signal strength is 'Alınan Veri: V24 195'. A 'Başlat' (Start) button is present, and the measurement status is 'Ölçüm Durumu: %100'.

Alınan RSSI	Belirlenen Mesafe
V23:239,75	V23:6,79
V24:188,60	V24:38,66
V25:245,70	V25:10,36
V26:237,80	V26:38,39

Below the table, the location is 'Bulunulan Bölge:Orta' and the determined coordinates are 'Belirlenen Koordinatlar'. The 'Trilaterasyon' (Trilateration) method is selected with a checked checkbox, while 'Parmak İzi' (Fingerprint) is unselected. The file name is 'Dosya Adı: Test ölçüm 30122023' and the point name is 'Nokta Adı: 1'. The coordinates are 'Y:98.213' and 'X:98.209'. A 'Kaydet' (Save) button is at the bottom.

Şekil 6.10. Geliştirilen konum belirleme uygulaması ölçüm sonuçlarının görüntülenmesi.

Söz konusu uygulama ile eğer eğitim verisi toplanıyor ise üst kısımda yer alan “Eğitim Verisi Toplama Modu” seçeneği açık hale getirilmelidir. Bu mod açıkken tamamlanmış bir ölçüm sonrasında elde edilen RSSI değerlerine ait ham ölçümler ve nokta numarası “Dosya Adı” kısmına yazılan .txt dosyası içerisine kayıt edilmektedir. Böylelikle bu uygulama ile aynı zamanda eğitim verileri de toplanabilmektedir.

Bu uygulamada kullanılan makine modellerinin eğitilmesi, değerlendirilmesi, hiper parametre optimizasyonu ile modeller için en uygun parametrelerin belirlenmesi gibi tüm işlemler Python programlama dili kullanılarak oluşturulan algoritmalar ile yapılmıştır. Bu kapsamda VS Code IDE (versiyon:1.84.1)'si ve Python (versiyon:3.11.5) programlama dili ile 3 adet algoritma geliştirilmiştir. Bu algoritmalar şunlardır;

- Modeli eğiten, parametreleri ayarlayan ve test eden algoritma,
- Trilaterasyon ve EKK kullanarak koordinatları hesaplayan algoritma,
- Parmak izi yöntemi ile koordinat belirleyen algoritmadır.


Bu algoritmalarından geliştirilen hiper parametre optimizasyon algoritması ile kullanılacak parametre değerlerinin belirlenmesi ve test verileri ile modelin test işlemi yapılmaktadır. Ardından parametreleri belirlenen modellerin Trilaterasyon, EKK ve Parmak İzi yöntemlerine göre koordinatları hesaplamaktadır. Koordinatların belirlenmesi ile elde edilen sonuçlar istatistiksel yöntemlerle değerlendirilerek çalışmada kullanılacak modellerin ve yöntemin seçimi yapılarak Android uygulamasına bu modeller ve yöntemler entegre edilmektedir.

6.3. Yöntem

Yapılan uygulamada verici istasyonlar istasyon kimlik adını belirli periyotlarda sürekli olarak yayınlamaktadır. Alıcı istasyon gelen sinyalleri işleyerek geldiği istasyon adını ve sinyalin RSSI değerini metin veri formatında gerçek zamanlı olarak Bluetooth ile akıllı telefonda bulunan Android uygulamasına gönderir. Bu uygulama her istasyondan 10 epok olacak şekilde verileri toplar. Her istasyondan 10 adet RSSI ölçümü yapıldıktan sonra bu verileri istatistiksel yöntemler kullanarak filtreler. Sonrasında bu verilerden oluşturulan bir veri seti mesafe tahmini ve parmak izi yöntemi için regresyon modellerinin eğitiminde kullanılır. Regresyon analizi ile bu modellerden başarılı olanları seçilerek mobil uygulamaya çalışma sahasında kullanılabilmesi için entegre edilir. Böylelikle uygulama sahasında yapılacak gerçek zamanlı uygulamada kullanıcıya mesafe ve koordinat değerlerini sunulabilmektedir. Burada verilerin filtrelemesinde kullanılan istatistiksel yöntemler, makine öğrenmesi modellerinin eğitiminde kullanılan veri seti yapısı, modellerin değerlendirilmesi, en iyi modelin belirlenmesinde kullanılan yöntemler ve uygulama sahası hakkında sonraki bölümlerde detaylı açıklamalar yapılmıştır.

6.3.1. Uygulama Sahası

Uygulama sahası olarak TEİAŞ 17.Bölge Müdürlüğü binasının 1. Katı kullanılmıştır. Binanın iç cephe ölçüsü 77.00 m × 18.60 m uzunluğa sahiptir. Bu katın içeriği çalışma odaları, toplantı salonu, arşiv, wc, asansör, çay ocağı, acil çıkış merdiveni ve depodan oluşmaktadır. Katta bulunan odalar, özel kullanım alanı olması sebebi ile yapılan uygulamaya dahil edilememiş olup Şekil 6.11 ile verilen ve görselde mavi ile taralı alan ölçümlerin ve testlerin yapıldığı alan olarak kullanılmıştır. Şekle göre uzun koridorların genişliği 2.10 metre ve orta alana kadar uzunlukları 35.35 metredir. Orta alan olarak belirtilen kısmın ise uzun kenarı 18.60 metre, kısa kenarı 6.30 metredir. Bu alanlara ait resimler Şekil 6.12 ve 6.13 ile verilmiştir.



Şekil 6.11. Uygulama sahası.




Şekil 6.12. Uygulama sahasında K26(soldaki resim) ve K24(sağdaki resim) adı verilen koridorlar.




Şekil 6.13. Uygulama sahasında Orta Alan adı verilen kısım.

Şekil 6.11’de gösterilen uygulama sahasında verici istasyonların konumu bir önceki bölümde bahsedilen sebeplerden ötürü iki farklı geometride yerleştirilmiştir. Buna göre ölçümlerde kullanılan vericilerin yerleşimi Uygulama 1 ve Uygulama 2 adı ile Şekil 6.14 ve 6.15’de gösterilmektedir. Ayrıca verici istasyonlarından V24 ve V26 adlı vericiler her iki uygulamada da sabit olması sebebi ile bulundukları koridorlar K24 koridor ve K26 koridor olarak isimlendirilmiştir.



Şekil 6.14. Uygulama 1 için verici istasyonların yerleşimi.



Şekil 6.15. Uygulama 2 için verici istasyonların yerleşimi.

6.3.2. Verilerin toplanması ve filtrelmesi

Yapılan çalışmada makine öğrenmesi tabanlı regresyon modellerinin eğitimi için uygulama sahası 1 ve 2 için yani Şekil 6.14 ve 6.15’de gösterildiği şekilde uygulama sahasına verici istasyonlar zeminden 1.05 metre yükseklikte yerleştirilmiştir. Mavi ile taralı alanlarda Çizelge 6.2’de detayları verilen ölçümler yerden 1 metre yükseklikte bulunan alıcı RF istasyonu ile yapılmıştır. Toplanan veriler uygulama sahasının tamamından homojen olarak yayılmış noktalardan toplanmaya çalışılmış .txt uzantılı dosyaya yapılan ölçümlere ilişkin veriler kayıt edilmiştir.

Çizelge 6.2. Eğitim ve test verisi için yapılan ölçümler.

	Eğitim Verisi				Toplam	Test Verisi	
	1. Ölçüm Tarihi	1.Ölçü Sayısı	2. Ölçü Tarihi	2.Ölçü Sayısı		Ölçüm Tarihi	Ölçü Sayısı
Uygulama Sahası 1	31.07.2023	315	6.08.2023	319	634	14.10.2023	92
Uygulama Sahası 2	26.08.2023	323	9.09.2023	318	641	15.10.2023	92

RSSI ölçümleri her noktada 4 istasyondan 10 epok RSSI değeri toplanarak yapılmış olup toplamda 40 adet RSSI değeri ölçüldükten sonra ölçülen RSSI değerleri filtrelemeye tabi tutulmuştur. Bu filtrelemenin amacı ölçümler sırasında çevresel etkilerden dolayı veya alıcı ve verici arasına hareketli bir engel girmesi gibi sebeplerden dolayı ölçü grubuna giren hatalı ölçümlerin ölçü grubundan çıkarılmasını sağlamaktır. Bu filtreleme eğitim verilerinin toplandığı sırada kullanılmamakta olup toplanan ham veriler Python’da geliştirilen algoritma içinde parametre ayarlamadan önce otomatik yapılmaktadır. Konum belirleme sırasında ise geliştirilen mobil uygulamada içerisinde gerçek zamanlı olarak yapılmaktadır. Bu sayede makine öğrenmesi modelleri tahmin yaptığı esnada girdi olarak sunulan RSSI değerinin eğitimde kullanılan RSSI değerleri gibi çevresel etkilerden arındırılarak tahmin doğruluğunun sabit kalması amaçlanmaktadır.

Çizelge 6 3. Uygulama sahasında bir noktada yapılan RSSI ve mesafe ölçümleri.

İstasyon Adı	Ölçülen RSSI Değerleri	Ölçümün Yapıldığı Mesafe(m)
V23	224, 236, 236, 236, 236, 236, 236, 237, 236, 236	13.36
V24	232, 232, 231, 231, 231, 231, 231, 231, 232, 232	33.03
V25	230, 228, 228, 231, 228, 229, 228, 229, 228, 228	7.72
V26	200, 200, 201, 201, 201, 200, 201, 201, 201, 201	43.9

Çizelge 6.3’de uygulama sahasında rastgele bir noktada yapılan ölçümlerden alınan gerçek veriler yansıtılmakta olup görüldüğü üzere V23 numaralı vericiden alınan birinci sinyalin RSSI ölçüsü diğer 9 adet ölçüme göre oldukça hatalıdır. Yapılan çalışmada işte bu gibi hatalı veriler Standart Sapma, Çeyrekler Açıklığı, Z Skoru, Modifiyeli Z Skoru yöntemleri ile ayıklanmaya çalışılmıştır. Birden fazla yöntem ile bu filtreleme işlemi yapılmasının sebebi, her bir yöntemin ölçüm grubundaki dağılımı farklı değerlendirerek kendine has bir filtreleme yapmasıdır. Bu yöntemler ile yapılan filtrelemeler sonucu ölçüm grubundan hatalı görülen ölçümler çıkarılmış olup kalan ölçülerin aritmetik ortalaması alınarak RSSI değerleri belirlenmiştir. Bu filtreleme yöntemleri dışında ayrıca herhangi bir filtrelemeye tabi tutulmayan ölçülerinde ayrıca aritmetik ortalaması hesaplanmıştır. Böylece herhangi bir filtreleme yapılmayan ölçümlerinde performansları gözetlenerek değerlendirilmeye tabi tutulmaktadır.

Sonuç olarak bir noktada beş farklı yöntem ile RSSI değeri belirlenmektedir. Bu veriler kullanılarak çalışma sahasında regresyon modelleri ile farklı kombinasyonlarda kullanılarak en iyi uyumun yakalanması, RSSI değerinin maruz kaldığı dış etkilerin en aza indirilmesi ve en yüksek doğrulukta konum ve mesafe belirleyen kombinasyonun seçilmesi amaçlanmaktadır. Ayrıca RSSI ölçümleri sırasında her ölçüm noktasının koordinatları lokal koordinat sisteminde TOPCON (model: GPT-9003M) Total Station yardımı ile ölçülmüştür. Ölçülen koordinatlar yardımı ile mesafe belirleyecek regresyon modellerinin eğitim için ihtiyaç duyduğu noktanın istasyonlara olan mesafesi Eşitlik 6.1 (Öklid mesafe denklemi) ile hesaplanmaktadır.

$$d = \sqrt{(y_i - y_A)^2 + (x_i - x_A)^2} \quad (6.1)$$

Eşitlik 6.1’de d referans istasyon ve alıcı arasındaki mesafeyi, y ve x değişkenleri bu konumlara ait koordinat değerlerini ifade etmektedir.

6.3.2.1. Standart Sapma

İstatiksel filtrelemede kullanılan yöntemlerden olan standart sapma için matematiksel denklemler aşağıdaki eşitlikler ile verilmiştir.

$$\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n} \quad (6.2)$$

$$s = \sqrt{\frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n - 1}} \quad (6.3)$$


$$t = 2s \quad (6.4)$$

$$|x_n - \bar{x}| > t \quad (6.5)$$

Bu denklemlere göre $\bar{x}$ veri setinin aritmetik ortalamasını n veri setinin eleman sayısını, s standart sapmayı ve t eşik değerini ifade eder. Yapılan hesaplamalarda hesaplanan standart sapmanın iki katı eşik değeri kabul edilerek dizinini her bir elemanı 6.5’de gösterilen eşitliğe yerleştirilerek kontrol sağlanmaktadır. Buna göre eşitliği sağlayan eleman hatalı ölçüm kabul edilerek ölçü grubundan çıkarılmaktadır.

6.3.2.2. IQR (Çeyrekler açıklığı)

Filtrelemede kullanılan istatiksel yöntemlerden olan çeyrekler açıklığı yöntemi bir veri kümesinin değişkenliğini veya yayılımını ölçmek için kullanılan yöntemlerdendir. Bu yöntemde veri gurubu 4 parçaya ayrıldıktan sonra belirlenen sınır değerleri dışında kalan verileri aykırı değer olarak kabul etmektedir. Burada veri gurubunun 4 parçaya ayrıldığı noktalar Q_1 , Q_2 ve Q_3 olarak (Şekil 6.16) isimlendirilmektedir. Burada Q_2 aynı zamanda ortanca(medyan) değerini ifade etmektedir. Matematiksel olarak hesaplama adımları aşağıda yer alan eşitlikler ile belirtilmiştir.



Şekil 6.16. IQR ile veri gurubunun parçalara ayrılması (Kılınç, 2019).

$$x_{(i)} \leq x_{(i+1)} \leq \dots \leq x_{(N)} \quad (6.6)$$

Eşitlik 6.6 ile veri seti küçükten büyüğe doğru sıralanır. N veri sayısını, $x_{(i)}$ i. sıradaki veriyi ifade etmekte olup veri dizisindeki en küçük sayısal değere sahip elemanı temsil etmektedir.

$$Q_1 = \left\lceil \frac{\text{alt yüzdelik dilim}}{100} \times N \right\rceil \quad (6.7)$$

$$Q_3 = \left\lceil \frac{\text{üst yüzdelik dilim}}{100} \times N \right\rceil \quad (6.8)$$

Burada, Q_1 ve Q_3 sırasıyla alt ve üst yüzdelik dilimdeki eleman sayısının kendisinden büyük en yakın tam sayı değerini ifade eder. Yapılan çalışmada alt yüzdelik dilim %30 üst yüzdelik dilim %70 olarak seçilmiştir.

$$IQR = Q_3 - Q_1 \quad (6.9)$$

Eşitlik 6.9 ile çeyrekler açıklığı hesaplanır. Sonrasında alt ve üst eşik değerleri bulunması için Eşitlik 6.10 ve 6.11’de verilen formülден yararlanılır (URL-10). Bu çalışma için çeyrekler açıklığı çarpanı olan k değeri 1.5 olarak seçilmiştir.

$$T_A = Q_1 - k.IQR \quad (6.10)$$

$$T_U = Q_3 + k.IQR \quad (6.11)$$

Alt ve üst eşik değeri hesaplandıktan sonra veri setindeki ölçü değerleri sırası ile aşağıda verilen Eşitlik 6.12’de x_i yerine yerleştirildiğinde eşitliği sağlayan değer hatalı kabul edilir.

$$x_i < T_A \text{ veya } x_i > T_U \quad (6.12)$$

6.3.2.3. Z Skoru Yöntemi

Z skoru, bir değişkenin belirli bir noktadaki dağılımının standart sapma birimleri cinsinden merkezden ne kadar uzakta olduğunu gösteren bir ölçüdür. Z skoru, normal

dağılımın standart sapmasına göre hesaplanır ve negatif veya pozitif değer alabilmektedir. Z skoru için daha önce standart sapma hesaplamasında gösterilen eşitlikler yardımı ile $\bar{x}$ (aritmetik ortalama) ve s (standart sapma) değerleri hesaplanır. Sonrasında aşağıda yer alan Eşitlik 6.13 (Santhanakrishnan ve Senthooan, 2022) kullanılarak her veri noktası için Z Skor değeri hesaplanır. Z skorunun mutlak değeri eşik değerinden büyük olan ölçüler, uyuşumsuz ölçüler olarak kabul edilir. Yapılan çalışmada Z Skor değeri için eşik değeri 1 olarak kabul edilmiştir. Yani hesaplanan $|z_i|$ değerinin 1'den büyük olduğu ölçü değerleri bu çalışmada hatalı kabul edilmiştir.

$$z_i = \frac{x_i - \bar{x}}{s} \quad (6.13)$$

6.3.2.4. Modifiyeli Z Skor Yöntemi

Modifiyeli Z Skor yöntemi ile skor hesaplanması, z skor yöntemine benzerdir. Modifiyeli z skor yöntemi, veri kümesindeki her bir değeri, veri kümesinin ortanca değerinden ne kadar uzakta olduğunu gösteren bir değere dönüştürmek için kullanılan bir yöntemdir. Bu yöntem, veri kümesinde uyuşumsuz değerler veya aşırı değerler olduğunda, standart z skor yönteminden daha güçlü bir normalizasyon yöntemi sağlamaktadır. Matematiksel olarak hesaplama adımları aşağıda yer alan eşitlikler ile belirtilmiştir.

$$x_{(i)} \leq x_{(i+1)} \leq \dots \leq x_{(N)} \quad (6.14)$$

Burada veri seti küçükten büyüğe doğru sıralanır. N veri sayısını, $x_{(i)}$ i. sıradaki veriyi ifade etmekte olup veri dizisindeki en küçük sayısal değere sahip elemanı temsil etmektedir. Sonrasında veri dizisinin ortanca değeri bulunur. Bu veri dizisi eleman sayısı çift sayı ise ortadaki iki elemanın ortalaması bu ortanca değeri verir. Sonrasında Eşitlik 6.15'deki formülde gösterildiği üzere veri dizisindeki her bir değerden medyan çıkartılır ve mutlak değerleri alınarak bir dizi oluşturulur. Bu dizinin medyanı MAD değerini verir (Iglewicz ve Hoaglin, 1993).

$$MAD = \text{medyan}(|x_i - \bar{x}|) \quad (6.15)$$

$$m_i = \frac{c \cdot (x_i - \tilde{x})}{MAD} \quad (6.16)$$

Son olarak Eşitlik 6.16'daki formül ile her bir elemanın Modifiyeli z skor değeri hesaplanır. Bu eşitliğe göre m_i modifiyeli z skorunu, x_i skor hesaplanacak değeri, $\tilde{x}$ veri kümesinin medyanı, MAD veri kümesinin medyan mutlak sapmasını ve c ise veri kümesinin dağılımını ifade etmekte olup grafiksel veya analitik yöntemler kullanılarak hesaplanabilmektedir. Çalışmada c değeri yapılan deneyler sırasında elde edilen ölçümlere göre 0.6745(normal dağılım için) olarak sabit kabul edilmiştir. Hesaplanan m_i değeri eşik değerinden büyük olduğu ölçü hatalı ölçü olarak kabul edilmektedir. Yapılan çalışmada eşik değeri olarak 0.75 kabul edilmiştir.

Sonuç olarak belirtilen filtreleme yöntemleri kullanılarak Çizelge 6.3'de belirtilen RSSI değerleri filtrelenmiş olup hatalı görülen ölçümler ve hesaplanan ortalama RSSI değeri Çizelge 6.4 ile gösterilmektedir. Çizelgede Standart Sapma (STD), Çeyrekler Açıklığı (IQR), Z Skor (ZS), Modifiyeli Z Skor (MZS) ve herhangi bir filtreleme kullanılmayan sonuçlar Filtresiz adlı sütunlarda belirtilmiştir.

Çizelge 6.4. Filtreleme sonucu elde edilen RSSI değerleri.

İstasyon Adı	Hatalı Görülen Ölçümler				Sonuç RSSI				
	STD	IQR	ZS	MZS	STD	IQR	ZS	MZS	Filtresiz
V23	224	224,237	224	224	236.11	236.00	236.11	236.11	234.90
V24	-	-	232,232,232,232	232,232,232,232	231.40	231.40	231.00	231.00	231.40
V25	231	231	230,231	230,231	228.44	228.44	228.25	228.25	228.70
V26	-	-	200,200,200	200,200,200	200.70	200.70	201.00	201.00	200.70

6.3.3.Regresyon analizi

Regresyon analizi, regresyon modellerinin oluşturulması, test edilmesi ve yorumlanması süreci olarak adlandırılır. Bu analizde verilerin dağılımını, ilişkilerin gücünü, istatistiksel anlamlılığı, modelin uygunluğunu ve tahminlerin doğruluğunu değerlendirmek için çeşitli teknikler ve metrikler kullanılmaktadır.

6.3.3.1. Regresyon modellerinin oluşturulması


Makine öğrenmesi tabanlı regresyon modelleri farklı veri tipleri ve dağılımları ile farklı performans göstermektedir. Bu sebep ile modellerin performansını değerlendirilmeden önce eğitimin yapılacağı doğru veri yapısının tespit edilmesi gerekmektedir. Bu sayede bu modellerden en yüksek düzeyde performans alınabilecektir. Regresyon modelleri temel olarak bağımlı değişken ve bağımsız değişken arasındaki örüntüyü anlamaya çalışarak buna göre yeni bağımsız değişkenler için bağımlı değişken tahmini yapmaktadırlar. Bu çalışmada bağımlı değişken alıcı ve veri istasyonları arasındaki mesafe, bağımsız değişkenler ise bu mesafelerde ölçülen RSSI değerleridir. Parmak izi yöntemi için ise bağımsız değişken aynı iken bağımlı değişken ölçümün yapıldığı alıcı istasyonun y ve x koordinatlarını ifade etmektedir.

Bu çalışmanın başlangıcında yapılan ön deneylerde Şekil 6.14'de gösterilen istasyon yerleşimi kullanılarak her istasyonun ölçülen RSSI verisi ve o istasyonun alıcıya olan uzaklığı kullanılarak eğitim (100 adet noktaya ait veri ile) sağlanmıştır. Eğitilen modeller için test verileri (20 adet noktaya ait veri ile) kullanılarak mesafe tahminleri yaptırılmıştır. Buna göre en iyi tahmin doğruluğuna sahip model ortalama ± 4.55 metre ile en kötü tahmin doğruluğuna sahip modelin ortalama ± 8.02 metre doğruluğunda mesafe tahminine sahip olduğu yani ortalama ± 6.28 metre doğrulukla mesafe tahmini yapılabildiği görülmüştür. Bunun üzerine tahmin doğruluğunun arttırılması için eğitim ve test verisinde kullanılan RSSI değerini sadece tahmin yapılan istasyonun değil kalan 3 istasyondan alınan RSSI verileri de eklenerek toplamda 4 istasyondan alınan RSSI değerleri kullanılmıştır. Bu verilerin yanında bağımlı değişken ise her istasyona ait mesafe değerleri kullanılarak her istasyon için ayrı model eğitimi gerçekleştirilmiştir. Bu şekilde tahmin doğruluğunda ciddi miktarda artış olduğu görülmüş olup tahmin doğruluğu ortalaması ± 3.32 metreye kadar indirilmiştir. Bu sonuçlar üzerinde çalışmada kullanılacak modellerin bu veri seti yapısının bu şekilde kullanılarak eğitim ve testlerinin yapılmasına karar verilmiştir.

Çalışmada yapılan Uygulama 1 ve Uygulama 2 senaryosu için Çizelge 6.2'de detayları verilen ölçümlerden elde edilen veriler, makine öğrenmesi modellerinin eğitiminde ve testlerde kullanılmak üzere Python da programlama dili yapısına göre dizilere aktarılmıştır. Eğitilecek modelin tahmin yapacağı aralığı küçültmek ve tahmin doğruluğunun arttırılması amacı ile eğitim verilerinden farklı gruplar oluşturularak uygulama sahası bölümlere ayrılmıştır. Bu kapsamda mesafe belirleme için 3 farklı

yöntem kurgulanmıştır. Bu yöntemler yöntem 1, yöntem 2 ve yöntem 3 olarak adlandırılmış olup yöntem 1 ve yöntem 3 hem mesafe belirleyen modellerin oluşturulmasında hem de parmak izi yöntemi kullanan modellerin oluşturulmasında kullanılmıştır. Yöntem 2 ise sadece mesafe belirleyen modellerin oluşturulmasında kullanılmıştır.

Yöntem 1’de uygulama sahası K24 koridoru, K26 koridoru ve Orta alan olmak üzere 3 farklı alana ayrılmış olup Şekil 6.17 ile bu alanların sınırları belirtilmektedir. Bu yöntemde ayrılan alanlardan toplanan veriler, sadece o alanların sınırları içerisinde tahmin yapacak modellerin eğitim ve testinde kullanılmıştır. Bu kapsamda her alan için 4 farklı model belirlenmiş olup bu modellerden her biri verici istasyonlardan sadece bir tanesi için mesafe belirlemektedir. Örneğin orta alan içinde bir noktada RSSI ölçümü yapıldığında V23 vericisine olan mesafeyi sadece orta alan verilerinden V23 vericisine olan mesafe ve orta alanda tüm vericilere ait RSSI verileri kullanılarak eğitilen model ile gerçekleştirilmektedir. Bu şekilde bu yöntemde her alan için 4 model oluşturularak toplamda 12 farklı regresyon modeli ile mesafe tahmini yapılmaktadır. Bu bölümlendirmede uygulama hangi alanın modelini kullanacağına yani ölçüm yapıldığı noktanın hangi alanda bulunduğu bu modellerden ayrı eğitilen bir sınıflandırma modeli olan Random Forest Sınıflandırma algoritması kullanılarak gerçekleştirilmektedir. Tüm uygulama sahasına ait Z Score ile filtrelenmiş RSSI verileri ve ölçüldükleri alan adı kullanarak bu model eğitilmiş olup yapılan testlerde %96 oranında doğrulukla ölçümün hangi alanda yapıldığına dair tahmin yapılabilmektedir. Geriye kalan %4’lük yanlışla kısmı alanların birbiri ile ayrıldıkları sınır bölgelerinde gerçekleşmektedir. Bu modelin kullandığı veri setinin yapısı Çizelge 6.7’de verilmiştir.



Şekil 6. 17. Çalışma sahasının yöntem 1'göre 3 farklı alana ayrılması.

Yöntem 2’de uygulama sahası farklı alanlara bölünmemiş olup uygulama sahasının tamamından toplanan veriler kullanılarak 4 farklı model belirlenmiştir. Bu modellerden her biri sadece bir vericiye olan mesafe tahminini gerçekleştirmektedir.

Yöntem 3’de ise uygulama sahası farklı bölgelere ayrılmamış olup uygulama sahasının tamamından toplanana veriler kullanılarak sadece bir model belirlenmiştir. Bu model ile 4 vericiden alınan RSSI değeri kullanılarak 4 vericiye olan mesafe tahmini gerçekleştirilmektedir.

Sonuç olarak her 3 yöntem için mesafe belirlemede toplam 17 farklı model ve ölçümün yapıldığı alanı belirlemede bir sınıflandırma modeli kullanılmaktadır. Bu modellerin eğitimde kullandığı veri yapısının şekli Çizelge 6.5, 6.6 ve 6.7 ile belirtilmiştir. Bu çizelgelere göre “R_” ile başlayan veriler RSSI değerlerini, “M_” ile başlayan veriler RSSI değerlerinin ölçüldüğü noktanın verici ile arasındaki mesafe değerlerini ifade etmektedir. “K_” ile başlayan veri ise ölçüm yapılan alan adını ifade etmekte olup K24, K26 ve Orta Alan parametrelerine karşılık gelen 0, 1, 2 değerlerinden birini almaktadır.

Çizelge 6.5. Mesafe belirlemede kullanılan regresyon modellerinin kullandığı veri yapısı.

	Model Adı	Bağımsız Değişken				Bağımlı Değişken(m)
K24 Koridorunda Ölçülen Veriler	MODEL 1	R_V23	R_V24	R_V25	R_V26	M_V23
	MODEL 2	R_V23	R_V24	R_V25	R_V26	M_V24
	MODEL 3	R_V23	R_V24	R_V25	R_V26	M_V25
	MODEL 4	R_V23	R_V24	R_V25	R_V26	M_V26
K26 Koridorunda Ölçülen Veriler	MODEL 5	R_V23	R_V24	R_V25	R_V26	M_V23
	MODEL 6	R_V23	R_V24	R_V25	R_V26	M_V24
	MODEL 7	R_V23	R_V24	R_V25	R_V26	M_V25
	MODEL 8	R_V23	R_V24	R_V25	R_V26	M_V26
Orta Alanda Ölçülen Veriler	MODEL 9	R_V23	R_V24	R_V25	R_V26	M_V23
	MODEL 10	R_V23	R_V24	R_V25	R_V26	M_V24
	MODEL 11	R_V23	R_V24	R_V25	R_V26	M_V25
	MODEL 12	R_V23	R_V24	R_V25	R_V26	M_V26
Tüm Veri Seti Kullanılan Modeller	MODEL 13	R_V23	R_V24	R_V25	R_V26	M_V23
	MODEL 14	R_V23	R_V24	R_V25	R_V26	M_V24
	MODEL 15	R_V23	R_V24	R_V25	R_V26	M_V25
	MODEL 16	R_V23	R_V24	R_V25	R_V26	M_V26

Çizelge 6.6. Mesafe belirlemede kullanılan regresyon modelinin kullandığı veri yapısı.

	Model Adı	Bağımsız Değişken				Bağımlı Değişken(m)			
Tüm Veri Seti Kullanılan Model	MODEL 17	R_V23	R_V24	R_V25	R_V26	M_V23	M_V24	M_V25	M_V26

Çizelge 6.7. Ölçüm yapılan alanı belirlemede kullanılan regresyon modellerinin kullandığı veri yapısı.

	Model Adı	Bağımsız Değişken				Bağımlı Değişken(m)
Ölçüm Yapılan Alan Adını Belirleyen Model	MODEL 18	R_V23	R_V24	R_V25	R_V26	K_ADI

Bu çalışmada parmak izi yöntemi ile konum belirleme doğruluğu araştırıldığı için bu veri setlerinin parmak izi yöntemi kullanacak modellerinin eğitimi içinde hazırlanması gerekmektedir. Parmak izi yönteminde bağımsız değişken RSSI ölçümleri iken bağımlı değişken ölçümlerin yapıldığı koordinatlardır. Bu sebep ile 4 vericiye olan mesafenin belirlenmesi ihtiyaç duyulmadığından daha az sayıda model yeterli olmaktadır.

Parmak izi yönteminde kullanılan modellerinin veri yapısı mesafe belirlemede kullanılan yöntemlerden yöntem 1 ve yöntem 3 kullanılarak oluşturulmaktadır. Buna göre Çizelge 6.8’de görüleceği üzere eğitim için 4 farklı veri seti oluşturulmuştur. Bu çizelgeye göre “R_” değerleri ölçülen RSSI değerlerini, “Y” ve “X” değerleri ise bu ölçümün yapıldığı koordinatları ifade etmektedir.

Çizelge 6.8. Parmak izi yöntemi için makine modellerinin eğitiminde kullanılan veri yapısı.

	Model Adı	Bağımsız Değişken				Bağımlı Değişken(m)	
K24 Koridorunda Ölçülen Veriler	MODEL 19	R_V23	R_V24	R_V25	R_V26	Y	X
K26 Koridorunda Ölçülen Veriler	MODEL 20	R_V23	R_V24	R_V25	R_V26	Y	X
Orta Alanda Ölçülen Veriler	MODEL 21	R_V23	R_V24	R_V25	R_V26	Y	X
Tüm Veri Seti Kullanılan Model	MODEL 22	R_V23	R_V24	R_V25	R_V26	Y	X

6.3.3.2. Modellerin değerlendirilmesinde kullanılan metrikler

Yapılan bu çalışmada modellerin performansının değerlendirilmesi ve aynı zamanda aşırı öğrenmenin ve öğrenememenin olup olmadığının tespiti çok önemli bir konuyu oluşturmaktadır. Çünkü bu kısımda belirlenen modelin gerçek uygulamalarda kullanılması sonucunda alınan sonuçların performansı, bu kısımda yapılan değerlendirmeye bağlı olarak tahmin edilebilecektir. Bu değerlendirmenin yapılabilmesi için üç farklı metrik kullanılmış olup bu metrikler sırası ile R^2 , RMSE (Karesel Ortalama Hatanın Kökü, ing: Root Mean Squared Error) ve MAE (Mutlak Ortalama Hata, ing: Mean Absolute Error)'dir.

6.3.3.2.1. R^2 analizi

R^2 metriği, bağımlı değişken ile bağımsız değişken arasındaki ilişkinin ne kadar iyi açıklandığını gösteren bir katsayı olarak tanımlanabilmektedir. Makine öğrenmesi çalışmalarında modellerin bağımsız değişkenlerle bağımlı değişken arasındaki varyansın ne kadar açıklayabildiğini ifade etmektedir. R^2 metriği, genellikle "determinasyon katsayısı" olarak da adlandırılır. Bu değer 0 ile 1 arasında değişir ve 1'e ne kadar yakınsa modelin veriler arasındaki ilişkiyi o kadar iyi anladığını gösterir.

R^2 Eşitlik 6.17 ile gösterilen denklem ile hesaplanabilmektedir (Kelleher ve diğ., 2015).

$$R^2 = 1 - \frac{SSR}{SST} \quad (6.17)$$

Burada SSR (Regresyon Hata Kareleri Toplamı-ing: Sum of Squared Residuals) regresyon modelinin tahmin ettiği değerler ile gerçek değerler arasındaki farkların karelerinin toplamıdır. SST (Toplam Kareler Toplamı- ing: Total Sum of Squares) ise bağımlı değişkenin ortalaması ile gerçek değerler arasındaki farkların karelerinin toplamıdır. SSR ve SST hesaplanmasında kullanılan temel matematiksel bağıntılar aşağıda açıklanmıştır.

$$SSR = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (6.18)$$

Eşitlik 6.18’de n veri nokta sayısını, y_i gerçek değerleri, $\hat{y}_i$ ise regresyon modelinin tahmin ettiği değerleri temsil eder. Aşağıda verilen Eşitlik 6.19 ile de SST’nin hesaplanmasında kullanılan temel matematiksel formül verilmiştir. Bu denklemde belirtilen y_i gerçek değerleri, $\bar{y}$ değeri ise bağımlı değişkenin tüm veri noktalarının ortalamasını ifade eder (Kelleher ve diğ., 2015).

$$SST = \sum_{i=1}^n (y_i - \bar{y})^2 \quad (6.19)$$

6.3.3.2.2. RMSE (Root Mean Squared Error- Karesel Ortalama Hatanın Kökü)

RMSE terimi, "Root Mean Squared Error" kelimelerinin baş harflerinden oluşmakta olup Türkçe’ye "Karesel Ortalama Hatanın Kökü" olarak çevrilebilir. RMSE, genellikle istatistik ve makine öğrenimi alanlarında değerlendirmede kullanılmaktadır. Özellikle regresyon problemlerinde yaygın olarak kullanılan RMSE’nin işlevi, tahmin edilen değerler ile gerçek değerler arasındaki farkları ölçerek, modelin performansı hakkında bilgi vermektir. Matematiksel olarak RMSE, gerçek değerlerle tahmin edilen değerler arasındaki farkın büyüklüğünü ve yönünü gösterir. Bunu yaparken tahminlerin gerçek değerlerden ne kadar saptığını belirlemek için farkların karelerinin ortalamasını alır ve sonucu karekök ile düzeltir. Bu sayede bu yöntem ile büyük hataların daha fazla ağırlığa sahip olması sağlanmaktadır.

RMSE'nin düşük olması, modelin daha iyi performans gösterdiği anlamına gelmektedir. Ancak, RMSE tek başına bir modelin kalitesini değerlendirmek için yeterli değildir. Çünkü RMSE tek başına modelin yaptığı tahminlerinin doğruluğu hakkında genel bilgi verir, fakat hata dağılımı hakkında yeterli bilgi sağlayamamaktadır. Farklı metriklerle birlikte kullanılarak modelin genel performansı daha sağlıklı bir şekilde değerlendirilebilir.

RMSE'nin en önemli avantajı matematiksel açıdan anlaşılması ve yorumlanmasının kolay olmasıdır. Ayrıca farklı modellerin performanslarını karşılaştırmaya ve en iyi modeli seçmeye olanak sağlaması önemli özelliklerindendir. Bu sebep ile bu çalışmada model performansını değerlendirmede ve veri seti için en uygun model seçiminde kullanımı tercih edilmiştir. Aşağıda verilen Eşitlik 6.20 ile RMSE hesaplanmasına ilişkin temel formül yer almaktadır.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (6.20)$$

Eşitlik 6.20'de, n veri sayısını, y_i gerçek değerleri, $\hat{y}_i$ ise regresyon modelinin tahmin ettiği değerleri temsil etmektedir (URL-6).

6.3.3.2.3. MAE (Mean Absolute Error- Ortalama Mutlak Hata)

MAE terimi, İngilizce'de "Mean Absolute Error" olarak adlandırılır ve Türkçe'de "Ortalama Mutlak Hata" anlamına gelmektedir. Regresyonda tahmin edilen bağımlı değişkenler ile gerçek değerler arasındaki farkın mutlak değerlerinin aritmetik ortalamasını ifade etmekte olup bu metrik tahmin edilen değerler ile gerçek değerler arasındaki gerçek farkı yansıtmaktadır. Buda hatanın büyüklüğü hakkında doğrudan fikir sahibi olunabilmesini sağlar. En büyük dezavantajı ise hesaplama içerisinde yer alan büyük hataların etkisini ölçememesidir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6.21)$$

Eşitlik 6.21 ile verilen denklem ile ortalama mutlak hata hesaplanabilmektedir. Bu denkleme göre, n veri sayısını, y_i gerçek değerleri, $\hat{y}_i$ tahmin edilen değerleri temsil etmektedir.

6.3.4. Test verilerinin belirlenmesi

Bölüm 6.3.3.2’de detaylı bilgi verilen metrikler ile yapılan değerlendirmede kullanılan test verilerinin uygun belirlenmesi, ileride yapılacak çalışmaların doğruluğu ve güvenilirliği yönünden önemli bir konudur. Bu sebep ile bu çalışmada iki grup test verisi kullanılmıştır. Bunlardan biri toplanan eğitim verilerinden ayrılarak elde edilen ve yapılan parametre ayarlaması sırasında model performanslarının test edilmesinde kullanılan veridir. Diğer test verisi ise Çizelge 6.2’de belirtilen veridir. Bu veri, seçilen modellerin test edilmesinde ve elde edilen konum doğruluğunun incelenmesinde kullanılan veridir. Bölüm 7’de verilen uygulama sonuçları bu veri kullanılarak elde edilmiştir.

Makine öğrenmesi uygulamalarında test verilerinin seçimi, farklı yöntemler ile yapılabilmekte olup bu alanda sıklıkla kullanılan algoritmalarından bazıları Hold-out, K Katlı çapraz doğrulama Rastgele örnekleme yöntemleridir.

Hold-Out yöntemi, veri kümesini genellikle eğitim ve test verisi olarak ikiye ayırarak kullanmaktadır. Eğitim verisi, modelin parametrelerini belirlemek için, test verisi ise modelin son performansını değerlendirmek için kullanılmaktadır. Bu yöntem, veri kümesinin büyük olduğu durumlarda etkilidir ancak test verisinin eğitim verisinden farklı bir dağılıma sahip olma riski, bu yöntemin en büyük dezavantajıdır.

K katlı çapraz doğrulama yönteminde, veri seti eşit parçalara bölünerek, her parça sırayla test verisi olarak kullanılırken diğer parçalar eğitim için kullanılmaktadır. Böylece K farklı test sonucu elde edilmekte ve model performansı bu testlerin ortalama değeriyle hesaplanmaktadır. Bu yöntem küçük veri setlerinde veya eğitim için yeterli örnek olmaması durumunda kullanılabilir. Ancak bu yöntemde parametre ayarlama işlemi oldukça zaman almaktadır.

Rastgele örnekleme yönteminde, veri kümesi rastgele bir oranda eğitim ve test verisi olarak ikiye ayrılır. Örneğin, veri kümesinin %80’i eğitim, %20’si test verisi olarak seçilebilir. Bu yöntem, veri kümesinin yeterince büyük ve dengeli olduğu durumlarda kullanılabilir. Fakat veri seti dengeli olmadığında modelin performansını tam yansıtmayabilmektedir.

Yapılan çalışmada modellerin parametre ayarlaması sırasında test edilmesi için kullanılan test verileri, bu yöntemlerden farklı olarak elle yapılan bir ayırma sonucunda elde edilmiştir. Test verisinin bu şekilde elde edilmesinin en büyük sebebi yukarıda bahsedilen yöntemlerinden bazılarının seçtiği test verileri veri setinin genelini tam yansıtmamakta, bazıları ise hiper parametre ayarlaması işleminin oldukça fazla zaman almasına sebep olmasıdır. Bu sebep ile çalışmada eğitim amaçlı toplanan veriler Uygulama 1 ve Uygulama 2 için ayrı ayrı CAD uygulamasında açılarak, her uygulama için çalışma sahasına homojen olarak yayılan 100'er adet test verisi eğitim verisinden ayrılmıştır. Bu sayede mevcut deney sahasına homojen olarak yayılmış bir test veri seti elde edilerek parametre ayarlamasında modellerin test edilmesinde kullanılmıştır.

6.3.5. Hiper parametre optimizasyonun yapılması ve model seçimi

Çalışmada kullanılan veriler toplanırken verilerin ön işlemeye yani filtrelemeye tabi tutulduğu Bölüm 6.3.2'de bahsedilmiştir. Bu ön işleme sonrası ölçülen her nokta için her vericiden 5 adet RSSI değeri belirlenmektedir. Ayrıca bu 5 adet RSSI verisi ile oluşturulan veri setleri çalışmada kullanımı tercih edilen 6 farklı makine öğrenmesi modelinin eğitiminde kullanılmaktadır. Buna göre yöntem 1 için belirtile belirtilen 17 model, kullanılacak 5 farklı filtreleme yöntemi ile elde edilen RSSI verisi ve 6 farklı regresyon modeli algoritması kombinasyonu sonucunda eğitilen toplam $510(17*5*6)$ model içerisinden seçilecektir. Parmak izi yönteminde ise Çizelge 6.8'de belirtilen 4 model, kullanılan 5 farklı filtreleme yöntemi ile elde edilen RSSI verisi ve 6 farklı regresyon modeli algoritması kombinasyonu sonucunda eğitilen toplam $120(4*5*6)$ model içerisinden seçilecektir.

Sonuç olarak uygulama senaryolarından (Uygulama 1 ve Uygulama 2) sadece bir tanesi için 630 farklı model eğitilmiş olup her iki uygulama için toplam 1260 eğitilmiş model ortaya çıkmaktadır. Fakat bu çalışmada oluşturulan bu modellerden sadece 42(her uygulama için 21 tane) tanesi seçilerek deney sahasında konum doğruluğunun belirlenmesi sırasında aktif kullanılacaktır. Çizelge 6.7 ile verilen model sınıflandırma algoritması kullandığı ve varsayılan parametreler ile yüksek doğrulukla çalıştığı için bu kısma dahil edilmemiştir.

Bu 1260 model içerisinden uygulamalarda kullanılacak 42 modelin seçilmesi için yapılacak değerlendirilmeden önce hiper parametre ayarlamalarının yapılması ve test verileri ile yaptıkları tahminlere göre performanslarının gözlemlenmesi gerekmektedir.

Bu kadar fazla türde veri seti ve makine öğrenmesi modeli ile çalışmak oldukça karmaşık ve zaman alan süreci beraberinde getirmektedir. Bu sebep ile hiper parametrelerin ayarlanması için bu çalışmaya özel Python programlama dili ile parametre ayarlama algoritması geliştirilmiştir. Hiper parametre optimizasyonu için geliştirilen algoritmanın temel çalışma şekli ise aşağıdaki gibidir.

- 6 farklı makine öğrenme tabanlı regresyon modeli için ayrı ayrı fonksiyonlar oluşturulmuştur.
- Bu fonksiyonlar girdi olarak eğitim verisi ve test verilerini (Bölüm 6.3.4’de belirtildiği şekilde elde edilen veriler) almaktadır.
- Girdi olarak gelen eğitim verisi için her fonksiyon kullandığı makine öğrenmesi algoritmasında seçilen parametreleri döngüler yardımı ile farklı değerler kullanarak model eğitimi yapmaktadır.
- Eğitilen model için test verileri kullanılarak tahmin yaptırılır.
- Yapılan tahminler için R^2 , RMSE ve MAE değerleri hesaplanır.
- Eğitim verisi de eğitilmiş modele girdi olarak sunulur tahmin yapması sağlanır. Yapılan tahminler içinde R^2 , RMSE ve MAE değeri ayrıca hesaplanır.
- Test verileri için en yüksek R^2 ve en düşük RMSE ve MAE değerini bulana kadar parametreler döngülere tanımlı aralıklarda değiştirilir.
- Fonksiyonlar belirtilen aralıktaki döngüleri tamamlandıktan sonra en yüksek R^2 , en düşük RMSE ve MAE değerlerini veren parametreyi ve bu değerleri çıktı olarak döndürür.

Hiper parametre optimizasyon algoritmasının etkilerinin görülmesi için Çizelge 6.9’da K26 koridorunda V23 vericisi ile alıcı arasındaki mesafeyi tespit etmek için eğitilen (ZS ile filtrelenen veri) ve test verileri ile test edilen modelin varsayılan parametreler ile elde ettiği sonuçlara yer verilmiştir. Çizelge 6.10’da ise aynı modelin geliştirilen hiper parametre optimizasyon algoritması ile parametre ayarlaması yapıldıktan sonraki performanslarını gösteren sonuçlar yer almaktadır. Söz konusu çizelgelerde R^2 , RMSE ve MAE sütunları test verisi kullanılarak elde edilen sonuçları, R^2_E , RMSE_E ve MAE_E sütunları ise eğitim verisi kullanılarak elde edilen sonuçları ifade etmektedir.

Çizelge 6.9. Varsayılan parametreler ile elde edilen model performansları.

MODEL ADI	R^2	R^2_E	RMSE (m)	RMSE_E (m)	MAE (m)	MAE_E (m)
SVR Regresyon	0.78	0.77	4.66	4.45	3.46	3.36
Bagging Regresyon	0.86	0.96	4.16	1.76	2.37	1.20
Random Forest Regresyon	0.86	0.98	3.62	1.45	2.31	1.05
XGB Regresyon	0.83	1.00	3.67	0.02	2.95	0.01
Gradient Boosting Regresyon	0.85	0.97	3.95	1.64	2.61	1.26
K-Neighbors Regresyon	0.88	0.86	4.05	3.52	2.43	2.50


Çizelge 6.10. Hiper parametre ayarlaması sonrası model performansları.

MODEL ADI	R^2	R^2_E	RMSE (m)	RMSE_E (m)	MAE (m)	MAE_E (m)
SVR Regresyon	0.88	0.88	3.38	3.23	2.62	2.18
Bagging Regresyon	0.88	0.97	3.26	1.61	1.99	1.10
Random Forest Regresyon	0.89	0.94	3.12	2.32	2.09	1.62
XGB Regresyon	0.86	0.99	3.57	0.96	2.31	0.65
Gradient Boosting Regresyon	0.89	0.97	3.24	1.73	2.37	1.25
K-Neighbors Regresyon	0.88	0.89	3.32	3.09	2.12	2.14

Bu sonuçlara göre modellerin elde performanslarında gözle görülür derecede bir artış elde edildiği görülmektedir. Fakat söz konusu algoritma ile hiper parametre ayarlaması esnasında bazı durumlarda modellerin aşırı öğrenmiş hale geldiği gözlemlenmiş olup bu oran eğitilen tüm modellerin durumu göz önüne alındığında oldukça düşük kalmaktadır. Bu durum genellikle XGB, Gradient Boosting ve K-Neighbors regresyon modellerinde meydana gelmiştir. Öte yandan bu algoritma ile varsayılan parametreler ile eğitilen ve aşırı öğrenen modellerin birçoğunun da genelleştirme yeteneği arttırılarak aşırı öğrenme durumunu oldukça azaltmıştır. Örneğin Çizelge 6.9 da verilen XGB regresyon modelinde aşırı öğrenme vardır. Bu durum Çizelge 6.10'da görüldüğü üzere azaltılmıştır.

Hazırlanan algoritma ile 1260 adet model için yaklaşık 46 saatlik bir program çalışma süresinden sonra parametreler ve bu parametrelerin performansları Çizelge 6.10'daki gibi belirlenmiştir. Fakat bu çalışmada 1260 model içerisinde sadece 42 tanesi Uygulama 1 ve Uygulama 2 senaryolarında test edilmek üzere kullanılacaktır. Bu sebep ile seçilecek bu modellerin performanslarının değerlendirilmesi sırasında modellerin veri setini aşırı öğrenmesi veya öğrenememesi durumu kontrol edilmelidir.

Makine öğrenmesi modelleri bazı durumlarda ya da bazı veri setleri ile çalıştığında veriler arasındaki ilişkiyi genelleştirememekte veya ezberleme yoluna girmesidir. Bu şekilde aşırı öğrenme veya öğrenememe durumu olan model eğitim verisi dışında daha önce görmediği bir veri için tahmin yaptığında genellikle bu tahminin, modelin beklenen tahmin doğruluğunun çok dışında olduğu görülmektedir. Bu sebep ile özellikle RSSI gibi değişkenliği çok yüksek olan bir veri ile çalışırken elde edilecek konum doğruluğunun belirlenen aralıklarda olması için test verilerinin seçimi, parametre ayarlaması ve model seçimine özellikle dikkat edilmesi gerekmektedir. Modellerin öğrenme durumuna ilişkin Şekil 6.18’de verilen görselde, fiyat ve miktar arasındaki ilişkinin regresyon modelince aşırı öğrenilmesi (soldaki grafik), öğrenilmemesi (orta grafik) ve ideal öğrenilme (sağdaki grafik) durumu gösterilmektedir.



Şekil 6. 18. Regresyon modellerinde aşırı öğrenme, öğrenememe, ideal öğrenme (URL-14).

Bu çalışmada kullanılan modellerin öğrenme durumlarının kontrol edilebilmesi için hem eğitim verilerinden yapılan tahminler için hem de test verilerinden yapılan tahminler için R^2 , RMSE ve MAE metrikleri birlikte değerlendirilmeye tabi tutulmuştur. Buna göre 1260 eğitilmiş ve parametreleri belirlenmiş model içerisinde 42 modelin seçilmesi için aşağıdaki kriterler göz önünde bulundurulmuştur.

- Test verileri için R^2 değeri 1’e en yakın model en iyi kabul edilmiş fakat bu modelin eğitim verileri ile yapılan tahminlerinden hesaplanan R^2 değeri 0.97’den büyük ise ve test verisi için hesaplanan R^2 değeri ile arasındaki fark 0.03’den daha büyük ise bu modelde aşırı öğrenme olduğu kabul edilmiştir.
- Eğitim verileri için hesaplanan R^2 değeri 1 ve MAE veya RMSE değerleri 0 ise modelde aşırı öğrenmenin olduğu kabul edilmiştir.

- Eğitim verileri için hesaplanan R^2 değeri test verileri için hesaplanan değerden daha düşükse modelin eğitim verilerini dahi tam kavrayamadığı bu yüzden başarısız olduğu kabul edilmiştir.
- Test verileri için hesaplanan RMSE ve MAE değerleri en küçük model en başarılı model kabul edilmiştir. Fakat eğitim verisi ile yapılan tahminler için hesaplanan MAE değeri 0.50 cm'den daha düşük ise ve test verisi için hesaplanan MAE değeri 0.50 cm'den büyük ise bu modelde de aşırı öğrenme olduğu kabul edilmektedir.
- Önceki 4 şartı sağlayan en yüksek R^2 ve en düşük RMSE, MAE değerlerine sahip model en başarılı model kabul edilmiştir.

Yukarıda belirtilen tüm kriterleri sağlayan modeller başarılı kabul edilerek eğitim verisinden bağımsız toplanan test verilerinde değerlendirilmek üzere seçilmiştir. Elde edilen sonuçlara göre hiper parametreleri belirlenmiş modeller arasından her çalışma sahası için ayrı olarak Çizelge 6.5 ve 6.6'da belirtilen veri seti yapısını kullanan ve hiper parametre optimizasyonu yapılmış 17 model, parmak izi yöntemi için yine Çizelge 6.8'daki veri seti yapısını kullanan 4 model seçilmiştir. Yine bu modellerin kullandığı RSSI verisinin filtreleme türü, test ve eğitim verileri ile elde edilen R^2 , RMSE ve MAE metriklerinin sayısal karşılığı aşağıda yer alan çizelgelerde verilmiştir.

Çizelge 6.11. Uygulama 1’de mesafe tahmini için seçilen modeller ve kullanılan veri adları.

	TAHMİN ADI	VERİ ADI	MODEL ADI	R^2	R^2_E	RMSE (m)	RMSE_E (m)	MAE (m)	MAE_E (m)
K24 Koridorunda Ölçülen Verileri Kullanan Modeller	MESAFE V23	RSSI_IQR	Random Forest Regresyon	0.99	0.99	2.53	1.63	1.77	1.06
	MESAFE V24	RSSI_ZS	Random Forest Regresyon	0.99	0.99	2.72	1.70	1.98	1.29
	MESAFE V25	RSSI_MZS	Random Forest Regresyon	0.99	0.99	2.49	1.78	1.71	1.18
	MESAFE V26	RSSI_IQR	Random Forest Regresyon	0.99	0.99	2.24	1.82	1.55	1.14
K26 Koridorunda Ölçülen Verileri Kullanan Modeller	MESAFE V23	RSSI_MZS	Bagging Regresyon	0.99	0.99	2.59	2.00	1.78	1.29
	MESAFE V24	RSSI_ZS	Bagging Regresyon	0.99	0.99	2.52	1.77	1.50	1.14
	MESAFE V25	RSSI_MZS	Bagging Regresyon	0.99	0.99	2.51	1.85	1.57	1.15
	MESAFE V26	RSSI_ZS	Bagging Regresyon	0.99	0.99	2.72	1.96	1.65	1.31
Orta Alan Ölçülen Verileri Kullanan Modeller	MESAFE V23	RSSI_STD	Bagging Regresyon	0.83	0.85	1.06	0.74	0.75	0.52
	MESAFE V24	RSSI_MZS	Bagging Regresyon	0.83	0.86	1.17	0.70	0.80	0.57
	MESAFE V25	RSSI_STD	Bagging Regresyon	0.79	0.79	1.30	0.75	0.91	0.54
	MESAFE V26	RSSI_MZS	Bagging Regresyon	0.80	0.86	1.21	0.70	0.90	0.52
Tüm Sahada Ölçülen Verileri Kullanan Modeller	MESAFE V23	RSSI_MZS	Bagging Regresyon	0.98	0.99	3.04	1.98	2.01	1.29
	MESAFE V24	RSSI_IQR	Bagging Regresyon	0.98	0.99	3.12	1.86	2.19	1.17
	MESAFE V25	RSSI_ZS	Bagging Regresyon	0.98	0.99	3.13	1.88	2.39	1.23
	MESAFE V26	RSSI_MZS	Bagging Regresyon	0.98	0.99	3.20	1.85	2.33	1.21
Tüm Sahada Ölçülen Verileri Kullanan Model	TÜM MESAFE	RSSI_IQR	Kneighbors Regresyon	0.96	0.98	3.51	2.52	2.07	1.49

Çizelge 6.12. Uygulama 1’de parmak izi yöntemi için seçilen modeller ve kullanılan veri adları.

	TAHMİN ADI	VERİ ADI	MODEL ADI	R^2	R^2_E	RMSE (m)	RMSE_E (m)	MAE (m)	MAE_E (m)
K24 Koridorunda Ölçülen Verileri Kullanan Modeller	K24 KONUM	RSSI_MZS	Bagging Regresyon	0.99	0.99	1.73	1.15	1.68	1.04
K26 Koridorunda Ölçülen Verileri Kullanan Modeller	K26 KONUM	RSSI_MZS	Bagging Regresyon	0.99	0.99	2.01	1.31	1.87	1.27
Orta Alan Ölçülen Verileri Kullanan Modeller	ORTA KONUM	RSSI_STD	Bagging Regresyon	0.80	0.93	1.66	0.99	1.71	1.00
Tüm Sahada Ölçülen Verileri Kullanan Model	TÜM KONUM	RSSI_STD	Bagging Regresyon	0.97	0.99	2.60	1.47	2.49	1.52

Çizelge 6.13. Uygulama 2’de mesafe tahmini için seçilen modeller ve kullanılan veri adları.

	TAHMİN ADI	VERİ ADI	MODEL ADI	R^2	R^2_E	RMSE (m)	RMSE_E (m)	MAE (m)	MAE_E (m)
K24 Koridorunda Ölçülen Verileri Kullanan Modeller	MESAFE V23	RSSI_IQR	Bagging Regresyon	0.96	0.98	1.56	1.27	0.98	0.79
	MESAFE V24	RSSI_ZS	Random Forest Regresyon	0.97	0.97	4.03	3.86	2.36	1.20
	MESAFE V25	RSSI_MZS	Bagging Regresyon	0.97	0.98	1.75	1.22	1.19	0.77
	MESAFE V26	RSSI_ZS	XGB Regresyon	0.98	1.00	3.18	1.13	1.85	0.78
K26 Koridorunda Ölçülen Verileri Kullanan Modeller	MESAFE V23	RSSI_STD	Bagging Regresyon	0.93	0.96	2.59	1.90	1.57	1.11
	MESAFE V24	RSSI_FILTRESİZ	Bagging Regresyon	0.93	0.98	6.63	2.88	2.29	1.50
	MESAFE V25	RSSI_STD	Bagging Regresyon	0.93	0.96	2.39	1.73	1.38	1.20
	MESAFE V26	RSSI_STD	Bagging Regresyon	0.93	0.97	6.39	3.62	2.46	2.10
Orta Alan Ölçülen Verileri Kullanan Modeller	MESAFE V23	RSSI_MZS	Bagging Regresyon	0.89	0.96	1.57	0.92	0.95	0.56
	MESAFE V24	RSSI_FILTRESİZ	Bagging Regresyon	0.90	0.98	1.13	0.76	0.89	0.58
	MESAFE V25	RSSI_MZS	Bagging Regresyon	0.92	0.96	1.36	0.94	0.92	0.65
	MESAFE V26	RSSI_FILTRESİZ	Bagging Regresyon	0.92	0.97	1.26	0.67	0.80	0.51
Tüm Sahada Ölçülen Verileri Kullanan Modeller	MESAFE V23	RSSI_MZS	Bagging Regresyon	0.96	0.98	2.00	1.40	1.30	0.92
	MESAFE V24	RSSI_STD	Bagging Regresyon	0.92	0.98	5.59	3.04	2.68	1.78
	MESAFE V25	RSSI_FILTRESİZ	Bagging Regresyon	0.96	0.97	1.99	1.73	1.36	1.03
	MESAFE V26	RSSI_FILTRESİZ	Bagging Regresyon	0.92	0.95	5.48	4.20	2.59	1.76
Tüm Sahada Ölçülen Verileri Kullanan Model	TÜM MESAFE	RSSI_MZS	Kneighbors Regresyon	0.92	0.97	4.19	2.77	2.30	1.33

Çizelge 6.14. Uygulama 2’de parmak izi yöntemi için seçilen modeller ve kullanılan veri adları.

	TAHMİN ADI	VERİ ADI	MODEL ADI	R^2	R^2_E	RMSE (m)	RMSE_E (m)	MAE (m)	MAE_E (m)
K24 Koridorunda Ölçülen Verileri Kullanan Model	K24 KONUM	RSSI_MZS	Random Forest Regresyon	0.97	0.97	3.01	2.88	2.54	1.25
K26 Koridorunda Ölçülen Verileri Kullanan Model	K26 KONUM	RSSI_ZS	Bagging Regresyon	0.98	0.98	2.59	2.45	2.24	1.69
Orta Alan Ölçülen Verileri Kullanan Model	ORTA KONUM	RSSI_ZS	Bagging Regresyon	0.82	0.95	1.52	0.83	1.87	0.93
Tüm Sahada Ölçülen Verileri Kullanan Model	TÜM KONUM	RSSI_MZS	Bagging Regresyon	0.91	0.97	4.21	2.60	3.69	2.04

Yukarıda verilen kriterlere göre seçilen modeller eğitim verisi içerisinde ayrılan test verisi kullanılarak seçilmiştir. Fakat bu modellerin gerçek dünya testlerinde başarılarının ölçülerek kullanılan test verisinin, yapılan parametre ayarlamasının ve model seçiminin başarılı olup olmadığının gözlemlenmesi gerekmektedir. Bu sebep ile her iki uygulama için ayrı bir test verisi toplanmıştır. Bu test verilerinin toplanmasında kullanılan yöntem eğitim verisi toplanırken kullanılan yöntem ile aynıdır. Ayrıca model değerlendirmesi sırasında karşılaşılan aşırı öğrenme, öğrenememe ve ideal öğrenmenin olduğu modellerden bazılarına ait sonuçlar Çizelge 6.15 ile örnek amaçlı verilmektedir.

Çizelge 6.15. Modellerin, öğrenememe, aşırı öğrenme ve ideal öğrenme durumları için örnek sonuç.

Öğrenme Durumu	Tahmin Adı	Veri Adı	Model Adı	R2	R2_E	RMSE (m)	RMSE_E (m)	MAE (m)	MAE_E (m)
Öğrenememe	Mesafe V23	RSSI_ZS	SVR Regresyon	0.95	0.93	1.82	2.2	1.4	1.45
Aşırı Öğrenme	Mesafe V23	RSSI_ZS	XGB Regresyon	0.92	1	2.41	0.43	1.59	0.31
İdeal Öğrenme	Mesafe V23	RSSI_ZS	Bagging Regresyon	0.96	0.98	1.56	1.27	0.98	0.79

7. UYGULAMA

Bu çalışmanın temel amacı kapalı mekanlarda uygun maliyetli donanımlarla konum belirlemek için gerekli donanımın ve yöntemin geliştirilerek elde edilen konum doğruluğunun arttırılması için araştırma ve deneyler yapmaktır. RSSI metriğin mesafeye veya doğrudan konuma çevrilebilmesi için yapılan araştırmalar sonucunda bu işlemin YSA, makine öğrenmesi tabanlı regresyon modelleri, polinom denklemleri ile yapılabildiği görülmüştür. Bunun üzerine uygulama sahasına homojen olarak yayılmış yaklaşık 120 adet noktanın koordinatları lokal koordinat sisteminde belirlenmiş olup bu noktalarda uygulama sahasına Şekil 6.14’de belirtilen şekilde yerleştirilen verici istasyonları kullanılarak RSSI ölçümü yapılmıştır. Ölçülen 120 adet noktanın 20 adeti çalışma sahasının her noktasından olacak şekilde seçilerek test verisi olarak ayrılmıştır. Bu veriler kullanılarak RSSI verisinden mesafe belirleme konusunda YSA, makine öğrenmesi tabanlı regresyon modelleri ve polinom denklemleri kullanılarak en başarılı yöntem seçilmeye çalışılmıştır. Sonrasında bu yöntemlerden en başarılı sonuçları veren yöntemin doğruluğunun ve performansının arttırılmasına yönelik kapsamlı çalışmalar yapılması planlanmıştır.

Bu yöntemlerden YSA yöntemi (Tensorflow Keras algoritması) ile yapılan ön deneylerde mesafe doğruluğu en iyi ± 5.26 metre doğrulukla en kötü ise ± 21.43 metre doğrulukla ve ortalama olarak ± 8.78 metre doğrulukla mesafe tespiti yapılmıştır. Yöntemin her tahmin için hesaplama ve eğitim süresinin diğer yöntemlerden fazla olması (yaklaşık 10 saniye) ve konum doğruluğunu arttırmak için yüksek miktarda veriye ihtiyaç duyulması sebebi ile bu yöntem tercih edilmemiştir.

Deney yapılan yöntemlerden bir diğeri olan polinom denklemlerinden birinci, ikinci, üçüncü ve dördüncü derece denklemleri kullanılarak RSSI ve mesafe arasındaki ilişki modellenmeye çalışılmıştır. Bu denklemlere göre test verileri ile hesaplanan en iyi mesafe doğruluğu ve en kötü mesafe doğruluğu Çizelge 7.1’de belirtilmiştir. Fakat bu yöntem ile elde edilen mesafe doğruluğu makine öğrenmesi tabanlı regresyon modellerine göre düşük olması sebebi ile tercih edilmemiştir.

Çizelge 7.1. RSSI değerinin mesafeye dönüştürülmesinde kullanılan Polinom denklemleri sonuçları.

Polinom derecesi	En İyi mesafe Doğruluğu (m)	En Kötü Mesafe Doğruluğu (m)	Ortalama Mesafe Doğruluğu (m)
1. Derece Polinom	4.98	9.20	5.30
2. Derece Polinom	4.63	11.40	6.05
3. Derece Polinom	4.50	15.13	6.36
4. Derece Polinom	4.59	36.04	11.23

Deneyde kullanılan yöntemlerden olan makine öğrenmesi tabanlı regresyon modellerinden 12 farklı regresyon algoritması ile test yapılmış olup bu modellerden en yüksek R^2 ve en düşük MAE değerini veren 6 tanesi seçilmiştir. Bu modeller;

- SVR Regresyon,
- Random Forest Regresyon,
- Baging Regresyon,
- XGB Regresyon,
- Gradient Regresyon,
- K-Neighbors Regresyon modelidir.

Bu modellerin sağlamış olduğu en yüksek mesafe doğruluğu ± 1.97 metre, en düşük mesafe doğruluğu ± 18.36 metre (20 test noktasından sadece 2 tanesinde) ve ortalama mesafe doğruluğu ise 3.32 metre tespit edilmiştir. Yapılan bu ön deney çalışmasında makine öğrenmesi tabanlı regresyon modellerinin hem hızlı hem de diğer yöntemlere göre daha doğru tahminler yapabilmesi sebebi ile bu çalışmada kullanılmasına karar verilmiştir.

Bu şekilde belirlenen mesafelerden en yüksek doğruluğa sahip birkaç nokta için trilaterasyon ile koordinat hesaplanması yapılarak sonuçları incelenmiştir. İstasyonlar ile alıcı arasında belirlenen mesafenin doğruluğu ± 0.3 metre ile ± 1.78 metre arasında değişen noktalar için hesaplanan koordinatlardaki hatanın ± 3 ile ± 8 metre arasında değiştiği görülmüştür. Hesaplanan konum doğruluğunun hesaplamada kullanılan mesafe doğruluğundan çok daha düşük olmasının en büyük sebebi trilaterasyonun zayıf yönü olan referans noktaların yerleşim geometrisi olup bu sebep ile verici istasyonların sadece Şekil 6.14'deki gibi değil ayrıca Şekil 6.15'deki gibide uygulama sahasına yerleştirilerek konum doğruluğu üzerindeki etkisi gözlemlenmiştir.

7.1. EKK Uygulanması

Bu çalışmada Parmak izi yöntemine göre doğrudan koordinat tahminleri yapılabilmektedir. Fakat mesafe tahmini için kullanılan modellerin mesafe tahminleri sonrasında ölçümün yapıldığı noktaların koordinatlarının belirlenmesi için Trilaterasyon yöntemi kullanılmıştır. Trilaterasyon yöntemi ile elde edilen koordinat doğruluğun artırılabilmesi için En Küçük Kareler (EKK) yöntemi ile tahmin yapılan mesafeler ve hesaplanan koordinatlar dengelenmiştir. En Küçük Kareler Yöntemi ile yapılan dengelemede işleyiş aşağıda verilmektedir.

Dengelemeye başlamadan önce dengelemenin ilk şartı olan serbestlik derecesinin kontrol edilmesi gerekmekte olup Eşitlik 7.1 ile bu hesabın yapıldığı denklem ifade edilmiştir. Buna göre f serbestlik derecesini, n ölçü sayısını, u ise bilinmeyen sayısını ifade etmektedir (İnal ve Turgut, 2002). Serbestlik derecesinin 1'den büyük olması durumunda EKK ile dengeleme işlemi 7.2 ve 7.3 eşitlikler ile başlanır. Bu çalışma için ölçü sayısı 4, bilinmeyen sayısı konumu bilinmeyen istasyonun koordinatları (y ve x) için 2 alınmıştır. Bu değerlere göre yapılan hesaplamada serbestlik derecesi 2 olarak hesaplanmakta olup dengeleme yapılabileceği anlaşılmaktadır.

$$f = n - u \quad (7.1)$$

$$Dx_i = Vx_i - Tx \quad (7.2)$$

$$Dy_i = Vy_i - Ty \quad (7.3)$$

Eşitlik 7.2 ve 7.3'e göre Dx_i ve Dy_i bu çalışma için konum bilinen verici istasyonlar ile konumu tahmin edilen ya da hesaplanan alıcı istasyon koordinatları arasındaki farkı, Vx_i , Vy_i verici istasyon koordinatlarını, Tx ve Ty alıcı istasyonun koordinatlarını ifade etmektedir.

$$S0_i = \sqrt{Dx_i^2 + Dy_i^2} \quad (7.4)$$

$$l = S0_i - S_i \quad (7.5)$$

Eşitlik 7.5'de l Eşitlik 7.4 yardımıyla hesaplanan mesafe(m) ile ölçülen mesafe(m) arasındaki farkı temsil etmektedir. S_i ise burada ölçülen mesafe bilgisini temsil etmektedir.

$$a_i = -\frac{Dx_i}{S0_i} \quad (7.6)$$

$$b_i = -\frac{Dy_i}{S0_i} \quad (7.7)$$

Eşitlik 7.6 ve 7.7 ile hesaplanan a_i ve b_i değerleri, Eşitlik 7.8'deki gibi $\underline{A}$ matrisi elemanlarını oluşturulur.

$$A = \begin{bmatrix} a_i & b_i \\ \vdots & \vdots \\ \vdots & \vdots \end{bmatrix} \quad (7.8)$$

$$P = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (7.10)$$

Eşitlik 7.10 ile belirtilen $\underline{P}$ matrisi ağırlık matrisini ifade etmektedir. Tüm ölçüler eşit ağırlıkta kabul edildiğinde Eşitlik 7.10'daki gibi bu matris birim matris olarak alınır. Fakat ağırlıklandırma yapıldığında köşegen elemanları, Eşitlik 7.11'de verilen denkleme göre hesaplanır.

$$\text{Ağırlık} = \frac{1}{a^2} \quad (7.11)$$

Bu eşitlikte a test verilerinden elde edilen gerçek değerler ile tahmin edilen mesafe arasındaki mutlak farkların ortalamasını ifade etmektedir. Sonrasındaki işlemler burada oluşturulan matrislerden yararlanılarak oluşturulur (İnal ve Turgut, 2002).

$$N = A^T P A \quad (7.12)$$

$$n = A^T P l \quad (7.13)$$

$$X = N^{-1} n \quad (7.14)$$

$$V = A \cdot X - l \quad (7.15)$$

Bu eşitliklerden $\underline{X}$ matrisi elemanları alıcının hesaplanan koordinatlarına getirilecek düzeltmeyi miktarını ifade etmektedir. $\underline{V}$ matrisi ise ölçülen mesafe

değerlerine getirilecek düzeltme miktarını ifade etmektedir. Ayrıca Eşitlik 7.16 ile karesel ortalama hata (m_0) hesaplanabilmektedir.

$$m_0(m) = \sqrt{\frac{V^T \cdot P \cdot V}{n - u}} \quad (7.16)$$

Bu çalışmada trilaterasyon ile hesaplanan konumun, referans noktalarının geometrisinden ve belirlenen mesafe değerlerindeki hatadan dolayı içerdiği hatanın azaltılması için aşağıda verilen yöntemler uygulanarak hesaplanan koordinatların doğruluğuna etkisi gözlemlenmiştir.

- EKK ile 1 iterasyonlu hesaplama
- EKK ile 100 iterasyonlu hesaplama (İlk iterasyon sonucu düzeltme eklenen koordinatlar EKK'nın ilk aşamasına döndürülerek tekrar EKK ya tabi tutulur. Bu işlemler yüz kez tekrarlanır.)
- Ağırlıklandırılmış EKK ile 1 iterasyonlu hesaplama
- Ağırlıklandırılmış EKK ile 100 iterasyonlu hesaplama
- EKK ile hesaplanan düzeltme vektörüne göre en büyük hatayı içeren mesafenin dengelemeden çıkartılarak 1 iterasyonlu EKK dengelemesi
- EKK ile hesaplanan düzeltme vektörüne göre en büyük hatayı içeren kenarın dengelemeden çıkartılarak 100 iterasyonlu EKK dengelemesi
- EKK ile hesaplanan düzeltme vektörüne göre en büyük hatayı içeren kenarın dengelemeden çıkartılarak 1 iterasyonlu ağırlıklandırılmış EKK dengelemesi
- EKK ile hesaplanan düzeltme vektörüne göre en büyük hatayı içeren kenarın dengelemeden çıkartılarak 100 iterasyonlu ağırlıklandırılmış EKK dengelemesi

Bu maddelerde belirtilen ağırlıklandırma işlemi EKK içerisinde bulunan P matrisinin köşegen elemanlarının Eşitlik 7.11'deki denkleme göre hesaplanması ile oluşmaktadır. Her 4 istasyon içinde bu işlem yapılarak EKK dengelemesi için ağırlık matrisi oluşturulmaktadır.

EKK'de iterasyon değerinin en yüksek 100 seçilmesinin sebebi dengeleme sırasında belirli bir iterasyondan sonra hesaplanan karesel ortalama hata sabit kalmaktadır. Fakat bazı durumlarda da karesel ortalama hata her iterasyonda birkaç değer arasında değişmekte olup sonsuza dek bu şekilde devam etmektedir. Bu sebep ile 100

iterasyonda bu dengeleme yapılmakta olup karesel ortalama hatanın belirli bir iterasyondan sonra sabit bir değere ulaşabilen noktaların tamamı için bu dengelemenin yapılmış olması amaçlanmaktadır.

7.2. Uygulama Sonuçları

Bölüm 6.3’de verilen yöntemler kullanılarak seçilen regresyon modellerinin eğitim verilerinden bağımsız olarak toplanan test verileri ile değerlendirilmesi ve seçilen modellerin gerçek kullanım senaryolarındaki başarısının ölçülmesi gerekmektedir. Bu amaçla her iki uygulama sahası için toplanan test verilerinden elde edilen konum ve mesafe değerleri için aşağıda belirtilen istatistiksel yöntemler kullanılarak performansları hesaplanmıştır.

- En düşük fark
- En yüksek fark
- Ortalama Hata
- Mutlak Ortalama Hata
- Ortanca Hata
- Standart Sapma
- Karesel Ortalama Hata
- R^2

Bu yöntemlerden;

En düşük fark: Test verisindeki gerçek değerler (mesafe ve koordinat) ile hesaplanan değerler (koordinat için y ve x ayrı ayrı) arasındaki farkların en düşük değerini ifade eder.

En yüksek fark: Test verisindeki gerçek değerler (mesafe ve koordinat) ile hesaplanan değerler (koordinat için y ve x ayrı ayrı) arasındaki farkların en yüksek değerini ifade eder.

Ortalama hata: Test verisindeki gerçek değerler (mesafe ve koordinat) ile hesaplanan değerler (koordinat için y ve x ayrı ayrı) arasındaki farkların ortalamasını ifade etmektedir.

Mutlak ortalama hata: Test verisindeki gerçek değerler (mesafe ve koordinat) ile hesaplanan değerler (koordinat için y ve x ayrı ayrı) arasındaki farkların mutlak

değerleri alınarak hesaplanan ortalamayı ifade etmektedir. Hesaplamada kullanılan matematiksel eşitlikler Bölüm 6.3.3.2.3’de daha önce verilmiştir.

Ortanca Hata: Test verisindeki gerçek değerler (mesafe ve koordinat) ile hesaplanan değerler (koordinat için y ve x ayrı ayrı) arasındaki farkların ortanca(medyan) değerini ifade eder.

Standart Sapma (STDS): Test verisindeki gerçek değerler (mesafe ve koordinat) ile hesaplanan değerler (koordinat için y ve x ayrı ayrı) arasındaki farkların standart sapmasını ifade etmektedir. Hesaplamada kullanılan matematiksel eşitlikler Bölüm 6.3.2.1’de daha önce verilmiştir.

Karesel Ortalama Hata (KOH): Bu değer Eşitlik 7.17 ile verilen formüle göre hesaplanmış olup bu formüle göre n test nokta sayısını, t ölçülen değeri, t0 gerçek değeri, u ise bilinmeyen sayısını ifade etmektedir.

$$KOH = \sqrt{\frac{\sum_{k=1}^n (t_k - t0_k)^2}{n - u}} \quad (7.17)$$

R²: Bu değer daha önce Bölüm 6.3.3.2.1’de verilen eşitliler ile ifade edilen formüle göre hesaplanmıştır.

Belirlenen makine öğrenmesi tabanlı regresyon modellerinin değerlendirilmesi iki farklı şekilde yapılmıştır. Bu değerlendirmelerden biri yukarıda verilen istatistiksel hesaplamalar ile diğeri ise Eşitlik 6.1’de verilen Öklid bağıntısına göre, hesaplanan konum ile gerçek konum arasındaki uzaklıkların ortalaması alınarak yapılmıştır.

7.2.1. Uygulama 1 için istatistiksel sonuçlar

Bir önceki bölümde belirtilen yöntemlere göre yapılan istatistiksel hesaplamalar sonucu, en iyi konum doğruluğunu sağlayan yöntemi seçebilmek için Y ve X değerlerinde hesaplanan STDS (Standart Sapma) ve KOH (Karesel Ortalama Hata) değerlerinin ortalaması alınmış olup hesaplanan en düşük sayısal değere sahip yöntemin en iyi konum doğruluğunu sağladığı kabul edilmiştir. Bu hem Uygulama 1 için hem de Uygulama 2 için uygulanarak en iyi performansı veren yöntem belirlenmeye çalışılmıştır.

Çizelge 7.2. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.

	Mesafe V23	Mesafe V24	Mesafe V25	Mesafe V26
Ölçü Sayısı	31	31	31	31
En Düşük Fark (m)	-5.730	-3.510	-7.010	-6.060
En Yüksek Fark (m)	5.320	8.030	5.020	5.130
Ortalama (m)	0.075	0.216	0.166	0.114
Mutlak Ortalama (m)	1.869	2.058	1.840	1.736
Ortanca (m)	-0.020	0.030	0.050	0.460
STDS (m)	2.573	2.760	2.522	2.278
KOH (m)	2.574	2.769	2.527	2.281
R²	0.99	0.99	0.99	0.99

Çizelge 7.3. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.

	Trilaterasyon 4 Nokta		EKK 1 İterasyon		EKK 100 İterasyon		Ağırlıklandırılmış EKK 1 İterasyon		Ağırlıklandırılmış EKK 100 İterasyon	
	Y	X	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	31	31	31	31	31	31	31	31	31	31
En Düşük Fark (m)	-6.666	-4.253	-9.252	-5.463	-4.444	-3.619	-8.956	-5.408	-4.442	-3.636
En Yüksek Fark (m)	7.441	5.220	4.254	6.585	4.036	8.198	4.245	6.427	4.193	8.523
Ortalama (m)	0.036	0.186	-0.625	-0.538	0.109	0.187	-0.583	-0.506	0.107	0.152
Mutlak Ortalama (m)	2.389	2.178	2.156	1.720	1.716	1.827	2.124	1.694	1.739	1.810
Ortanca (m)	-0.215	0.027	-0.369	-0.520	-0.066	-0.117	-0.337	-0.534	-0.050	-0.158
STDS (m)	3.219	2.679	2.858	2.372	2.196	2.586	2.816	2.352	2.217	2.591
KOH (m)	3.219	2.686	2.927	2.434	2.199	2.593	2.878	2.407	2.219	2.595
R²	0.96	0.98	0.97	0.98	0.98	0.98	0.97	0.98	0.98	0.98

Çizelge 7.4. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.

	EKK 1 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 1 İterasyon 3 Nokta		EKK 100 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 100 İterasyon 3 Nokta	
	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	31	31	31	31	31	31	31	31
En Düşük Fark (m)	-5.018	-3.554	-5.010	-3.600	-6.184	-4.899	-5.016	-3.603
En Yüksek Fark (m)	7.245	6.839	7.368	6.962	4.702	6.438	4.861	6.348
Ortalama (m)	0.208	0.316	0.236	0.321	-0.367	-0.201	-0.327	-0.190
Mutlak Ortalama (m)	2.109	1.958	2.114	1.983	2.037	1.709	2.008	1.799
Ortanca (m)	0.001	-0.502	0.002	-0.506	-0.147	-0.505	-0.162	-0.541
STDS (m)	2.780	2.642	2.802	2.668	2.647	2.244	2.580	2.379
KOH (m)	2.788	2.661	2.813	2.688	2.673	2.253	2.601	2.488
R²	0.97	0.98	0.97	0.98	0.98	0.98	0.98	0.99

Yukarıda verilen Çizelge 7.2 Uygulama 1 için yöntem 1'e göre K24 koridorunda yapılan test ölçümlerin de elde edilen mesafe tahminlerine ilişkin istatistiksel sonuçları göstermektedir. Bu mesafe tahminleri ile trilaterasyon kullanılarak koordinatlar hesaplanmış olup önceki bölümde bahsedildiği gibi EKK ile dengeleme yapılarak elde edilen konum doğruluklarına ilişkin istatistiksel hesaplamalar Çizelge 7.3 ve 7.4 ile verilmiştir. Buna göre yöntem 1 ile K24 koridorunda belirlenen en iyi konum doğruluğu değeri bölümün başında belirtilen değerlendirmeye göre Çizelge 7.3'de yer alan "EKK 100 İterasyon" yöntemi ile hesaplanmıştır.

Çizelge 7.5. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.

	Mesafe V23	Mesafe V24	Mesafe V25	Mesafe V26
Ölçü Sayısı	31	31	31	31
En Düşük Fark (m)	-7.750	-4.510	-7.270	-6.810
En Yüksek Fark (m)	6.670	9.730	5.890	7.080
Ortalama (m)	0.079	0.679	-0.255	-0.175
Mutlak Ortalama (m)	1.855	1.572	1.611	1.767
Ortanca (m)	0.400	0.160	-0.310	-0.110
STDS (m)	2.634	2.471	2.542	2.760
KOH (m)	2.636	2.565	2.555	2.766
R²	0.99	0.99	0.99	0.99

Çizelge 7.6. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.

	Trilaterasyon 4 Nokta		EKK 1 İterasyon		EKK 100 İterasyon		Ağırlıklandırılmış EKK 1 İterasyon		Ağırlıklandırılmış EKK 100 İterasyon	
	Y	X	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	31	31	31	31	31	31	31	31	31	31
En Düşük Fark (m)	-14.079	-11.787	-3.408	-6.019	-3.285	-4.935	-3.449	-5.847	-3.310	-4.942
En Yüksek Fark (m)	11.920	11.495	7.606	11.464	7.118	10.226	7.489	11.970	7.602	10.295
Ortalama (m)	0.367	0.681	0.623	1.119	0.595	0.935	0.598	1.152	0.580	0.954
Mutlak Ortalama (m)	3.852	4.217	2.190	2.440	2.039	2.112	2.195	2.442	2.055	2.118
Ortanca (m)	-0.337	-0.247	-0.231	0.494	-0.311	0.192	-0.211	0.474	-0.317	0.128
STDS (m)	5.465	5.538	2.905	3.562	2.711	3.061	2.889	3.568	2.736	3.065
KOH (m)	5.478	5.581	2.973	3.739	2.778	3.205	2.953	3.755	2.799	3.215
R²	0.90	0.90	0.97	0.95	0.97	0.97	0.97	0.95	0.97	0.97

Çizelge 7.7. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.

	EKK 1 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 1 İterasyon 3 Nokta		EKK 100 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 100 İterasyon 3 Nokta	
	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	31	31	31	31	31	31	31	31
En Düşük Fark (m)	-4.579	-4.957	-4.550	-4.948	-3.712	-5.095	-3.757	-4.936
En Yüksek Fark (m)	9.590	11.791	9.346	11.689	6.785	11.856	6.542	11.812
Ortalama (m)	0.637	0.981	0.579	0.963	0.455	0.818	0.455	0.866
Mutlak Ortalama (m)	2.160	2.728	2.141	2.718	1.848	2.414	1.839	2.380
Ortanca (m)	-0.262	-0.093	-0.331	-0.098	-0.165	0.064	-0.145	0.014
STDS (m)	3.127	4.053	3.115	4.038	2.621	3.648	2.593	3.572
KOH (m)	3.193	4.174	3.170	4.155	2.662	3.741	2.634	3.679
R²	0.97	0.94	0.97	0.94	0.98	0.95	0.98	0.96

Yukarıda verilen Çizelge 7.5 Uygulama 1 için yöntem 1'e göre K26 koridorunda yapılan test ölçümlerin de elde edilen mesafe tahminlerine ilişkin istatistiksel sonuçları göstermektedir. Bu mesafe tahminleri ile elde edilen konum doğruluklarına ilişkin

istatistiksel hesaplamalar Çizelge 7.6 ve 7.7 ile verilmiştir. Elde edilen sonuçlar için yapılan değerlendirmeye göre yöntem 1 ile K26 koridorunda belirlenen en iyi konum doğruluğu değeri, Çizelge 7.6’da yer alan “EKK 100 İterasyon” yöntemi ile hesaplanmıştır.

Çizelge 7.8. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.

	Mesafe V23	Mesafe V24	Mesafe V25	Mesafe V26
Ölçü Sayısı	30	30	30	30
En Düşük Fark (m)	-2.600	-3.880	-2.740	-2.260
En Yüksek Fark (m)	1.820	2.560	2.210	2.900
Ortalama (m)	-0.145	-0.218	-0.039	0.341
Mutlak Ortalama (m)	0.832	0.730	0.984	0.950
Ortanca (m)	-0.160	-0.035	-0.040	0.270
STDS (m)	1.064	1.173	1.322	1.182
KOH (m)	1.074	1.193	1.322	1.231
R²	0.94	0.85	0.81	0.88

Çizelge 7.9. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.

	Trilaterasyon 4 Nokta		EKK 1 İterasyon		EKK 100 İterasyon		Ağırlıklandırılmış EKK 1 İterasyon		Ağırlıklandırılmış EKK 100 İterasyon	
	Y	X	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	30	30	30	30	30	30	30	30	30	30
En Düşük Fark (m)	-8.590	-9.699	-11.466	-10.495	-12.269	-10.593	-11.242	-10.763	-12.189	-10.744
En Yüksek Fark (m)	4.309	5.434	4.305	4.582	4.337	4.601	4.864	4.682	5.065	4.728
Ortalama (m)	-0.788	-1.014	-0.712	-0.938	-0.683	-0.910	-0.649	-0.899	-0.617	-0.849
Mutlak Ortalama (m)	2.468	2.392	2.173	2.298	2.162	2.329	2.190	2.297	2.193	2.335
Ortanca (m)	-0.323	-0.511	-0.378	-0.716	-0.259	-0.592	-0.311	-0.671	-0.239	-0.557
STDS (m)	3.211	3.138	3.245	3.174	3.373	3.270	3.269	3.221	3.416	3.310
KOH (m)	3.309	3.303	3.325	3.314	3.444	3.398	3.335	3.347	3.473	3.421
R²	0.76	0.74	0.75	0.73	0.70	0.69	0.75	0.72	0.69	0.68

Çizelge 7. 10. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.

	EKK 1 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 1 İterasyon 3 Nokta		EKK 100 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 100 İterasyon 3 Nokta	
	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	30	30	30	30	30	30	30	30
En Düşük Fark (m)	-11.927	-10.394	-12.018	-10.432	-11.938	-10.393	-12.027	-10.433
En Yüksek Fark (m)	3.452	4.588	3.760	4.616	3.705	4.593	3.901	4.620
Ortalama (m)	-0.633	-0.851	-0.615	-0.834	-0.616	-0.836	-0.602	-0.822
Mutlak Ortalama (m)	2.171	2.258	2.170	2.262	2.179	2.264	2.175	2.265
Ortanca (m)	-0.289	-0.450	-0.264	-0.440	-0.282	-0.462	-0.260	-0.438
STDS (m)	3.316	3.205	3.334	3.220	3.327	3.212	3.341	3.226
KOH (m)	3.377	3.320	3.392	3.330	3.386	3.322	3.397	3.333
R ²	0.73	0.73	0.72	0.72	0.73	0.73	0.72	0.72

Yukarıda verilen Çizelge 7.8 Uygulama 1 için yöntem 1'e göre Orta Alanda yapılan test ölçümlerin de elde edilen mesafe tahminlerine ilişkin istatistiksel sonuçları göstermektedir. Bu mesafe tahminleri ile elde edilen konum doğruluklarına ilişkin istatistiksel hesaplamalar Çizelge 7.9 ve 7.10 ile verilmiştir. Elde edilen sonuçlar için yapılan değerlendirmeye göre yöntem 1 ile Orta Alanda belirlenen en iyi konum doğruluğu değeri, Çizelge 7.9'da yer alan "EKK 1 İterasyon" yöntemi ile hesaplanmıştır.

Çizelge 7.11. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.

	Mesafe V23	Mesafe V24	Mesafe V25	Mesafe V26
Ölçü Sayısı	92	92	92	92
En Düşük Fark (m)	-10.600	-8.900	-9.410	-10.600
En Yüksek Fark (m)	8.900	9.990	10.690	10.030
Ortalama (m)	-0.384	-0.215	0.162	-0.052
Mutlak Ortalama (m)	2.131	2.110	2.274	2.229
Ortanca (m)	-0.030	0.040	0.035	-0.015
STDS (m)	3.033	3.131	3.140	3.216
KOH (m)	3.057	3.139	3.144	3.216
R ²	0.97	0.97	0.97	0.97

Çizelge 7. 12. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.

	Trilaterasyon 4 Nokta		EKK 1 İterasyon		EKK 100 İterasyon		Ağırlıklandırılmış EKK 1 İterasyon		Ağırlıklandırılmış EKK 100 İterasyon	
	Y	X	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	92	92	92	92	92	92	92	92	92	92
En Düşük Fark (m)	-12.956	-14.346	-13.324	-10.225	-13.295	-10.411	-13.271	-10.161	-13.250	-10.382
En Yüksek Fark (m)	15.690	22.319	10.149	13.939	10.105	11.482	10.122	13.946	10.072	11.420
Ortalama (m)	0.680	0.399	0.511	0.265	0.279	0.000	0.530	0.266	0.275	0.005
Mutlak Ortalama (m)	4.584	4.367	3.061	3.204	2.912	2.705	3.064	3.206	2.912	2.699
Ortanca (m)	-0.166	0.113	0.169	0.005	0.136	0.184	0.159	-0.011	0.133	0.222
STDS (m)	6.000	6.068	4.217	4.386	4.051	3.767	4.223	4.390	4.062	3.765
KOH (m)	6.039	6.081	4.248	4.394	4.061	3.767	4.256	4.398	4.072	3.765
R²	0.82	0.82	0.91	0.91	0.92	0.93	0.91	0.91	0.92	0.93

Çizelge 7.13. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.

	EKK 1 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 1 İterasyon 3 Nokta		EKK 100 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 100 İterasyon 3 Nokta	
	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	92	92	92	92	92	92	92	92
En Düşük Fark (m)	-13.029	-10.426	-13.007	-10.459	-13.023	-10.428	-13.000	-10.459
En Yüksek Fark (m)	10.752	16.156	12.929	11.960	10.010	11.939	10.054	11.937
Ortalama (m)	0.397	0.173	0.403	0.066	0.344	0.015	0.342	0.016
Mutlak Ortalama (m)	3.161	3.083	3.012	2.834	2.980	2.811	2.976	2.811
Ortanca (m)	0.230	0.177	0.304	-0.002	0.425	0.339	0.438	0.282
STDS (m)	4.310	4.252	4.181	3.929	4.140	3.861	4.139	3.865
KOH (m)	4.329	4.256	4.201	3.930	4.154	3.861	4.154	3.865
R²	0.91	0.91	0.91	0.92	0.91	0.93	0.91	0.93

Yukarıda verilen Çizelge 7.11 Uygulama 1 için yöntem 2'ye göre Tüm uygulama sahasında 4 model kullanılarak yapılan test ölçümlerin de elde edilen mesafe tahminlerine ilişkin istatistiksel sonuçları göstermektedir. Bu mesafe tahminleri ile elde edilen konum

doğruluklarına ilişkin istatistiksel hesaplamalar Çizelge 7.12 ve 7.13 ile verilmiştir. Elde edilen sonuçlar için yapılan değerlendirmeye göre yöntem 2 ile tüm uygulama sahasında 4 model ile belirlenen en iyi konum doğruluğu değeri, Çizelge 7.12’de yer alan “EKK 100 İterasyon” yöntemi ile hesaplanmıştır.

Çizelge 7.14. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.

	Mesafe V23	Mesafe V24	Mesafe V25	Mesafe V26
Ölçü Sayısı	92	92	92	92
En Düşük Fark (m)	-11.000	-8.870	-15.500	-15.210
En Yüksek Fark (m)	15.150	15.500	10.930	11.000
Ortalama (m)	-0.015	0.035	-0.015	0.020
Mutlak Ortalama (m)	2.251	2.230	2.299	2.319
Ortanca (m)	0.150	0.090	-0.125	-0.090
STDS (m)	3.510	3.435	3.586	3.587
KOH (m)	3.510	3.435	3.586	3.587
R²	0.97	0.97	0.97	0.97

Çizelge 7.15. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.

	Trilaterasyon 4 Nokta		EKK 1 İterasyon		EKK 100 İterasyon		Ağırlıklandırılmış EKK 1 İterasyon		Ağırlıklandırılmış EKK 100 İterasyon	
	Y	X	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	92	92	92	92	92	92	92	92	92	92
En Düşük Fark (m)	-10.322	-7.842	-11.020	-7.522	-10.987	-10.304	-11.020	-7.523	-10.987	-10.302
En Yüksek Fark (m)	7.664	11.483	7.939	10.803	7.925	10.836	7.935	10.805	7.921	10.839
Ortalama (m)	-0.176	-0.175	-0.232	-0.231	-0.271	-0.268	-0.232	-0.230	-0.271	-0.267
Mutlak Ortalama (m)	1.850	1.912	1.909	1.888	1.998	1.984	1.909	1.888	1.998	1.983
Ortanca (m)	-0.105	0.098	-0.119	-0.122	-0.106	-0.095	-0.121	-0.119	-0.107	-0.092
STDS (m)	2.722	2.843	2.805	2.792	2.976	3.016	2.804	2.792	2.975	3.016
KOH (m)	2.728	2.849	2.815	2.802	2.989	3.028	2.814	2.802	2.988	3.027
R²	0.96	0.96	0.96	0.96	0.95	0.96	0.96	0.96	0.95	0.96

Çizelge 7.16. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.

	EKK 1 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 1 İterasyon 3 Nokta		EKK 100 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 100 İterasyon 3 Nokta	
	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	92	92	92	92	92	92	92	92
En Düşük Fark (m)	-11.015	-9.799	-11.009	-9.864	-11.017	-9.576	-11.012	-9.595
En Yüksek Fark (m)	8.049	10.893	8.050	10.900	8.049	10.891	8.050	10.898
Ortalama (m)	-0.291	-0.267	-0.292	-0.268	-0.290	-0.269	-0.291	-0.269
Mutlak Ortalama (m)	2.012	1.969	2.014	1.971	2.012	1.970	2.012	1.970
Ortanca (m)	-0.137	-0.212	-0.137	-0.215	-0.139	-0.211	-0.137	-0.215
STDS (m)	2.988	2.975	2.991	2.980	2.983	2.976	2.984	2.978
KOH (m)	3.003	2.987	3.006	2.992	2.997	2.988	2.998	2.990
R ²	0.95	0.96	0.95	0.96	0.95	0.96	0.95	0.96

Yukarıda verilen Çizelge 7.14, Uygulama 1 için yöntem 3’e göre tüm uygulama sahasında 1 model kullanılarak yapılan test ölçümlerin de elde edilen mesafe tahminlerine ilişkin istatistiksel sonuçları göstermektedir. Bu mesafe tahminleri ile elde edilen konum doğruluklarına ilişkin istatistiksel hesaplamalar Çizelge 7.15 ve 7.16 ile verilmiştir. Elde edilen sonuçlar için yapılan değerlendirmeye göre yöntem 3 ile tüm uygulama sahasında 1 model ile belirlenen en iyi konum doğruluğu değeri, Çizelge 7.15’de yer alan “Trilaterasyon 4 Nokta” yöntemi ile hesaplanmıştır.

Çizelge 7.17. Parmak izi yöntemine göre elde edilen konum doğruluklarına ilişkin istatistiksel sonuçlar.

	Parmak İzi K24		Parmak İzi K26		Parmak İzi Orta		Parmak İzi Tüm Saha	
	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	31	31	31	31	30	30	92	92
En Düşük Fark (m)	-4.653	-3.434	-5.748	-4.841	-4.394	-4.531	-7.055	-6.758
En Yüksek Fark (m)	3.408	5.279	4.707	5.392	5.469	2.172	12.593	7.126
Ortalama (m)	-0.115	0.068	-0.240	0.240	0.117	-0.334	0.080	-0.307
Mutlak Ortalama (m)	1.199	1.248	1.282	1.462	1.179	1.084	1.912	1.893
Ortanca (m)	-0.132	0.016	-0.100	0.149	0.164	-0.114	-0.009	-0.128
STDS (m)	1.703	1.801	1.966	2.092	1.734	1.414	2.698	2.504
KOH (m)	1.707	1.803	1.981	2.107	1.738	1.454	2.699	2.523
R ²	0.99	0.99	0.99	0.99	0.80	0.85	0.96	0.97

Çizelge 7.17’de Parmak izi yöntemine göre belirlenen 4 modelin RSSI değerlerinden doğrudan hesapladığı konum değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar bulunmaktadır. Diğer yöntemlerde yapılan değerlendirme bu yönteme de uygulanmış olup en iyi konum doğruluğunun yöntem 1’e göre yapılan alanlara ayırma sonucunda elde edildiği görülmüştür.

Çizelge 7.18. Uygulama 1 için yapılan değerlendirmede belirlenen yöntemler ve hesaplanan skorları.

Konum Belirlenen Alan	Yöntem Adı	Skor
K24	EKK 100 İterasyon	2.39
K26	EKK 100 İterasyon	2.94
Orta Alan	EKK 1 İterasyon	3.26
Tüm Alan 4 Model	EKK 100 İterasyon	3.91
Tüm Alan 1 Model	Trilaterasyon 4 Nokta	2.79
Parmak İzi K24	-	1.75
Parmak İzi K26	-	2.03
Parmak İzi Orta Alan	-	1.59
Parmak İzi Tüm Alan	-	2.61

Sonuç olarak Uygulama 1 için en iyi konum doğruluğunu veren yöntemler Çizelge 7.18’de verilmiştir. Çizelge 7.18’de belirtilen skor sütunda yer alan sayısal değerler SDTS ve KOH değerlerinin ortalamasını ifade etmektedir. Bu değerlere göre yöntem 1’e göre yapılan yani uygulama sahasını bölgelere ayırarak parmak izi yöntemi ile konum belirlemenin daha başarılı olduğu görülmektedir.

Çizelge 7.19. Trilaterasyon ile belirlenen konumların Öklid uzunluğuna göre belirlenmiş ortalama hataları.

	K24	K26	Orta Alan	Tüm Konum 4 Model	Tüm Konum 1 Model
Trilaterasyon 4 Nokta(m)	3.63	5.98	3.58	6.74	2.73
EKK 1 İterasyon(m)	2.97	3.63	3.31	4.81	2.79
EKK 100 İterasyon(m)	2.71	3.14	3.33	4.32	2.91
Ağırlıklandırılmış EKK 1 İterasyon(m)	2.94	3.62	3.31	4.81	2.79
Ağırlıklandırılmış EKK 100 İterasyon(m)	2.71	3.15	3.35	4.31	2.91
EKK 1 İterasyon 3 Nokta(m)	3.07	3.76	3.28	4.72	2.92
Ağırlıklandırılmış EKK 1 İterasyon 3 Nokta(m)	3.09	3.76	3.28	4.47	2.93
EKK 100 İterasyon 3 Nokta(m)	2.83	3.38	3.28	4.42	2.92
Ağırlıklandırılmış EKK 100 İterasyon 3 Nokta(m)	2.76	3.33	3.28	4.42	2.92

Çizelge 7.20. Parmak izi yöntemi ile belirlenen konumların Öklid uzunluğuna göre belirlenmiş ortalama hataları.

	Ortalama Konum Hatası(m)
Parmak İzi K24	1.76
Parmak İzi K26	1.96
Parmak İzi Orta Alan	1.85
Parmak İzi Tüm Saha	2.87

Çizelge 7.19 ve 7.20’de daha önce verilen istatistiksel hesaplamalarda kullanılan aynı konum verileri kullanılmış olup daha önce Eşitlik 6.1 ile verilen Öklid uzunluğu formülü kullanılarak gerçek koordinatlar ile belirlenen yöntemlere göre hesaplanan koordinatlar arasındaki mesafe değerleri kullanılarak bu çizelgeler oluşturulmuştur. Bu çizelgelerde verilen sonuçlar incelendiğinde yapılan diğer değerlendirme ile benzer sonuçlar görülmektedir. Yani Uygulama 1 için yöntem 1’e göre uygulama sahasını bölgelere ayırmak ve parmak izi yöntemi ile konum belirlemek diğer yöntemlere göre

daha iyi sonuç vermektedir. Öte yandan Çizelge 6.12’de hiper parametre optimizasyonu sonucunda belirlenen parmak izi modellerinin performansı ile eğitim verisinden bağımsız toplanan test verisi ile belirlenen konuma ait istatistiksel değerlerin birbirine benzer olduğu, elde edilen doğrulukta aşırı sapma olmadığı tespit edilmiştir.

7.2.2. Uygulama 2 için istatistiksel sonuçlar

Bölüm 6.3’de belirlenen modellerin test verileri ile performansları ölçülerek elde ettiği sonuçların istatistiksel değerleri hesaplanmış olup aşağıda yer alan çizelgelerde belirtilmiştir. Bu değerlere göre önceki bölümde yapılan değerlendirmenin aynısı yapılarak en iyi performansı veren yöntem seçilmeye çalışılacaktır.

Çizelge 7.21. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.

	Mesafe V23	Mesafe V24	Mesafe V25	Mesafe V26
Ölçü Sayısı	31	31	31	31
En Düşük Fark (m)	-5.600	-9.480	-4.870	-7.550
En Yüksek Fark (m)	2.250	7.500	3.310	6.860
Ortalama (m)	-0.262	-0.013	-0.266	-0.097
Mutlak Ortalama (m)	1.069	2.161	1.279	1.963
Ortanca (m)	0.060	0.000	-0.320	0.210
STDS (m)	1.528	3.220	1.752	2.889
KOH (m)	1.551	3.220	1.773	2.890
R²	0.97	0.98	0.97	0.98

Çizelge 7.22. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.

	Trilaterasyon 4 Nokta		EKK 1 İterasyon		EKK 100 İterasyon		Ağırlıklandırılmış EKK 1 İterasyon		Ağırlıklandırılmış EKK 100 İterasyon	
	Y	X	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	31	31	31	31	31	31	31	31	31	31
En Düşük Fark (m)	-4.228	-5.746	-2.685	-6.427	-2.764	-6.037	-2.470	-5.804	-2.509	-5.602
En Yüksek Fark (m)	4.675	5.157	3.341	4.822	10.301	4.817	2.579	5.062	7.503	5.058
Ortalama (m)	0.032	0.146	-0.057	0.175	0.186	0.382	-0.054	0.298	0.099	0.406
Mutlak Ortalama (m)	1.696	1.782	1.019	1.284	1.274	1.290	0.969	1.201	1.166	1.218
Ortanca (m)	0.200	-0.021	-0.067	0.132	-0.009	0.134	-0.026	0.231	-0.068	0.283
STDS (m)	2.168	2.463	1.343	1.971	2.206	1.947	1.248	1.815	1.771	1.809
KOH (m)	2.168	2.468	1.344	1.979	2.214	1.986	1.249	1.840	1.773	1.855
R²	0.98	0.98	0.99	0.99	0.98	0.99	0.99	0.99	0.99	0.99

Çizelge 7.23. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.

	EKK 1 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 1 İterasyon 3 Nokta		EKK 100 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 100 İterasyon 3 Nokta	
	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	31	31	31	31	31	31	31	31
En Düşük Fark (m)	-2.496	-4.957	-6.109	-8.989	-2.236	-7.490	-2.196	-6.982
En Yüksek Fark (m)	2.124	5.137	2.121	5.158	2.121	5.137	1.975	5.160
Ortalama (m)	-0.169	0.185	-0.298	-0.187	-0.095	0.172	-0.065	0.074
Mutlak Ortalama (m)	1.079	1.180	1.186	1.627	0.933	1.320	0.922	1.404
Ortanca (m)	-0.178	-0.134	-0.089	-0.137	-0.220	-0.037	-0.092	-0.042
STDS (m)	1.271	1.799	1.600	2.650	1.119	2.192	1.125	2.196
KOH (m)	1.283	1.809	1.628	2.657	1.123	2.199	1.127	2.198
R²	0.99	0.99	0.99	0.98	1.00	0.98	1.00	0.98

Yukarıda verilen Çizelge 7.21 Uygulama 2 için yöntem 1'e göre K24 koridorunda yapılan test ölçümlerin de elde edilen mesafe tahminlerine ilişkin istatistiksel sonuçları göstermektedir. Bu mesafe tahminleri ile trilaterasyon yöntemi kullanılarak koordinatlar hesaplanmış olup elde edilen konum doğruluklarına ilişkin istatistiksel hesaplamalar Çizelge 7.22 ve 7.23 ile verilmiştir. Buna göre yöntem 1 ile K24 koridorunda belirlenen en iyi konum doğruluğu yapılan değerlendirmeye göre Çizelge 7.22'de yer alan "Ağırlıklandırılmış EKK 1 İterasyon" yöntemi ile hesaplanmıştır.

Çizelge 7.24. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.

	Mesafe V23	Mesafe V24	Mesafe V25	Mesafe V26
Ölçü Sayısı	31	31	31	31
En Düşük Fark (m)	-4.510	-8.910	-3.430	-8.040
En Yüksek Fark (m)	5.150	9.620	4.500	6.340
Ortalama (m)	-0.010	0.329	0.223	0.007
Mutlak Ortalama (m)	1.393	1.998	1.187	2.184
Ortanca (m)	-0.010	0.140	0.070	-0.190
STDS (m)	1.920	3.065	1.660	3.074
KOH (m)	1.920	3.084	1.675	3.074
R²	0.96	0.98	0.96	0.98

Çizelge 7.25. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.

	Trilaterasyon 4 Nokta		EKK 1 İterasyon		EKK 100 İterasyon		Ağırlıklandırılmış EKK 1 İterasyon		Ağırlıklandırılmış EKK 100 İterasyon	
	Y	X	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	31	31	31	31	31	31	31	31	31	31
En Düşük Fark (m)	-5.991	-4.714	-5.493	-3.736	-5.730	-6.399	-5.179	-3.985	-5.197	-4.000
En Yüksek Fark (m)	7.648	4.793	4.820	5.104	2.774	5.088	5.012	5.177	3.377	5.189
Ortalama (m)	0.201	0.184	0.013	0.260	-0.271	0.024	-0.105	0.291	-0.294	0.108
Mutlak Ortalama (m)	1.838	1.732	1.458	1.489	1.405	1.648	1.372	1.419	1.357	1.515
Ortanca (m)	0.064	0.220	-0.097	0.191	-0.152	0.015	-0.075	0.178	-0.215	0.241
STDS (m)	2.747	2.358	2.073	1.992	1.965	2.326	1.939	1.847	1.884	1.970
KOH (m)	2.755	2.366	2.073	2.009	1.984	2.326	1.942	1.870	1.907	1.973
R²	0.97	0.98	0.98	0.99	0.99	0.98	0.99	0.99	0.99	0.99

Çizelge 7.26. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.

	EKK 1 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 1 İterasyon 3 Nokta		EKK 100 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 100 İterasyon 3 Nokta	
	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	31	31	31	31	31	31	31	31
En Düşük Fark (m)	-6.594	-5.007	-8.898	-9.941	-8.523	-9.234	-8.604	-9.265
En Yüksek Fark (m)	5.721	6.339	5.808	6.586	5.847	6.169	6.160	6.369
Ortalama (m)	-0.140	0.369	-0.239	0.056	-0.161	0.113	-0.163	0.095
Mutlak Ortalama (m)	1.407	1.571	1.537	1.635	1.515	1.589	1.509	1.551
Ortanca (m)	-0.032	0.404	0.042	0.036	0.231	0.039	0.207	0.139
STDS (m)	2.090	2.185	2.554	2.646	2.470	2.509	2.521	2.524
KOH (m)	2.095	2.217	2.565	2.647	2.475	2.511	2.526	2.526
R²	0.98	0.98	0.98	0.98	0.98	0.98	0.98	0.98

Yukarıda verilen Çizelge 7.24 Uygulama 2 için yöntem 1'e göre K26 koridorunda yapılan test ölçümlerin de elde edilen mesafe tahminlerine ilişkin istatistiksel sonuçları göstermektedir. Bu mesafe tahminleri ile elde edilen konum doğruluklarına ilişkin istatistiksel hesaplamalar Çizelge 7.25 ve 7.26 ile verilmiştir. Elde edilen sonuçlar için

yapılan değerlendirmeye göre yöntem 1 ile K26 koridorunda belirlenen en iyi konum doğruluğu değeri, Çizelge 7.25’de yer alan “Ağırlıklandırılmış EKK 1 İterasyon” yöntemi ile hesaplanmıştır.

Çizelge 7.27. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.

	Mesafe V23	Mesafe V24	Mesafe V25	Mesafe V26
Ölçü Sayısı	30	30	30	30
En Düşük Fark (m)	-3.860	-2.650	-2.300	-2.290
En Yüksek Fark (m)	3.760	1.930	2.330	3.230
Ortalama (m)	0.034	0.080	0.089	0.214
Mutlak Ortalama (m)	0.853	0.953	0.832	0.931
Ortanca (m)	0.000	-0.055	0.080	0.185
STDS (m)	1.339	1.181	1.073	1.272
KOH (m)	1.340	1.184	1.077	1.290
R²	0.92	0.44	0.95	0.34

Çizelge 7.28. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.

	Trilaterasyon 4 Nokta		EKK 1 İterasyon		EKK 100 İterasyon		Ağırlıklandırılmış EKK 1 İterasyon		Ağırlıklandırılmış EKK 100 İterasyon	
	Y	X	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	30	30	30	30	30	30	30	30	30	30
En Düşük Fark (m)	-1.558	-2.867	-1.581	-3.111	-1.581	-3.116	-1.582	-3.087	-1.582	-3.092
En Yüksek Fark (m)	2.014	1.876	2.245	1.762	2.244	1.751	2.232	1.781	2.232	1.774
Ortalama (m)	0.097	0.000	0.094	-0.005	0.095	-0.006	0.091	-0.010	0.092	-0.011
Mutlak Ortalama (m)	0.788	0.955	0.803	0.990	0.804	0.989	0.800	0.990	0.801	0.990
Ortanca (m)	0.135	0.137	0.128	0.259	0.129	0.259	0.126	0.253	0.127	0.253
STDS (m)	0.981	1.213	1.009	1.256	1.010	1.255	1.005	1.254	1.006	1.252
KOH (m)	0.986	1.213	1.013	1.256	1.014	1.255	1.009	1.254	1.010	1.253
R²	0.93	0.88	0.93	0.87	0.93	0.87	0.93	0.88	0.93	0.88

Çizelge 7.29. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.

	EKK 1 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 1 İterasyon 3 Nokta		EKK 100 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 100 İterasyon 3 Nokta	
	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	30	30	30	30	30	30	30	30
En Düşük Fark (m)	-1.716	-3.606	-1.716	-3.626	-1.717	-3.618	-1.717	-3.641
En Yüksek Fark (m)	2.590	2.871	2.580	2.877	2.559	2.846	2.542	2.848
Ortalama (m)	0.127	0.060	0.128	0.060	0.114	0.062	0.116	0.061
Mutlak Ortalama (m)	0.858	0.973	0.858	0.974	0.862	0.973	0.860	0.974
Ortanca (m)	0.045	0.151	0.058	0.157	-0.061	0.153	-0.042	0.159
STDS (m)	1.069	1.370	1.069	1.372	1.070	1.370	1.069	1.371
KOH (m)	1.077	1.372	1.077	1.373	1.076	1.372	1.076	1.373
R²	0.92	0.85	0.92	0.85	0.92	0.85	0.92	0.85

Yukarıda verilen Çizelge 7.27 ile Uygulama 2 için yöntem 1’e göre Orta Alanda yapılan test ölçümlerin de elde edilen mesafe tahminlerine ilişkin istatistiksel sonuçları göstermektedir. Bu mesafe tahminleri ile elde edilen konum doğruluklarına ilişkin istatistiksel hesaplamalar Çizelge 7.28 ve 7.29 ile verilmiştir. Elde edilen sonuçlar için yapılan değerlendirmeye göre yöntem 1 ile Orta Alanda belirlenen en iyi konum doğruluğu değeri, Çizelge 7.28’de yer alan “Trilaterasyon 4 Nokta” yöntemi ile hesaplanmıştır. Çizelge 7.27’de belirtilen mesafe tahminlerine ilişkin istatistiksel sonuçlarda V24 ve V26 vericilerine olan mesafe tahminlerinde R^2 değerinin sırası ile 0.44 ve 0.34 olarak hesaplandığı görülmüştür. Fakat hesaplanan konumlara ilişkin sonuçlar incelendiğinde bu değer in yükseldiği görülmüştür. Bu sebep ile elde edilen sonuçlara göre modellerde parametre değişikliğine ihtiyaç duyulmamıştır.

Çizelge 7.30. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.

	Mesafe V23	Mesafe V24	Mesafe V25	Mesafe V26
Ölçü Sayısı	92	92	92	92
En Düşük Fark (m)	-7.020	-14.300	-7.020	-30.080
En Yüksek Fark (m)	7.060	31.670	5.380	12.500
Ortalama (m)	0.014	0.806	-0.029	-1.134
Mutlak Ortalama (m)	1.383	2.990	1.418	2.948
Ortanca (m)	-0.065	0.090	-0.045	-0.510
STDS (m)	2.012	5.564	1.995	5.392
KOH (m)	2.012	5.623	1.995	5.511
R²	0.96	0.92	0.96	0.92

Çizelge 7.31. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.

	Trilaterasyon 4 Nokta		EKK 1 İterasyon		EKK 100 İterasyon		Ağırlıklandırılmış EKK 1 İterasyon		Ağırlıklandırılmış EKK 100 İterasyon	
	Y	X	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	92	92	92	92	92	92	92	92	92	92
En Düşük Fark (m)	-17.897	-9.285	-17.312	-7.309	-21.918	-15.472	-15.879	-8.653	-15.856	-8.459
En Yüksek Fark (m)	10.671	18.450	9.754	17.083	8.162	32.060	7.610	15.617	7.114	25.557
Ortalama (m)	-0.875	0.490	-0.568	0.604	-0.601	0.695	-0.496	0.461	-0.512	0.721
Mutlak Ortalama (m)	2.640	2.542	2.084	2.267	2.015	2.535	1.871	1.984	1.819	2.162
Ortanca (m)	-0.527	0.395	-0.304	0.436	-0.591	0.532	-0.232	0.218	-0.292	0.317
STDS (m)	4.205	4.090	3.509	3.612	3.522	4.786	3.123	3.112	3.051	4.015
KOH (m)	4.296	4.119	3.555	3.663	3.573	4.837	3.162	3.146	3.094	4.079
R ²	0.91	0.92	0.94	0.94	0.94	0.89	0.95	0.95	0.95	0.92

Çizelge 7.32. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.

	EKK 1 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 1 İterasyon 3 Nokta		EKK 100 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 100 İterasyon 3 Nokta	
	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	92	92	92	92	92	92	92	92
En Düşük Fark (m)	-16.373	-9.163	-16.648	-7.951	-16.358	-9.175	-16.617	-7.958
En Yüksek Fark (m)	18.455	14.616	18.489	15.438	16.548	14.605	16.621	39.095
Ortalama (m)	-0.438	0.530	-0.375	0.726	-0.439	0.530	-0.394	0.974
Mutlak Ortalama (m)	1.992	1.932	2.008	1.997	1.962	1.939	1.935	2.270
Ortanca (m)	-0.230	0.347	-0.239	0.310	-0.224	0.258	-0.217	0.314
STDS (m)	3.587	3.067	3.619	3.383	3.462	3.076	3.479	5.030
KOH (m)	3.614	3.113	3.639	3.461	3.490	3.121	3.502	5.125
R ²	0.93	0.95	0.93	0.94	0.94	0.95	0.94	0.87

Yukarıda verilen Çizelge 7.30 ile Uygulama 2 için yöntem 2'ye göre tüm uygulama sahasında 4 model kullanılarak yapılan test ölçümlerin de elde edilen mesafe tahminlerine ilişkin istatistiksel sonuçları göstermektedir. Bu mesafe tahminleri ile elde edilen konum doğruluklarına ilişkin istatistiksel hesaplamalar Çizelge 7.31 ve 7.32 ile

verilmiştir. Elde edilen sonuçlar için yapılan değerlendirmeye göre yöntem 2 ile tüm uygulama sahasında 4 model ile belirlenen en iyi konum doğruluğu değeri, Çizelge 7.31’de yer alan “Ağırlıklandırılmış EKK 1 İterasyon” yöntemi ile hesaplanmıştır.

Çizelge 7.33. Test ölçümlerinde belirlenen mesafe değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar.

	Mesafe V23	Mesafe V24	Mesafe V25	Mesafe V26
Ölçü Sayısı	92	92	92	92
En Düşük Fark (m)	-6.680	-25.020	-7.280	-29.440
En Yüksek Fark (m)	7.320	30.440	6.420	24.820
Ortalama (m)	0.106	0.393	-0.301	-0.378
Mutlak Ortalama (m)	1.662	3.115	1.648	3.108
Ortanca (m)	0.030	-0.020	-0.385	-0.095
STDS (m)	2.398	6.007	2.371	5.931
KOH (m)	2.400	6.020	2.391	5.943
R²	0.95	0.90	0.94	0.91

Çizelge 7.34. Dört referans ile Trilaterasyon ve EKK kullanılarak hesaplanan konum doğruluklarına ilişkin istatistiksel sonuçlar.

	Trilaterasyon 4 Nokta		EKK 1 İterasyon		EKK 100 İterasyon		Ağırlıklandırılmış EKK 1 İterasyon		Ağırlıklandırılmış EKK 100 İterasyon	
	Y	X	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	92	92	92	92	92	92	92	92	92	92
En Düşük Fark (m)	-24.393	-16.593	-23.077	-19.414	-14.775	-7.015	-21.127	-26.714	-15.885	-12.872
En Yüksek Fark (m)	19.701	19.906	24.230	19.528	40.072	33.408	31.042	17.331	43.098	25.287
Ortalama (m)	-0.452	0.114	-0.429	0.115	-0.070	0.439	-0.391	0.079	-0.153	0.402
Mutlak Ortalama (m)	2.269	2.437	2.289	2.471	2.272	2.459	2.391	2.561	2.214	2.435
Ortanca (m)	-0.174	-0.260	-0.174	-0.261	-0.174	-0.261	-0.174	-0.163	-0.174	-0.163
STDS (m)	4.492	4.318	4.713	4.464	5.303	4.900	5.123	4.860	5.541	4.553
KOH (m)	4.515	4.319	4.732	4.465	5.304	4.920	5.138	4.861	5.544	4.571
R²	0.90	0.91	0.89	0.90	0.86	0.88	0.87	0.89	0.85	0.90

Çizelge 7.35. Üç referans ve EKK kullanılarak yapılan dengelenme sonucu hesaplanan istatistiksel sonuçlar.

	EKK 1 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 1 İterasyon 3 Nokta		EKK 100 İterasyon 3 Nokta		Ağırlıklandırılmış EKK 100 İterasyon 3 Nokta	
	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	92	92	92	92	92	92	92	92
En Düşük Fark (m)	-40.988	-29.428	-14.316	-9.769	-36.975	-28.537	-14.326	-9.785
En Yüksek Fark (m)	35.120	16.485	37.718	31.284	35.952	16.529	32.877	30.088
Ortalama (m)	-0.677	-0.151	-0.080	0.412	-0.624	-0.107	-0.175	0.334
Mutlak Ortalama (m)	2.613	2.566	2.219	2.531	2.580	2.591	2.185	2.541
Ortanca (m)	-0.174	-0.162	-0.174	-0.163	-0.174	-0.162	-0.174	-0.163
STDS (m)	6.509	4.913	5.016	4.956	6.298	4.913	4.660	4.879
KOH (m)	6.545	4.915	5.017	4.974	6.329	4.914	4.663	4.891
R²	0.78	0.88	0.87	0.88	0.80	0.88	0.89	0.88

Yukarıda verilen Çizelge 7.33 ile Uygulama 2 için yöntem 3'e göre tüm uygulama sahasında 1 model kullanılarak yapılan test ölçümlerin de elde edilen mesafe tahminlerine ilişkin istatistiksel sonuçları göstermektedir. Bu mesafe tahminleri ile elde edilen konum doğruluklarına ilişkin istatistiksel hesaplamalar Çizelge 7.34 ve 7.35 ile verilmiştir. Elde edilen sonuçlar için yapılan değerlendirmeye göre yöntem 3 ile tüm uygulama sahasında 1 model ile belirlenen en iyi konum doğruluğu değeri, Çizelge 7.34'de yer alan "Trilaterasyon 4 Nokta" yöntemi ile hesaplanmıştır.

Çizelge 7.36. Parmak izi yöntemine göre elde edilen konum doğruluklarına ilişkin istatistiksel sonuçlar.

	Parmak İzi K24		Parmak İzi K26		Parmak İzi Orta		Parmak İzi Tüm Saha	
	Y	X	Y	X	Y	X	Y	X
Ölçü Sayısı	31	31	31	31	30	30	92	92
En Düşük Fark (m)	-5.224	-6.817	-6.203	-9.014	-1.626	-4.325	-18.179	-12.621
En Yüksek Fark (m)	5.921	5.022	6.563	5.567	4.103	2.208	12.759	21.584
Ortalama (m)	-0.129	-0.052	0.266	-0.499	0.364	-0.182	-0.287	0.398
Mutlak Ortalama (m)	1.476	1.509	1.505	1.650	1.088	1.084	2.184	2.768
Ortanca (m)	0.000	0.000	0.070	-0.200	0.199	-0.186	0.038	0.284
STDS (m)	2.193	2.203	2.469	2.722	1.362	1.483	3.843	4.594
KOH (m)	2.197	2.203	2.483	2.769	1.412	1.494	3.854	4.612
R²	0.98	0.98	0.98	0.97	0.86	0.82	0.93	0.90

Çizelge 7.36’da Parmak izi yöntemine göre belirlenen 4 modelin RSSI değerlerinden doğrudan hesapladığı konum değerlerinin doğruluklarına ilişkin istatistiksel sonuçlar bulunmaktadır. Diğer yöntemlerde yapılan değerlendirme bu yönteme de uygulanmış olup en iyi konum doğruluğunun yöntem 1’e göre yapılan alanlara ayırma sonucunda elde edildiği görülmüştür.

Çizelge 7.37. Uygulama 2 için yapılan değerlendirmede belirlenen yöntemler ve hesaplanan skorları.

Konum Belirlenen Alan	Yöntem Adı	Skor
K24	Ağırlıklandırılmış EKK 1 İterasyon	1.54
K26	Ağırlıklandırılmış EKK 1 İterasyon	1.9
Orta Alan	Trilaterasyon 4 Nokta	1.1
Tüm Alan 4 Model	Ağırlıklandırılmış EKK 1 İterasyon	3.14
Tüm Alan 1 Model	Trilaterasyon 4 Nokta	4.41
Parmak İzi K24	-	2.2
Parmak İzi K26	-	2.61
Parmak İzi Orta Alan	-	1.44
Parmak İzi Tüm Alan	-	4.22

Uygulama 2 için en iyi konum doğruluğunu veren yöntemler Çizelge 7.37’de verilmiştir. Çizelge 7.37’de belirtilen skor sütunda yer alan sayısal değerlere göre yöntem 1 ile yapılan yani uygulama sahasını bölgelere ayırarak mesafe belirleme ve sonrasında trilaterasyon ve EKK ile konum belirlemenin daha başarılı olduğu görülmektedir.

Çizelge 7.38. Trilaterasyon ile belirlenen konumların Öklid uzunluğuna göre belirlenmiş ortalama hataları.

	K24	K26	Orta Alan	Tüm Konum 4 Model	Tüm Konum 1 Model
Trilaterasyon 4 Nokta(m)	2.69	2.81	1.34	3.89	3.39
EKK 1 İterasyon(m)	1.86	2.31	1.38	3.29	3.44
EKK 100 İterasyon(m)	2.35	2.41	1.38	3.52	3.58
Ağırlıklandırılmış EKK 1 İterasyon(m)	1.79	2.15	1.38	2.95	3.57
Ağırlıklandırılmış EKK 100 İterasyon(m)	1.95	2.21	1.38	3.08	3.49
EKK 1 İterasyon 3 Nokta(m)	1.83	2.29	1.37	3.06	3.85
Ağırlıklandırılmış EKK 1 İterasyon 3 Nokta(m)	2.23	2.57	1.37	3.13	3.63
EKK 100 İterasyon 3 Nokta(m)	1.86	2.50	1.37	3.03	3.82
Ağırlıklandırılmış EKK 100 İterasyon 3 Nokta(m)	1.90	2.48	1.37	3.36	3.56

Çizelge 7.39. Parmak izi yöntemi ile belirlenen konumların Öklid uzunluğuna göre belirlenmiş ortalama hataları.

	Ortalama Konum Hatası(m)
Parmak İzi K24	2.16
Parmak İzi K26	2.26
Parmak İzi Orta Alan	1.77
Parmak İzi Tüm Saha	3.72

Çizelge 7.38 ve 7.39’da daha önce verilen istatistiksel hesaplamalarda kullanılan aynı konum verileri kullanılmış olup Eşitlik 6.1 ile verilen Öklid uzunluğu formülü kullanılarak oluşturulmuştur. Bu çizelgelerde verilen sonuçlar incelendiğinde daha önce yapılan değerlendirme ile benzer sonuçlar görülmektedir. Yani Uygulama 2 için yöntem 1’e göre uygulama sahasını bölgelere ayırarak trilaterasyon ve EKK ile konum belirlemenin parmak izi yöntemine göre daha başarılı sonuçlar verdiği görülmektedir. Öte yandan Çizelge 6.14’de hiper parametre optimizasyonu sonucunda belirlenen parmak izi

modellerinin performansı ile eğitim verisinden bağımsız toplanan test verisinden elde edilen ortalama konum doğruluğu değerlerinin birbirine benzer olduğu modellerin beklenen performansı gösterdiği tespit edilmiştir.

Her iki uygulama için elde edilen en iyi konum doğruluğunu veren sonuçlar incelendiğinde;

- Uygulama 1 için yöntem 3'e göre trilaterasyon kullanılarak elde edilen ortalama konum doğruluğu ± 2.73 m ve yöntem 1'göre Parmak izi kullanılarak elde edilen ortalama konum doğruluğu ise ± 1.86 metredir.
- Uygulama 2 için yöntem 1'e göre trilaterasyon ve ağırlıklandırılmış EKK kullanılarak belirlenen ortalama konum doğruluğu ± 1.76 m ve Parmak izi yöntemi ile elde edilen ortalama konum doğruluğu ise ortalama ± 2.06 metredir.

Bu sonuçlara göre çalışma sahası için en iyi konum doğruluğu değerini, uygulama 2 ve yöntem 1'e göre trilaterasyon ve EKK ile elde edilen sonuçlar (± 1.76 m) vermektedir.

Literatürde yapılan çalışmalar incelendiğinde çalışma alanı büyüklüğü ve kullanılan donanımlar göz önünde bulundurularak karşılaştırma yapılabilecek çalışma sayısı oldukça azdır. Bu sebep ile çalışma alanı büyüklüğü göz önünde bulundurularak yapılan benzer çalışmalardan bazılarının sonuçları aşağıda verilmektedir.

- Özdemir (2020) yaptığı çalışmada Çizelge 3.9 ile bildirilen sonuçlar incelendiğinde en iyi konum doğruluğu değerinin (2.kat uygulama sahasında Ağırlıklandırılmış KNN yöntemi ve komşu sayısı=5 için) ± 2.29 metre olarak bulunduğu görülmektedir.
- Bahl ve Padmanabhan (2000) $43.5 \text{ m} \times 22.5 \text{ m}$ büyüklüğünde uygulama sahasında yaptığı çalışmada Çizelge 1 ile bildirilen sonuçlara göre Ampirik yöntemde ± 1.92 m (%25 yüzdelik dilim medyan değeri) ± 2.94 m (%50 yüzdelik dilim medyan değeri) ve ± 4.69 m (%75 yüzdelik dilin medyan değeri) konum doğruluğunun elde edildiği bildirilmiştir.

Söz konusu çalışmalardan her ikisinde de Wi-Fi tabanlı donanımlar kullanılmakta olup sonuçları ile bu çalışma sonucunda elde edilen konum doğrulukları karşılaştırıldığında daha yüksek konum doğruluğunun elde edilebildiği görülmektedir. Fakat kullanılan donanım sayısı ve yöntemlerin farklı olması sebebi ile net bir karşılaştırma yapılamamaktadır.

8. SONUÇ ve ÖNERİLER

Bu çalışmanın temel amacı kapalı mekanlarda konum belirleme işlevini yerine getirecek bir sistemin geliştirilerek konum doğruluğunun arttırılmasına ve incelenmesine yönelik araştırma yapmaktır. RSSI ölçümü yapabilen ve son zamanlarda popülerliği oldukça artan LoRa RF modülleri kullanılarak bu sistem geliştirilmiştir. Söz konusu sistem, RF modülleri ve ESP32 kontrolcü kartları kullanılarak oluşturulan 4 adet verici ve 1 adet alıcı olarak görev yapacak donanımdan ve Android tabanlı mobil uygulamadan oluşmaktadır. Geliştirilen donanımlar ile ölçülen RSSI değerleri gerçek zamanlı olarak Android tabanlı mobil uygulamaya Bluetooth aracılığı ile gönderilmektedir. Bu uygulama ile alıcı istasyondan gelen RSSI ölçümleri toplanarak her istasyondan 10 epok ölçüm yapılmakta, yapılan ölçümler istatistiksel yöntemlerle ön işlemeye tabi tutulmakta ve makine öğrenmesi tabanlı regresyon modelleri kullanılarak yapılan ölçümler, mesafeye veya parmak izi yöntemi ile doğrudan koordinata çevrilebilmektedir.

Çalışmada iki farklı konum belirleme yöntemi seçilmiş olup bunlar Trilaterasyon ve Parmak İzi yöntemleridir. Trilaterasyonun dezavantajlarından olan referans istasyonları yerleşim geometrisinin uygun olması gerekliliği sebebi ile uygulama sahasına verici istasyon olarak görev yapan donanımlar 2 farklı şekilde yerleştirilmiştir. Her iki yerleşimde de sahadan eğitim verileri toplanmış olup bu çalışma kapsamında geliştirilen 3 farklı yöntem ile bu veriler ayrılarak regresyon modellerinin eğitiminde kullanılmıştır. Bu yöntemlerde çalışma sahası bölgelere ayrılarak ve eğitilmiş model sayısı arttırılarak elde edilebilecek konum doğruluğunun arttırılması amaçlanmıştır. Belirlenen bu yöntemler ile oluşturulan regresyon modelleri, yine çalışma kapsamında geliştirilen hiper parametre ayarlama algoritması ile eğitim verileri kullanılarak eğitilmiş ve test verileri (eğitim verileri içerisinden ayrılmıştır) ile test edilerek performansları değerlendirilmiştir. Değerlendirilen modellerden Uygulama 1 ve 2 için mesafe belirlemede kullanılacak toplam 34 eğitilmiş model ve parmak izi yöntemi için ise 8 adet model seçilmiştir. Sonrasında uygulama sahasından her iki uygulama için test verileri toplanarak seçilen bu modellerin performansları gözlemlenmiştir. Mesafe tahmini yapan modellerin elde ettikleri mesafelerden trilaterasyon yöntemi ile koordinat hesaplanmış olup EKK ile koordinat belirleme doğruluğu arttırılmaya çalışılmıştır.

Uygulama 1 için elde edilen konum doğrulukları incelendiğinde yöntem 1'e göre uygulama sahasının bölgelere ayrılması ile oluşturulan modellerin parmak izi yöntemi ile belirledikleri konumların daha doğru olduğu görülmüştür. Bu modeller ile K24

koridorunda ortalama ± 1.76 m, K26 koridorunda ± 1.96 m ve Orta Alanda ± 1.85 metre doğrulukla (Öklid mesafe bağıntısına göre hesaplanan ortalama değer) konum belirlenebilmiş olup ortalama ± 1.86 metre doğrulukla konum belirlenebilmektedir. Bu modellerin kullandığı model Bagging Regresyon modeli olup filtrelemede MZS skoru (K24 ve K26 koridorları için) ve STDS (Orta Alan için) yöntemleri kullanılmaktadır.

Uygulama 2 için elde edilen konum doğrulukları incelendiğinde yöntem 1'e göre uygulama sahasının bölgelere ayrılması ile oluşturulan modellerin mesafe tahminleri sonucunda "Trilaterasyon 4 Nokta (Orta Alan)" ve "Ağırlıklandırılmış EKK 1 İterasyon (K24 ve K26 koridorları için)" yöntemi ile belirledikleri konumların doğruluğunun daha yüksek olduğu görülmüştür. Bu modeller ile K24 koridorunda ortalama ± 1.79 m, K26 koridorunda ± 2.15 m ve Orta Alanda ± 1.34 m doğrulukla konum belirlenebilmiş olup ortalama ± 1.76 metre doğrulukla konum belirlenebilmektedir. Bu modellerin mesafe belirlemede kullandığı model ağırlıkla Bagging Regresyon modeli olup kullanılan filtrelemede IQR, ZS, MZS, SDTS ve Filtrelemesiz yöntemleri kullanılmıştır.

Her iki uygulamadan elde edilen konum doğrulukları incelendiğinde uygulama sahasını yöntem 1'deki gibi alanlara ayırarak regresyon modellerinin tahmin yapacağı alanı küçültmenin elde edilen konum doğruluğunu arttırdığı görülmektedir. Ayrıca kapalı mekân şeklinin dikdörtgen yapıda olması ve uzun kenarın kısa kenara oranının yüksek olduğu mekanlarda yani trilaterasyon için referans noktalarının yerleşiminin birbirine yakın olduğu ve uygun geometrinin sağlanamadığı alanlarda parmak izi yöntemi daha kullanışlı olduğu görülmüştür. Uygulama 1'de kullanılan verici istasyon yerleşimi bu dezavantajı açıkça yansıtmakta olup trilaterasyon ile konum belirlenirken bu dezavantaj yüzünden belirlenen konum hatasındaki artış EKK yöntemi ile büyük oranda azaltabilmektedir. Fakat referans istasyonları daha geniş açılarda yerleştirebilmenin mümkün olduğu alanlarda mesafe tahminlerinin yapılarak trilaterasyon ile konum belirlemenin ve EKK ile dengelemenin kullanılarak daha doğru sonuçlar alınabileceği görülmüştür.

Uygulamaların yapıldığı sahasının büyük olması, arada kalın duvarların bulunması ve görüş hattının kısıtlı olması sebebi ile elde edilen konum doğrulukları uygulama alanı büyüklüğü göz önüne alındığında maalesef GNSS'nin açık alanlarda verdiği doğruluğa göre düşük kalmaktadır. Öte yandan bu şekilde yapılacak bir konum belirleme sisteminin bazı dezavantajları bulunmaktadır. Bunlar;

- Regresyon modelleri için toplanan eğitim verilerinin birden fazla periyotta toplanması gerekliliği ve veri toplanması aşamasında koordinatlarının ölçülmesinin oldukça fazla zaman alması,
- Eğitim verilerinin toplandığı alanda bulunan sabit engellerin sonrasında ortadan kalkması ya da var olmayan bir engelin sonradan ortaya çıkması elde edilen doğruluğun düşmesine yol açmaktadır. Bu sebep ile böyle bir durumun olduğu alanlarda kullanılan eğitim verisinin güncellenmesi gerekliliğinin ortaya çıkmakta olması,
- Uygulamada elde edilen sonuçlar, farklı filtreleme yöntemi ve farklı regresyon modellerinden oluşan kombinasyonlar kullanılarak elde edildiği için oldukça karmaşık bir model oluşturma ve belirleme sürecine sahiptir. (Geliştirilen algoritmalar ile bu süreç en basit hale getirilmeye çalışılmıştır),
- Anten kazancı yüksek antenlerin seçilmesi durumunda konum belirlemede tüm ölçümler boyunca anten yönünün aynı kalması gerekliliği,
- RSSI değeri çevresel koşullardan oldukça fazla etkilenmesi sebebi ile çevrede meydana gelen en ufak farklılıklar, bu metriği etkilemektedir. Bu durumda RSSI ile konum belirlemede elde edilen sonucun güvenilirliği konusunda net bir sonuca ulaşamamasına yol açmaktadır.

Sonuç olarak yapılan çalışma ile gerçek dünya koşullarına uygun bir alanda RSSI ile konum belirleyecek düşük maliyetli bir sistem geliştirilmiştir. Çalışılan yöntemler ve elde edilen konumlara ilişkin doğruluklar sunularak kapalı mekân konumlandırmasına yönelik yapılan çalışmalara katkıda bulunulmaya çalışılmıştır. Ayrıca bu çalışma kapsamında geliştirilen algoritmalar ve donanımlar farklı çalışma bölgelerine kolaylıkla kurularak kısa sürede çalışması sağlanabilecek şekilde tasarlanmıştır.

8.1. Öneriler

Bu çalışmada elde edilen deneyim ve sonuçlara göre RSSI gibi değişkenliği ve etkilenebilirliği yüksek bir metrik ile yapılan çalışmalarda bir noktadaki RSSI ölçümlerinin birden fazla sayıda tekrarlı ölçümler ile alınmasının (bu çalışmada 10 tekrarlı ölçüm yapılmıştır) ve filtrelemeye tabi tutulmasının konum doğruluğun artırılmasında olumlu fayda sağladığı görülmüş olup yapılacak bu ve benzeri

çalıřmalarda kullanılması önerilmektedir. Buna ek olarak alıřmada kullanılan regresyon modellerinin eęitiminde baęımsız deęiřken olarak sadece RSSI deęeri kullanılmıřtır. Bu deęere ek olarak sinyal gürültü oranının ve ölçümün yapıldığı ortamın sıcaklık, nem vs. gibi deęerlerinin de regresyon modellerinin eęitiminde kullanılması sonucunda belirlenen konum doęruluęuna olumlu yönde fayda sağlayacağı düşünölmektedir.

Dięer bir husus ise RSSI ölçümleri sırasında alıcı ve verici istasyonların zeminden yükseklięine göre ölçölen RSSI deęerinin deęiřtięi bilinmektedir. Bu alıřmada tüm ölçümler sabit yüksekliklerde bulunan donanımlar ile yapılmıřtır. Bu sebep ile farklı istasyon yükseklięinde yapılan ölçümlerin, sonuçları olumlu ya da olumsuz olarak hangi yönde etkiledięinin ayrıca bir alıřma ile araştırılması gerekmektedir.

Son olarak bilindięi üzere teknolojinin gelişim hızı gün getike katlanarak artmaktadır. Bu alıřmada kullanılan donanım ve makine öğrenmesi tabanlı regresyon modellerinde de bu gelişim kendini gösterecektedir. Geliřtirilen yeni algoritmalar sayesinde, RSSI ile yapılan kapalı mekân konumlandırma sistemlerinin doęruluęunun artacağı öngörülmektedir. Ayrıca teknolojinin gelişimi ve teknolojiye ulaşımın kolaylaşmasına paralel olarak günümüzde hemen hemen her yapıda Wi-Fi modemleri bulunmakta olup kullanımı oldukça artmıřtır. Bu durumun Wi-Fi donanımlarını RSSI ile kapalı mekân konumlandırma sistemlerinde kullanılmasını cazip kılmasına karşın RF modüllerinin yüksek menzili ve düşük maliyeti sayesinde kapalı mekanlarda RSSI ile konum belirlemede kullanılmasını avantajlı kılmaktadır.

KAYNAKLAR

- Alsmadi, L., Kong, X., Sandrasegaran, K. and Fang, G., 2021, An Improved Indoor Positioning Accuracy Using Filtered RSSI and Beacon Weight, *IEEE Sensors Journal*, 21(16),18205-18213.
- Bahl, P. ve Padmanabhan, V. N., 2000, RADAR:An İn-Building RF-Based User Location and Tracking System, *Proceedings IEEE INFOCOM 2000. Conference on Computer Communications. Nineteenth Annual Joint Conference of the IEEE Computer and Communications Societies*, 775-784.
- Breiman, L., 1996, Bagging predictors. *Machine learning*, 24(2), 123-140.
- Chen, T., Guestrin, C., 2016, XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794.
- Cortes, C., ve Vapnik, V., 1995, Support-vector networks, *Machine learning*, 20(3), 273-297.
- Friis, H. T., 1946, A Note On A Simple Transmission Formula. *Proceedings of the IRE*, 34(5), 254-256.
- Friedman, J. H., 2001, Greedy function approximation: A Gradient Boosting Machine, *Annals of statistics*, 29(5), 1189-1232.
- Géron, A., 2019, Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow, 2nd Edition, *O'Reilly Media*.
- Gray R. M., 1990, Entropy and İnformation Theory, Springer-Verlag, New York, 21-55.
- İnal, C. ve Turgut, B., 2002, GPS Ağlarının Dengelenmesi, *S.Ü. Müh-Mim.Fak. Derg.*, c.17, 19-22.
- Iglewicz, B. ve Hoaglin, D.C., 1993, How to Detect and Handle Outliers, 16, *ASQC Quality Press,USA*, 11-12.
- Kahveci, M., Yıldız, F., 2017, GNSS Uydularla Konum Belirleme Sistemleri Teori ve Uygulama,8.Basım, Nobel Akademik Yayıncılık, Ankara, 1-18.
- Karaca, A., 2008, Kapalı Alanda Radyo Dalgaları Yardımıyla Konum Belirleme ve Paket Takibi, Yüksek Lisans Tezi, *Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü*, Eskişehir, s.1-26.
- Kelleher, J. D., Namee, B. M., ve D'Arcy, A., 2015, Fundamentals of Machine Learning for Predictive Data Analytics: Algorithms, Worked Examples, and Case Studies, *The MIT Press*, 81-82.

- Özdemir, B., 2020, Kapalı Mekanlarda RSS Tabanlı Konum Belirleme Yaklaşımı: Parmak İzi Methodunun Uygulanması ve Performans Analizi, Doktora Tezi, *Konya Teknik Üniversitesi Lisans Üstü Eğitim Enstitüsü*, Konya, 64-67.
- Quinlan, J. R., 1979, Discovering rules by induction from large collections of examples. In D. Michie (Ed.), *Edinburgh University Press*, Expert systems in the micro-electronic age, 168-201.
- Ramirez R, Huang C-Y, Liao C-A, Lin P-T, Lin H-W, Liang S-H., 2021, A Practice of BLE RSSI Measurement for Indoor Positioning, *Sensors*, 21(15):5181, <https://doi.org/10.3390/s21155181>
- Saray, T., 2017, Radyo Dalgaları Kullanarak Yeraltı Maden Ocağında Çalışan Madencilerin İzlenmesi, Yüksek Lisans Tezi, *Konya Karatay Üniversitesi Fen Bilimleri Enstitüsü*, Konya, 42-52.
- Santhanakrishnan, K. ve Senthoooran, V., 2022, A Parallel distributed Cluster Computing Model for Z-Score Computation in Respect of Sri Lankan University Admissions, *2022 2nd International Conference on Advanced Research in Computing (ICARC)*, Belihuloya, Sri Lanka, 344-348.
- Russel, S. and Norvig, P., 2010, Artificial Intelligence: A Modern Approach, Third Edition, *Prentice Hall*, 693-695
- Tekbaş, A., Tuncer, T. ve Erdem, E., 2020, RSSI Sinyalleri Kullanarak İç Ortamda Parmak İzi Tabanlı YSA ile Konum Tespitinin Gerçekleştirilmesi, *DÜMF Mühendislik Dergisi*, 11:3, 925-931.
- Vapnik, V., Golowich, S. E., ve Smola, A., 1997, Support vector method for function approximation, regression estimation, and signal processing, M. C. Mozer, M. I. Jordan, & T. Petsche (Eds.), *MIT Press*, Advances in neural information processing systems 9, Cambridge, 281-287.
- Varshney, V., Goel, R.K. ve Qadeer, M.A., 2016, Indoor positioning system using Wi-Fi & Bluetooth Low Energy technology, *Thirteenth International Conference on Wireless and Optical Communications Networks (WOCN)*, Hyderabad, India, 1-6.
- Yaman, Ş., Gündoğdu, K. ve Çalhan, A. 2021, Yeni Bir İç Mekân Konum Bulma Sistemi, *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 9(2), 636-645.

İNTERNET KAYNAKLARI

- URL-1:Berserkerus, 2008, AM ve FM modülasyon, Web adresi: <https://ru.wikipedia.org/wiki/User:Berserkerus>, [Erişim Tarihi:17.12.2023].
- URL-2:BTK, 2018, Uluslararası Telekomünikasyon Birliği-ITU, BTK, Web adresi: <https://www.btk.gov.tr/itu>, [Erişim Tarihi:08.09.2023].
- URL-3:Chetvorno, 2015, Animation of a dipole antenna radiating radio waves, Web adresi: https://commons.wikimedia.org/wiki/File:Dipole_xmting_antenna_animation_4_4_08x318x150ms.gif, [Erişim Tarihi:08.09.2023].
- URL-4:Ebyte, 2022, RF Modul and Software, Web adresi: <https://www.cdebyte.com/Module>, [Erişim Tarihi:03.08.2023].
- URL-5:EOTH, 2023, EOTH 868 MHz 915 MHz anten LORA 12 dbi SMA, Web adresi: https://tr.aliexpress.com/item/1005004262704793.html?spm=a2g0o.order_list.order_list_main.19.40793d12VvcSLe&gatewayAdapt=glo2tur, [Erişim Tarihi:20.01.2023].
- URL-6:Erdoğan, M., 2023, Makine Öğrenmesi Regresyon Modellerindeki Hata Metriklerine Güncel Bakış: MAE, MSE, RMSE, R-Kare (R2), Web adresi: <https://medium.com/academy-team/makine-%C3%B6%C4%9Frenmesi-regresyon-modellerindeki-hata-metriklerine-g%C3%BCncel-bak%C4%B1%C5%9F-mae-mse-rmse-r-kare-d1ab758c5759>, [Erişim Tarihi:05.07.2023].
- URL-7:Espressif Systems, 2021, Features, Web adresi: <https://products.espressif.com/#/product-selector?language=en&names=>, [Erişim Tarihi:24.10.2023].
- URL-8:ITU, 2010, Federal Spectrum Use Summary, National Telecommunications And Information Administration Office Of Spectrum Management, Web adresi: https://web.archive.org/web/20190418082815/https://www.ntia.doc.gov/files/ntia/Spectrum_Use_Summary_Master-06212010.pdf, [Erişim Tarihi:28.09.2023].
- URL-9:Karaahmet, H. Y., 2008, Dalga Boyu, Frekans ve Güç gösterimi, Web adresi: <https://commons.wikimedia.org/wiki/File:Dalgaboyu.jpg>, [Erişim Tarihi:08.09.2023].
- URL-10:Kılınç, D., 2019, Python ile Veri Ön İşleme, Medium, Web adresi: <https://medium.com/@denizkilinc/python-ile-veri-ön-işlemeye-dalış-f89f921658bd>, [Erişim Tarihi:08.09.2023].
- URL-11:Michitangi, R., 2021, EByte_LoRa_E22_Series_Library, Github, Web adresi: https://github.com/xreef/EByte_LoRa_E22_Series_Library, [Erişim Tarihi:03.04.2023].

- URL-12:Minew, 2020, Angle of Arrival — Minew Stretches out Its Antennae to Higher-precision Positioning, Web adresi: <https://www.minew.com/angle-of-arrival-minew-stretches-out-its-antennae-to-higher-precision-positioning/>, [Erişim Tarihi:04.09.2023].
- URL-13:Pandey, A., 2021, The Math Behind KNN, Web adresi: <https://ai.plainenglish.io/the-math-behind-knn-7883aa8e314c>, [Erişim Tarihi:12.09.2023].
- URL-14:Şener, Y., 2020, Polinomsal (Polynomial) Regresyon ve Python Uygulaması, Medium,Web adresi: <https://yigitsener.medium.com/polinomsal-polynomial-regresyon-ve-python-uygulamas%C4%B1-f742fb61a158>, [Erişim Tarihi:05.05.2023].
- URL-15:Tell., J., 2023, Developing a New Wireless Hardware Product? Here's Your Most Important Decision, Web adresi: <https://predictabledesigns.com/most-important-decision-when-creating-wireless-product/>, [Erişim Tarihi:17.12.2023].
- URL-16:Wikipedia, 2020, Radyo Spectrum, Wikipedia The Free Encyclopedia, https://en.wikipedia.org/wiki/Radio_spectrum, [Erişim Tarihi:17.12.2023].
- URL-17:Yang, Y., 2018, Random Forests for Regression and Classification, McGill University,Web adresi: <https://www.math.mcgill.ca/yyang/resources/doc/randomforest.pdf>, [Erişim Tarihi:23.08.2023].