T.C.

AKDENİZ ÜNİVERSİTESİ

SÜRÜ ZEKÂSI OPTİMİZASYON ALGORİTMALARI İLE İÇ MEKÂN KONUMLANDIRMA

Yasin KAM

FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

TEMMUZ 2023

ANTALYA

T.C.

AKDENİZ ÜNİVERSİTESİ

SÜRÜ ZEKÂSI OPTİMİZASYON ALGORİTMALARI İLE İÇ MEKÂN KONUMLANDIRMA

Yasin KAM

FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

TEMMUZ 2023

ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

SÜRÜ ZEKÂSI OPTİMİZASYON ALGORİTMALARI İLE İÇ MEKÂN KONUMLANDIRMA

Yasin KAM

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

TEMMUZ 2023

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

SÜRÜ ZEKÂSI OPTİMİZASYON ALGORİTMALARI İLE İÇ MEKÂN KONUMLANDIRMA

Yasin KAM

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

Bu tez 21/07/2023 tarihinde jüri tarafından oybirliği ile kabul edilmiştir.

Prof. Dr. Ümit Deniz ULUŞAR (Danışman)
Prof. Dr. Ömer Halil ÇOLAK
Prof. Dr. Tuncay YİĞİT

ÖZET

SÜRÜ ZEKÂSI OPTİMİZASYON ALGORİTMALARI İLE İÇ MEKÂN KONUMLANDIRMA

Yasin KAM

Yüksek Lisans Tezi, Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Ümit Deniz ULUŞAR

Temmuz 2023; 66 sayfa

Bu tez çalışması, iç mekân konumlama problemine makine öğrenmesi ve sürü optimizasyonu tekniklerinin entegrasyonunu araştırmayı amaçlamaktadır. İç mekân konumlama, insanların bir iç mekân ortamında belirli bir konumu tespit etmeyi gerektiren önemli bir sorundur. Bu alanda hızlı, doğru ve güvenilir konum tespiti yöntemleri büyük önem taşımaktadır.

Bu çalışmada, öncelikle akıllı telefon uygulaması yardımıyla bir iç mekân ortamında kullanılacak veri toplama altyapısı kurulmuştur. Konumlandırma yapılacak alanda radyo haritası oluşturmak için Wi-Fi tabanlı ağ ile ölçümler yapılarak alınan işaret gücü göstergesi (RSSI-Received Signal Strength Indicator) belirli aralıklarla işaretlenen noktalarda kaydedilmiştir. Makine öğrenmesi teknikleri, toplanan verileri analiz etmek ve iç mekân konumunu tahmin etmek için kullanılmıştır. Yapay sinir ağları ve karar ağaçları gibi farklı algoritmaların performansları karşılaştırılmış ve en iyi sonuçları elde etmek için uygun olanlar seçilmiştir. Sürü optimizasyonu yöntemleri, konum tahmininde kullanılan algoritmanın doğruluğunu artırmak için entegre edilmiştir. Partikül sürü optimizasyonu ve balina kolonisi optimizasyonu gibi algoritmalar, makine öğrenmesi modelinin parametrelerini ayarlamak ve daha iyi sonuçlar elde etmek için kullanılmıştır.

Bu çalışma, bir iç mekân ortamında konum tespiti için etkili bir yöntem sunmaktadır. Deneyler ve sonuçlar, makine öğrenmesi ve sürü optimizasyonu tekniklerinin entegrasyonunun iç mekân konumlama performansını artırdığını göstermektedir.

ANAHTAR KELİMELER: İç mekân konumlandırma, kablosuz bağlantı, kablosuz sensör ağları, makine öğrenmesi, sinyal gücü göstergesi, sürü optimizasyonu

JÜRİ: Prof. Dr. Ümit Deniz ULUŞAR

Prof. Dr. Ömer Halil ÇOLAK

Prof. Dr. Tuncay YİĞİT

ABSTRACT

INDOOR POSITIONING WITH SWARM INTELLIGENCE OPTIMIZATION ALGORITHMS

Yasin KAM

M.Sc. Thesis in Electrical-Electronics Engineering

Supervisor: Prof. Dr. Ümit Deniz ULUŞAR

July 2023; 66 pages

This thesis study aims to investigate the integration of machine learning and swarm optimization techniques to the indoor positioning problem. Indoor positioning is an important problem that requires people to identify a specific location in an indoor environment. Fast, accurate and reliable location detection methods are of great importance in this field.

In this study, first, a data collection infrastructure to be used in an indoor environment was established with the help of a smart phone application. To create a radio map in the area to be positioned, measurements were made with a Wi-Fi-based network and the received signal strength indicator (RSSI-Received Signal Strength Indicator) was recorded at the marked points at certain intervals. Machine learning techniques have been used to analyse the collected data and predict indoor location. The performances of different algorithms, such as artificial neural networks and decision trees, were compared and the appropriate ones were selected to obtain the best results. Swarm optimization methods are integrated to increase the accuracy of the algorithm used in position estimation. Algorithms such as particle swarm optimization and whale colony optimization have been used to tune the parameters of the machine learning model and achieve better results.

This study presents an effective method for location detection in an indoor environment. Experiments and results show that the integration of machine learning and swarm optimization techniques improves indoor positioning performance.

KEYWORDS: Indoor positioning, machine learning, RSSI, swarm optimization, Wi-Fi, wireless sensor networks

COMMITTEE: Prof. Dr. Ümit Deniz ULUŞAR

Prof. Dr. Ömer Halil ÇOLAK

Prof. Dr. Tuncay YİĞİT

ÖNSÖZ

Bu tez, makine öğrenmesi ve sürü optimizasyonu tekniklerinin kullanıldığı iç mekân konumlama konusunda yapılan bir araştırmayı içermektedir. İç mekân konumlama, insanların veya cihazların iç mekânda konumunu doğru bir şekilde belirlemeyi amaçlayan bir süreçtir. Bu alanda elde edilen sonuçlar, kullanıcıların iç mekânlarda gezinmelerini kolaylaştırmak veya cihazların iç mekânda tespit edilmesi ile hizmet kalitesini artırmak ve yeni deneyimler sunmak için birçok uygulama alanında kullanılabilmektedir.

Araştırma sonuçları, iç mekân konumlama alanında daha doğru ve güvenilir yöntemlerin geliştirilmesine katkı sağlamayı hedeflemektedir. Bu çalışma, ilgili sektörlerdeki profesyoneller, araştırmacılar ve akademisyenler için kıymetli bir kaynak olmayı amaçlamaktadır.

Yüksek lisans eğitimim ve tez çalışmam boyunca bana her desteği veren, gelecekteki kariyerimde rol model olan danışman hocam Prof. Dr. Ümit Deniz ULUŞAR başta olmak üzere, proje çalışmasına destek veren ComNets Laboratuvar bünyesindeki çalışma arkadaşlarıma teşekkür ederim. Değerlim Fatıma KAM'a ve yanımda olduklarını bildiğim, beni daima motive eden kıymetli aileme sonsuz teşekkürlerimi sunarım. Çalışmalarımın bilimsel çalışmalara katkı sağlamasını dilerim.

İÇİNDEKİLER

ÖZET i
ABSTRACT ii
ÖNSÖZ iii
AKADEMİK BEYAN vi
SİMGELER VE KISALTMALAR vii
ŞEKİLLER DİZİNİ ix
ÇİZELGELER DİZİNİ xii
1. GİRİŞ 1
2. KAYNAK TARAMASI 3
2.1. Alınan Sinyal Gücü – Received Signal Strength (RSS) 9
2.2. Wi-Fi – IEEE 802.11n 13
2.3. Makine Öğrenmesi 13
2.3.1. K – En yakın komşu algoritması 14
2.3.2. K – Rastgele orman algoritması 14
2.3.3. Karar ağaçları 14
2.3.4. Sürü Zekâsı 14
2.4. Sürü Zekâsı Algoritmaları 15
2.4.1. Balina optimizasyon algoritması (Whale optimization algorithm) 15
2.4.2. Parçacık sürü optimizasyonu (Particle swarm optimization) 16
2.5. Parmak İzi Tekniği 17
3. MATERYAL VE METOT 18
3.1. Uygulama 18
3.1.1. Haritalama 18
3.1.2. Mobil uygulama 20
3.1.3. Sunucu 21
3.2. Veri Seti 22
3.2.1. Sinyallerin toplanması 23
3.2.2. Verilerin işlenmesi 23
3.3. Sürü Algoritmaları Kullanılarak Makine Öğrenmesi Algoritmalarında Optimum Hiper Parametrelerin Tespiti 24
3.3.1. Parçacık sürü optimizasyon algoritması ile hiper parametre seçimi 24

3.3.2. Balina optimizasyon algoritması ile hiper parametre seçimi 26
3.4. Metrikler 28
3.4.1. Doğruluk 28
3.4.2. Kesinlik 28
3.4.2. Duyarlılık 28
4. BULGULAR VE TARTIŞMA 30
5. SONUÇLAR 62
6. KAYNAKLAR 63
ÖZGEÇMİŞ

AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduğum “Sürü Zekâsı Optimizasyon Algoritmaları ile İç Mekân Konumlandırma” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

03/07/2023
Yasin KAM

SİMGELER VE KISALTMALAR

Simgeler

c : Işık hızı

d : Mesafe

d_0 : Referans mesafe

f : Frekans

m : Metre

sn : Saniye

λ : Dalga boyu

π : Pi sayısı

Hz : Hertz

τ : Referans zaman

e : Euler sayısı

X : Konum

dB : Desibel

dBm : Desibelmili

Kısaltmalar

GPS : Küresel konumlanma sistemi- Global positioning system

RSS : Alınan işaret gücü- Received signal strength

RSSI : Alınan işaret gücü göstergesi – Received signal strength indicator

K-NN : K- en yakın komşu- K- Nearest Neighbour

PSO : Parçacık sürü optimizasyonu- Particle swarm optimization

WOA : Balina optimizasyon algoritması- Whale optimization algorithm

Wi-Fi : Kablosuz bağlantı- Wireless fidelity

AP : Erişim noktası- Access Point

LBS : Konum tabanlı sistemler- Location based systems

IOT : Nesnelerin interneti- Internet of things

MTC : Makine tipi iletişim- Machine type communication

UWB : Ultra geniş bant- Ultra wide band

WILL : Kablosuz iç mekan yerelleştirmesi olmayan saha araştırması- Wireless indoor localization without site survey

WAP : Kablosuz erişim noktası- Wireless access point

DESIP : İç mekân konumlandırması için çıkarımsal ayrışma

NN : Sinir ağı- Neural network

SMO : Sıralı minimal optimizasyon- Serial minimal optimization

CNN : Evrimsel sinir ağları- Convolutional neural network

SAE : Özyineleme kodlayıcı- Stacked autoencoders

CDAE : Evrişimsel gürültü giderici otomatik kodlayıcı- Cascade denoising autoencoders

DNN : Derin sinir ağları- Deep neural network

DBN : Derin inanç ağları- Deep belief network

RP : Referans noktası- Reference point

BLE : Bluetooth düşük enerji- Bluetooth low energy

ANN : Yapay sinir ağı- Artificial neural network

MLE : Maksimum olasılık tahmini- Maximum likelihood estimation

IDW : Ters mesafe ağırlıklı- Inverse distance weight

PCA : Temel bileşen analizi- Principal component analysis

LDPL : Uzun mesafe yol kaybı- Long distance path loss

WLAN: Kablosuz yerel alan ağı- Wireless local area network

ISM : Endüstriyel bilimsel tıbbi- Industrial scientific medical

LOS : Görüş hattı- Line of sight

AI : Yapay zeka- Artificail intelligence

ML : Makine öğrenmesi- Machine learning

ŞEKİLLER DİZİNİ

Şekil 2.1. Sinyal kayıp oranının merkezden dışarıya mesafe ilişkisinin gösterimi 11

Şekil 2.2. Balina avlanmasının gösterimi 16

Şekil 3.1. Harita üzerinde oda ve kat bilgilerinin gösterimi 18

Şekil 3.2. Uydu görüntüsü üzerinde oda ve kat bilgilerinin gösterimi 19

Şekil 3.3. Harita üzerinde oda ve kat bilgilerinin düzenlenmesinin gösterimi 19

Şekil 3.4. Mobil uygulamada veri toplamak üzere haritanın kat ve odaların gösterimi . 20

Şekil 3.5. Mobil uygulamada veri toplama işlemi 21

Şekil 3.6. Parçacık sürü optimizasyonu yerel minimum simüle gösterimi 26

Şekil 3.7. Balina optimizasyon algoritması temel prensibi 28

Şekil 4.1. Odalarda algılanan ölçüm sayıları 30

Şekil 4.2. Tüm binadaki ölçümlerin RSSI dağılımı 31

Şekil 4.3. RSSI ölçümlerinin kutu grafiği 31

Şekil 4.4. Bir ölçümde görülen erişim noktası sayısının keman grafiği 32

Şekil 4.5. Ölçüm yapılan odaların bina içinde dağılımı 33

Şekil 4.6. Ölçüm yapılan odaların bina içinde 3 boyutlu dağılımı 33

Şekil 4.7. 5 Erişim noktası (AP) için sınıflandırma algoritmalarının doğruluk değerleri ve standart sapmaları 35

Şekil 4.8. 5 Erişim noktası (AP) için sınıflandırma algoritmalarının kesinlik değerleri ve standart sapmaları 35

Şekil 4.9. 5 Erişim noktası (AP) için sınıflandırma algoritmalarının duyarlılık değerleri ve standart sapmaları 36

Şekil 4.10. 5 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri doğruluk değerleri ve standart sapmaları 38

Şekil 4.11. 5 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri kesinlik değerleri ve standart sapmaları 38

Şekil 4.12. 5 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri duyarlılık değerleri ve standart sapmaları 39

Şekil 4.13. 5 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri doğruluk değerleri ve standart sapmaları 41

Şekil 4.14. 5 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri kesinlik değerleri ve standart sapmaları 41

Şekil 4.15. 5 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri duyarlılık değerleri ve standart sapmaları 42

Şekil 4.16. 10 Erişim noktası (AP) için sınıflandırma algoritmalarının duyarlılık değerleri ve standart sapmaları..... 43

Şekil 4.17. 10 Erişim noktası (AP) için sınıflandırma algoritmalarının kesinlik değerleri ve standart sapmaları..... 44

Şekil 4.18. 10 Erişim noktası (AP) için sınıflandırma algoritmalarının duyarlılık değerleri ve standart sapmaları..... 44

Şekil 4.19. 10 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri doğruluk değerleri ve standart sapmaları 46

Şekil 4.20. 10 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri kesinlik değerleri ve standart sapmaları 47

Şekil 4.21. 10 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri duyarlılık değerleri ve standart sapmaları 48

Şekil 4.22. 10 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri doğruluk değerleri ve standart sapmaları 50

Şekil 4.23. 10 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri kesinlik değerleri ve standart sapmaları 50

Şekil 4.24. 10 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri duyarlılık değerleri ve standart sapmaları 51

Şekil 4.25. 15 Erişim noktası (AP) için sınıflandırma algoritmalarının doğruluk değerleri ve standart sapmaları..... 53

Şekil 4.26. 15 Erişim noktası (AP) için sınıflandırma algoritmalarının kesinlik değerleri ve standart sapmaları..... 53

Şekil 4.27. 15 Erişim noktası (AP) için sınıflandırma algoritmalarının duyarlılık değerleri ve standart sapmaları..... 54

Şekil 4.28. 15 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri doğruluk değerleri ve standart sapmaları 56

Şekil 4.29. 15 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri kesinlik değerleri ve standart sapmaları 56

Şekil 4.30. 15 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri duyarlılık değerleri ve standart sapmaları 57

Şekil 4.31. 15 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri doğruluk değerleri ve standart sapmaları 59

Şekil 4.32. 15 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri kesinlik değerleri ve standart sapmaları 59

Şekil 4.33. 15 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri duyarlılık değerleri ve standart sapmaları 60

ÇİZELGELER DİZİNİ

Çizelge 2.1. RSS%- RSS(RSSI) dönüşümü CISCO 12

Çizelge 4.1. Veri setinin tamamına uygulanana makine öğrenmesi algoritması sonucu 32

Çizelge 4.2. 5 erişim noktası için makine öğrenmesi modelleri en yüksek ve en düşük doğruluk, kesinlik ve duyarlılık sonuçları 34

Çizelge 4.3. 5 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri en yüksek ve en düşük doğruluk, kesinlik ve duyarlılık sonuçları 37

Çizelge 4.4. PSO algoritması sonucu 5 erişim noktası için elde edilen hiper parametreler 37

Çizelge 4.5. 5 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri en yüksek ve en düşük doğruluk, kesinlik ve duyarlılık sonuçları 40

Çizelge 4.6. WOA algoritması sonucu 5 erişim noktası için elde edilen hiper parametreler 40

Çizelge 4.7. 10 erişim noktası için makine öğrenmesi modelleri en yüksek ve en düşük doğruluk, kesinlik ve duyarlılık sonuçları 42

Çizelge 4.8. 10 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri en yüksek ve en düşük doğruluk, kesinlik ve duyarlılık sonuçları 45

Çizelge 4.9. PSO algoritması sonucu 10 erişim noktası için elde edilen hiper parametreler 45

Çizelge 4.10. 10 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri en yüksek ve en düşük doğruluk, kesinlik ve duyarlılık sonuçları 49

Çizelge 4.11. WOA algoritması sonucu 10 erişim noktası için elde edilen hiper parametreler 49

Çizelge 4.12. 15 erişim noktası için makine öğrenmesi modelleri en yüksek ve en düşük doğruluk, kesinlik ve duyarlılık sonuçları 52

Çizelge 4.13. 15 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modellerinin en yüksek ve en düşük doğruluk, kesinlik ve duyarlılık sonuçları 55

Çizelge 4.14. PSO algoritması sonucu 15 erişim noktası için elde edilen hiper parametreler 55

Çizelge 4.15. 15 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modellerinin en yüksek ve en düşük doğruluk, kesinlik ve duyarlılık sonuçları..... 58

Çizelge 4.16. WOA algoritması sonucu 15 erişim noktası için elde edilen hiper parametreler..... 58

1. GİRİŞ

İç mekan konumlandırmada GPS sinyallerinin zayıflaması, görüş hattının olmaması gibi etkenler GPS kullanılabilirliğini sınırlamaktadır (Lui vd. 2007). Bu nedenlerle iç mekan konumlandırmada birçok farklı teknik söz konusudur. Bunlar kapalı mekanda bulunan sinyallerin işlenmesi üzerine kurulu olduğu gibi kimi zaman da kapalı mekanın öğrenilmesi üzerine de inşaa edilmiştir. Kameralar, kızılötesi işaretler, sesler, Wi-Fi, rfid, bluetooth ve diğer sinyal işaretleri iç mekan konumlandırma sistemlerinde kullanılmaktadır (Obeidat vd. 2021).

Makine öğrenmesi, iç mekan konumlandırmada önemli bir rol oynayan güçlü bir araçtır. İç mekan konumlandırma, otonom robotların etkileşimlerini optimize etmek, artırılmış gerçeklik deneyimlerini geliştirmek ve yer tabanlı hizmetlerin doğruluğunu artırmak için kullanılır. Makine öğrenmesi, karmaşık veri setlerini analiz ederek iç mekanların haritalandırılmasını ve nesnelerin tanınmasını sağlar. Sensör verileri, kamera görüntüleri ve lazer tarama bilgileri gibi kaynaklar kullanılarak, algoritmalar iç mekanların yapılarını ve özelliklerini anlamak için eğitilebilir. Bu sayede, kullanıcıların veya cihazların konumunu doğru bir şekilde belirlemek ve gerçek zamanlı konumlandırma sağlamak mümkün olur. Makine öğrenmesi ayrıca, büyük ölçekli iç mekanlarda konumlandırmayı ölçeklendirerek hassas sonuçlar üretebilir. Tüm bu faktörler, makine öğrenmesinin iç mekan konumlandırmada önemini vurgulayan etkili bir yaklaşım olduğunu göstermektedir.

Makine öğreniminde hiper parametre seçimi, optimum model performansı elde etmek için önemlidir. Hiper parametrelerin ince ayarı, doğru tahminlerin gerekli olduğu iç mekan konumlandırmada özellikle önemlidir. Bina içi konumlandırmaya yönelik yaygın bir yaklaşım, öznitelik olarak Alınan Sinyal Gücü Göstergesi (RSSI) değerlerinin kullanılmasıdır. RSSI değerleri, modellerin bir bina içindeki farklı odalar arasında ayrım yapmasına izin vererek, sinyal gücü hakkında değerli bilgiler sağlar.

Hiper parametreler, öğrenme sürecinden önce ayarlanan ve modelin davranışını ve performansını kontrol eden parametrelerdir. RSSI değerlerini kullanan iç mekan konumlandırma için bu hiper parametreler, modelin tahminlerinin doğruluğunu ve sağlamlığını büyük ölçüde etkiler.

Hiper parametreleri optimize etmek, modelin görünmeyen veriler üzerindeki performansını en üst düzeye çıkaran değerlerin kombinasyonunu bulmayı içerir. Bununla birlikte, hiper parametre uzayında manuel olarak arama yapmak genellikle zaman alıcıdır ve pratik değildir. Bu nedenle, hiper parametre optimizasyon algoritması gibi otomatikleştirilmiş bir yaklaşımın kullanılması, geniş parametre alanını verimli bir şekilde keşfetmek ve en uygun konfigürasyonu bulmak için gereklidir.

Hiper parametre optimizasyonunun amacı, yetersiz uyum ve fazla uyum arasında bir denge kurmaktır. Yetersiz uyum, model, verilerdeki temel kalıpları yakalayacak karmaşıklıktan yoksun olduğunda ortaya çıkar ve bu da düşük performansa yol açar. Öte yandan, model aşırı derecede karmaşık olduğunda, eğitim verilerinin ezberlenmesine ve görünmeyen örneklere zayıf genelleme yapılmasına neden olan fazla uyum meydana gelir.

İç mekan konumlandırmada oda sınıflandırması durumunda, K-En Yakın Komşulardaki (KNN) komşu sayısı (k), mesafe metrikleri, ağırlıklandırma yöntemleri ve algoritma seçimleri gibi hiper parametreler, KNN modelinin performansını önemli ölçüde etkilemektedir. Ek olarak, karar ağaçlarının sayısı, ağaçların derinliği ve bölme kriterleri gibi Rastgele Orman algoritmasına özgü hiper parametrelerin en iyi sonuçlar için dikkatlice ayarlanması gerekmektedir.

Bu çalışma, RSSI değerlerini kullanarak iç mekan konumlandırmada oda sınıflandırmasında optimum hiper parametreleri seçmek için sağlam bir metodoloji geliştirmeye odaklanmaktadır. Hiper parametre alanını verimli bir şekilde aramak için Particle Swarm Optimization (PSO), Whale Optimization Algorithm (WOA) gibi popüler hiper parametre optimizasyon teknikleri incelendi. Bu tekniklerden yararlanarak, sınıflandırma modelinin doğruluğunu en üst düzeye çıkaran ve iç mekan yerelleştirme senaryolarında güvenilir oda sınıflandırması sağlayan hiper parametre konfigürasyonu belirlendi.

Genel olarak, RSSI değerleri kullanılarak iç mekan konumlandırmada makine öğrenimi için hiper parametre seçimi süreci, modellerin doğruluğunu ve sağlamlığını geliştirmek için büyük bir potansiyele sahiptir. Bu çalışma ile, hiper parametre optimizasyon tekniklerinin gelişimine katkıda bulunmayı ve iç mekan konumlandırma uygulamalarında optimum model performansı elde etmek için bilgiler sağlandı.

Wi-Fi sinyalleri, iç mekan konumlandırmada önemli bir rol oynayan değerli bir kaynaktır. Wi-Fi ağları, yaygın olarak kullanılan kablosuz iletişim teknolojilerinden biridir ve hemen hemen her iç mekanda bulunurlar. Bu sinyallerin kullanılması, kullanıcıların veya cihazların iç mekanlarda doğru bir şekilde konumlandırılmasını sağlayabilir. Wi-Fi sinyalleri, cihazlar arasında yapılan iletişimde kullanılan güçlü sinyallerdir ve bu sinyallerin yoğunluğu ve kalitesi, iç mekanlarda konum tahmini için kullanılabilir. Wi-Fi tabanlı konumlandırma sistemleri, bir dizi erişim noktasından (AP) gelen sinyal gücü ve gecikme süresi gibi verileri analiz ederek, kullanıcının konumunu belirlemek için algoritmalara dayanır. Bu sayede, iç mekanlarda Wi-Fi sinyalleri kullanılarak gerçek zamanlı konumlandırma ve navigasyon hizmetleri sunulabilir.

Wi-Fi tabanlı iç mekan konumlandırma, birçok uygulama alanında büyük faydalar sağlar. Örneğin, alışveriş merkezlerinde müşterilerin konumlarını tespit ederek, onlara kişiselleştirilmiş indirimler veya bilgiler sunmak mümkün olabilir. Ayrıca, hastanelerde veya havaalanlarında kaybolmuş eşyaların veya ekipmanların bulunması için Wi-Fi tabanlı konumlandırma sistemleri kullanılabilir. Wi-Fi sinyalleri, iç mekanlarda doğru ve hassas konumlandırma sağlama yeteneğiyle, kullanıcı deneyimini artıran, iş verimliliğini geliştiren ve güvenlik sistemlerine katkıda bulunan önemli bir teknolojidir.

Bu tezin 2. bölümünde alınan sinyal gücü, Wi-Fi, makine öğrenmesi, sürü optimizasyonu, parmak izi tekniği ve bu kavramların iç mekan konumlandırma problemlerinde nasıl kullanıldığı hakkında literatürdeki çalışmalardan bahsedildi. 3. bölümde bu çalışmada kullanılan yöntemler açıklandı, kullanılan mobil uygulama ve yazılımdan bahsedildi, hazırlanan veri seti hakkında bilgi verildi. 4. bölümde çalışma sonucu elde edilen sonuçlar hakkındaki bulgular ve tartışmalardan bahsedildi. Son olarak 5. bölümde elde edilen sonuçlar değerlendirildi.

2. KAYNAK TARAMASI

Akıllı telefonlar, giyilebilir cihazlar ve diğer kablosuz teknolojilerin geniş çapta yayılması, konum tabanlı hizmetlerin (LBS) ve iç mekân lokalizasyonunun önemli bir talep görmesine yol açmıştır. İç mekân lokalizasyonu, bir cihazın veya kullanıcının iç mekân ortamında konumunu belirleme sürecini ifade eder. İç mekân cihaz lokalizasyonu endüstriyel ortamlarda, kablosuz sensör ağlarında ve robotikte yoğun bir şekilde araştırılmış olmasına rağmen, kablosuz iletişim yeteneklerine sahip akıllı telefonlar ve giyilebilir cihazların ortaya çıkışıyla birlikte bu alan köklü bir değişime uğramıştır. Bu cihazların lokalizasyonu ve takibi, ilgili kullanıcıların lokalizasyonunu ve takibini eşanlamlı hale getirmiş ve çeşitli uygulama ve hizmetlerin kapısını aralamıştır (pathapati subbu vd. 2014).

Kullanıcı ve cihaz lokalizasyonunun uygulama alanları sağlık, endüstri, felaket yönetimi, bina yönetimi, gözetim ve daha pek çok sektörü kapsamaktadır. Ayrıca, bu lokalizasyon teknikleri İnternet of Things (IoT), akıllı mimariler (örneğin akıllı şehirler, akıllı binalar, akıllı şebekeler) ve Machine Type Communication (MTC) gibi yeni teknolojilerde de önemli bir rol oynamaktadır. IoT, milyarlarca cihaza uçtan uca bağlantı sağlamayı amaçlayan bir dizi heterojen teknoloji ve iletişim standardını içermektedir. Uzun menzilli IoT teknolojileri, uzun mesafeli makine-makine iletişimi üzerinde odaklanırken, Bluetooth, ZigBee, Wi-Fi ve Ultra Wide Band (UWB) gibi kısa menzilli teknolojiler IoT ağı için vazgeçilmez birer bileşen olarak kalır (Zafari, Gkelias, ve Leung 2019).

İç mekân ortamlarında, uzun menzilli IoT teknolojilerinin doğruluğu sınırlıdır, ancak kısa menzilli iletişim teknolojileri görece doğru iç mekân konumlarını tahmin edebilir. Bununla birlikte, bu cihazların küresel konumu (enlem-boylam coğrafi koordinatları) belirlenmesi, referans noktalarının küresel konumunun bilinmesine bağlıdır. Statik ve mobil IoT cihazlarının sorunsuz ve kapsayıcı iç mekân/dış mekân lokalizasyonu ve navigasyonunu sağlamak için geleneksel kısa menzilli lokalizasyon tekniklerini, ortaya çıkan uzun menzilli IoT teknolojileriyle birleştirmek elzemdir. Bu iş birliği, gelecekteki IoT ağlarının ve hizmetlerinin çeşitlilik gösteren lokalizasyon gereksinimlerini karşılamak için büyük önem taşır (Yassin vd. 2017).

Wu ve arkadaşları WILL (Kablosuz İç Mekan Yerelleştirmesi Olmayan Saha Araştırması) adlı bir yaklaşım önermektedir. Yazarlar, cep telefonlarından kullanıcı hareketlerinden yararlanarak iç mekan lokalizasyonunun zorluklarını ele almayı hedefliyor. WILL'in temel katkısı, geleneksel yaklaşımlarda tipik olarak gerekli olan saha araştırması sürecini ortadan kaldırırken, rekabetçi yerelleştirme doğruluğu elde etmeye devam etmesidir. WILL, daha sonra yerelleştirme sürecine yardımcı olmak için kullanılan kullanıcı hareketlerini yakalamak için cep telefonlarındaki ivmeölçer sensörlerinden yararlanır. Yazarlar, hızlanma kalıplarını analiz ederek, yürüyen kullanıcıların statik kullanıcılara kıyasla farklı varyasyonlar sergilediğini ve yerelleştirme için değerli bilgiler sağladığını gözlemledi. Eğitim aşamasında, bir binadaki kullanıcılar normal faaliyetlerine devam ederken, cep telefonları otomatik olarak WiFi sinyal güçlerini ölçer ve ivmeölçer okumalarını kaydeder. Toplanan ham

parmak izleri daha sonra önceden işlenir ve ölçüm sırasında kullanıcının hareket durumlarına göre uzayda sürekli ve uzayda süreksiz tipler olarak kategorize edilir. Bu parmak izleri ayrıca, yüksek benzerliğe sahip sanal kaplar olarak işlev gören farklı sanal odalara sınıflandırılır. Bu sanal odalar ile fiziksel konumlar arasındaki ilişkiyi kurmak için, sürekli alan verilerinden kullanıcı izleme bilgileri kullanılarak mantıksal bir kat planı oluşturulur. Bu mantıksal kat planı, daha önce bağımsız olan parmak izlerini etkili bir şekilde birbirine bağlayarak sanal odalar arasındaki bağlantı ve erişilebilirliği yakalar. Yalıtılmış parmak izlerini fiziksel odalarla ilişkilendirerek, mantıksal kat planını bilinen bir zemin gerçeği kat planına eşlemek için yeni bir eşleme yöntemi kullanılır. Bu ilişkilendirmeler, ileride başvurmak üzere bir kat planı veri tabanında saklanır. Hizmet verme aşamasında, bir kullanıcı mevcut ölçümleriyle bir konum sorgusu gönderdiğinde, WILL sunucusu tahmini bir konumla yanıt verir. Sorgu, WiFi ölçümlerini ve duyusal verileri içerebilir. Yerelleştirme motoru, sanal odayı belirlemek için parmak izi veri tabanına başvurur ve ilgili fiziksel odayı kat planı veri tabanından alır. Tahmini konum ve potansiyel olarak kullanıcının mevcut konumunun kat planı kullanıcıya geri verilir. Ek olarak, sorgulama verileri parmak izi veri tabanını güncellemek için kullanılabilir. Özetle, saha araştırmalarına olan ihtiyacı ortadan kaldıran kablosuz bir iç mekan yerelleştirme yaklaşımı olarak WILL'i tanıttı. Cep telefonlarından kullanıcı hareketleri ve parmak izi verilerinden yararlanan WILL, rekabetçi yerelleştirme doğruluğu elde eder ve iç mekan yerelleştirme teknikleri için yeni olanaklar sunar (Wu vd., t.y.).

Bozkurt ve arkadaşları, iç mekan konumlandırması için makine öğrenme algoritmalarının kapsamlı bir analizini sunmaktadır. Çalışma, orijinal veri setini kullanarak sınıflandırmayı gerçekleştirirken, 520 Kablosuz Erişim Noktası (WAP) tarafından sağlanan RSS değerlerini ve BUILDINGID, FLOOR, SPACEID ve RelativePos özniteliklerinden oluşan yeni bir öznitelik olan "cell"i tanıtmaktadır. Ardından, "İç Mekan Konumlandırması için Çıkarımsal Ayrışma (DESIP)" adı verilen yeni bir yöntem önerilmektedir. Bu yöntemde, sınıflandırma görevi için yalnızca bina bilgileri ve 520 WAP tarafından sağlanan RSS değerleri kullanılmaktadır. İlk sınıflandırma aşamasında, bina bilgisi sınıf olarak tanımlanır ve veritabanı, bina bilgisine dayalı olarak üçe bölünür. Daha sonra, her bir alt küme, katman bilgilerine göre sınıflandırılır. İlk sınıflandırmada her test veri noktasının binası tahmin edilirken, ikinci sınıflandırma aşamasında birinci sınıflandırmada binası belirlenen test veri noktalarının katmanı tahmin edilir. Son olarak, ikinci sınıflandırmada bina bilgisine göre bölünen veri setleri, katman bilgisine dayalı olarak yeniden bölünür. Katman bilgisine göre bölünen her bir veri seti, alan ve göreceli konum özelliklerini kullanarak sınıflandırılır. Yapay Sinir Ağları (NN), Sıralı Minimal Optimizasyon (SMO), J48, Naïve Bayes ve Bayes Net gibi çeşitli makine öğrenme algoritmaları sınıflandırma görevinde kullanılırken, sınıflandırma performansını değerlendirmek için doğruluk ölçütü benimsenir. Ayrıca, AdaBoostM1 ve Bagging gibi enseble öğrenme algoritmaları, J48'nin performansını artırmak için kullanılır. Deneyler için, yalnızca eğitim veri seti kullanılarak IP_Train ve IP_Test adlı yeni veri setleri oluşturulur. Bu veri setleri, sınıflandırma sürecinin eğitim ve test aşamalarında kullanılır. Sınıflandırmayı, DESIP yaklaşımına göre bina, katman ve bölge olmak üzere üç aşamada gerçekleştirirler. Bina sınıflandırmasında, IP_Train ve IP_Test veri setlerinden sırasıyla B012_Train ve B012_Test veri setleri oluşturulur. Bu veri setleri, 520 WAP'den gelen RSS değerlerini ve tüm bina bilgilerini içermektedir. Katman

sınıflandırmasında, IP_Train ve IP_Test veri setleri, farklı binalar için üçe bölünür. IP_Train'den B0_F0123_Train, B1_F0123_Train ve B2_F01234_Train veri setleri, IP_Test'ten ise B0_F0123_Test, B1_F0123_Test ve B2_F01234_Test veri setleri oluşturulur. Bu altı veri seti, yalnızca bir binayı ve o binaya ait tüm katman bilgilerini içeren yapıya sahiptir. Bölge sınıflandırmasında, katman sınıflandırması aşamasında zaten bölünen veri setleri tekrar bölgeye göre bölünür. Örneğin, B0_F0123 veri setinden B0_F0_R_Train, B0_F1_R_Train, B0_F2_R_Train ve B0_F3_R_Train veri setleri oluşturulur. Aynı bölme işlemi, geri kalan eğitim ve test katman veri setleri için tekrarlanır. Bölgeye göre bölme işlemi için alan ve göreceli konum bilgileri birleştirilerek "region" adı verilen yeni bir özellik tanımlanır ve bölge sınıflandırması için ilgili veri setlerine eklenir. Sonuç olarak, araştırma, orijinal veri seti kullanılarak yapılan başlangıç sınıflandırmasını içermekte ve çıkarımsal ayrışma stratejisini benimseyen yenilikçi DESIP yöntemini tanıtmaktadır. Çalışma, farklı makine öğrenme algoritmalarını ve enseble tekniklerini değerlendirirken, bina, katman ve bölge olmak üzere farklı sınıflandırma aşamalarını dikkate almaktadır. Elde edilen bulgular, iç mekan konumlandırma görevleri için farklı algoritmaların performansını ve uygulanabilirliğini değerli bir şekilde ortaya koymaktadır (Bozkurt vd. 2015).

Song ve arkadaşları, çok katlı bina ve çok katlı yer belirleme için WiFi parmak izi kullanarak Evrişimsel Sinir Ağı (CNN) tabanlı bir iç mekan konumlandırma sistemi olan "CNNLoc" yöntemini önermektedir. Bu yöntemde, seyrek Alınan Sinyal Gücü (RSS) verilerinden kesin özelliklerin çıkarılabilmesi için Özyineleme Kodlayıcı (SAE) kullanılırken, konumlandırma aşamasında yüksek doğruluk elde etmek için CNN etkin bir şekilde eğitilmektedir. Elde edilen sonuçlar, bina ve katman sınıflandırmalarında sırasıyla %100 ve %95 oranında doğruluk sağladığını göstermektedir. CNN'nin kullanımıyla, sinir ağlarında genel matris çarpımının yerini alan evrişim işlemi kullanılarak hesaplama karmaşıklığı azaltılmaktadır. Bu çalışmanın temel katkıları çok katlı bina ve çok katlı iç mekan konumlandırması için derin öğrenme modeli önerilmesi, bu model, veri boyutunu azaltmak için SAE ağını kullanmakta ve parmak izi veri setinden önemli özellikleri çıkarmak için bir boyutlandırılmış bir CNN ile birleştirmektedir. Bu şekilde, konumlandırma doğruluğu artırılmaktadır. Geleneksel rastgele seçim yöntemi yerine yeni bir algoritma kullanılarak eğitim veri setinden doğrulama seti çıkarılmaktadır. Bu yöntem, özellikle veri seti hacmi küçük olduğunda, rastgele seçim yöntemiyle ortaya çıkan istikrarsızlık sorununu çözmektedir (Song vd., t.y.).

Qin ve arkadaşları, CDAE-CNN tabanlı bir Wi-Fi parmak izi iç mekan konumlandırma sistemi olan "CCpos"u önermektedir. Bu sistemde, çevrimdışı aşamada K-ortalama algoritması kullanılarak doğrulama seti eğitim setinden çıkarılmaktadır. Çevrimiçi aşamada ise RSSI önce gürültüden arındırılmakta ve önemli özellikler CDAE (evrişimsel gürültü giderici otomatik kodlayıcı) kullanılarak çıkarılmaktadır. Daha sonra konum tahmini CNN tarafından yapılmaktadır. Ana katkıları, eğitim setindeki veri kapsamının küçük veri setleri durumunda eksik olması nedeniyle rastgele seçim yönteminin yer belirleme sonuçlarında dalgalanmalara neden olabileceği sorununu çözmek için doğrulama setini çıkarmak için K-ortalama kümeleme algoritması kullanılmaktadır. Bu sistem, CDAE ve CNN'yi birleştiren yeni bir ağ modeli tasarlamaktadır. Bu model, CDAE ağını veri boyutunu azaltmak için kullanırken, eğitim sürecinde gürültü ekleyerek ve gürültü azaltma yaparak ağı daha sağlam invariant

özellikler öğrenmeye ve girişin daha etkili bir temsilini elde etmeye zorlar. Ayrıca, RSSI verilerinden önemli özellikler çıkarılabilir ve ardından CNN, konumlandırma aşamasında yüksek başarı oranı elde etmek için eğitilir (Qin, Tian, ve Wang 2021).

Kim ve diğerleri, çok katlı ve çok bina ortamlarında DNN'lerin kullanımını önermektedir. Daha ölçeklenebilir bir yapıda olan bir DNN mimarisi önerilmektedir. Bu mimari, özellik uzayı boyutunu azaltmak için Yığılmış Otomatik Kodlayıcı (SAE) ve ölçeklenebilir bina/kat sınıflandırması ve kat seviyesi konum tahmini için beslemeli çoklu etiketli bir sınıflandırıcıdan oluşmaktadır. Bu sistemin performansı UJIIndoorLoc veri kümesi kullanılarak değerlendirilmiştir (Elesawi ve Kim 2021).

Felix ve arkadaşları, regresyon için yaygın olarak kullanılan derin modelleri, DNN, DBN ve GB-DBN'yi kullanır. Ayrıca, DBN ve GB-DBN gibi farklı önyükleme algoritmalarının parmak izi iç mekan konumlandırma sistemleri üzerindeki etkisini araştırmıştır. Önerilen algoritmanın çevrimdışı aşamasında, birden fazla erişim noktasından (AP) her referans noktasında (RP) birden çok örnekleme zamanında bir dizi RSS değeri toplanır. Bu RSS değerleri, j. AP için rij ve i. RP için τ zamanındaki ri(τ) olarak gösterilir ve parmak izleri oluşturmak için kullanılır. Her parmak izi, RSS değerlerini ve ilgili RP'nin bilinen fiziksel konum bilgisini içeren bir demet olarak temsil edilir. Çevrimdışı aşamanın son adımında, sunucu toplanan radyo haritası kullanılarak denetimli eğitim yapar, burada parmak izleri eğitim verisi olarak kullanılır. Eğitilen model daha sonra çevrimiçi aşamada kullanılmak üzere saklanır. Çevrimiçi aşamada, bir kullanıcı konum tahmini istediğinde, sunucu kullanıcıdan gerçek zamanlı RSS değerlerini rˆ alır. Bu değerler, kullanıcının bilinmeyen konumu l'deki tüm AP'lerden gelen RSS değerlerini temsil eder. Sunucu, alınan RSS değerleri rˆ temelinde eğitilmiş desen eşleme algoritmasını kullanarak tahmini konumu ˆ tahmin eder (Felix Zavala, Siller, ve Alvarez 2016).

Nowicki ve Wietrzykowski, tek bir taramaya dayalı olarak kat ve bina tahmini yapmak için sınıflandırma odaklı bir Derin Sinir Ağı (DNN) ve oto kodlayıcılar kullanılmasını önermektedir. Wi-Fi taramaları, çevrede bulunan erişim noktalarının sinyal gücü ölçümlerini içerir, ancak ortamda bulunan tüm ağların gözlemlenmesi mümkün değildir. Bu nedenle, makine öğrenimi yaklaşımları için azaltılmış üst düzey özelliklerin önerilmesi zor olabilir. Yazarlar, bu sorunu üst üste binmiş oto kodlayıcılar kullanarak çözmeyi önermektedir. Üst üste binmiş oto kodlayıcılar (Stacked Autoencoders, SAE), denetimsiz öğrenme sırasında girdi verisinin azaltılmış temsilini öğrenerek veri boyutunu azaltmada kullanılan derin ağ bileşenleridir. SAE, denetimsiz öğrenme sırasında öğrenilir ve kodlayıcı-dekoder çiftinin çıktıda girdi ile aynı bilgiyi sağlaması hedeflenir. Kodlayıcı ve dekoder arasındaki katmanın boyutu, girdi vektörünün boyutundan daha küçük olduğundan, ağ, girdide sağlanan bilginin azaltılmış temsilini öğrenmek zorundadır. Denetimsiz öğrenme aşaması tamamlandığında, SAE'nin dekoder kısmı bağlantıdan çıkarılır ve derin ağın tipik tam bağlantılı katmanları, kodlayıcının çıktısına bağlanır. Bu kısma "sınıflandırıcı" adı verilir. Denetimli öğrenme aşamasından önce, etiketli veri eğitim, doğrulama ve test kümelerine ayrılır. DNN, eğitim verisi üzerinde öğrenilirken performans doğrulama verisiyle kontrol edilir ve nihai performans test setine dayalı olarak değerlendirilir (Nowicki, Wietrzykowski, ve Skrzypczyński 2016).

Choi ve Beakcheol tarafından yürütülen çalışmada, K-NN (K En Yakın Komşu) algoritması ve hareketli ortalamalı filtre kullanıldığı belirtilmektedir. Bu yöntemlerin, Wi-Fi parmak izi tekniğinin düşük doğruluk oranını ve triangülasyon tekniğinin çevresel faktörlerden kaynaklanan dezavantajını aşmak için kullanıldığı ifade edilmektedir. K-NN algoritması, ölçülen RSSI (Alınan Sinyal Gücü Göstergesi) değerlerini sıralama ile işleme başlar. Belirlenen "k" sayısına göre, ölçülen beaconlar, konum ve RSSI değerleri arasından pozisyonlandırma yapılır. Bu sonuç daha sonra veritabanındaki sonuçlarla karşılaştırılarak konum belirlenir. Deney ortamı, 3x3 metrelik bir alana 24 hücreye bölünmüş ve 10 beacon yerleştirilmiştir. Her bir nokta için 30 ölçüm gerçekleştirilmiştir. Elde edilen sonuçların %86 doğruluk oranında olduğu bulunmuştur (Choi ve Jang 2017).

Kanaris ve arkadaşları tarafından yapılan çalışmada, başlangıçta oluşturulan Wi-Fi fingerprint veri setini filtrelemek için i-KNN (işaretçi K-en yakın komşu) algoritmasının geliştirildiği belirtilmektedir. Bu geliştirme sayesinde, daha kesin sonuçlar elde etmek amacıyla final pozisyon tespitinde kullanılacak bir veri seti oluşturulmaktadır. Filtreleme algoritması, Wi-Fi ve BLE (Bluetooth Low Energy) lokasyonları ile radyo haritası gibi verileri girdi olarak kullanmaktadır. BLE cihazları ve fingerprint lokasyonları arasındaki mesafeler, "Fingerprints to BLE Distance" prosedürü kullanılarak hesaplanmaktadır. Hesaplanan lokasyonlar, matris formuna dönüştürülmektedir. Gerçek zamanlı pozisyon tespiti sırasında, algoritma "BLE Discovery" prosedürü ile çevredeki cihazları tarayarak RSSI (Received Signal Strength Indicator) değerlerine göre sıralama yapmaktadır. i-KNN algoritması, en yakın cihazları seçerek pozisyon tespitini bu cihazlar üzerinden gerçekleştirmektedir. Ölçüm sürecinde, sinyaller bina içerisinde 1 metre aralıklarla yerden 90 cm yükseklikte bulunan 110 farklı noktadan alınmaktadır. Her noktada, 24 erişim noktasından 30 ayrı RSS ölçümü yapılmaktadır (Kanaris vd. 2017).

Chai ve diğerleri tarafından yapılan çalışmada, dış değerlerin filtrelenmesi için RSSI (Received Signal Strength Indicator) değerlerinin standart sapması ve ortalama değerinin hesaplandığı belirtilmektedir. Bu adımda, (mean-2*std) dışında kalan RSSI değerleri elenmektedir. Kalan değerlerin ortalaması alınarak, ileriki aşamalarda kullanılmak üzere bu değer saklanmaktadır. Kalman filtrelemesi aşamasından sonra, mobil cihazın konumunun tespiti Triangulasyon yöntemiyle gerçekleştirilmektedir. Önerilen yöntem, 0.2 - 0.4 metre aralığında bir pozisyon hatası sağlamaktadır (Chai, An, ve Du 2016).

Saleem ve Wyne tarafından yürütülen çalışmada, Yapay Sinir Ağı (ANN) ve Maximum Likelihood Estimation (MLE) modelleri karşılaştırılmıştır. ANN modelinde, eğitim aşamasında RSS değerleri ile coğrafi konumlar arasındaki ilişkiyi belirlemek için model ağırlıkları ayarlanmaktadır. ANN modeli, hafıza gereksinimi ve sonuç doğruluğu açısından feed-forward MLP (Çok Katmanlı Algılayıcı) mimarisini kullanmaktadır. Üç katmanlı bir MLP kullanılmıştır, giriş, çıkış ve tek bir gizli katmandan oluşmaktadır. Giriş katmanındaki düğüm sayısı, çevrimdışı aşamada ölçülen erişim noktası sayısına eşittir. Çıktı katmanında ise enlem ve boylam değerlerine karşılık gelen iki düğüm bulunmaktadır. Gizli katmanda ise 10 nöron kullanılmış ve hiperbolik tanjant fonksiyonu aktivasyon fonksiyonu olarak tercih edilmiştir. Çıktı katmanının aktivasyon

fonksiyonu olarak lineer bir fonksiyon kullanılmıştır. Eğitim algoritması olarak Levenberg-Marquardt algoritması seçilmiştir. Olasılıksal metotlarda ise RSS değerleri rastgele değişkenler olarak ele alınmakta ve RSS değerlerinin istatistiksel dağılımından faydalanılarak bilinmeyen noktaların konumu hesaplanmaktadır. Ancak, bu çalışmada yazarlar MLE yöntemini kullanmış olup, tahmin edilen konumun yalnızca referans noktalarının konumlarından biri olarak bulunabileceğini belirtmişlerdir. Bu nedenle, daha doğru sonuçlar elde etmek için bu noktalar arasında interpolasyon tekniğinin uygulanabileceğini belirtmişler ve iki farklı interpolasyon tekniğine değinmişlerdir. Konum hesaplaması için 400 m²'lik bir oda seçilmiş ve odanın dört köşesine dört erişim noktası yerleştirilmiştir. Oda içerisinde 4 metre aralıklarla 25 nokta belirlenmiş ve bu noktalarda ölçümler yapılmıştır. Sonuçlar makalede sunulmaktadır (Saleem ve Wyne 2016).

Ahn ve Han tarafından yürütülen çalışmada, kitlekaynak kullanarak radyo haritası oluşturma yöntemleri üzerine bilgi sunulmuştur. İlk olarak, radyo haritasının oluşturulması için Ters Mesafe Ağırlıklı (IDW) interpolasyon yöntemine değinilmiştir. Radyo haritasının geliştirilmesi için konum bilgilerinin etiketlenmesi gerekmektedir ve bu amaçla durum modellemesi, ileri geri algoritması ve eşit dağılım yöntemleri gibi işlemler uygulanmaktadır (Lee vd. 2017).

Li ve diğerleri iç mekân yerelleştirme için iki aşamalı bir yaklaşım sunmuştur. Metodoloji, her biri yerelleştirme sürecinin belirli yönlerini ele alan bir çevrimdışı aşama ve bir çevrimiçi aşamadan oluşur. Çevrimdışı aşamada, yazarlar önceden belirlenmiş referans noktalarında RSS (Alınan Sinyal Gücü) değerlerini toplar. RSS parmak izlerinin boyutunu azaltmak için Temel Bileşen Analizi (PCA) uygulanır. Daha sonra, RSS değerlerini kümelemek için denetimsiz bir yakınlık yayma tekniği kullanılır. Bu kümeleme işlemi ikili amaçlara hizmet eder: ilk olarak, Yapay Sinir Ağı'nın (YSA) eğitim aşamasında hesaplama karmaşıklığını azaltır; ikinci olarak, paylaşılan özelliklere sahip RSS değerlerini aynı kümede gruplayarak YSA modelinin performansını artırır. Ortaya çıkan kümeler daha sonra Parçacık Sürü Optimizasyonu (PSO) algoritması kullanılarak bireysel YSA örneklerini eğitmek için kullanılır. Çevrimiçi aşamaya geçilirken, RSS değerlerine PCA dönüşümü uygulanır ve ardından karşılık gelen küme üyeliğini belirlemek için kümelerle bir karşılaştırma yapılır. Yazarlar, geri yayılım yerine PSO'yu benimsemelerini gerekçelendirerek, PSO'nun geri yayılımla ilişkili yerel minimum yakalama sorunundan kaçınırken küresel bir optimizasyon çözümü sağladığını vurguluyor. PSO, YSA'nın ağırlık ve yanlılık değerlerini optimize etmek için kullanılır. Veri toplama açısından, yazarlar çevrimdışı aşamada 188 referans noktasından elde edilen 9.400 parmak izinden oluşan bir veri seti derliyor. Ardından, çevrimiçi aşamada, 100 test noktasından ek olarak 200 RSS değeri toplanır. Önerilen YSA mimarisi, iki gizli katman içerir ve yazarlar, ek katmanların dahil edilmesinin, önemli performans kazanımları olmadan eğitim süresinin artmasına neden olacağını iddia eder. Hiperbolik tanjant (tanh) aktivasyon fonksiyonu kullanılırken, giriş katmanı erişim noktalarının PCA ile azaltılmış RSS değerlerini alır ve boyutsallık 16'dan 9'a düşürülür. Sistemin istenen çıktısı enlem ve boylam koordinatlarıdır. Deneyler yoluyla, yazarlar optimal gizli düğüm sayısının 9 olduğunu ve bunun da 1.95 m'lik bir ortalama

konum hatası verdiğini belirlediler. Ayrıca, PSO algoritmasının parçacık seçim parametresi, eğitim süresi ile konum hatası arasında en uygun dengeyi sağladığı için 600'e ayarlanmıştır, çünkü bu değerin aşılması eğitim süresinin artmasına ve doğruluğun düşmesine neden olur. Özet olarak, makale, PSO tabanlı YSA eğitimi ve kümeleme tekniklerinin bir kombinasyonunu kullanarak Wi-Fi iç mekân yerelleştirmesine yeni bir yaklaşım sunmaktadır (Li vd. 2016).

Cheng ve diğerleri, sürü zekâsı algoritmalarını bir yapay sinir ağı ile birleştirmiştir. Çalışmada, eğitim amaçlı 1800 veri noktası ve test için 900 veri noktasından oluşan bir veri seti kullanılmıştır. İki farklı konumlandırma senaryosu göz önünde bulundurulmuştur: bölgesel konumlandırma ve koordinat konumlandırma. Bölgesel konumlandırmada, sistemin çıktısı, hedef cihazın bulunduğu belirli alanı temsil ederken, koordinat konumlandırmada çıktı, hedef cihazın kesin x ve y koordinatlarını sağlar. Yapay sinir ağının performansını optimize etmek için, gizli katmanlardaki optimal nöron sayısını belirlemek ve öğrenme oranını ayarlamak için sürü optimizasyonu algoritmaları kullanılmıştır. Öğrenme oranı, 0.01 arama aralığı ile 0.01 ila 1 aralığından seçilmiştir. Özellikle, nöron sayısı için arama aralığı olarak 1 değeri seçilmiştir ve bu, tekil bir nöron konfigürasyonunu göstermiştir. Bölgesel konumlandırma bağlamında, kullanılan uygunluk fonksiyonu, hata sayısının toplam veri noktası sayısına oranı olarak hesaplanan hata oranıdır. Tersine, koordinat konumlandırmada, uygunluk fonksiyonu olarak ortalama mesafe hatası kullanılır. Bölgesel konumlandırma yaklaşımı için yapay sinir ağının giriş katmanı, 5 erişim noktasının varlığını barındıracak şekilde tasarlanırken, çıkış katmanı, çalışmada ele alınan 9 farklı bölge için sonuç verecek şekilde yapılandırılmıştır. Bu mimari yapılandırma, iç ortam içinde doğru bölgesel konumlandırma sağlar. Sonuç olarak araştırma, sürü zekâsı algoritmalarını yapay sinir ağı ile birleştiren yenilikçi bir sistem önererek iç mekân konumlandırma alanına katkıda bulunmaktadır (Cheng, Wang, ve Huang 2020).

2.1. Alınan Sinyal Gücü – Received Signal Strength (RSS)

Alınan sinyal gücü (RSS), iç mekân lokalizasyonu için en basit ve en yaygın kullanılan sinyal ölçümlerinden biridir. RSS, bir verici cihazdan alınan genellikle desibel- miliwatt (dBm) cinsinden ölçülen sinyal gücüdür. Bu değer, verici (Tx) ve alıcı (Rx) cihazları arasındaki mesafeyi tahmin etmede kullanılabilir. RSS değeri verici ve alıcı arasındaki mesafe ile azalır. RSSI ise alıcı cihaz tarafından alınan sinyal gücünün bir göstergesidir (Zafari vd. 2019). Tx ve Rx arasındaki d mesafesi, RSSI ve (1)'den bir yol kaybı yayılım modeli kullanılarak şu şekilde tahmin edilebilir:

$$\mathrm{RSSI} = -10 * \mathrm{n} * (\log_{10}(\mathrm{d})) + \mathrm{A} \qquad (2.1)$$

Burada n, yol kaybı üstel katsayısı (path loss exponent) ve A, Rx'ten bir referans mesafesinde alınan sinyal gücüdür. RSS ve mesafe arasındaki ilişki, özellikle kapalı ortamlarda gölgelenme, saçılma, solma, kırılma, çoklu yol nedeniyle doğrusal olmak

zorunda değildir. Bu nedenle doğruluğu artırmak için Gauss Filtresi, Kalman Filtresi, Hareketli Ortalama Filtresi gibi farklı filtreler kullanılabilir. RSS tabanlı sistemler zaman bilgisine dayanmaz ve cihazlar arasında senkronizasyona gerek yoktur. RSS tabanlı yerelleştirme sistemleri, zamana dayalı yöntemlere ve açıya dayalı yöntemlere kıyasla uzun menzilli mesafelerde zayıf doğruluk sağlar; ancak kısa menzilli mesafelerde RSS tabanlı sistemler daha doğrudur (Obeidat vd. 2021).

Kapalı mekanlarda, alınan sinyal gücü göstergesi (RSSI), çoklu yol gölgelenmesi nedeniyle değişikliklere uğrar. Patwari ve Wilson tarafından yılında belirtildiği gibi, alıcıda ölçülen karmaşık tabanbandı sinyal gerilimi aşağıdaki gibi temsil edilebilir:

$$V(t) = \sum\left(V_i * e^{(-j\theta i)}\right) \quad (2.2)$$

Burada Vi ve θi, i. çoklu yol bileşeninin genliğini ve fazını temsil eder.

RSSI, decibel (dB) cinsinden ölçülen alınan gücü ifade eder ve aşağıdaki gibi hesaplanır:

$$RSSI = 10 * log(\sum(|V_i|^2)) \quad (2.3)$$

(Patwari ve Wilson 2011).

RSSI'nin sadece sinyal dalga boyuna bağlı olarak mesafe ile değiştiğini değil, aynı zamanda alıcının hareketsiz olduğu durumlarda bile zaman içinde dalgalanmalar gösterdiğini belirtmek önemlidir. Wu ve arkadaşları tipik bir laboratuvar ortamında yapılan deneysel çalışmalarda, RSSI okumalarının bir dakika içinde 5 dB kadar değişebileceği bulunmuştur (Wu vd., t.y.). Ayrıca, Lim ve arkadaşları RSSI sinyallerinin hem küçük (saniyeler) hem de büyük (saatler) zaman ölçeklerinde değişebildiğini ve tipik bir öğrenci bölmesinde 7 dB'ye kadar çıkabileceğini gözlemlemiştir (Lim ve Wong 2007).

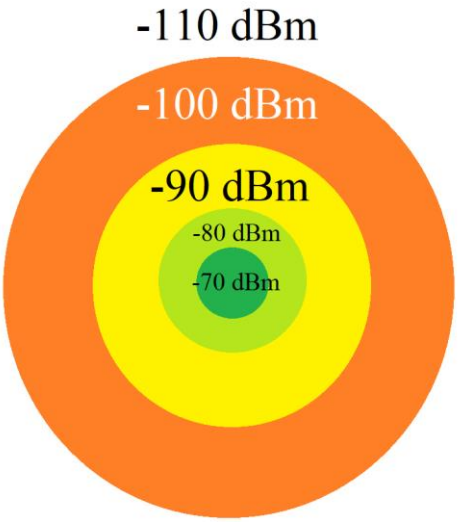
Bu RSSI değişikliklerinin yer belirleme tekniklerine etkisi bulunmaktadır. Güç tabanlı menzil belirleme, RSSI'yi mesafeye Log-normal Mesafe Yolu Kaybı (LDPL) modeli kullanarak eşlemeye dayanır ve bu model Seidel ve Rappaport tarafından önerilmiştir. LDPL modeline göre, mesafesi d olan ölçülen yol kaybı (PL(d)) aşağıdaki gibi tanımlanabilir:

$$PL(d) = PL(d_0) + 10 * n * \left(\log_{10}\left(\frac{d}{d_0}\right)\right) + X_\sigma \quad (2.4)$$

Burada PL(d0), referans noktası d0'da ortalama yol kaybını, n yol kaybı üssünü ve X_σ gölgelenme tarafından oluşturulan sönümlemeyi temsil eden sıfır ortalamalı normal rassal bir değişkendir.

LDPL modeli, RSSI'nin mesafe ile monotonik olarak azaldığını varsayar. Ancak, rastgele gölgelenme etkisi (X_σ) nedeniyle bu monotonik trend yalnızca gölgelenmenin

varyansı (σ) tarafından sınırlanan nispeten büyük bir ölçekte geçerlidir. Çoklu yol zengin kapalı mekanlarda, RSSI sinyal dalga boyu ölçeğinde dalgalanır ve büyük X_σ değerlerine sahip önemli gölgelenme etkilerine yol açar. Sonuç olarak, yakın konumlardaki yerleri ayırt etmek, beklenen monotonik trendi bulanıklaştıran çoklu yol gölgelenmesindeki önemli sapma nedeniyle zorlaşır (Seidel ve Rappaport 1994).



Şekil 2.1. Sinyal kayıp oranının merkezden dışarıya mesafe ilişkisinin gösterimi

Çizelge 2.1. RSS%- RSS(RSSI) dönüşümü CISCO

%0=-113dBm	%20=-92dBm	%40=70dBm	%60=-47dBm	%80=-27dBm
%1=-112dBm	%21=-91dBm	%41=-9dBm	%61=-46dBm	%81=-25dBm
%2=-111dBm	%22=-90dBm	%42=-8dBm	%62=-45dBm	%82=-24dBm
%3=-110dBm	%23=-89dBm	%43=-7dBm	%63=-44dBm	%83=-23dBm
%4=-109dBm	%24=-88dBm	%44=-5dBm	%64=-44dBm	%84= -22Bm
%5=-108dBm	%25=-87dBm	%45=-4dBm	%65=-43dBm	%85=-20dBm
%6=-107dBm	%26=-86dBm	%46=-3dBm	%66=-42dBm	%86=-19dBm
%7=-106dBm	%27=-85dBm	%47=-2dBm	%67=-42dBm	%87=-18dBm
%8=-105dBm	%28=-84dBm	%48=-0dBm	%68=-41dBm	%88=-17dBm
%9=-104dBm	%29=-83dBm	%49=-59dBm	%69=-40dBm	%89=-16dBm
%10=-103dBm	%30=-82dBm	%50=-58dBm	%70=-39dBm	%90=-15dBm
%11=-102dBm	%31=-81dBm	%51=-56dBm	%71=-38dBm	%91=-14dBm
%12=-101dBm	%32=-80dBm	%52=-55dBm	%72=-37dBm	%92=-13dBm
%13=-99dBm	%33=-79dBm	%53=-53dBm	%73=-35dBm	%93=-12dBm
%14=-98dBm	%34=-78dBm	%54=-52dBm	%74=-34dBm	%94=-10dBm
%15=-97dBm	%35=-77dBm	%55=-50dBm	%75=-33dBm	%95=-10dBm
%16=-96dBm	%36=-75dBm	%56=-50dBm	%76=-32dBm	%96=-10dBm
%17=-95dBm	%37=-74dBm	%57=-49dBm	%77=-30 dBm	%97=-10dBm
%18=-94dBm	%38=-73dBm	%58=-48dBm	%78=-29dBm	%98=-10dBm
%19=-93dBm	%39=-72dBm	%59=-48dBm	%79=-28dBm	%99=-10dBm

2.2. Wi-Fi – IEEE 802.11n

IEEE 802.11 standardı, Wi-Fi'nin başlıca Kablosuz Yerel Alan Ağı (WLAN) cihazlarında kullanıldığı bir standarttır. Wi-Fi, Endüstriyel, Bilimsel, Tıbbi (ISM) bandında çalışır ve Wi-Fi cihazları 2.4GHz veya 5GHz frekans bantlarında iletişim sağlar. Wi-Fi'nin alım menzili başlangıçta 50-100 metre civarındaydı, ancak günümüzde yaklaşık olarak 1 kilometreye kadar artmıştır (Centenaro vd. 2016). Wi-Fi tabanlı konumlandırma sistemlerinin birkaç faydası vardır. Wi-Fi kullanmanın faydalarından biri, neredeyse her binanın artık Wi-Fi altyapısına sahip olmasıdır. Bu nedenle, Wi-Fi tabanlı sistemler ek donanım kurulumu gerektirmez. Bunun yanı sıra, WLAN'de LOS gerekli değildir. WLAN'ın da sinyal dalgalanması ve ISM bandında girişim gibi bazı sınırlamaları vardır.

2.3. Makine Öğrenmesi

Makine Öğrenmesi (ML), bilgisayarların açıkça programlanmadan görevleri gerçekleştirmesini sağlayan algoritmaların ve istatistiksel modellerin geliştirilmesine odaklanan yapay zekanın (AI) bir alt alanıdır. Bu sistemler, deneyimlerden öğrenmek ve gelişmek için tasarlanmıştır.

Üç ana makine öğrenmesi türü vardır:

Denetimli Öğrenme: Denetimli öğrenmede, modele etiketli eğitim verileri sağlanır. Verilerin özellikleri ile etiketleri arasındaki ilişkiyi öğrenmek için bir algoritma kullanılır. Bu ilişki öğrenildikten sonra, model bunu yeni, daha önce görülmemiş verilere uygulayabilir. Yaygın bir örnek, "spam" veya "spam değil" olarak etiketlenmiş bir e-posta veri kümesinden öğrenebilen bir spam algılama sistemidir (Russell ve Norvig 2023).

Denetimsiz Öğrenme: Denetimsiz öğrenmede, modele etiketlenmemiş veriler verilir ve veriler içindeki kalıpları ve ilişkileri kümeleme, boyut küçültme gibi yöntemlerle bulması istenir. Yaygın bir örnek, müşterileri satın alma davranışlarına göre gruplandıran bir müşteri segmentasyon modelidir (Russell ve Norvig 2023).

Pekiştirmeli Öğrenme: Pekiştirmeli öğrenmede, bir aracının, kümülatif ödül kavramını en üst düzeye çıkarmak için bir ortamda eylemlerde bulunarak karar vermeyi öğrendiği bir makine öğrenimi türüdür. Ajan, açıkça öğretilmek yerine eylemlerinin sonuçlarından öğrenir ve eylemlerini geçmiş deneyimlerine (sömürü) ve ayrıca yeni seçimlere (keşif) dayalı olarak seçer (Sutton ve Barto 1998).

Makine öğrenmesi, görüntü işleme, doğal dil işleme ve öneri sistemleri dahil olmak üzere çok çeşitli uygulamalara sahiptir. Bozkurt ve diğerlerinin yaptığı çalışmaya göre Karar Ağacı ve K-NN algoritmaları sınıflandırma probleminde en iyi sonuçları vermiştir (Bozkurt vd. 2015). Belmonte-Fernandez ve diğerlerinin yaptığı çalışmada Rastgele Orman algoritması en iyi performansı göstermektedir (Belmonte-Fernandez vd. 2019).

2.3.1. K - En yakın komşu algoritması

K-en yakın komşular (K-NN) algoritması, sınıflandırma ve regresyon görevleri için kullanılan bir denetimli makine öğrenme tekniğidir. Tahmin yapmak için girdi veri noktaları arasındaki benzerliğe dayanan parametrik olmayan bir yöntemdir (Cover ve Hart 1967). K-NN algoritması, veri noktaları arasındaki benzerliği ölçmek için bir mesafe metriği kullanır. Yaygın olarak kullanılan mesafe metrikleri arasında Öklid mesafesi, Manhattan mesafesi, Chebyshev mesafesi gibi metrikler bulunur. k parametresi, tahmin yapmak için dikkate alınması gereken en yakın komşuların sayısını temsil eder. Uygun bir k değerinin seçilmesi genellikle çapraz doğrulama veya diğer optimizasyon teknikleriyle belirlenir. Daha küçük bir k değeri, daha yerelleştirilmiş karar sınırlarına izin verirken, daha büyük bir k değeri sınırların daha düzgün olmasını sağlar.

2.3.2. K - Rastgele orman algoritması

Rastgele orman algoritması hem sınıflandırma hem de regresyon görevleri için kullanılan bir denetimli makine öğrenmesi algoritmasıdır. Bir karar ağaçları topluluğu oluşturarak ve tahminlerini oylama veya ortalama alma yoluyla birleştirerek çalışır. Rastgele ormanlar, torbalama adı verilen bir teknik kullanarak bir karar ağaçları topluluğu oluşturur. Torbalama, rastgele örnekleme yoluyla eğitim verilerinin birden çok alt kümesini oluşturmayı içerir. Her alt küme, bir karar ağacını eğitmek için kullanılır. Sınıflandırma görevleri için rastgele ormanlar, tek tek ağaçların tahminlerini çoğunluk oylamasıyla birleştirir. En çok oyu alan sınıf nihai tahmin olur. Regresyon görevleri için, nihai tahmini elde etmek için tek tek ağaçların tahminlerinin ortalaması alınır (Hastie, Tibshirani, ve Friedman 2009).

2.3.3. Karar ağaçları

Karar ağaçları algoritması denetimli makine öğrenmesi türüdür. Eğitim verilerine dayalı olarak ağaç benzeri bir karar modeli ve olası sonuçları oluşturur. Ağacın her iç düğümü bir özelliği veya özelliği temsil eder ve her yaprak düğümü bir sınıf etiketini veya tahmin edilen bir değeri temsil eder. Algoritma, verileri her iç düğümde bölmek için en önemli özelliği seçer. Bölme kriteri, görevin türüne bağlıdır (Hastie, Tibshirani, ve Friedman 2009).

2.3.4. Sürü Zekâsı

Sürü zekâsı, merkezi olmayan kontrol ve öz-örgütlenme kullanarak koordine olan birçok canlıdan veya nesneden oluşan, doğal ve yapay sistemlerle ilgilenen disiplindir. Evrimsel açıdan hayatta kalmak üzere avlanma ve güvende olma eğilimleriyle bazı canlılar belirli bir sistematik davranış içinde hareket eder. Bu disiplin de özellikle bireylerin birbirleriyle ve çevreleriyle yerel etkileşimlerinden kaynaklanan kolektif davranışlara odaklanır. Sürü zekâsı tarafından incelenen sistemlere örnek olarak karınca ve termit kolonileri, balık sürüleri, kuş sürüleri, kara hayvanları sürüleri

verilebilir. Bazı insan yapıları, özellikle bazı çok robotlu sistemler ve ayrıca optimizasyon ve veri analizi problemlerinin üstesinden gelmek için yazılmış belirli bilgisayar programları da sürü zekasının alanına girer.

Sürü zekâsı, yukarıda belirtilen özelliklere sahip sistemlerin çeşitli alanlarda gözlemlenebilmesi nedeniyle belirgin bir multidisipliner karaktere sahiptir. Sürü zekâsı araştırmaları farklı kriterlere göre iki şekilde sınıflandırılabilir.

Doğal ve Yapay: Sürü zekâsı araştırmasını analiz edilen sistemlerin doğasına göre iki başlıkta ayırmak uygundur. Bu nedenle, biyolojik sistemlerin incelendiği doğal sürü zekâsı araştırmasından ve insan eserlerinin incelendiği yapay sürü zekâsından bahsedilebilir.

Bilimsel ve Mühendislik: Sürü zekâsı araştırmasının alternatif ve daha bilgilendirici bir sınıflandırması, izlenen hedeflere dayalı olarak verilebilir; bilimsel ve mühendislik akışı. Bilimsel akışın amacı, sürü istihbarat sistemlerini modellemek ve bir sistemin bir bütün olarak yerel birey-birey ve birey-çevre etkileşimlerinin bir sonucu olarak koordineli bir şekilde davranmasına izin veren mekanizmaları seçip anlamaktır. Öte yandan, mühendislik akışının amacı, bilimsel akış tarafından geliştirilen anlayıştan, pratik açıdan ilgili sorunları çözebilen sistemler tasarlamak için yararlanmaktır.

2.4. Sürü Zekâsı Algoritmaları

Sürü zekâ algoritmaları, evrim sürecinin bir sonucu olarak sürü zekâsını temel alan ve sürü zekâsının matematiksel olarak modellenmesi ile geliştirilmiş algoritmalardır. Bu algoritmalar kimi zaman karıncalarda olduğu gibi (Blum ve Li 2008) eklem bacaklı türü canlıların davranışını temel aldığı gibi bazen ise balinalarda olduğu gibi (Mirjalili ve Lewis 2016) kordalılar şubesinden bir canlının av mekanizmasından esinlenilmesi ile elde edilen algoritmalardır. Buradan yola çıkarak bu algortimalar spesifik ve özelleşmiş bir türden bağımsız olarak farklı türlerdeki davranışları baz almıştır. Aynı şekilde genellikle canlıların davranışları arasında örgün bir benzerlikten söz etmek oldukça zordur. Karıncaların yiyecek aramalarının matematiksel olarak modellenmesi ile balinaların avlanma sürecinde yararlandığı davranışın bir benzerliğinden söz edilemez.

2.4.1. Balina optimizasyon algoritması (Whale optimization algorithm)

Balina optimizasyon algoritması (WOA), kambur balinaların avlanma davranışlarından ilham alan bir optimizasyon algoritmasıdır. İki ana aşaması vardır: sömürü ve keşif. Sömürü aşamasında, algoritma, arama aracılarının konumlarını şimdiye kadar bulunan en iyi çözüme doğru günceller. Konumları A ve C katsayı vektörlerine göre ayarlamak için (2.1) ve (2.2)'deki formüleri kullanır. Bu güncellemeler, kambur balinaların avlarına yaklaşırken çevrelenme davranışlarını simüle eder. Keşif aşamasında, algoritma (2.7) ve (2.8) denklemlerini kullanarak arama aracısı konumlarını güncelleyerek rastgele bir arama gerçekleştirir. Rastgele arama ajanları, arama alanını keşfetmek için popülasyondan seçilir. Algoritma, rasgele bir olasılık değerine (p) dayalı olarak kullanım ve keşif aşamaları arasında geçiş yapar. p, 0,5'ten küçükse, kullanım aşaması yürütülür; aksi takdirde keşif aşaması yürütülür. Bu,

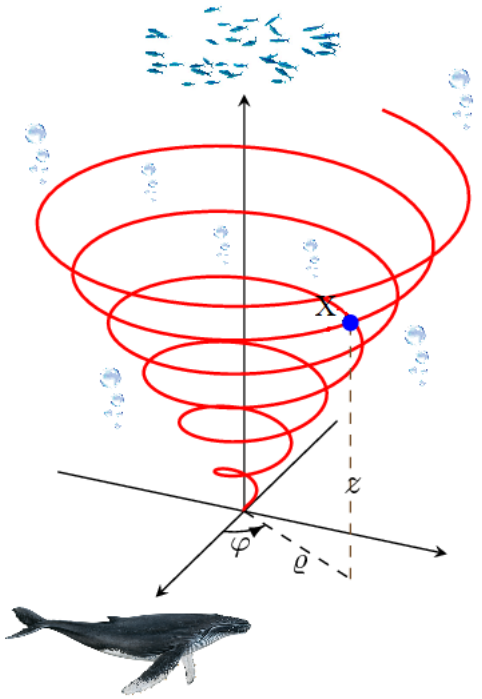
algoritmanın kambur balinaların uyarlanabilir avlanma stratejilerini taklit etmesini sağlar. WOA algoritması rastgele çözümlerle başlar ve tatmin edici bir çözüme veya maksimum yineleme sayısına ulaşmak gibi bir sonlandırma kriteri karşılanana kadar arama ajanlarının konumlarını yinelemeli olarak günceller (Mirjalili ve Lewis 2016).

$$D = |C * \rightarrow -X * (t) + X(t)| \quad (2.5)$$

$$X(t+1) = -\rightarrow X * (t) - A * D \quad (2.6)$$

$$D = |\mathrm{C} * -\rightarrow X_{rand} - X| \quad (2.7)$$

$$X(t+1) = X_{rand} - A * D \quad (2.8)$$



Şekil 2.2. Balina avlanmasının gösterimi

2.4.2. Parçacık sürü optimizasyonu (Particle swarm optimization)

Parçacık sürü optimizasyonu (PSO), doğal bir olay olan böceklerin veya kuş sürülerinin hareketlerinden esinlenerek geliştirilmiş bir optimizasyon algoritmasıdır. PSO, bir problemin eniyileme (optimizasyon) problemi olduğu durumlarda kullanılır.

PSO, bir popülasyon tabanlı algoritmadır ve çözüm adaylarını taklit eden "parçacıklar" (particles) olarak adlandırılan bireylerden oluşur. Her parçacık bir çözüm adayını temsil eder ve bir hedef fonksiyonunu optimize etmek için belirli bir yönde hareket eder (Eberhart ve Kennedy 1995).

Her parçacık, bir konum ve bir hız vektörü ile temsil edilir. Konum, parçacığın mevcut çözümünü temsil ederken, hız vektörü, parçacığın belirli bir iterasyonda hareket

etmek için kullanacağı hızı ve yönü belirler. Parçacıklar, en iyi bireysel konumlarını hatırlar ve aynı zamanda tüm popülasyon içindeki en iyi konumu takip eden bir lider konumunu günceller.

Algoritma, her iterasyonda parçacıkların konum ve hızlarını günceller. Bu güncelleme, parçacığın mevcut konumunu ve hızını, kendi en iyi konumu ve lider konumu arasında bir denge oluşturarak yapar. Parçacıklar, hedef fonksiyonun değerini minimize etmek veya maksimize etmek için en iyi konumlarını ararlar.

PSO'nun temel fikri, parçacıkların arama alanında gezinirken birbirlerinin deneyimlerinden öğrenmeleridir. Parçacıklar, lider parçacığın bulduğu iyi çözümleri takip ederek birlikte hareket ederler ve bu sayede global olarak daha iyi çözümleri keşfedebilirler.

PSO'nun avantajları arasında basitlik, genellikle hızlı bir şekilde yakınsaması ve çok boyutlu optimizasyon problemlerine uygulanabilmesi sayılabilir. Ancak, algoritma parametrelerinin ayarlanması ve bazı problemlerde hızlı yakınsama sağlamak için iterasyon sayısının yeterli olması gibi zorluklar da mevcuttur.

2.5. Parmak İzi Tekniği

Parmak izi tekniği, genellikle ortamın özelliklerini (parmak izlerini) toplamak ve ardından gerçek zamanlı ölçümleri veri tabanında depolanan en yakın parmak izleriyle eşleştirerek hedefin konumunu belirlemek için bir çevresel araştırma gerektirir. Parmak izi, ortalama, varyans ve histogram gibi çoklu düğümlerden alınan bir sinyalin istatistiksel niteliklerinin bir vektörüdür. Parmak izi yöntemi görüş mesafesi (line of sight) ölçümü gerektirmez ve ortamdaki kablosuz sinyal altyapısını kullandığı için herhangi bir ek donanım gerektirmez. Parmak izi alma tekniği iki aşamadan oluşur: çevrimdışı aşama ve çevrimiçi aşama. Çevrimdışı aşamada, radyo haritaları oluşturmak için bir ortamdaki saha araştırması veya bir sinyal yayılma modeli kullanılmalıdır. Radyo haritası, bir ortamdaki RSS, sinyal fazı, yayılma süresi, sinyal açıları gibi radyo sinyali özellikleriyle birleştirilmiş bilinen konumların bir veri tabanıdır. Radyo haritasının inşası, alanın hücrelere bölünmesiyle başlar. AP'lerden gelen sinyal vektörleri bir süre bu hücrelerde toplanır ve veri tabanında saklanır.

Çevrimiçi aşamada, lokalizasyon algoritması, cihazın konumunu tahmin etmek için gerçek zamanlı sinyal vektörünü ve veri tabanında depolanan sinyal vektörlerini kullanır. Lokalizasyon algoritması için deterministik veya olasılıksal yaklaşımlar kullanılabilir. Parmak izi alma tekniğinin en büyük dezavantajı, konum tahmini doğruluğunun çevrimdışı fazda toplanan verilerin doğruluğuna ve çevresel değişikliklere bağlı olmasıdır. Bu sebepler ve zaman alıcı ölçümler nedeniyle kitle kaynak tekniğine dayalı otomatik radyo harita güncelleme yöntemleri kullanılmalıdır.

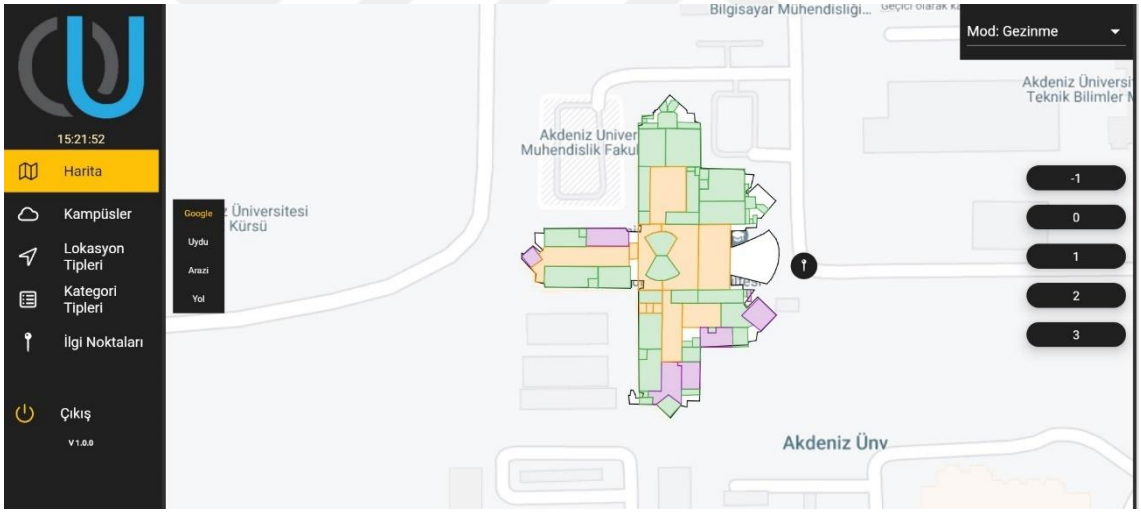
3. MATERYAL VE METOT

Bu çalışma ana çalışma prensipleri ve mimarisi bakımından üç kısımdan oluşmaktadır. İlk kısım belirli bir binanın modellenmesi ve odalarının görsel olarak ifade edilmesidir. İkinci kısım kapalı mekânda bulunan Wi-Fi sinyal verilerinin toplandığı kısımdır. Çalışmanın son kısmı ise toplanan veri ile makine öğrenmesi algoritmalarını eğiterek oda sınıflandırması çalışması ve sürü optimizasyonu algoritmalarını kullanarak bu makine öğrenmesi modellerinin optimum hiper parametre konfigürasyonlarının sağlanmasını içermektedir.

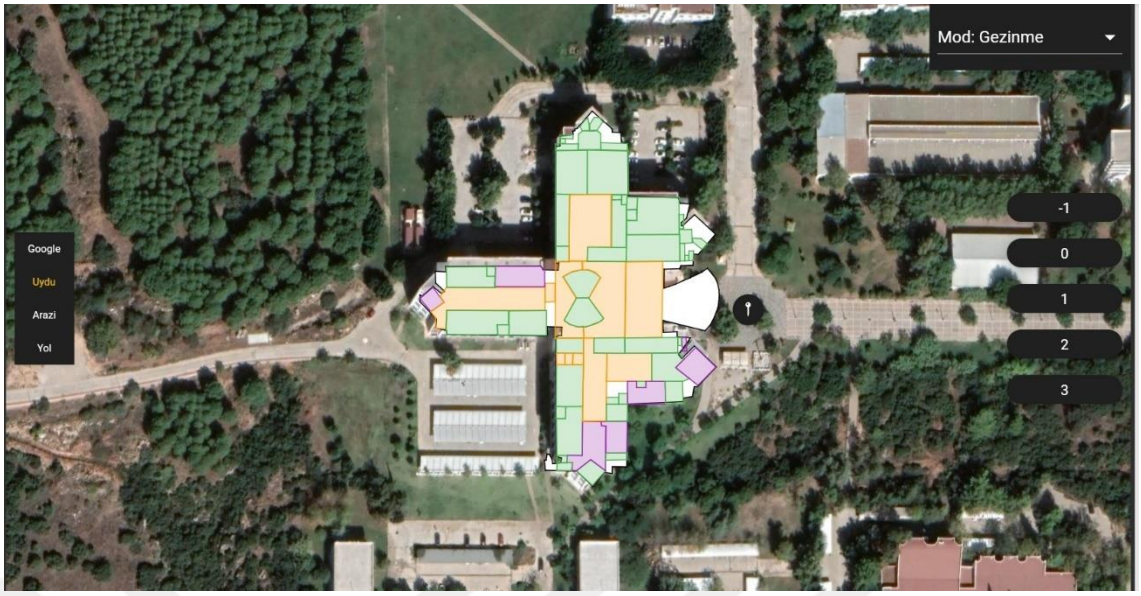
3.1. Uygulama

3.1.1. Haritalama

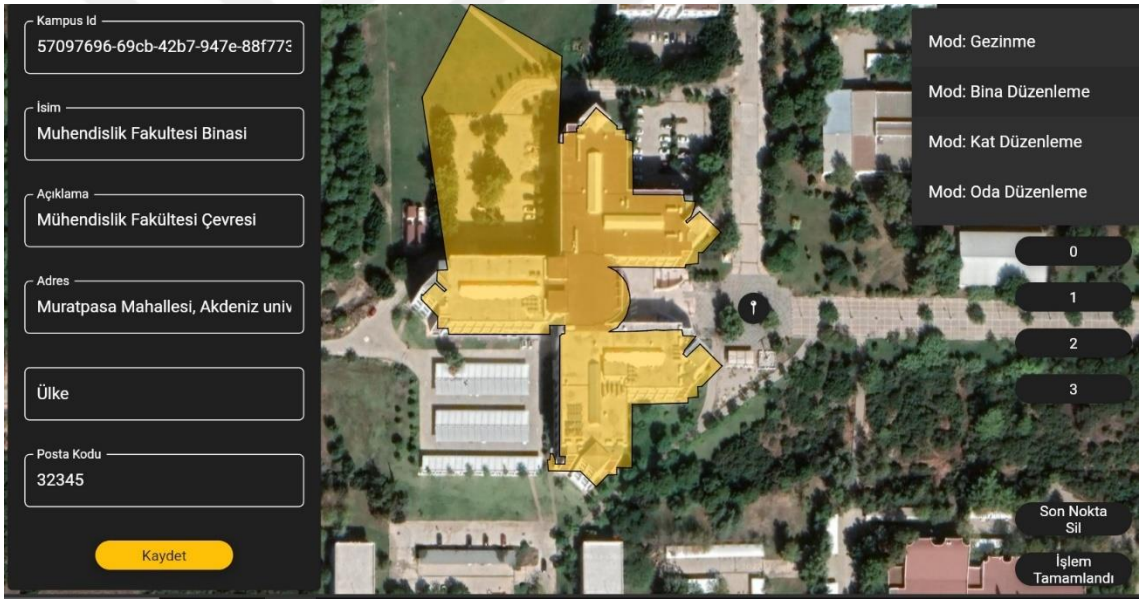
Çalışmada, Akdeniz Üniversitesi Mühendislik Fakültesi binası baz alınmıştır. Haritalama mimarisi genelden özele olacak şekilde bina, kat ve odalar olarak ifade edilmiştir. Mühendislik fakültesi binası içinde zemin kat dahilinde 5 kat bulunmakta ve her katta farklı sayıda oda ve koridor bulunmaktadır. Binanın her oda ve kat bilgisinin dahil olduğu bu bilgiler haritada anlamlı bir hale gelmek üzere GoogleMaps ve OpenStreetMap haritaları ve bir yazılım üzerinde gösterilmesi sağlandı.



Şekil 3.1. Harita üzerinde oda ve kat bilgilerinin gösterimi



Şekil 3.2. Uydu görüntüsü üzerinde oda ve kat bilgilerinin gösterimi

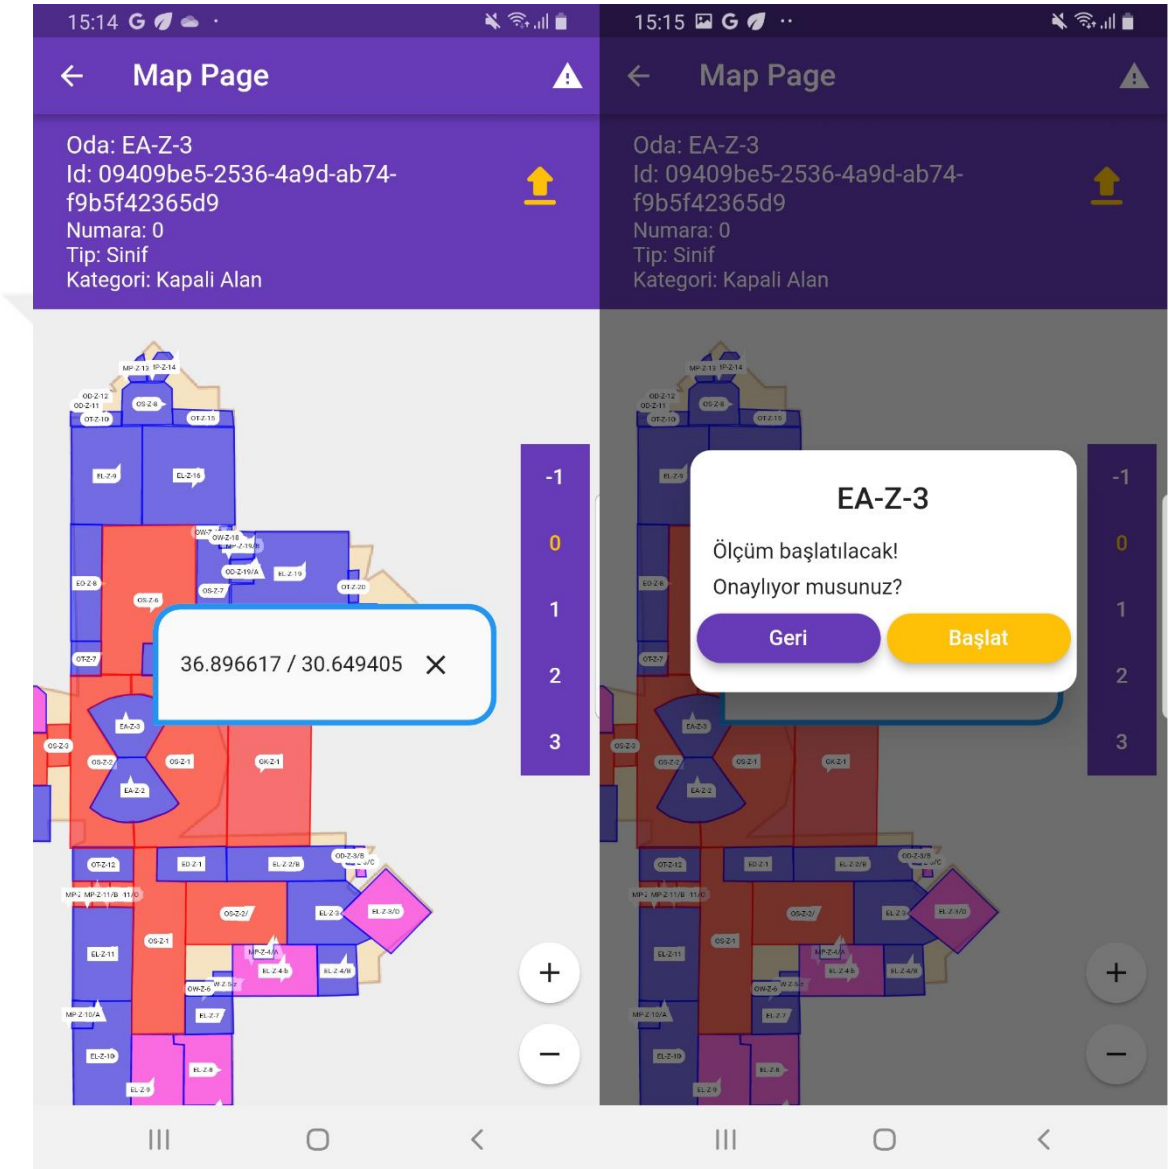


Şekil 3.3. Harita üzerinde oda ve kat bilgilerinin düzenlenmesinin gösterimi

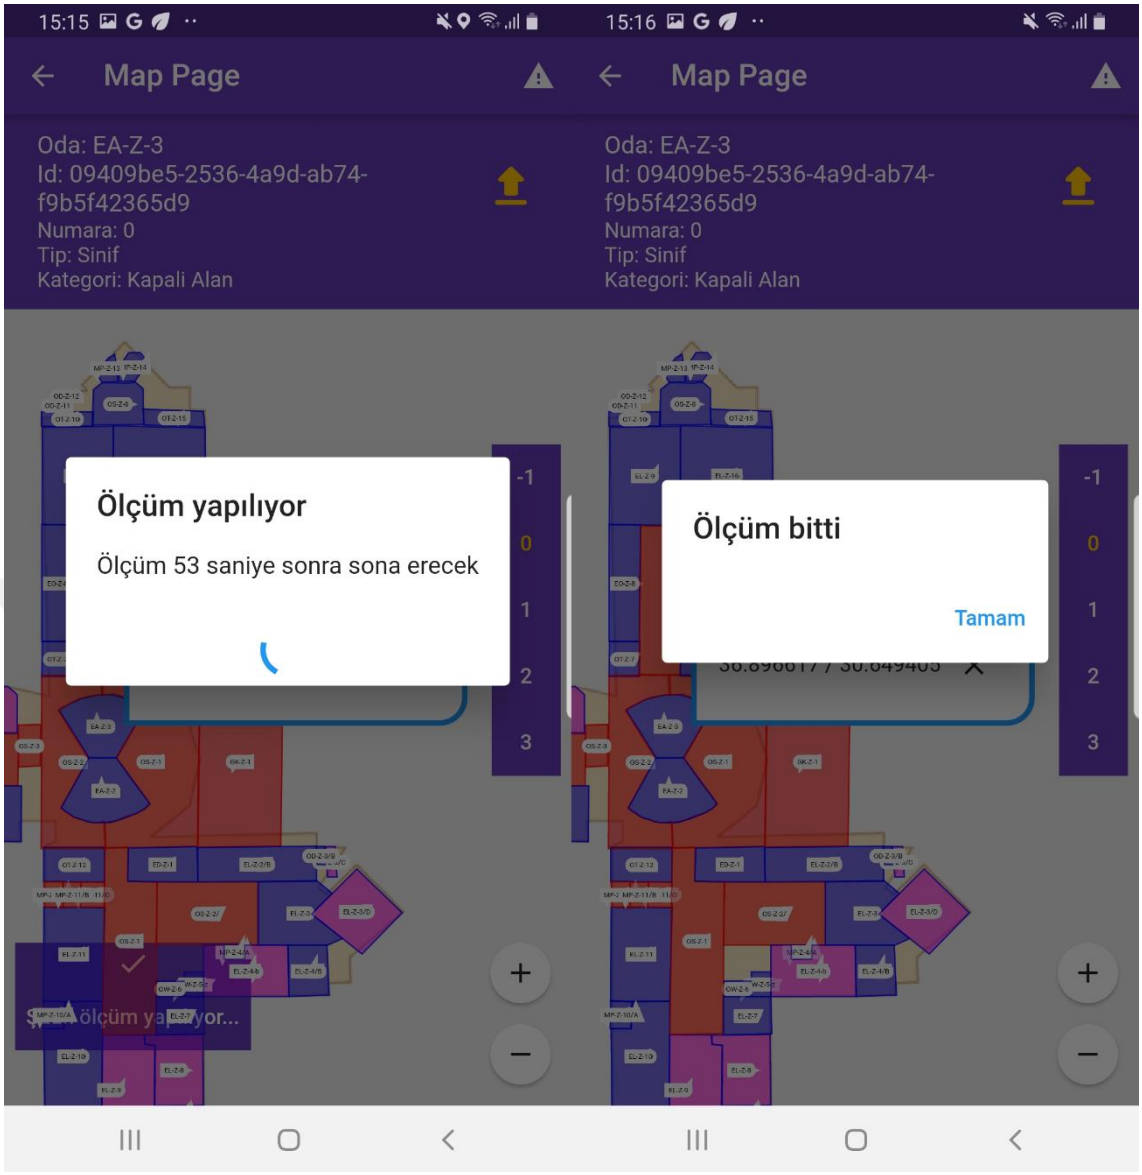
GoogleMaps OpenStreetMap ile her oda ve kat bilgisinin harita üzerinde görselleştirilmesini sağlayan harita çizim programı oluşturuldu. Bu web uygulaması yazılımı açıkça kat ve odaların harita üzerine iki boyutlu alanlar olarak ifadesini içermektedir. Bu odaların ve katların her bir tanesi bina planına bağlı kalarak gerçek konumlarında harita üzerinde iki boyutlu alanlar olarak görselleştirildi.

3.1.2. Mobil uygulama

Wi-Fi sinyallerinin akıllı telefonlar ile toplanması ve veri tabanında depolanarak lokalizasyon için kullanması amacıyla Android işletim sistemi için Flutter ortamında bir mobil uygulama geliştirildi. Geliştirilen uygulama ile erişim noktalarının Wi-Fi sinyalleri, MAC adresi bilgileri, mobil cihazın harita üzerindeki üç boyutlu koordinatları, ölçüm yapılan saat, kat ve oda bilgileri toplanabilmektedir.



Şekil 3.4. Mobil uygulamada veri toplamak üzere haritanın kat ve odaların gösterimi



Şekil 3.5. Mobil uygulamada veri toplama işlemi

3.1.3. Sunucu

Çalışmanın bu aşamasında toplanan verilerin veri tabanında kaydedilmesi hedeflenmiştir. Sunucu bilgisayar tarafı için katmanlı bir web servisleri sunan .NET Core uygulaması geliştirilmiştir. Akıllı bir telefonla toplanan Wi-Fi işaretleri ile seçili konum bilgisi verisinin http bağlantı protokolü ve json veri tipi ile sunucu bilgisayar tarafına aktarılması sağlanmıştır. Burada her bir ölçüm 60 saniyelik veri grupları olarak elde edildi. (Kul, Özyer, ve Tavli 2014; Paul ve Wan 2009; Tian vd. 2009) ve toplanan tüm Wi-Fi verileri http protokolü ve json veri tipi formatı ile sunucuya aktarıldı.

3.2. Veri Seti

Bu bölümde veri seti, destekleyici yazılım ve veri toplama aşaması açıklanmıştır.

Veri seti, veri işlemeyi kolaylaştırmak için "csv" dosyaları olarak sağlanır ve "csv" dosyalarını okumak için özel bir yazılım gerekmez. "csv" dosyası aşağıdaki sütunlardan oluşmaktadır:

1. Koordinatlar: Veri kümesindeki üç sütun, ölçümlerin yapıldığı sınıfların GPS koordinatlarını (enlem, boylam ve kat) gösterir. Örnek: veri kümesindeki bir ölçüm için:

$$(x, y, z) = (36.89672737982672, 30.649524638866378, 1) \quad (3.1)$$

2. RSSI ve Mac Adresi: Toplam ölçüm süresi boyunca görülen tüm MAC adresleri olarak 85 sütun vardır. Bu sütunlar sayısal ve alfabetik olarak sıralanmıştır. Her satırda o MAC adresine sahip Wi-Fi erişim noktasından alınan RSSI bilgisi veri setinde gösterilir. Her satır bir ölçüme karşılık gelir. Duyulmayan erişim noktaları 0 dBm olarak ayarlanmıştır. Örneğin, veri setinde, MAC adresi “x” olan Wi-Fi erişim noktası -66 dBm'de duyulmuştur. RSSI değerleri, her ölçümün zaman damgaları arasında enterpole edilir.

3. Zaman Damgası: Zaman damgası sütunu, UNIX zaman biçimindeki her ölçümün enterpolasyonlu zaman damgalarını temsil eder. Sağlanan zaman damgaları, her ölçümün başlangıç ve bitiş zamanları arasında bir mobil cihaza kaydedilir.

4. Oda: Oda sütunu, ölçümlerin yapıldığı odanın kimlik numarasını gösterir. Veri toplama işlemi Mühendislik Fakültesi binası dersliklerinde yapılmış olup, mobil uygulamada ölçümler alınmadan önce bu oda kimlik numaraları girilmiştir. Veri setinde toplam 20 derslik bulunmaktadır.

3.2.1. Sinyallerin toplanması

Sinyal toplama işleminin ilk aşaması, parmak izi tekniğinin çevrimdışı aşaması için gerekli olan verileri toplamak ve bu veriler ile konumlandırma yapılacak olan binanın üç boyutlu radyo haritasını oluşturmaktır. Parmak izi tekniğinin bir avantajı olarak bu çalışmada veri toplamak için radyo haritası oluşturulmak istenen binanın kurulu Wi-Fi cihazlarının oluşturduğu sinyaller kullanılmıştır. Ölçümler için Akdeniz Üniversitesi Mühendislik Fakültesi binası seçilmiştir ve binanın kat ve odalarının detaylı haritası çıkartılarak uygulamaya entegre edilmiştir. Veri toplama için kullanılan telefonun modeli, Android sürümü Android 7.1.2 olan Samsung Galaxy J200F'dir. Veri toplama sürecinde maksimum verim elde etmek için powerbank ile cihaz şarjı maksimumda tutulmuştur (Zhou vd. 2004). Mühendislik Fakültesi binasının tüm dersliklerinde birer dakikalık ölçümler yapılmıştır. Parmak izi tekniği doğrudan görüş (LoS) gerektirmediğinden ölçümler esnasında bu faktör dikkate alınmamıştır. Kullanılan mobil uygulamada öncelikle fakülte seçimi yapılmaktadır. Daha sonra fakültede birden fazla bina varsa bina seçimi yapılır ve sonrasında açılan ekranda kat seçimi yapılabilir. Seçilen kata göre binanın kat planı veri tabanından yüklenir. Ölçümü başlatmak için haritada çizilen alanlarda bir nokta seçilir. Üstte açılan pencerede oda id'si, oda tipi ve kategorisi görüntülenir. Bu pencerede sarı ok düğmesine basmak bir dakikalık ölçümü başlatır. Ölçümler veri tabanına kaydedilir.

3.2.2. Verilerin işlenmesi

Parmak izi tekniğinin çevrimdışı aşamasında toplanan veriler veri tabanına kaydedildi. Veri tabanında depolanan bu veriler pgAdmin4 yazılımı kullanılarak sorgu komutları ile seçildi ve “csv” dosyası formatına aktarıldı. Makine öğrenmesi modeli için girdi olarak RSSI değerleri kullanıldı ve oda sınıflandırma problemi için etiket olarak oda bilgisi tahmin edildi. Sınıflandırma problemi için etiketler dize olarak kaydedildiği için bu değerlerin nümerik değerlere dönüştürülmesi için çoklu etiket ikilileştirme tekniği kullanıldı ve ikilik tabanlı vektörlere dönüştürüldü. Etiket dizesindeki tüm karakterler bir ikili vektöre indislendi ve dizede mevcut olan karakterler vektörde 1, olmayan karakterler 0 olarak kodlandı. Verinin eğitim ve test kümelerine ayrılması esnasında test kümesi parmak izi tekniğinin çevrimiçi aşamasında kullanılacak veri olarak ayrıldı. Ölçümlerde erişilmeyen erişim noktalarının RSSI değerleri “-1000” olarak atandı. Ölçüm esnasında binadaki erişim noktalarının tam olarak yeri bilinmediği ve bir kısmı binadaki insanların mobil erişim noktaları olduğu için bir dakikalık ölçümler sonucunda 15 seferden az görülen Wi-Fi cihazları filtrelendi ve elde edilen nihai sonuç 85 Wi-Fi Erişim Noktası oldu. Verinin ön işlenmesi Google Colab ortamında, Python programlama dili kullanılarak gerçekleştirildi. Makine öğrenmesi modelleri aynı ortamda, scikit-learn modülü kullanılarak eğitildi.

Eksik zaman damgaları için Alınan Sinyal Gücü Göstergesi (RSSI) değerlerini oluşturmak amacıyla zaman damgası hizalamasına dayalı bir veri enterpolasyon tekniği

kullanıldı. Zaman damgalarına karşılık gelen RSSI değerlerini enterpolasyon yapmak için scipy kitaplığından PchipInterpolator kullanıldı. Shams ve diğerlerinin yaptığı çalışmada PCHIP enterpolasyonunun daha iyi performans verdiği görülmektedir (Bin Shams vd. 2016). Enterpolasyon sonuçları, orijinal veri kümesindeki zaman damgaları ve karşılık gelen RSSI değerleri kullanılarak oluşturuldu.

3.3. Sürü Algoritmaları Kullanılarak Makine Öğrenmesi Algoritmalarında Optimum Hiper Parametrelerin Tespiti

Bu çalışmada, Parçacık Sürü Optimizasyon algoritması (Lorenzo, Nalepa, Kawulok, vd. 2017) ve Balina Optimizasyon Algoritması diğer sürü optimizasyonu algoritmalarına kıyasla lokal minimallerden kurtulma becerisi, keşfetme ve yakınsama davranışı bakımından öne çıkmaları sebebiyle tercih edildi (Mohammed, Umar, ve Rashid 2019).

Çalışmanın ilk aşamasında oda sınıflandırması işlemi makine öğrenmesi algoritmaları kullanılarak gerçekleştirildi. Verinin tamamı kullanıldığında oda sınıflandırması yüzde yüz doğruluk, kesinlik ve duyarlılık ile gerçekleştirildi. Hangi makine öğrenmesi algoritmalarının daha başarılı performans gösterdiğini tespit etmek için algoritmaların performansı daha az erişim noktası (5, 10, 15) ile test edildi. İkinci aşamada, ilk aşamada test edilen üç algoritma üzerinde sürü optimizasyonu algoritmaları kullanılarak hiper parametre uzayında optimum hiper parametreler bulunarak makine öğrenmesi algoritmalarının performans artırımı sağlandı.

3.3.1. Parçacık sürü optimizasyon algoritması ile hiper parametre seçimi

Bu çalışmada sürü optimizasyon algoritması hiper parametre seçme amaçlı kullanılmıştır. Amaç, doğruluk değerlendirme ölçütüyle ölçüldüğü şekliyle, en iyi model performansına yol açan en uygun hiper parametre kombinasyonunu bulmaktır. PSO algoritmasındaki her parçacık, makine öğrenimi modeli için potansiyel bir hiper parametre kombinasyonunu temsil eder. Hiper parametreler, parçacığın arama uzayındaki konumu olarak kodlanır. Her yinelemede, parçacıklar hızlarını mevcut hızlarına, kişisel en iyi konumlarına (parçacık tarafından şimdiye kadar bulunan en iyi hiper parametre konfigürasyonu) ve genel en iyi pozisyona (sürüdeki herhangi bir parçacık tarafından bulunan en iyi hiper parametre konfigürasyonu) göre günceller. Yeni hız, parçacığın hareketinin yönünü ve büyüklüğünü belirler. Her parçacığın konumu daha sonra mevcut konumu ve hızına göre güncellenir. Hiper parametreler için arama alanı, her bir hiper parametrenin alabileceği aralık veya değerler belirtilerek tanımlanır. PSO algoritması tarafından keşfedilebilen tüm olası hiper parametre kombinasyonlarını kapsar. PSO algoritması ilk aşamada bir parçacık sürüsünü tanımlayarak başlar. Sürüdeki parçacıkların sayısı, problemin karmaşıklığına ve mevcut hesaplama kaynaklarına göre belirlenir. Her parçacığın konumu, tanımlanmış arama alanı içinde rastgele başlatılır. Her parçacık için makine öğrenimi modeli, karşılık gelen hiper parametre kombinasyonu kullanılarak eğitilir. Modelin performansı daha sonra

doğruluk kriteri kullanılarak değerlendirilir. Başlangıçta, her bir parçacığın kişisel en iyi konumu ve uygunluk değeri, sırasıyla mevcut konumlarına ve karşılık gelen değerlendirme metrik değerine ayarlanır. Sürüdeki tüm parçacıklar arasında en iyi uygunluk değerine sahip parçacık, küresel en iyi parçacık olarak tanımlanır. Konumu ve uygunluk değeri, sırasıyla global en iyi konum ve uygunluk değeri olarak atanır. PSO algoritması, arama alanını verimli bir şekilde keşfetmek için parçacıkların konumlarını ve hızlarını yinelemeli olarak günceller. Her parçacık hızını mevcut hızına, kişisel en iyi konumuna ve küresel en iyi konumuna göre günceller. Yeni hız, parçacığın bireysel deneyimini ve küresel en iyi konumu dengeleyen bir hız güncelleme denklemi kullanılarak belirlenir. Bu formül aşağıda verilmiştir:

$$V_i(t+1) = w * V_i(\mathrm{t}) + \mathrm{c1} * \mathrm{r1}\left(pbest_i - x_i(\mathrm{t})\right) + \mathrm{c2} * \mathrm{r2} * \left(\mathrm{gbest} - x_i(\mathrm{t})\right) \qquad (3.2)$$

Burada V_i (t+1), i parçacığının t+1 zamanındaki yeni hızıdır,

w önceki hızın etkisini belirleyen atalet ağırlığıdır,

V_i (t), i parçacığının t zamanındaki mevcut hızıdır,

c1 ve c2 sırasıyla kişisel en iyi ve genel en iyi için ivme katsayılarıdır,

r1 ve r2, [0,1] aralığında rastgele değerlerdir,

$pbest_i$, i parçacığının kişisel en iyi konumudur ve

x_i(t), i parçacığının t zamanındaki mevcut konumudur.

Her parçacığın konumu, mevcut konumuna ve yeni hesaplanan hızına göre güncellenir. Konum güncelleme denklemi, arama uzayındaki yeni konumu belirler. Bu formül aşağıda verilmiştir:

$$x_i(\mathrm{t}+1) = x_i(\mathrm{t}) + v_i(\mathrm{t}+1) \qquad (3.3)$$

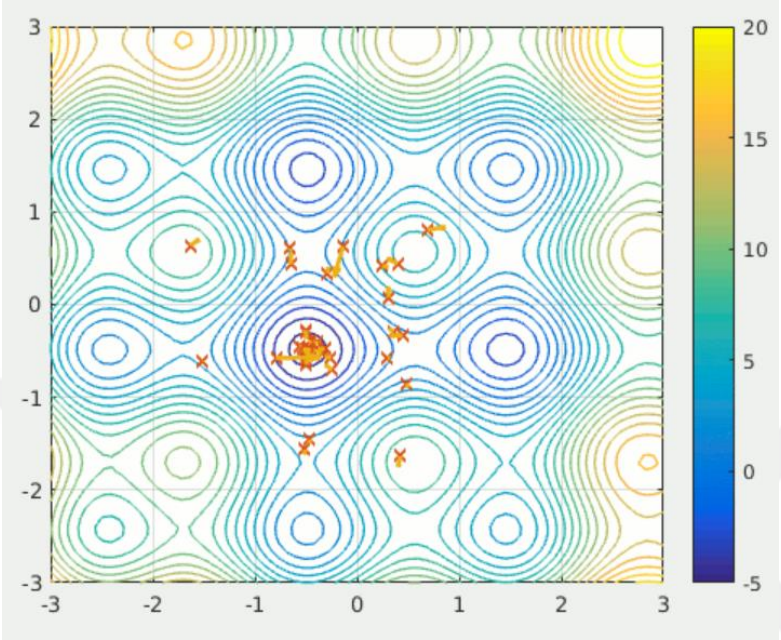
Burada x_i (t+1), i parçacığının t+1 zamanındaki yeni konumudur,

x_i(t), i parçacığının t zamanındaki mevcut konumudur ve

v_i(t+1), i parçacığının t+1 zamanındaki yeni hızıdır.

Konumları güncelledikten sonra makine öğrenimi modeli, her bir parçacığın yeni konumu tarafından temsil edilen hiper parametre yapılandırması kullanılarak eğitilir ve değerlendirilir. Değerlendirme metrikleri, her parçacığın uygunluk değerini belirlemek için hesaplanır. Bir parçacığın yeni konumu, mevcut kişisel en iyi uygunluğundan daha iyi bir uygunluk değerine yol açarsa, kişisel en iyi konumu ve uygunluğu güncellenir. Benzer şekilde, bir parçacığın yeni konumu mevcut küresel en iyi uygunluktan daha iyi bir uygunluk değeri verirse, küresel en iyi konum ve uygunluk güncellenir. PSO algoritması yinelemelerini tamamladıktan sonra, global en iyi konuma karşılık gelen

hiper parametre konfigürasyonu, hiper parametrelerin en iyi kombinasyonu olarak tanımlanır. En iyi hiper parametre yapılandırması, nihai bir makine öğrenimi modelini eğitmek için uygulanır. Bu modelin performansı, gerçek dünya senaryolarındaki etkinliğini değerlendirmek için bağımsız bir test veri seti kullanılarak değerlendirilir.



Şekil 3.6. Parçacık sürü optimizasyonu yerel minimum simüle gösterimi

3.3.2. Balina optimizasyon algoritması ile hiper parametre seçimi

Bu çalışmada Balina Optimizasyon Algoritmasını (WOA) kullanmanın birincil amacı, belirli bir makine öğrenimi modeli için en uygun hiper parametre yapılandırmasını keşfetmektir. WOA algoritması bağlamında, her balina, makine öğrenimi modeli için potansiyel bir hiper parametre kombinasyonunu temsil eder. Hiper parametrelerin kendileri, balinanın arama alanı içindeki konumu olarak kodlanır. WOA algoritması, avı çevreleme ve balon ağıyla besleme olmak üzere iki temel mekanizmadan yararlanır. Avı çevreleme, potansiyel optimal çözümü kapsayarak arama uzayının keşfedilmesini sağlar. Tersine, balon ağıyla besleme çevrelenen bölge içindeki yerel en iyi çözümlerden yararlanmaya odaklanır. Hiper parametre arama alanı, WOA algoritmasının keşfedebileceği tüm kombinasyonları kapsayan, her bir hiper parametre için izin verilen aralık veya değerler belirtilerek tanımlanır. Balina sayısı problemin karmaşıklığına ve mevcut hesaplama kaynaklarına göre belirlenir Belirli bir hiper parametre konfigürasyonunu temsil eden her balinanın konumu, belirlenmiş arama alanı içinde rastgele başlatılır. Makine öğrenimi modeli her balina için karşılık gelen hiper parametre kombinasyonuyla eğitilir ve doğruluk metriği ile performans ölçülür. Başlangıçta, tüm popülasyon arasında en iyi uygunluk değerini sergileyen balina, küresel en iyi balina olarak tanımlanır. O ana kadar keşfedilen en başarılı hiper parametre kombinasyonunu yansıtan konumu ve uygunluk değeri, sırasıyla küresel en

iyi konum ve uygunluk değeri olarak atanır. WOA algoritması, arama alanını verimli bir şekilde keşfetmek için balinaların konumlarını yinelemeli olarak günceller. Avı çevreleme aşamasında, her balina konumunu küresel en iyi konuma doğru ayarlayarak günceller. Yeni konum aşağıdaki denklem kullanılarak belirlenir:

$$x_{new} = x_{gbest} - A * D \quad (3.4)$$

Burada x_{new} ,balinanın yeni konumudur.

x_{gbest}, küresel en iyi konumdur.

A, çevreleme davranışını kontrol eden katsayıdır (tipik olarak yinelemelerle doğrusal olarak azalır).

D, balinanın mevcut konumu ile küresel en iyi konum arasındaki mesafedir.

Balon ağıyla besleme aşamasında balinalar, çevrelerindeki yerel en iyi çözümleri keşfederek konumlarını günceller. Yeni konumlar aşağıdaki denklem kullanılarak hesaplanır:

$$x_{new} = x_{localbest} + \mathrm{A} * \mathrm{C} \quad (3.5)$$

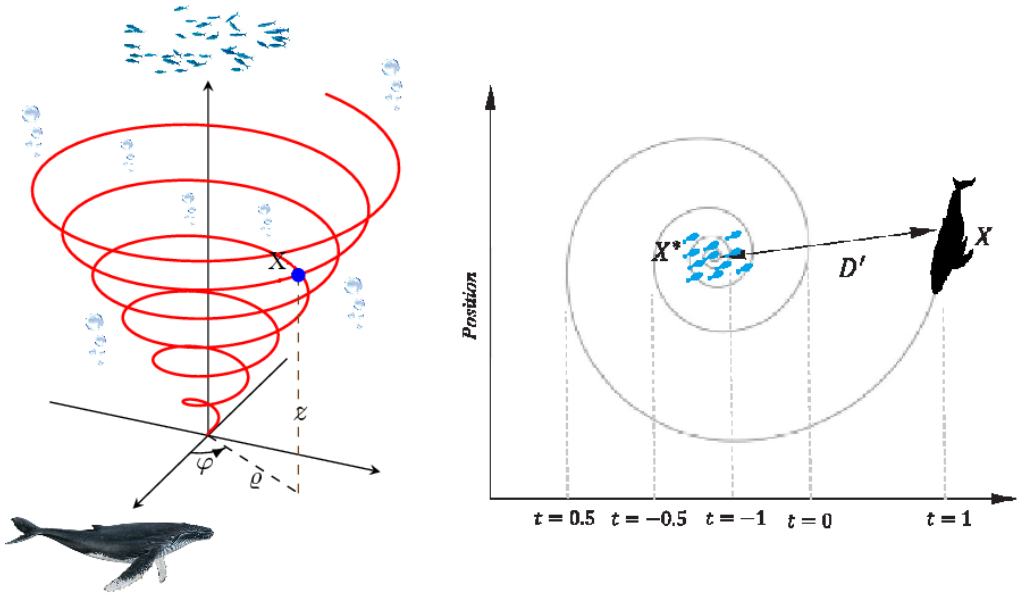
Burada x_{new}, balinanın yeni konumudur,

$x_{localbest}$, balinanın çevresindeki en iyi yerel konumdur.

A, keşif davranışını kontrol eden katsayıdır (tipik olarak yinelemelerle doğrusal olarak azalır).

C, [-1, 1]'de rastgele bir vektördür.

Konum güncellemelerinin ardından, makine öğrenimi modeli, balinaların yeni konumlarıyla temsil edilen hiper parametre kombinasyonları kullanılarak eğitim ve değerlendirmeye tabi tutulur. Doğruluk metriği, her balina için uygunluk değerini hesaplamak için kullanılır. Bir balinanın yeni konumunun, mevcut küresel en iyi uygunluk değerine kıyasla daha üstün bir uygunluk değeri vermesi durumunda, küresel en iyi konum ve uygunluk değeri buna göre güncellenir. WOA algoritmasındaki yinelemelerin tamamlanmasının ardından, global en iyi konuma karşılık gelen hiper parametre kombinasyonu, hiper parametrelerin optimal kombinasyonu olarak belirlenir. Bu optimum kombinasyon, nihai bir makine öğrenimi modelini eğitmek için kullanılır. Modelin performansı daha sonra, gerçek dünya senaryolarındaki etkinliğini ölçmek için bağımsız bir test veri seti kullanılarak değerlendirilir.



Şekil 3.7. Balina optimizasyon algoritması temel prensibi

$$X(t+1) = D' * e^{b}t * cos(2\pi t) + X^{*}(t) \tag{3.6}$$

3.4. Metrikler

3.4.1. Doğruluk

Doğruluk, bir sınıflandırma modelinin veri noktalarının etiketlerini veya sınıflarını ne kadar doğru tahmin ettiğinin bir ölçüsüdür. Doğru tahmin sayısının toplam tahmin sayısına oranı olarak hesaplanır. Doğruluk, modelin performansının genel bir görünümünü verir.

$$Doğruluk = \frac{\text{(Doğru Tahmin Sayısı)}}{\text{(Toplam Tahmin Sayısı)}} \tag{3.7}$$

3.4.2. Kesinlik

Kesinlik, olumlu olarak tahmin edilen örneklerden kaçının gerçekte doğru pozitif olduğunun bir ölçüsüdür. Olumlu tahminlerin kalitesine odaklanır. Kesinlik, gerçek pozitiflerin (doğru tahmin edilen pozitif durumlar) gerçek pozitifler ve yanlış pozitiflerin (yanlış tahmin edilen pozitif durumlar) toplamına oranı olarak hesaplanır.

$$Kesinlik = \frac{\text{(Gerçek Pozitifler)}}{\text{(Gerçek Pozitifler+Yanlış Pozitifler)}} \tag{3.8}$$

3.4.2. Duyarlılık

Hassasiyet veya gerçek pozitif oran olarak da bilinen duyarlılık, bir modelin tüm pozitif örnekleri ne kadar iyi yakaladığının bir ölçüsüdür. Modelin tüm olumlu örnekleri

bulma yeteneğine odaklanır. Duyarlılık, gerçek pozitiflerin gerçek pozitiflerin ve yanlış negatiflerin toplamına oranı olarak hesaplanır.

$$Duyarlılık = \frac{(\text{Gerçek Pozitifler})}{(\text{Gerçek Pozitifler+Yanlış Negatifler})} \quad (3.9)$$

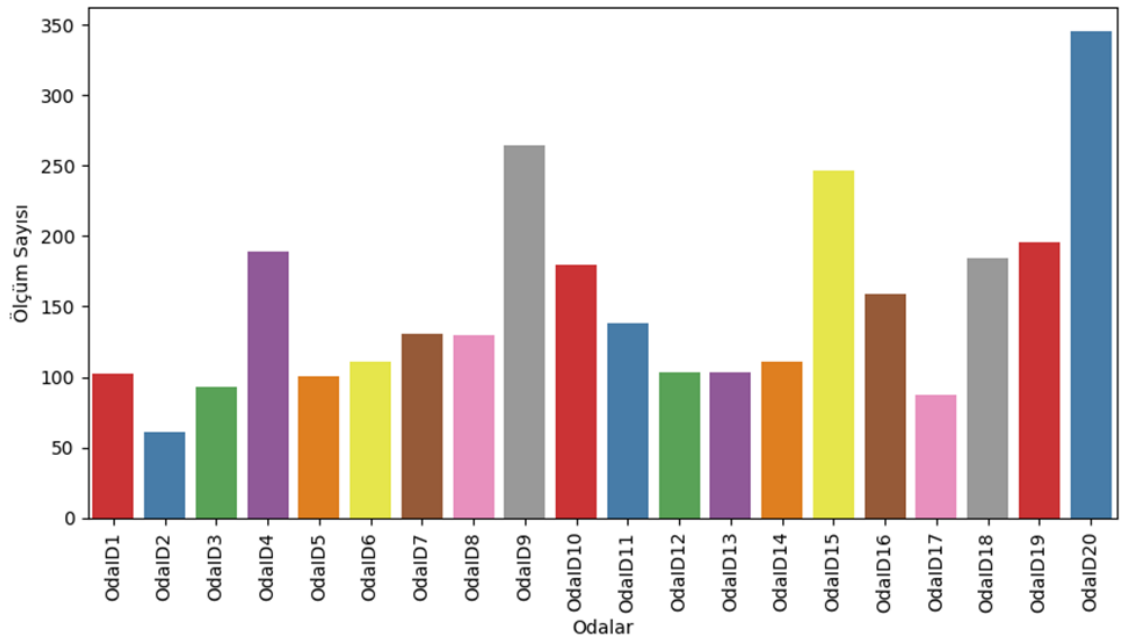
İnterpolasyon, matematik ve bilgisayar bilimlerinde sıklıkla kullanılan bir tekniktir. Temel olarak, bilinen veriler arasındaki noktalar arasında yeni noktaların tahmin edilmesi için kullanılır. Bir fonksiyonun veya veri setinin eksik veya bilinmeyen değerlerini tahmin etmek için kullanılan bu yöntem, verilerin düzgün bir şekilde takip ettiği bir modelin var olduğunu varsayar.

İnterpolasyon, birçok farklı algoritma ve yöntem içerir. En basit ve yaygın yöntemlerden biri doğrusal interpolasyondur. Doğrusal interpolasyonda, iki bilinen nokta arasındaki çizgiyi kullanarak yeni bir noktanın değerini tahmin ederiz. Daha karmaşık interpolasyon yöntemleri, polinomlar veya spline fonksiyonları kullanarak daha hassas tahminler yapabilir. Bu yöntemler, verilerin daha karmaşık desenlere veya eğrilere sahip olduğu durumlarda kullanılır.

İnterpolasyon, veri analizi, grafik oluşturma, bilgisayar grafikleri ve görüntü işleme gibi birçok alanda yaygın olarak kullanılan bir tekniktir. Ancak, interpolasyonun bazen verilerin dışında yanıltıcı sonuçlar verebileceği ve dikkatli bir şekilde kullanılması gerektiği unutulmamalıdır.

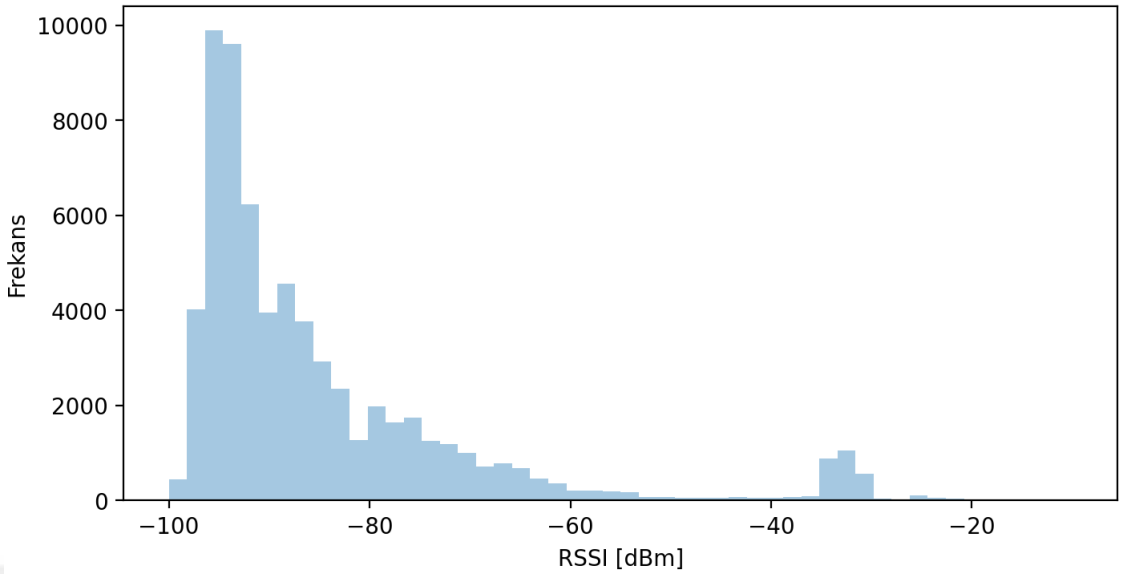
4. BULGULAR VE TARTIŞMA

20 odada yapılmış olan 3034 RSSI ölçümünün odalara göre dağılımı Şekil 4.1'de gösterildi. Ölçüm yapılan oda sayısı 20, odalarda ortalama ölçüm sayısı 152'dir. Bir odada alınmış en yüksek ölçüm 345, en az ise 61 ölçümdür.



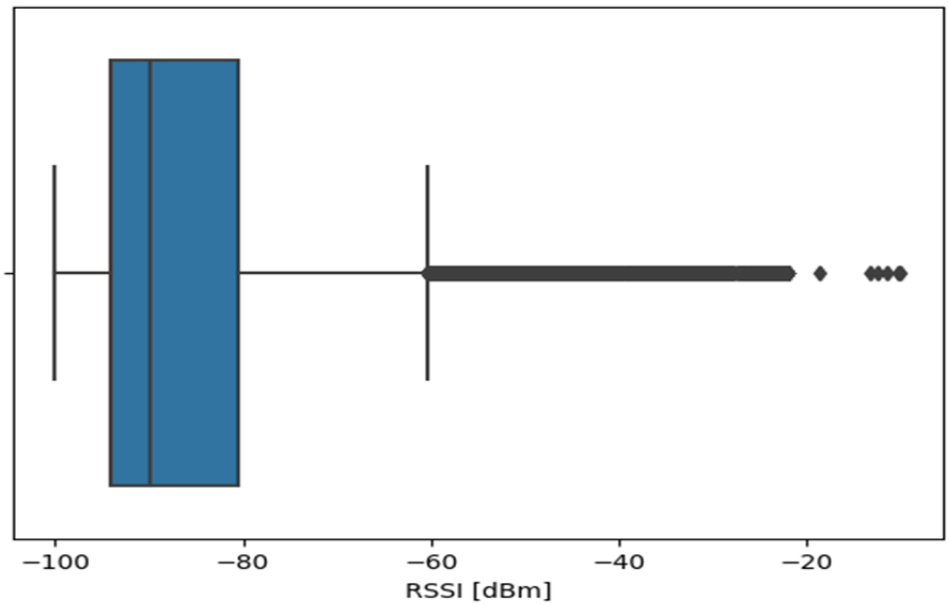
Şekil 4.1. Odalarda algılanan ölçüm sayıları

Toplam algılanan RSSI değeri sayısı 65125, ölçüm esnasında görülmeyen erişim noktalarının değerlerini -1000 olarak atandığı var sayıldığında bu sayı 257890 olarak görüldü. Şekil 4.2'de ölçüm yapılan binadaki RSSI dağılımı görülmektedir. Bu şekilden anlaşıldığı üzere, RSSI dağılımı sola çarpık olarak görülmektedir. Ölçümlerin büyük çoğunluğu -100 dBm ve -80 dBm aralığında olmakla birlikte, -60 dBm ve -20 dBm aralığındaki değerler aykırı değerler olarak görülmektedir.



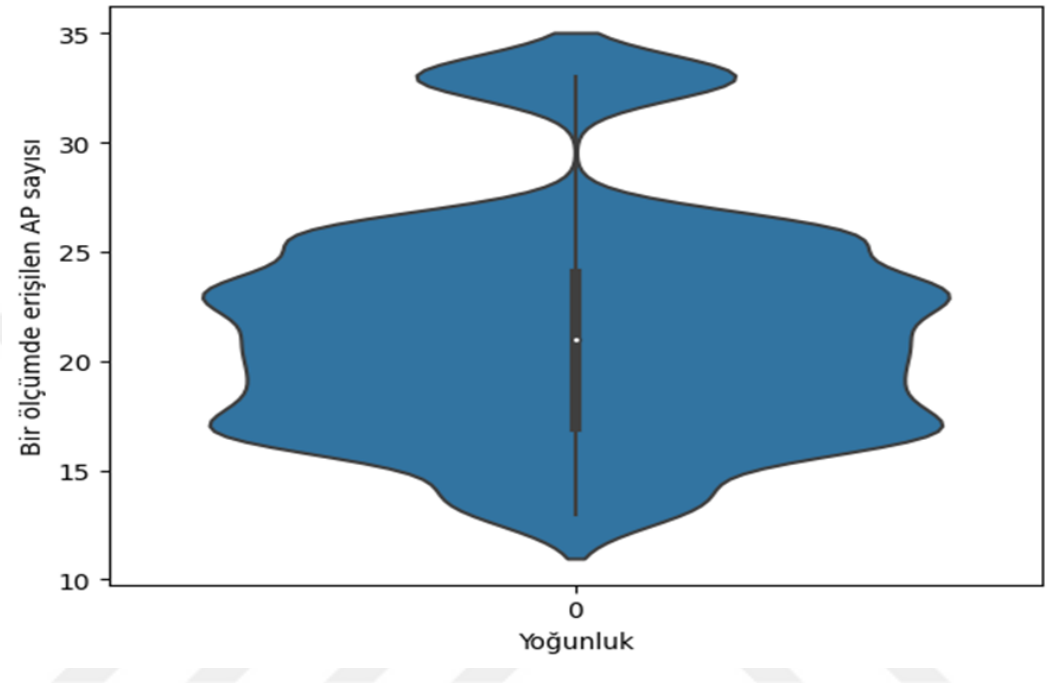
Şekil 4.2. Tüm binadaki ölçümlerin RSSI dağılımı.

Şekil 4.3'te ölçümlerin kutu grafiği görülmektedir. Bu kutu grafiğe göre RSSI değerlerinin ortalaması-84.61 dBm, verinin standart sapması 15.004392 olarak bulundu. Ölçülen en düşük RSSI değeri -100 dBm, en yüksek-9.99 dBm'dir. Q1 yani ilk çeyrek, verilerin %25'inin altına düştüğü değeri temsil eder, bu değer -94 dBm'dir. Q2 yani ikinci çeyrek, artan düzende sıralandığında veri kümesinin ortadaki değerini temsil eder. Buna göre verilerin %50'si -90 dBm'in altına düştüğü görülmektedir. Q3 yani üçüncü çeyrek, verilerin %75'inin altına düştüğü değeri temsil eder ve bu değer-80.55 dBm olarak bulundu. -60 dBm ve aşağısındaki değerler ayrık değerler olarak görülmektedir.



Şekil 4.3. RSSI ölçümlerinin kutu grafiği.

Şekil 4.4, bir ölçümde erişilen erişim noktalarının keman grafiğini göstermektedir. Bu grafiğe göre, bir ölçümde ortalama erişilen erişim noktası sayısı yaklaşık 21, verinin standart sapması 5.042477 olarak bulundu. Bir ölçümde en az 13, en fazla 33 erişim noktası görüldü. İlk çeyrek bilgisine göre ölçümlerin %25'inde 17 ve altında erişim noktası, ikinci çeyrek bilgisine göre ölçümlerin %50'sinde 21 ve altında erişim noktası, %75'inde ise 24 ve altında erişim noktası görüldü.

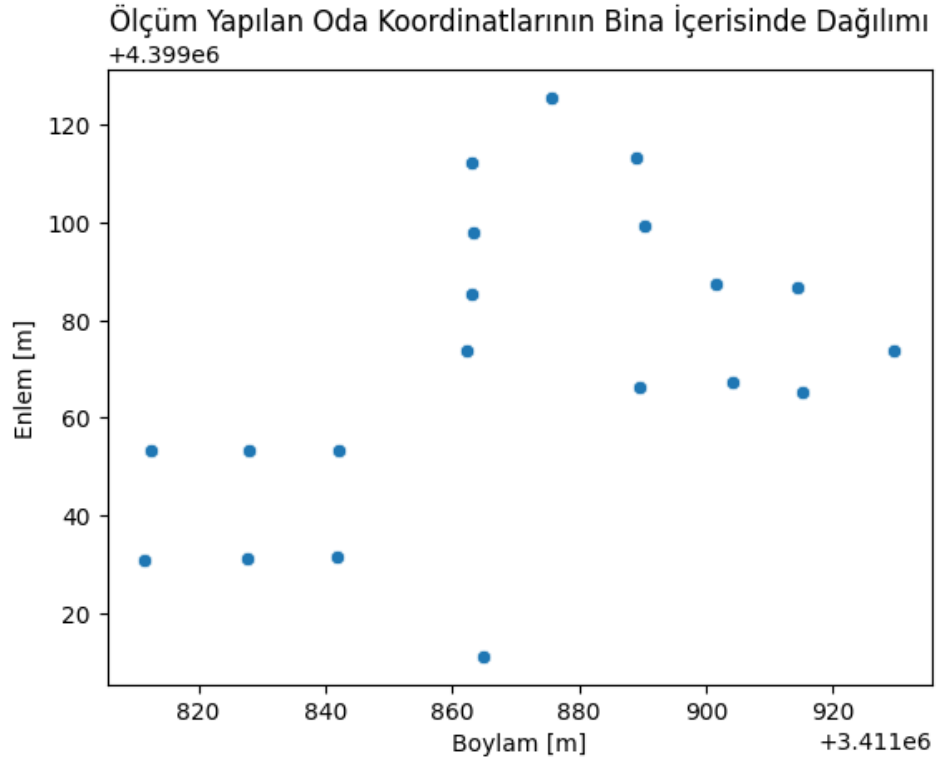


Şekil 4.4. Bir ölçümde görülen erişim noktası sayısının keman grafiği.

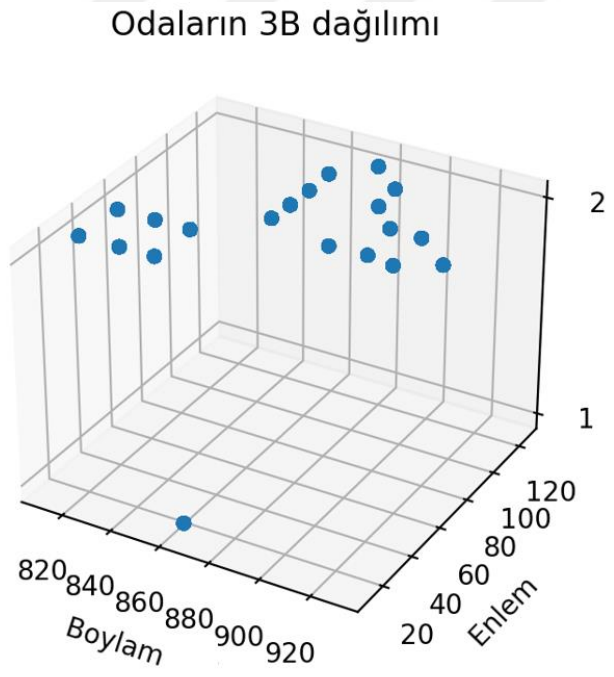
Veri setinin tamamına makine öğrenmesi algoritmaları uygulanması sonucunda elde edilen oda sınıflandırması sonuçları Çizelge 4.1'de gösterilmektedir.

Çizelge 4.1. Veri setinin tamamına uygulanan makine öğrenmesi algoritması sonuçları

Algoritma	**Doğruluk**	**Kesinlik**	**Duyarlılık**
K- En Yakın Komşu	1.00	1.00	1.00
Rastgele Orman	1.00	1.00	1.00
Karar Ağacı	1.00	1.00	1.00



Şekil 4.5. Ölçüm yapılan odaların bina içinde dağılımı



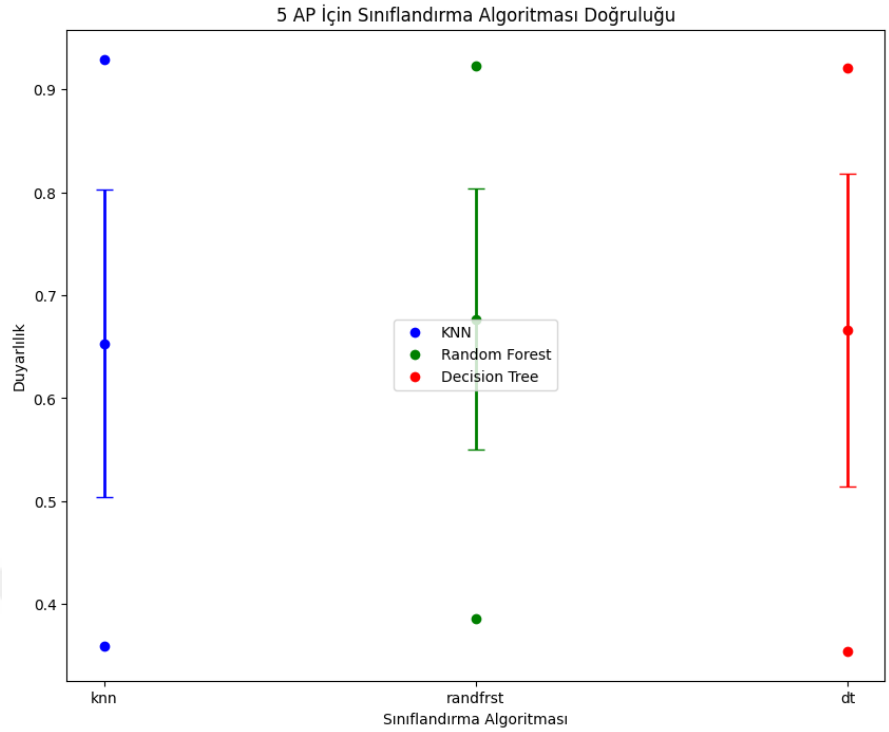
Şekil 4.6. Ölçüm yapılan odaların bina içinde 3 boyutlu dağılımı

Elde edilen %100 sınıflandırma başarısı sonucunda, algoritmaların performanslarını ölçmek için veri setinden rastgele 50 kez, sırasıyla 5, 10, 15 özellik (mac adresi ve karşılık gelen RSSI bilgisi) seçildi ve doğruluk, kesinlik ve duyarlılık ölçümleri, standart sapma, en düşük ve en yüksek değer bilgileri kaydedildi.

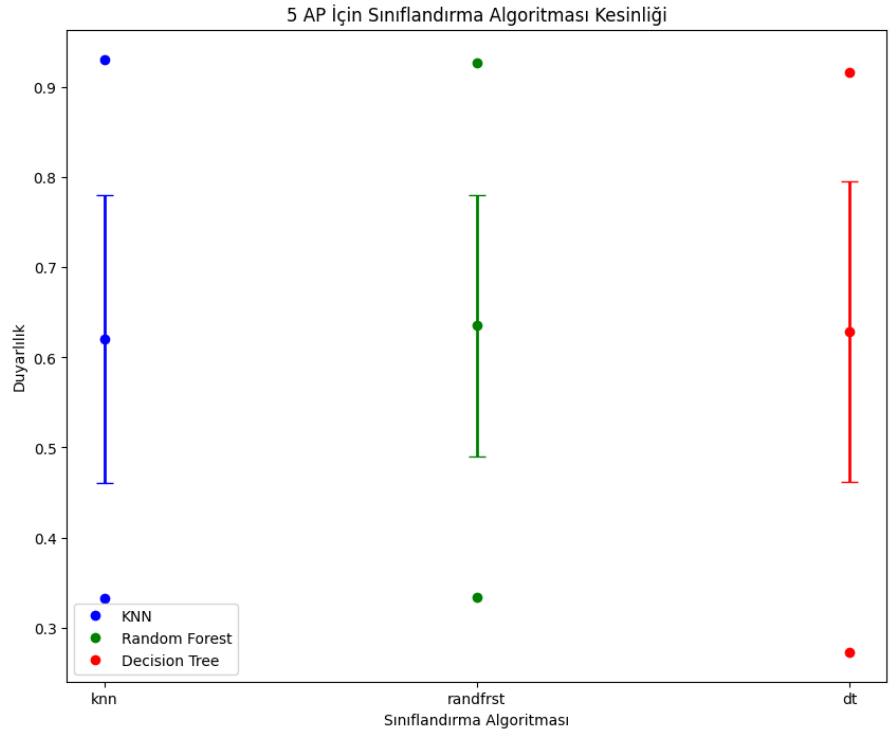
5 erişim noktası için algoritmaların doğruluk, kesinlik ve duyarlılık değerleri Çizelge 4.2'de gösterilmektedir. K- En Yakın Komşu algoritması için elde edilen ortalama doğruluk, kesinlik ve duyarlılık değerleri sırasıyla, 0.652982, 0.620668, 0.652982, standart sapmaları sırasıyla 0.149502, 0.159802, 0.149502 olarak bulundu. Rastgele Orman algoritması için ortalama doğruluk, kesinlik ve duyarlılık değerleri sırasıyla 0.676409, 0.634857, 0. 676409, standart sapmaları sırasıyla 0.126768, 0.144794, 0.126768 olarak bulundu. Karar Ağacı algoritması için ortalama doğruluk, kesinlik ve duyarlılık değerleri sırasıyla 0.665997, 0.628936, 0.665997, standart sapmaları sırasıyla 0.151875, 0166374, 0.151875 olarak bulundu. Bu değerler Şekil 4.7, Şekil 4.8 ve Şekil 4.9'de çizdirilmiştir. Elde edilen bu sonuçlar Rastgele Orman algoritmasının en iyi sonuçları verdiğini göstermektedir.

Çizelge 4.2. 5 erişim noktası için makine öğrenmesi modelleri en yüksek ve en düşük doğruluk, kesinlik ve duyarlılık sonuçları

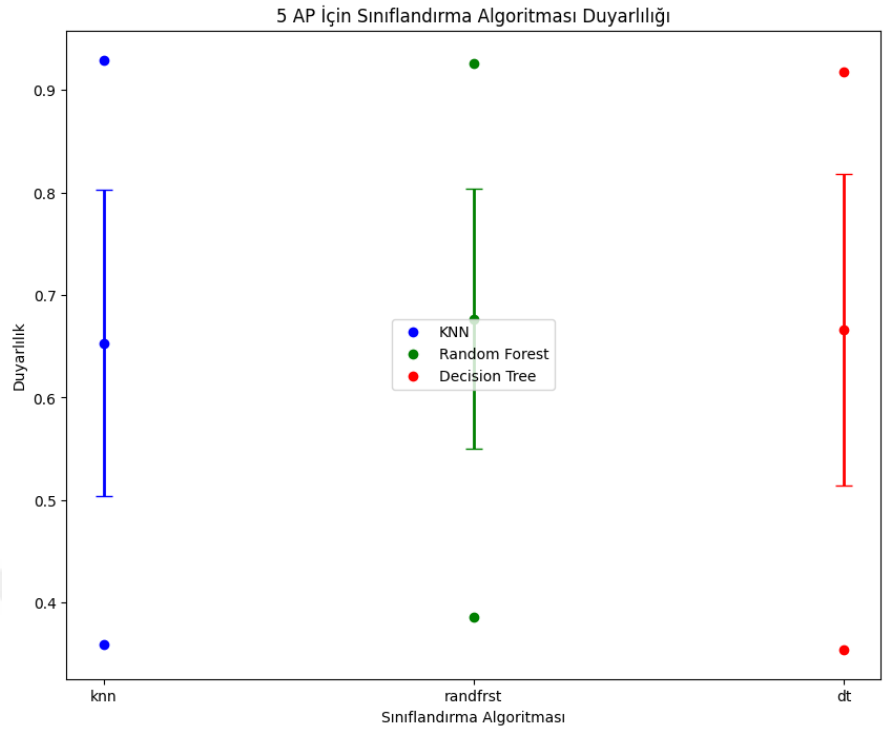
Algoritma	**Doğruluk**		**Kesinlik**		**Duyarlılık**	
	En Yüksek	En Düşük	En Yüksek	En Düşük	En Yüksek	En Düşük
K-NN	0.929160	0.359143	0.9311008	0.333028	0.929160	0.359143
RF	0.922570	0.385502	0.923452	0.333805	0.922570	0.385502
DT	0.920923	0.354201	0.919682	0.274721	0.920923	0.354201



Şekil 4.7. 5 Erişim noktası (AP) için sınıflandırma algoritmalarının doğruluk değerleri ve standart sapmaları



Şekil 4.8. 5 Erişim noktası (AP) için sınıflandırma algoritmalarının kesinlik değerleri ve standart sapmaları



Şekil 4.9. 5 Erişim noktası (AP) için sınıflandırma algoritmalarının duyarlılık değerleri ve standart sapmaları

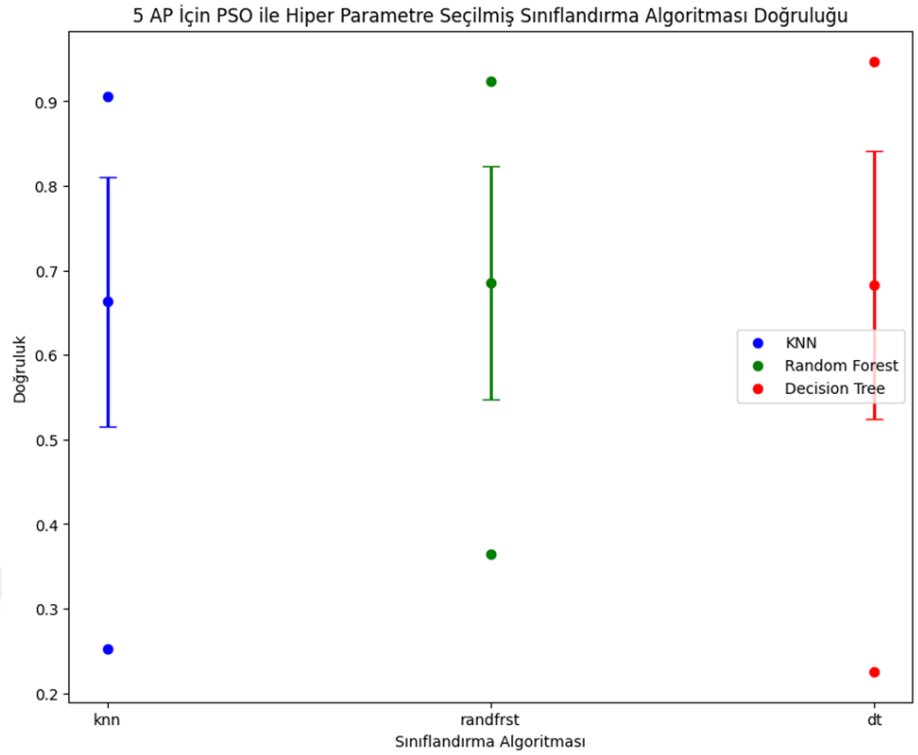
Çizelge 4.3'te 5 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modellerinin sonuçları gösterildi. K- En Yakın Komşu algoritması için elde edilen ortalama doğruluk, kesinlik ve duyarlılık değerleri sırasıyla 0.658089, 0.636742, 0.658089, standart sapmaları sırasıyla 0.146840, 0.159361, 0.146840 olarak bulundu. Rastgele Orman algoritması için ortalama doğruluk, kesinlik ve duyarlılık değerleri sırasıyla, 0.687150, 0.643326, 0.687150, standart sapmaları 0.138616, 0.160247, 0.138616 olarak bulundu. Karar Ağacı algoritmaları 0.691269, 0.651544, 0.691269, standart sapmaları 0.155691, 0.183319, 0.155691 olarak bulundu. Bu değerler Şekil 4.10, Şekil 4.11 ve Şekil 4.12'da çizdirildi. PSO algoritması sonucunda elde edilen optimum hiper parametreler Çizelge 4.4'te verilmektedir. PSO algoritması sonucunda makine öğrenmesi modellerinin performansının arttığı gözlemlenmekle birlikte, Karar Ağacı algoritmasının en iyi performansı gösterdiği görülmektedir. K-NN algoritmasının standart sapmaları düşerken, diğer iki algoritmanın standart sapmasının arttığı gözlemlenmektedir.

Çizelge 4.3. 5 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri en yüksek ve en düşük doğruluk, kesinlik ve duyarlılık sonuçları

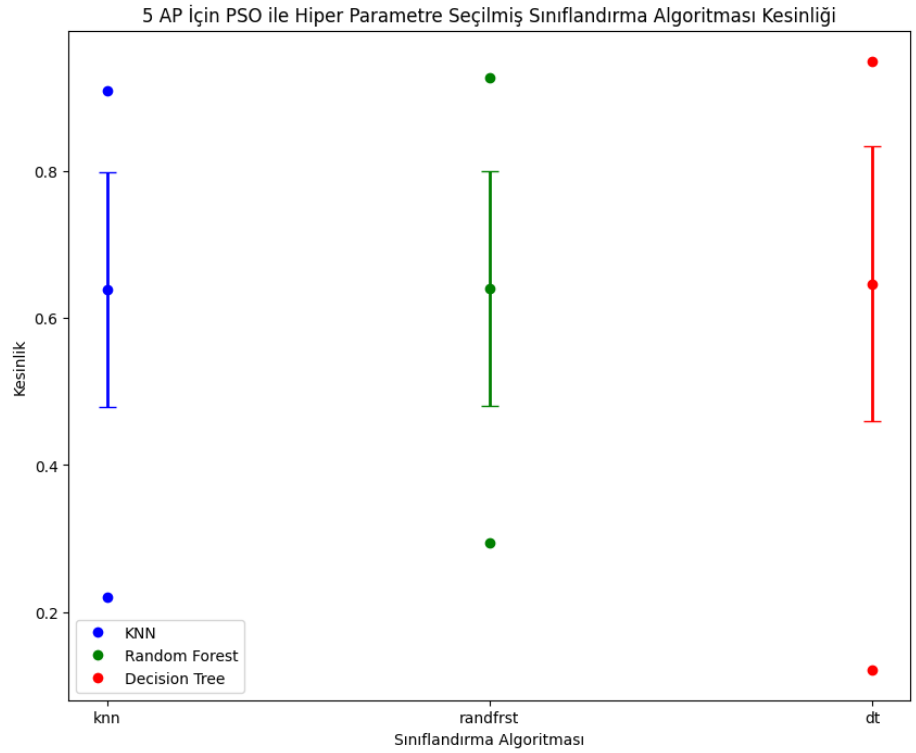
Algoritma	**Doğruluk**		**Kesinlik**		**Duyarlılık**	
	En Yüksek	En Düşük	En Yüksek	En Düşük	En Yüksek	En Düşük
K-NN	0.901153	0.252060	0.902856	0.219411	0. 901153	0. 252060
RF	0.925865	0.364085	0.929295	0.293754	0.925865	0.364085
DT	0.963756	0.225700	0.964056	0.121604	0.963756	0.225700

Çizelge 4.4. PSO algoritması sonucu 5 erişim noktası için elde edilen hiper parametreler

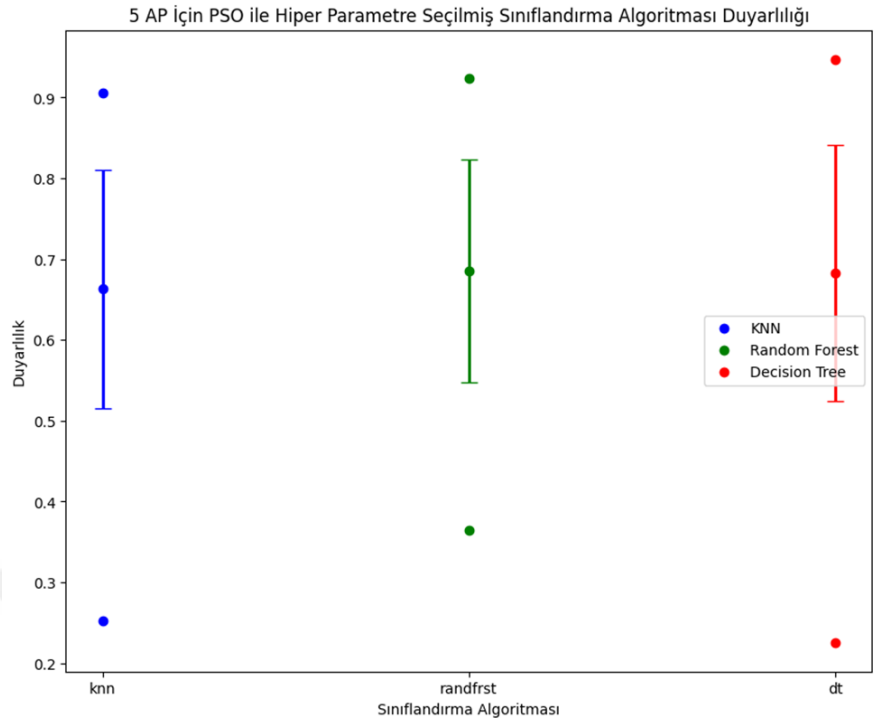
Algoritma	**Hiper parametreler**
K- En Yakın Komşu	k = 4, mesafe metriği = manhattan, ağırlık metodu = distance, algoritma = auto, yaprak boyutu = 30
Rastgele Orman	Tahminci sayısı = 10, maksimum derinlik = 20, kriter = gini, minimum veri bölünmesi = 10, minimum yapraktaki veri = 5, maksimum öznitelik = log2
Karar Ağacı	Bölücü = best, maksimum derinlik = 20, kriter = logaritmik kayıp, minimum veri bölünmesi = 10, minimum yapraktaki veri = 5, maksimum öznitelik = log2



Şekil 4.10. 5 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri doğruluk değerleri ve standart sapmaları



Şekil 4.11. 5 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri kesinlik değerleri ve standart sapmaları



Şekil 4.12. 5 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri duyarlılık değerleri ve standart sapmaları

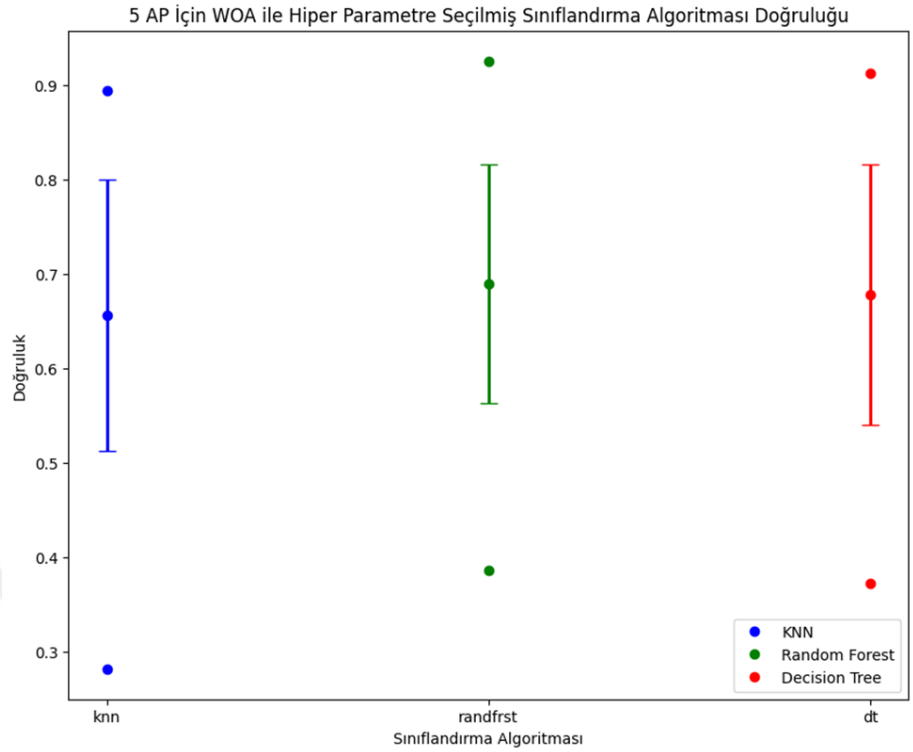
Çizelge 4.5'te 5 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modellerinin sonuçları gösterilmektedir. K-NN algoritması için ortalama doğruluk, kesinlik ve duyarlılık değerleri sırasıyla 0.656376, 0.632598, 0.656376 ve standart sapma değerleri sırasıyla, 0.143267, 0.159305, 0.143267 olarak bulundu. Rastgele Orman algoritması için ortalama doğruluk, kesinlik ve duyarlılık değerleri sırasıyla 0.689951, 0.647672, 0.689951, standart sapmaları sırasıyla 0.126262, 0.146167, 0.126262 olarak bulundu. Karar Ağacı algoritması için ortalama doğruluk, kesinlik ve duyarlılık değerleri sırasıyla 0.678188, 0.638944, 0.678188, standart sapmaları sırasıyla 0.138519, 0.157726, 0.138519 olarak bulundu. Bu değerler Şekil 4.13, Şekil 4.14 ve Şekil 4.15'te çizdirilmiştir. WOA optimizasyonu sonucu bulunan optimum hiper parametreler Çizelge 4.6'da verilmiştir. WOA optimizasyonunun K-NN ve Rastgele Orman algoritmaları için daha iyi sonuç verdiği ve standart sapmaların düştüğü gözlemlenmekle birlikte, Karar Ağacı algoritmasının performansını PSO algoritmasına göre daha az iyileştirdiği gözlemlenmektedir.

Çizelge 4.5. 5 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri en yüksek ve en düşük doğruluk, kesinlik ve duyarlılık sonuçları

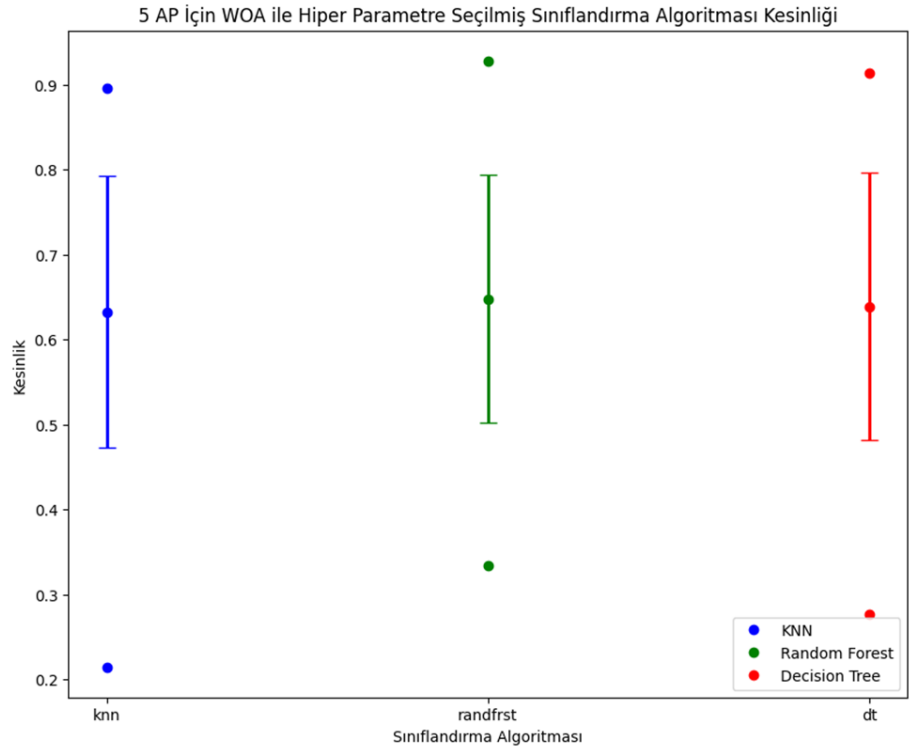
Algoritma	**Doğruluk**		**Kesinlik**		**Duyarlılık**	
	En Yüksek	En Düşük	En Yüksek	En Düşük	En Yüksek	En Düşük
K-NN	0.894563	0.281713	0.895555	0.214389	0.894563	0.281713
RF	0.925865	0.385502	0.927932	0.2333805	0.925865	0.385502
DT	0.912685	0.372322	0.913002	0.276635	0.912685	0.372323

Çizelge 4.6. WOA algoritması sonucu 5 erişim noktası için elde edilen hiper parametreler

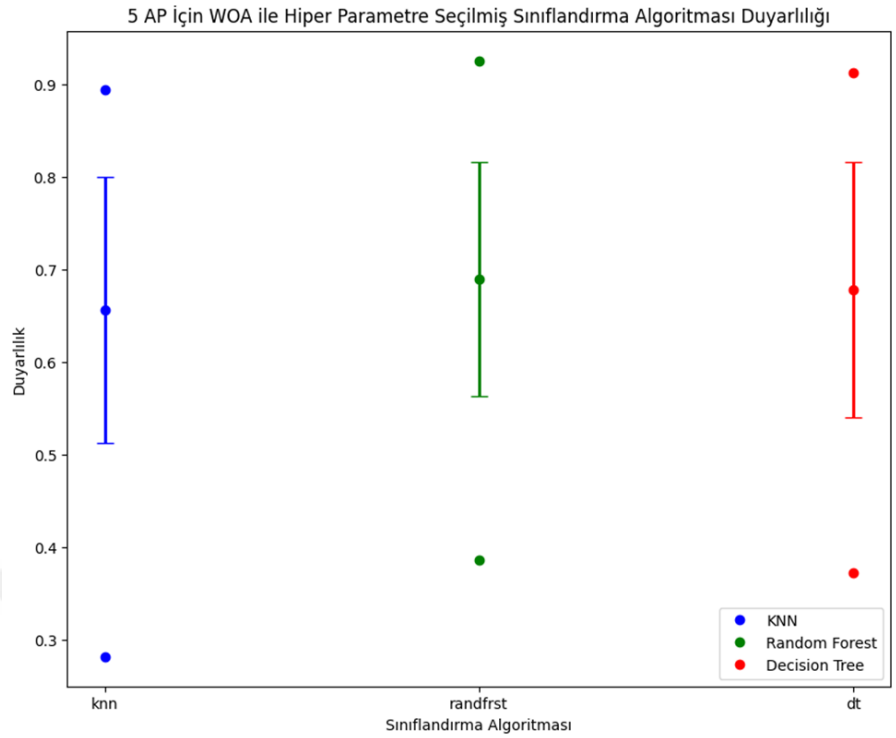
Algoritma	**Hiper parametreler**
K- En Yakın Komşu	k = 3, mesafe metriği = manhattan, ağırlık metodu = distance, algoritma = auto, yaprak boyutu = 15
Rastgele Orman	Tahminci sayısı = 25, maksimum derinlik = 10, kriter = entropy, minimum veri bölünmesi = 5, minimum yapraktaki veri = 2, maksimum öznitelik = log2
Karar Ağacı	Bölücü = best, maksimum derinlik = 10, kriter = gini, minimum veri bölünmesi = 2, minimum yapraktaki veri = 2, maksimum öznitelik = sqrt



Şekil 4.13. 5 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri doğruluk değerleri ve standart sapmaları



Şekil 4.14. 5 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri kesinlik değerleri ve standart sapmaları



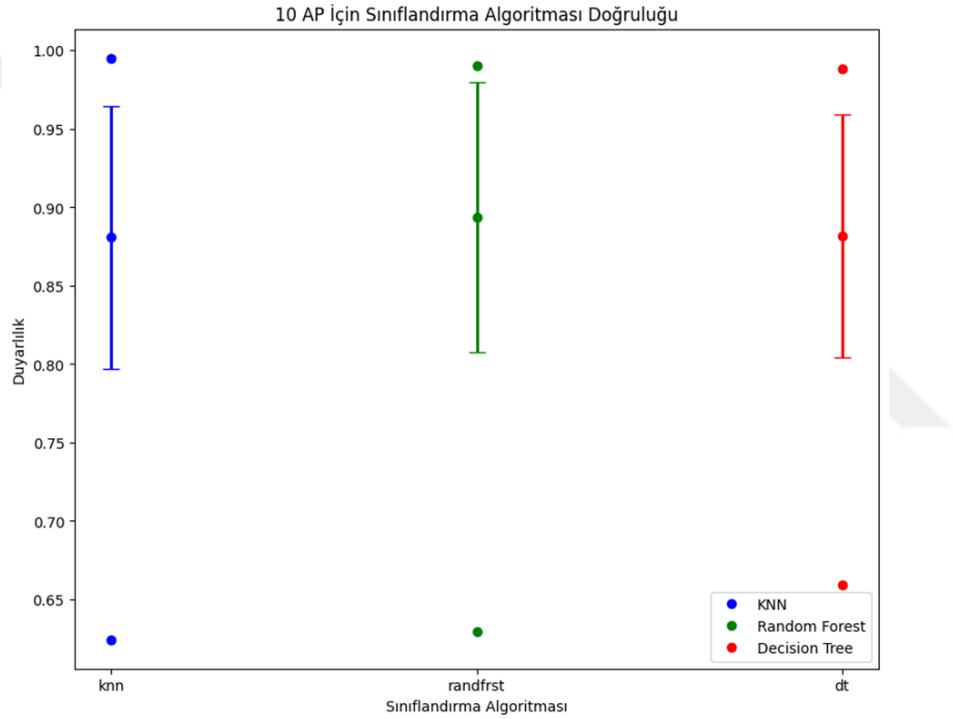
Şekil 4.15. 5 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri duyarlılık değerleri ve standart sapmaları

Kullanılan makine öğrenmesi modelleri ve optimizasyon algoritmalarının performanslarını test etmek için çalışmaya 10 erişim noktası ile devam edildi. 10 erişim noktası için makine öğrenmesi modellerinin elde ettiği değerler Çizelge 4.7, Çizelge 4.8 ve Çizelge 4.10'da gösterilmektedir. Çizelge 4.9 ve Çizelge 4.11 sırasıyla PSO ve WOA algoritmaları sonucu elde edilen optimum hiper parametreleri göstermektedir.

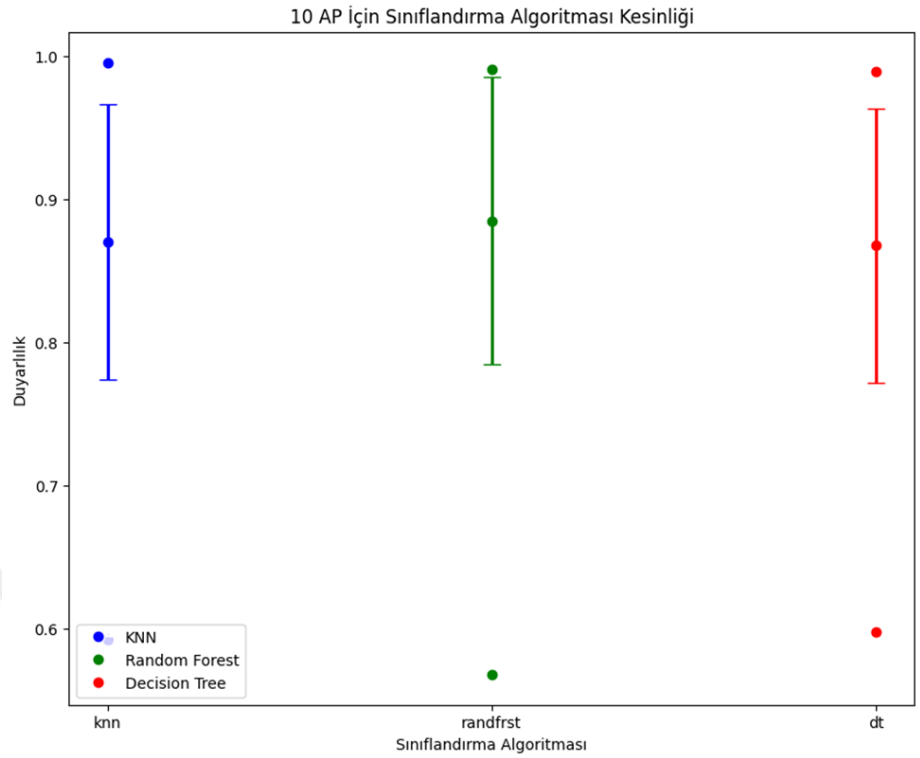
Çizelge 4.7. 10 erişim noktası için makine öğrenmesi modelleri en yüksek ve en düşük doğruluk, kesinlik ve duyarlılık sonuçları

Algoritma	**Doğruluk**		**Kesinlik**		**Duyarlılık**	
	En Yüksek	En Düşük	En Yüksek	En Düşük	En Yüksek	En Düşük
K-NN	0.995058	0.624382	0.995351	0.592340	0.995058	0.624382
RF	0.990115	0.629324	0.990494	0.567979	0.990115	0.629324
DT	0.988468	0.989243	0.989244	0.597213	0.988468	0.989243

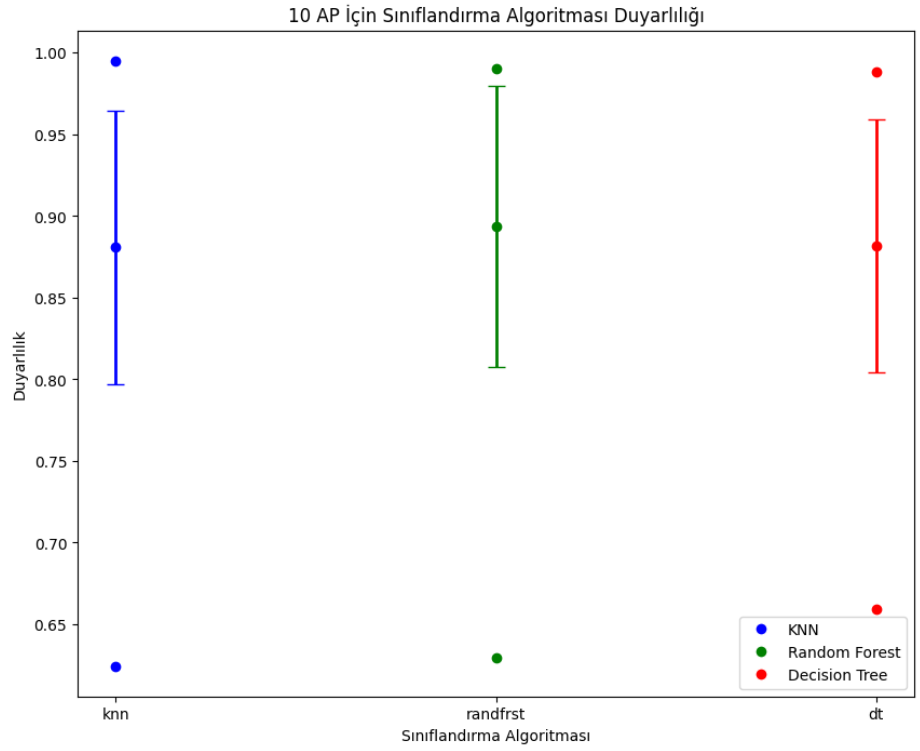
10 erişim noktası için K-NN algoritması ile elde edilen ortalama doğruluk, kesinlik ve duyarlılık değerleri sırasıyla 0.880890, 0.869889, 0.880890, standart sapmalar sırasıyla 0.083688, 0.096427, 0.083688 olarak bulundu. Rastgele Orman algoritması için ortalama doğruluk, kesinlik ve duyarlılık değerleri sırasıyla 0.893707, 0.884753, 0.893707, standart sapmalar sırasıyla 0.086109, 0.100154, 0.086109 olarak bulundu. Karar Ağacı algoritması için elde edilen ortalama doğruluk, kesinlik ve duyarlılık değerleri sırasıyla 0.882998, 0.875390, 0.882998, standart sapmalar sırasıyla 0.085526, 0.097127, 0.085526 olarak bulundu. Şekil 4.16, Şekil 4.17 ve Şekil 4.18'da 10 erişim noktası için elde edilen bu değerler çizdirildi. Genel olarak, erişim noktası sayısı 5'ten 10'a çıktıkça her üç algoritmanın da (K-NN, Rastgele Orman, Karar Ağacı) performansının arttığı ve daha iyi sınıflandırma sonucu verdiği gözlemlenmektedir. Ek olarak, standart sapmaların azalma eğiliminde olduğunu ve dolayısıyla daha tutarlı bir performans verdiği sonucu çıkarılmaktadır.



Şekil 4.16. 10 Erişim noktası (AP) için sınıflandırma algoritmalarının duyarlılık değerleri ve standart sapmaları



Şekil 4.17. 10 Erişim noktası (AP) için sınıflandırma algoritmalarının kesinlik değerleri ve standart sapmaları



Şekil 4.18. 10 Erişim noktası (AP) için sınıflandırma algoritmalarının duyarlılık değerleri ve standart sapmaları

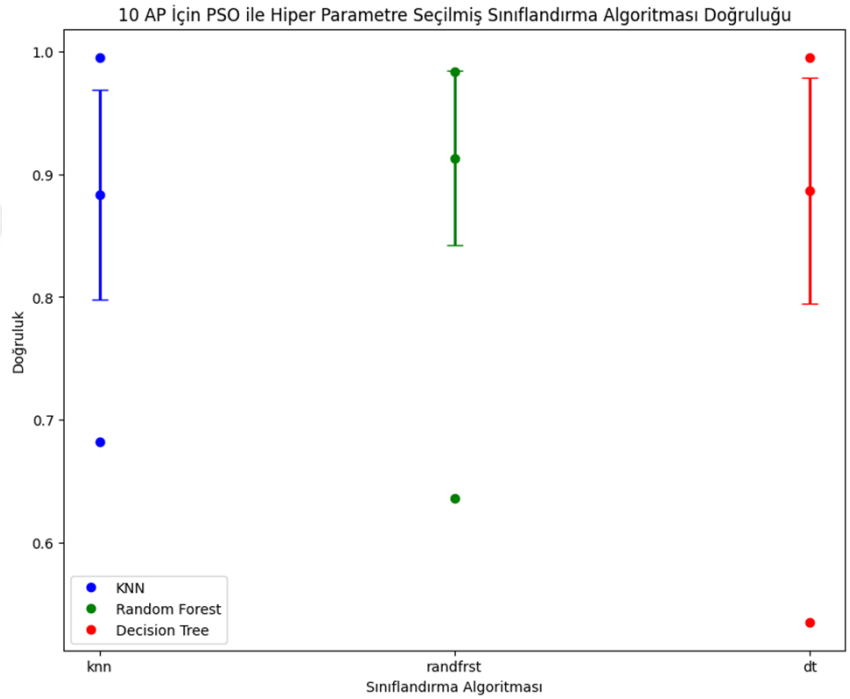
Çizelge 4.8. 10 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri en yüksek ve en düşük doğruluk, kesinlik ve duyarlılık sonuçları

Algoritma	**Doğruluk**		**Kesinlik**		**Duyarlılık**	
	En Yüksek	En Düşük	En Yüksek	En Düşük	En Yüksek	En Düşük
K-NN	0.995058	0.682043	0.995231	0.659070	0.995058	0.682043
RF	0.983526	0.635914	0.983922	0.547317	0.983526	0.635914
DT	0.995058	0.535420	0.995521	0.467794	0.995058	0.535420

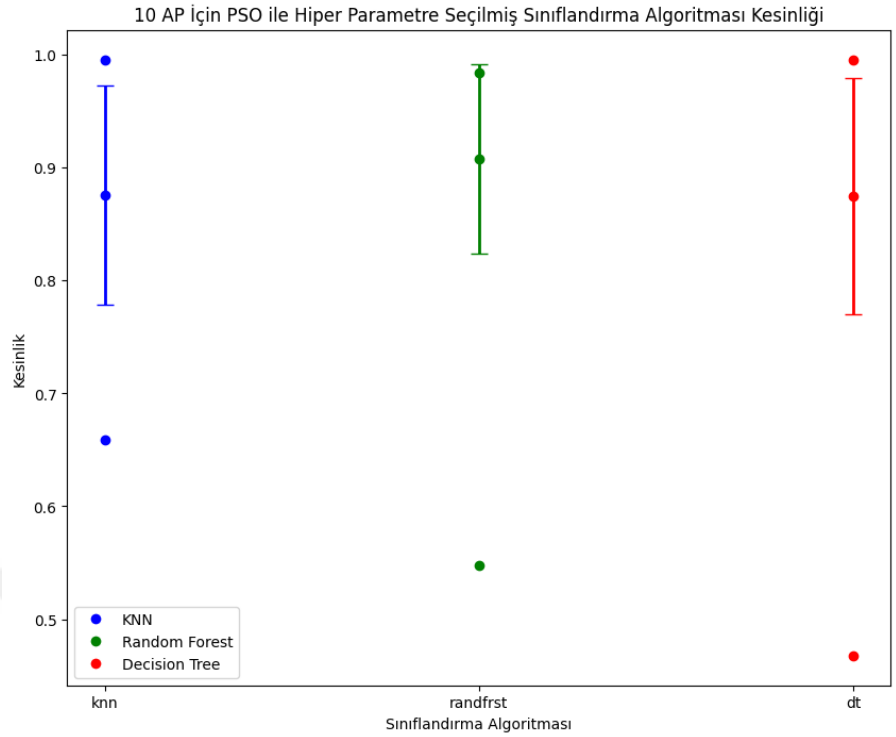
Çizelge 4.9. PSO algoritması sonucu 10 erişim noktası için elde edilen hiper parametreler

Algoritma	**Hiper parametreler**
K- En Yakın Komşu	k = 2, mesafe metriği = euclidean, ağırlık metodu = uniform, algoritma = brute, yaprak boyutu = 40
Rastgele Orman	Tahminci sayısı = 10, maksimum derinlik = 20, kriter =gini, minimum veri bölünmesi = 2, minimum yapraktaki veri = 5, maksimum öznitelik = sqrt
Karar Ağacı	Bölücü = best, maksimum derinlik = 20, kriter = logaritmik kayıp, minimum veri bölünmesi = 2, minimum yapraktaki veri = 1, maksimum öznitelik = sqrt

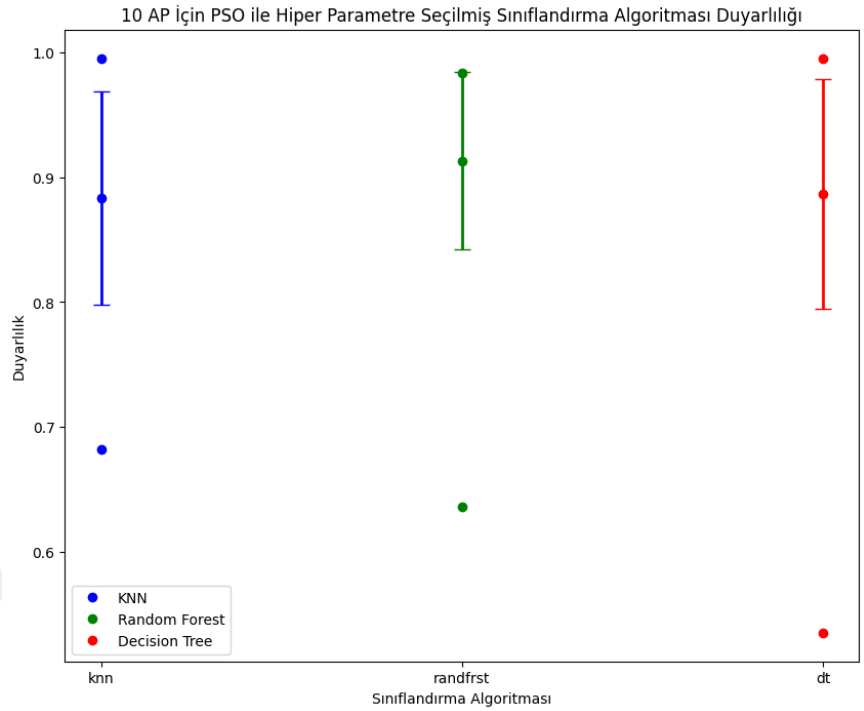
10 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış K-NN algoritması ile elde edilen ortalama doğruluk, kesinlik ve duyarlılık sonuçları sırasıyla 0.882998, 0.875390, 0.882998, standart sapmaları sırasıyla 0.085526, 0.097127, 0.085526 olarak bulundu. Rastgele Orman algoritması için elde edilen ortalama doğruluk, kesinlik ve duyarlılık sonuçları sırasıyla 0.913081, 0.907452, 0.913081, standart sapmalar sırasıyla 0.071308, 0.083799, 0.071308 olarak bulundu. Karar Ağacı algoritması için elde edilen ortalama doğruluk, kesinlik ve duyarlılık sonuçları sırasıyla 0.886421, 0.8759617, 0.886421, standart sapmalar sırasıyla 0.091847, 0.104539, 0.091847 olarak bulundu. Şekil 4.19, Şekil 4.20 ve Şekil 4.21'da bu değerler çizdirildi.



Şekil 4.19. 10 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri doğruluk değerleri ve standart sapmaları



Şekil 4.20. 10 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri kesinlik değerleri ve standart sapmaları



Şekil 4.21. 10 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri duyarlılık değerleri ve standart sapmaları

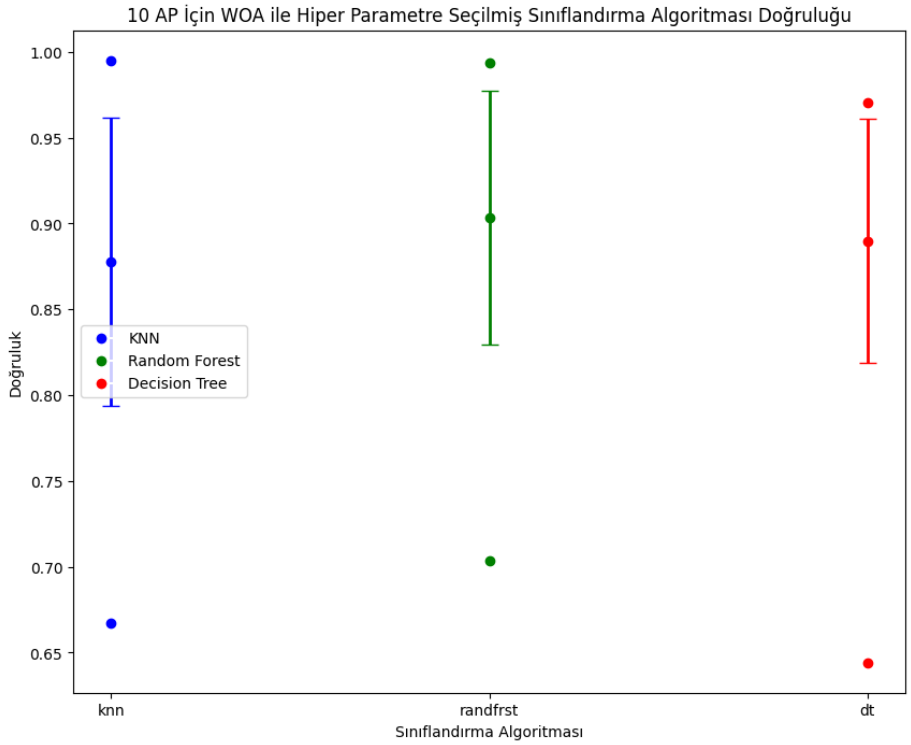
10 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış K-NN algoritması ile elde edilen ortalama doğruluk, kesinlik ve duyarlılık sonuçları sırasıyla 0.882010, 0.875026, 0.882010, standart sapmaları sırasıyla 0.083908, 0.096910, 0.083908 olarak bulundu. Rastgele Orman algoritması için elde edilen ortalama doğruluk, kesinlik ve duyarlılık sonuçları sırasıyla 0.903229, 0.889812, 0.903229, standart sapmalar sırasıyla 0.074015, 0.090760, 0. 074015 olarak bulundu. Karar Ağacı algoritması için elde edilen ortalama doğruluk, kesinlik ve duyarlılık sonuçları sırasıyla 0.889753, 0.884891, 0.889753, standart sapmalar sırasıyla 0.071000, 0.081894, 0.071000 olarak bulundu. Şekil 4.22, Şekil 4.23 ve Şekil 4.24'da bu değerler çizdirildi.

Çizelge 4.10. 10 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri en yüksek ve en düşük doğruluk, kesinlik ve duyarlılık sonuçları

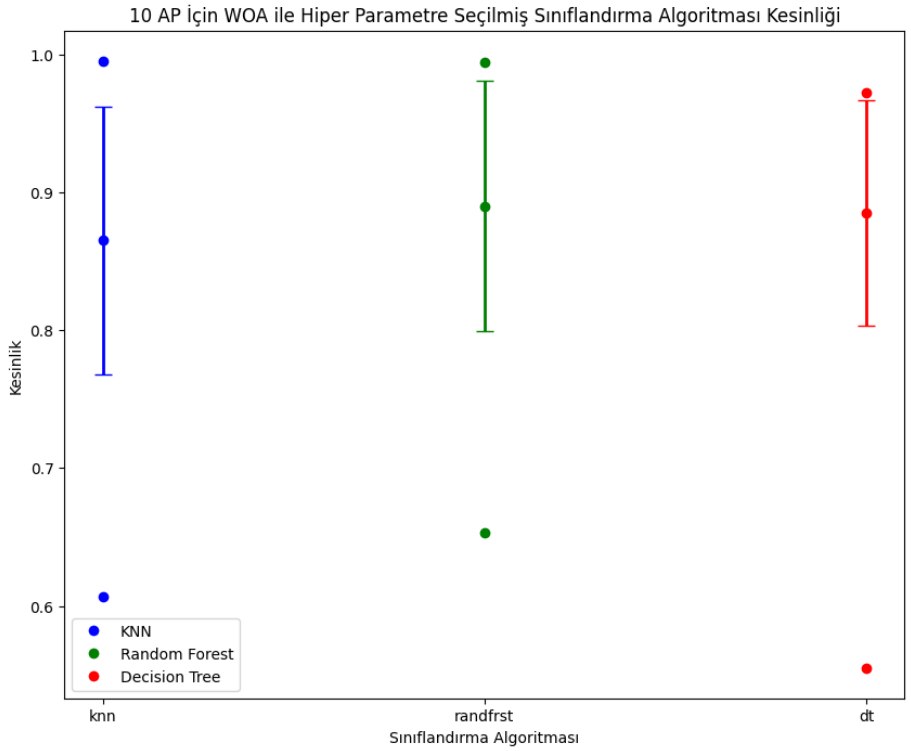
Algoritma	Doğruluk		Kesinlik		Duyarlılık	
	En Yüksek	En Düşük	En Yüksek	En Düşük	En Yüksek	En Düşük
K-NN	0.995058	0.667216	0.995124	0.606853	0.995058	0.667216
RF	0.993410	0.703460	0.994424	0.653314	0.993410	0.703460
DT	0.970346	0.644152	0.971815	0.555043	0.970346	0.644152

Çizelge 4.11. WOA algoritması sonucu 10 erişim noktası için elde edilen hiper parametreler

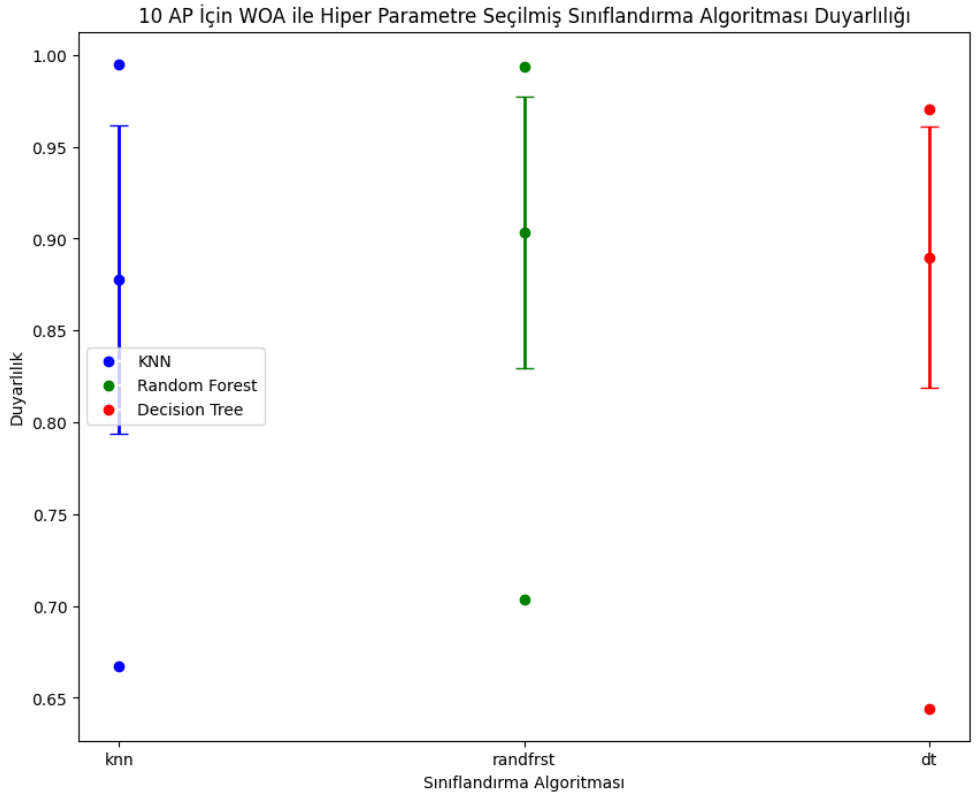
Algoritma	Hiper parametreler
K- En Yakın Komşu	k = 2, mesafe metriği = euclidean, ağırlık metodu = uniform, algoritma = brute, yaprak boyutu = 20
Rastgele Orman	Tahminci sayısı = 60, maksimum derinlik = 15, kriter = entropy, minimum veri bölünmesi = 5, minimum yapraktaki veri = 2, maksimum öznitelik = log2
Karar Ağacı	Bölücü = best, maksimum derinlik = 20, kriter = gini, minimum veri bölünmesi = 2, minimum yapraktaki veri = 4, maksimum öznitelik = sqrt



Şekil 4.22. 10 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri doğruluk değerleri ve standart sapmaları



Şekil 4.23. 10 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri kesinlik değerleri ve standart sapmaları



Şekil 4.24. 10 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri duyarlılık değerleri ve standart sapmaları

K-NN ve Karar Ağacı algoritmalarının performansındaki daha yüksek değişkenlik, veri setinin belirli özelliklerine karşı daha duyarlı olduklarını ve Rastgele Orman algoritması kadar iyi genelleyemeyebileceklerini göstermektedir. Makine öğrenmesi algoritmalarının hiper parametre seçimiyle birleştirilmesi, 10 erişim noktası için üç algoritmanın (K-NN, Rastgele Orman, Karar Ağacı) tümünde daha fazla performans iyileştirmesine yol açtığı gözlemlenmektedir. Rastgele Orman algoritması, optimizasyon algoritmaları ve hiper parametre seçimi ile birleştirildiğinde sürekli olarak en yüksek ortalama doğruluk, kesinlik ve hassasiyet değerlerine ulaşmaktadır. Bu, optimizasyon algoritmalarının Rastgele Orman algoritmasının hiper parametrelerini etkili bir şekilde optimize ederek performansın artmasına yol açtığını göstermektedir. K-NN ve Karar Ağacı algoritmaları, optimizasyon algoritmaları ve hiper parametre seçimi ile birleştirildiğinde, normal muadillerine kıyasla iyileştirilmiş performans vermektedir. Bu, optimizasyon algoritmalarının daha iyi hiper parametre konfigürasyonları bulmaya yardımcı olduğunu ve gelişmiş sınıflandırma sonuçlarıyla sonuçlandığını göstermektedir.

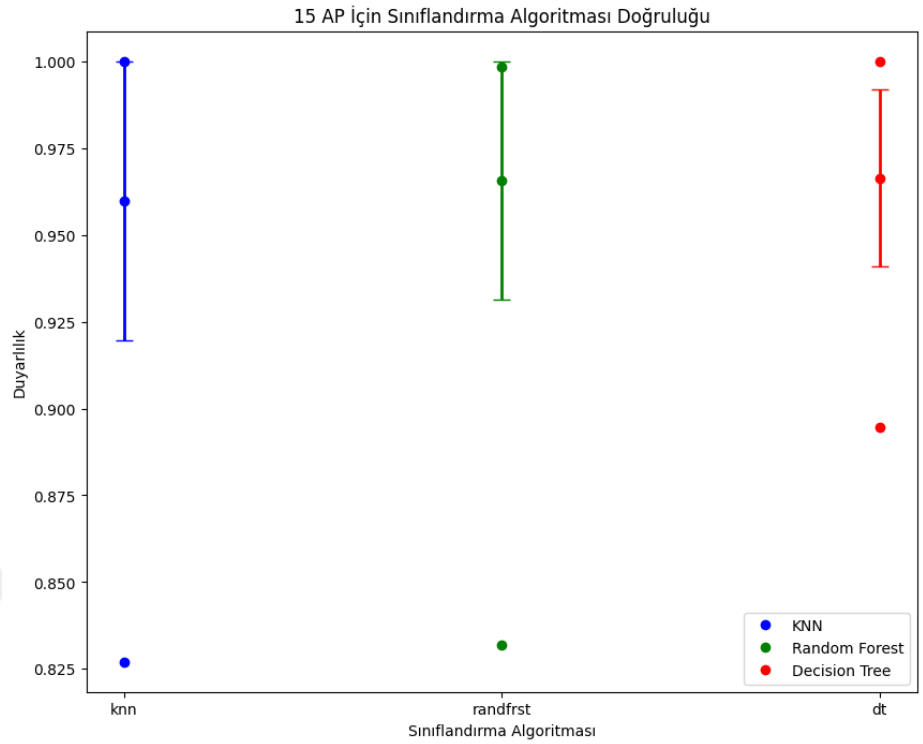
Optimizasyon algoritmaları ve hiper parametre seçimi (PSO ve WOA) içeren algoritmalar için standart sapmalardaki azalma, bu yaklaşımların birden çok çalıştırmada daha tutarlı ve istikrarlı performansa katkıda bulunduğunu göstermektedir. Bu artan kararlılık, optimizasyon algoritmalarının daha sağlam hiper parametre yapılandırmaları bulmaya yardımcı olduğunu ve algoritmanın performansındaki değişkenliği azalttığını gösterir.

Çalışmaya 15 erişim noktası ile devam edildi. Çizelge 4.12'de 15 erişim noktası için makine öğrenmesi modellerinin elde ettiği değerler gösterilmektedir. Çizelge 4.13 15 erişim noktası için sırasıyla PSO algoritması sonucu elde edilen optimum hiper parametreler ile eğitilmiş makine öğrenmesi modellerinin sonuçlarını göstermektedir. Çizelge 4.14'te PSO algoritması ile elde edilen hiper parametreler gösterilmektedir. Şekil 4.25, 4.26 ve 4.27'te makine öğrenmesi algoritmalarından elde edilen sonuçlar göstermektedir.

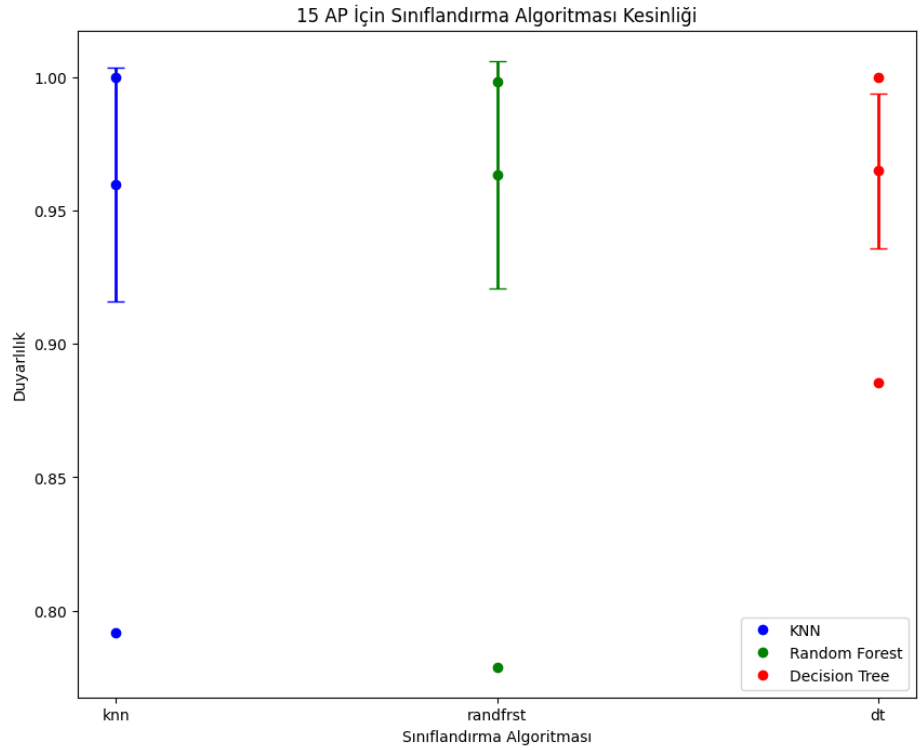
15 erişim noktası için K-NN algoritmasından elde edilen ortalama doğruluk, kesinlik ve duyarlılık sonuçları sırasıyla, 0.959868, 0.959790, 0.959868, standart sapmalar sırasıyla, 0.040062, 0.043788, 0.040062 olarak bulundu. Rastgele Orman algoritmasından elde edilen ortalama doğruluk, kesinlik ve duyarlılık sonuçları sırasıyla 0.965766, 0.963415, 0.965766, standart sapmalar sırasıyla 0.034343, 0.042666, 0.034343 olarak bulundu. Karar Ağacı algoritmasından elde edilen ortalama doğruluk, kesinlik ve duyarlılık sonuçları sırasıyla 0.966392, 0.964792, 0.966392, standart sapmalar sırasıyla 0.025499, 0.029064, 0.025499 olarak bulundu.

Çizelge 4.12. 15 erişim noktası için makine öğrenmesi modelleri en yüksek ve en düşük doğruluk, kesinlik ve duyarlılık sonuçları

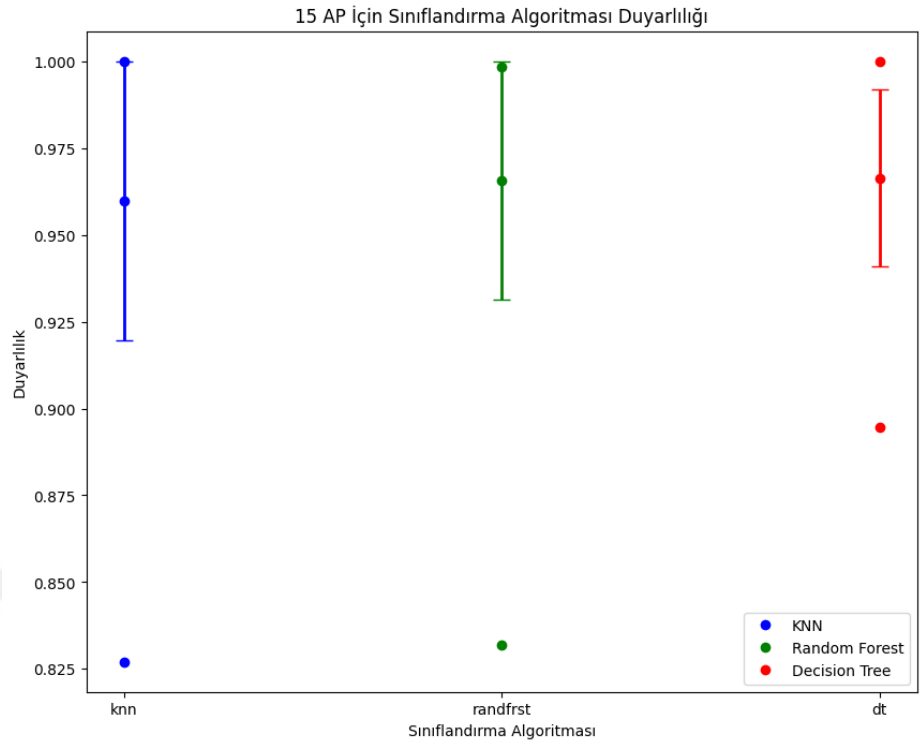
Algoritma	**Doğruluk**		**Kesinlik**		**Duyarlılık**	
	En Yüksek	En Düşük	En Yüksek	En Düşük	En Yüksek	En Düşük
K-NN	1.0	0.827018	1.0	0.791635	1.0	0.827018
RF	0.998353	0.831960	0.998407	0.778816	0.998353	0.831960
DT	1.0	0.894563	1.0	0.885315	1.0	0.894563



Şekil 4.25. 15 Erişim noktası (AP) için sınıflandırma algoritmalarının doğruluk değerleri ve standart sapmaları



Şekil 4.26. 15 Erişim noktası (AP) için sınıflandırma algoritmalarının kesinlik değerleri ve standart sapmaları



Şekil 4.27. 15 Erişim noktası (AP) için sınıflandırma algoritmalarının duyarlılık değerleri ve standart sapmaları

15 erişim noktası için PSO algoritması ile hiper parametreleri seçilmiş K-NN algoritmasından elde edilen ortalama doğruluk, kesinlik ve duyarlılık sonuçları sırasıyla, 0.966194, 0.965234, 0.966194, standart sapmalar sırasıyla, 0.034507, 0.039750, 0.034507 olarak bulundu. Rastgele Orman algoritmasından elde edilen ortalama doğruluk, kesinlik ve duyarlılık sonuçları sırasıyla 0.970774, 0.970052, 0.970774, standart sapmalar sırasıyla 0.028463, 0.031613, 0.028463 olarak bulundu. Karar Ağacı algoritmasından elde edilen ortalama doğruluk, kesinlik ve duyarlılık sonuçları sırasıyla 0.967808, 0.967447, 0.967808, standart sapmalar sırasıyla 0.027836, 0.030811, 0.027836 olarak bulundu.

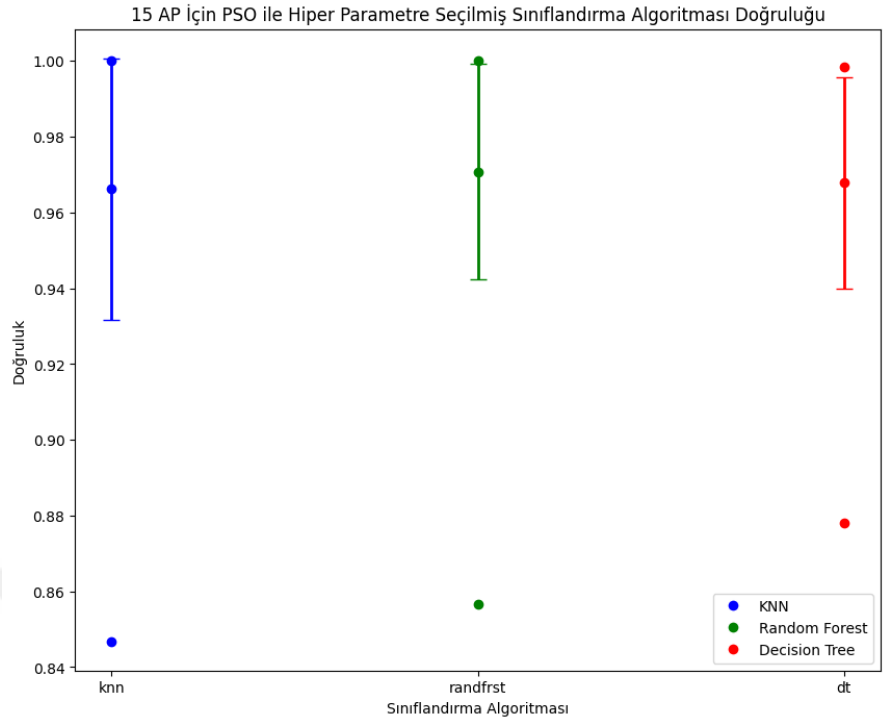
Çizelge 4.13. 15 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modellerinin en yüksek ve en düşük doğruluk, kesinlik ve duyarlılık sonuçları

Algoritma	Doğruluk		Kesinlik		Duyarlılık	
	En Yüksek	En Düşük	En Yüksek	En Düşük	En Yüksek	En Düşük
K-NN	1.0	0.846787	1.0	0.819162	1.0	0.846787
RF	1.0	0.856672	1.0	0.859190	1.0	0.856672
DT	0.998353	0.878089	0.998470	0.857495	0.998353	0.878089

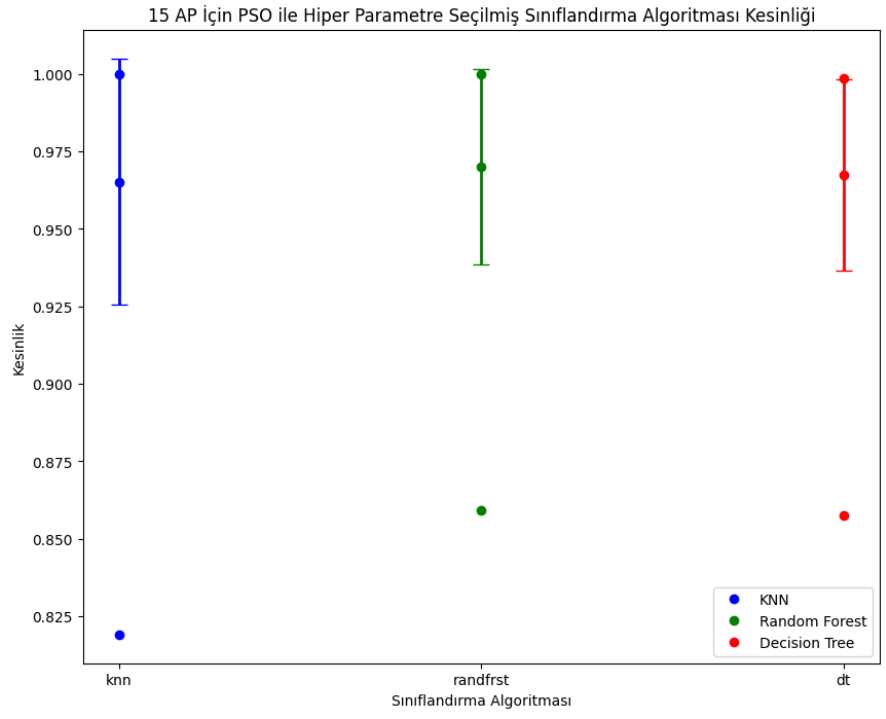
Çizelge 4.14. PSO algoritması sonucu 15 erişim noktası için elde edilen hiper parametreler

Algoritma	Hiper parametreler
K- En Yakın Komşu	k = 6, mesafe metriği = chebyshev, ağırlık metodu = uniform, algoritma = kd ağacı, yaprak boyutu = 30
Rastgele Orman	Tahminci sayısı = 10, maksimum derinlik = 10, kriter = logaritmik kayıp, minimum veri bölünmesi = 2, minimum yapraktaki veri = 4, maksimum öznitelik = sqrt
Karar Ağacı	Bölücü = best, maksimum derinlik = 20, kriter = logaritmik kayıp, minimum veri bölünmesi = 10, minimum yapraktaki veri = 1, maksimum öznitelik = sqrt

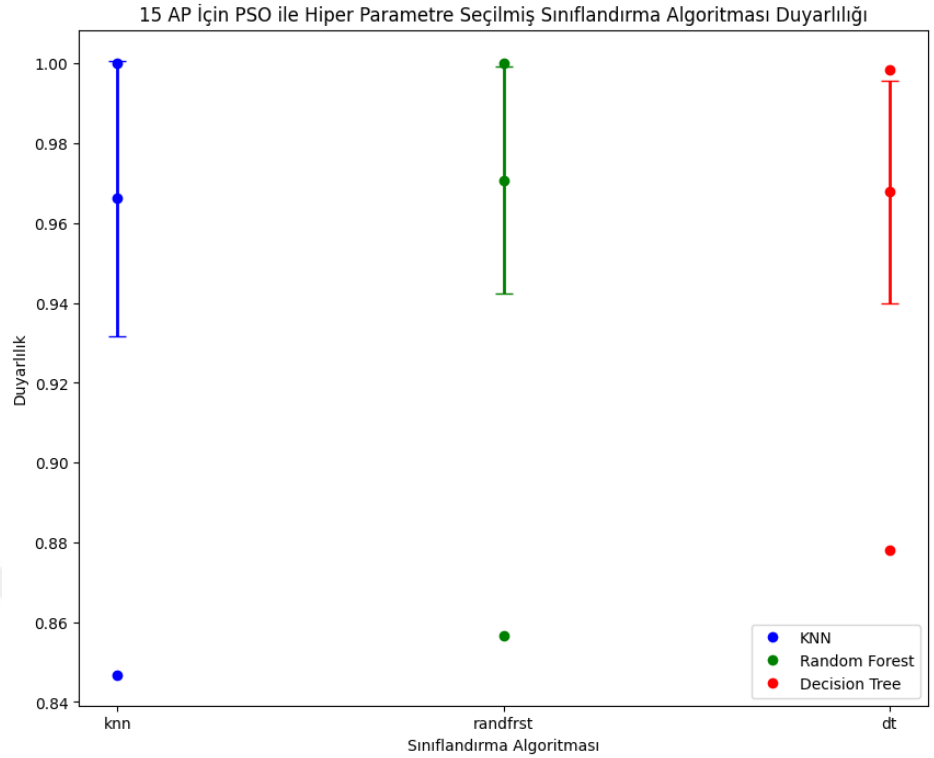
Şekil 4.28, 4.29 ve 4.30'de 15 erişim noktası için PSO algoritması ile hiper parametreleri seçilmiş makine öğrenmesi algoritmalarının sınıflandırma sonuçları çizdirilmiştir.



Şekil 4.28. 15 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri doğruluk değerleri ve standart sapmaları



Şekil 4.29. 15 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri kesinlik değerleri ve standart sapmaları



Şekil 4.30. 15 erişim noktası için PSO algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri duyarlılık değerleri ve standart sapmaları

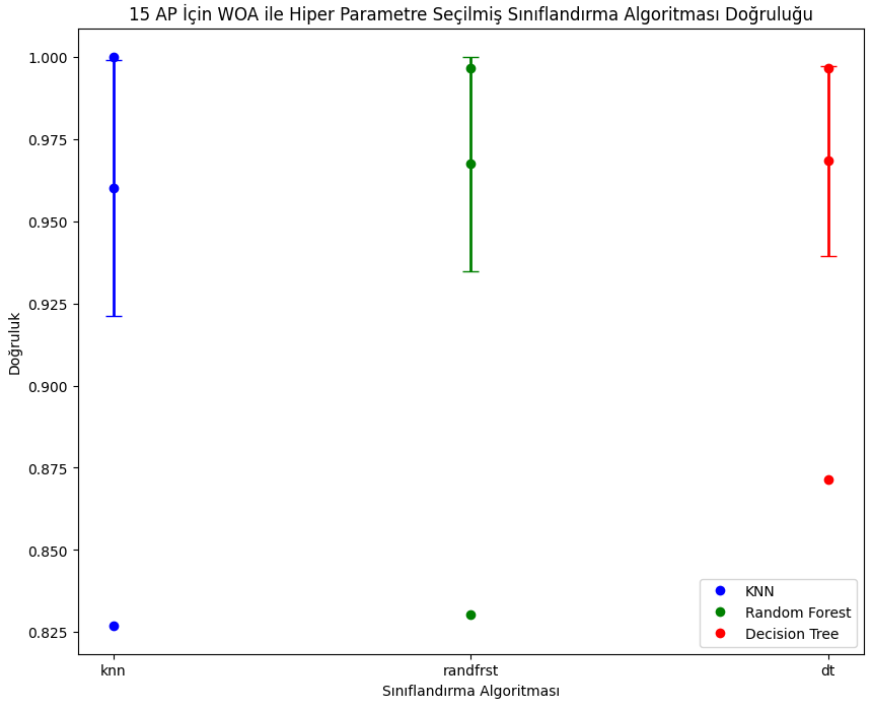
Çizelge 4.15'te WOA optimizasyonu sonucu hiper parametreleri seçilmiş makine öğrenmesi modellerinin sınıflandırma sonuçları gösterilmektedir. K-NN algoritması için ortalama doğruluk, kesinlik ve duyarlılık değerleri sırasıyla 0.960131, 0.960355, 0.960131, standart sapmaları sırasıyla 0.038818, 0.042701, 0.038818 olarak bulundu. Rastgele Orman algoritması için ortalama doğruluk, kesinlik ve duyarlılık değerleri sırasıyla 0.967512, 0.964922, 0.967512, standart sapmaları sırasıyla 0.032604, 0.041718, 0.032604 olarak bulundu. Karar Ağacı algoritması için ortalama doğruluk, kesinlik ve duyarlılık değerleri sırasıyla 0.968434, 0.968017, 0.968434, standart sapmaları sırasıyla 0.028885, 0.032152, 0.028885 olarak bulundu. Şekil 4.31, 4.32 ve 4.33'de WOA optimizasyonu sonucu elde edilen hiper parametreler ile eğitilen makine öğrenmesi algoritmalarının sınıflandırma sonuçları verildi. Çizelge 4.16'da 15 erişim noktası için WOA optimizasyonu sonucu elde edilen hiper parametreler görülmektedir.

Çizelge 4.15. 15 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modellerinin en yüksek ve en düşük doğruluk, kesinlik ve duyarlılık sonuçları

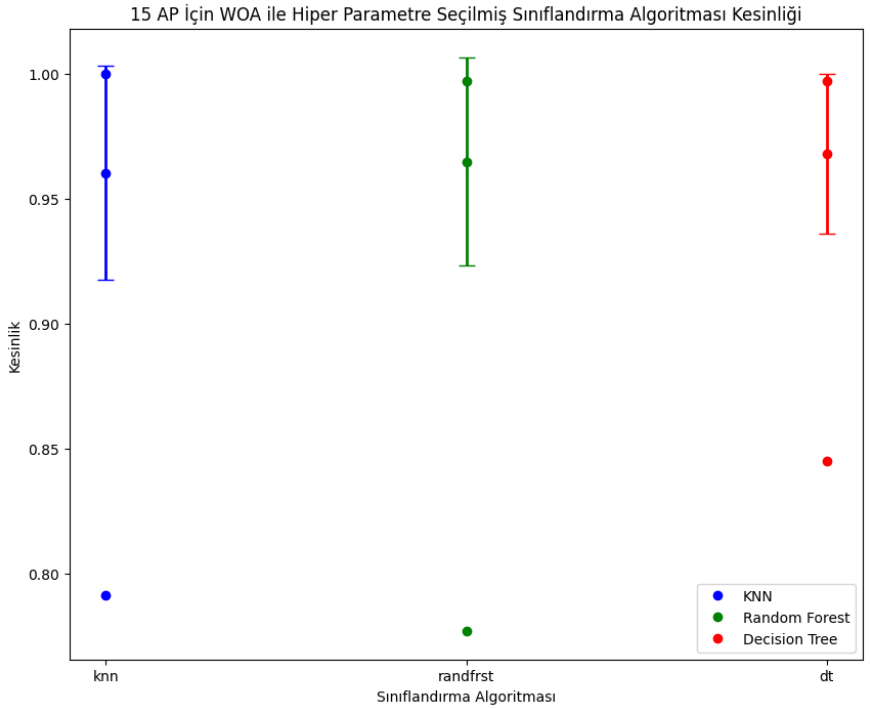
Algoritma	Doğruluk		Kesinlik		Duyarlılık	
	En Yüksek	En Düşük	En Yüksek	En Düşük	En Yüksek	En Düşük
K-NN	1.0	0.827018	1.0	0.791635	1.0	0.827018
RF	0.996705	0.830313	0.996992	0.777230	0.996705	0.830313
DT	0.996705	0.871500	0.996979	0.844917	0.996705	0.871500

Çizelge 4.16. WOA algoritması sonucu 15 erişim noktası için elde edilen hiper parametreler

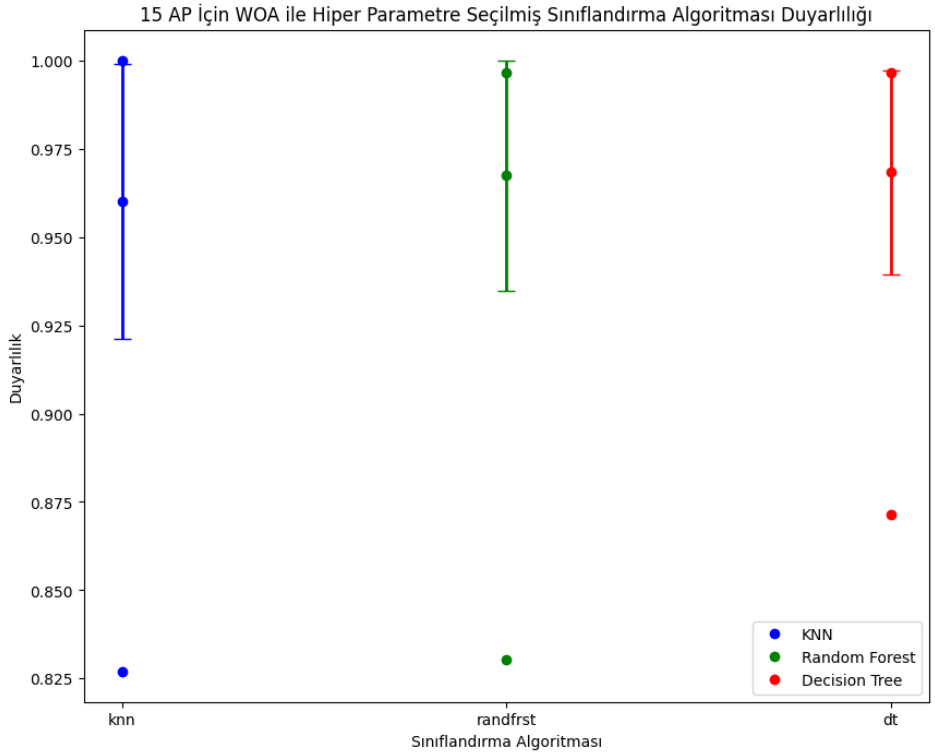
Algoritma	Hiper parametreler
K- En Yakın Komşu	k = 7, mesafe metriği = manhattan, ağırlık metodu = uniform, algoritma = auto, yaprak boyutu = 30
Rastgele Orman	Tahminci sayısı = 40, maksimum derinlik = 10, kriter = entropy, minimum veri bölünmesi = 5, minimum yapraktaki veri = 2, maksimum öznitelik = sqrt
Karar Ağacı	Bölücü = best, maksimum derinlik = 10, kriter = entropy, minimum veri bölünmesi = 2, minimum yapraktaki veri = 1, maksimum öznitelik = log2



Şekil 4.31. 15 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri doğruluk değerleri ve standart sapmaları



Şekil 4.32. 15 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri kesinlik değerleri ve standart sapmaları



Şekil 4.33. 15 erişim noktası için WOA algoritması ile hiper parametre seçimi yapılmış makine öğrenmesi modelleri duyarlılık değerleri ve standart sapmaları

Her üç algoritma için de (K-NN, Rastgele Orman, Karar Ağacı) elde edilen ortalama doğruluk, kesinlik ve duyarlılık değerleri, 0,959868 ile 0,966392 arasında değişen önemli ölçüde yüksek performans göstermektedir. Bu değerler, modellerin 15 erişim noktasına sahip veri seti için daha yüksek sınıflandırma sonuçlarına ulaştığını göstermektedir. 0,025499 ile 0,043788 arasında değişen standart sapmalar, modellerin performansında nispeten düşük değişkenlik olduğunu ve sınıflandırma sonuçlarındaki tutarlılığı göstermektedir.

PSO algoritması ile hiper parametre seçimi yapılarak her üç algoritmanın (K-NN, Rastgele Orman, Karar Ağacı) ortalama doğruluk, kesinlik ve duyarlılık değerleri iyileştirildi (15 erişim noktası için). PSO algoritması sonucu elde edilen hiper parametrelerle eğitilmiş makine öğrenmesi modellerinin verdiği ortalama doğruluk, kesinlik ve hassasiyet değerleri 0,966194 ile 0,970774 arasındadır. Bu sonuç PSO algoritması ile optimize edilmiş modellerde sınıflandırma performansının arttığını göstermektedir. PSO için optimize edilmiş modellerin standart sapmaları, 0,028463 ile 0,039750 arasında değişen azaltılmış değişkenlik ile tutarlı ve kararlı performans göstermektedir. Bu, PSO algoritmasının optimum hiper parametreleri etkili bir şekilde arayarak daha sağlam ve güvenilir sonuçlar verdiği anlamına gelmektedir.

Benzer şekilde, hiper parametre seçimi için WOA optimizasyonu kullanıldığında, üç algoritmanın tümü için ortalama doğruluk, kesinlik ve duyarlılık

değerleri iyileştirildi. PSO algoritması sonucu elde edilen hiper parametrelerle eğitilmiş makine öğrenmesi modellerinin verdiği ortalama doğruluk, kesinlik ve hassasiyet değerleri, 0,960131 ile 0,968434 arasındadır, bu sonuç PSO algoritması ile optimize edilmiş modellerde sınıflandırma performansının arttığını göstermektedir. WOA için optimize edilmiş modellerin standart sapmaları, 0,028885 ile 0,042701 arasında değişen, tutarlı ve istikrarlı bir performans göstermektedir. Bu, WOA algoritmasının optimum hiper parametreleri bulmak için arama alanını etkili bir şekilde araştırdığı ve değişkenliği azaltılmış daha güvenilir modeller ile sonuçlandığı anlamına gelmektedir.

5. SONUÇLAR

Bu tez çalışması kapsamında, iç mekân konumlandırma için makine öğrenmesi algoritmalarının detaylı ve karşılaştırmalı bir çalışması yapıldı. İç mekanlarda bulunan erişim noktalarından veri toplanabilmesi için bir mobil uygulama geliştirildi ve modellerin test edilmesi amacıyla veri kümesi oluşturuldu.

Veri kümesinde sınıflandırma sağlamak üzere makine öğrenme algoritmalarının sürü optimizasyonu yöntemleri ile hiper parametre seçimleri yapılarak performans artırımı sağlandı. Test sonuçları doğruluk, kesinlik ve duyarlılık başarım kriterleri çerçevesinde görselleştirilerek karşılaştırmalı analizleri gerçekleştirildi.

Çalışmamızdaki sonuçlara göre konumlandırma süreçlerinde Rastgele Orman ve Karar Ağacı algoritmaları K-NN algoritmasından daha iyi performans göstererek sınıflandırmada yüksek ortalama doğruluk, kesinlik ve duyarlılık değerleri sağladığı ve veri kümesinin karmaşıklığını yönetmede daha etkili olduğunu gösterdi. Bunun yanında üç algoritma için de veri setinde bulunan erişim noktası sayısı arttıkça algoritmaların doğruluğunda artış ve sonuçların standart sapmalarında düşüş gözlemlendi.

PSO ve WOA algoritmalarının üç makine öğrenme algoritmasında da benzer ortalama performans artışı sağladığı gözlemlendi. Rastgele Orman algoritması, her üç algoritma arasında en yüksek ortalama doğruluk, kesinlik ve hassasiyet değerlerine ulaştı. Bununla birlikte, standart sapmalarda farklılıklar gözlendi, bu da optimizasyon algoritması seçiminin sonuçların kararlılığını etkileyebileceğini göstermektedir.

Son olarak, veri aktarım sürecinde verilerin çok fazla olması mobil uygulamanın çalıştırıldığı telefonun bataryasının hızlı bir şekilde tüketilmesine neden olduğu gözlemlendi. Buna yönelik veri toplama süreçlerinde verinin geçici süre telefon hafızasında tutulması ve sıkıştırılarak aktarılması sağlandı. Ancak bu tür yaklaşım sürekli takip gerektiren uygulamalar için kullanımı kısıtlayan bir unsur olarak değerlendirilmektedir. İlerleyen çalışmalarda verinin sürekli aktarımına yönelik bir protokolün ve veri sıkıştırma tekniğinin geliştirilmesi düşünülmektedir.

Ayrıca, çalışma esnasında, hareket eden bir nesnenin ölçüm sırasında ölçüm yapan telefonun etrafında hareket etmesi, odada başka sinyal yayan cihazların bulunması gibi birçok faktörün sinyal güç değerlerini etkileyebildiği gözlemlendi. Sonraki çalışmalarda bu etkenlerin konumlandırma başarısını arttırma konusunda kullanımının değerlendirilmesi düşünülmektedir.

Bu tez çalışması PSO ve WOA sürü zekâ optimizasyon algoritmalarının makine öğrenmesini optimize etmesi ile iç mekân konumlandırmada başarım analizi ve karşılaşılan kısıtlar, sonraki iç mekân konumlandırma çalışmalarında farklı optimizasyon teknikleri ve farklı makine öğrenmeleri ile anlamlı bir nitelik taşıyabilecektir.

6. KAYNAKLAR

Ahn, J., & Han, D. (2017). Crowd-assisted radio map construction for WiFi positioning systems. In 2017 International Conference on Indoor Positioning and Indoor Navigation (IPIN) (pp. 1-8). Sapporo. doi: 10.1109/IPIN.2017.8115872.

Belmonte-Fernández, Ó., Puertas-Cabedo, A., Torres-Sospedra, J., MontoliuColás, R., & Trilles-Oliver, S. (2017). An Indoor Positioning System Based on Wearables for Ambient-Assisted Living. Sensors, 17(1), 36.

Belmonte-Fernández, Ó., Gascó-Compte, A., Sansano-Sansano, E., Quinde, M., Manuel, J. G. G., & Augusto, J. C. (2019). Evaluation of crowdsourcing Wi-Fi radio map creation in a real scenario for AAL applications. In 2019 15th International Conference on Intelligent Environments (IE) (pp. 30-36). doi: 10.1109/IE.2019.00005.

Bishop, C. M. (2006). Pattern Recognition and Machine Learning. Springer.

Bin Shams, M., Haji, S., Salman, A., Abdali, H., & Alsaffar, A. (2016). Time series analysis of Bahrain's first hybrid renewable energy system. Energy, 103, 1-15. doi: 10.1016/j.energy.2016.02.028.

Blum, C. (2005). Ant colony optimization: Introduction and recent trends. Physics of Life Reviews, 2, 353-373.

Bozkurt, S., Elibol, G., Gunal, S., & Yayan, U. (2015). A comparative study on machine learning algorithms for indoor positioning. In Proceedings of the 2015 International Symposium on Innovations in Intelligent Systems and Applications (INISTA) (pp. 1-15). Madrid, Spain.

Breiman, L. (2001). Random forests. Machine learning, 45(1), 5-32.

Centenaro, M., Vangelista, L., Zanella, A., & Zorzi, M. (2016). Long-range communications in unlicensed bands: The rising stars in the IoT and smart city scenarios. IEEE Wireless Communications, 23(5), 60-67.

Chai, S., An, R., & Du, Z. (2016). An indoor positioning algorithm using Bluetooth low energy RSSI. In Proceedings of the 2016 International Conference on Advanced Materials Science and Environmental Engineering (pp. 1-15). Chiang Mai, Thailand: Atlantis Press.

Cheng, C.-H., Wang, T.-P., & Huang, Y.-F. (2020). Indoor positioning system using artificial neural network with swarm intelligence. IEEE Access, 8, 84248-84257.

Choi, M. S., & Beakcheol, J. (2017). An accurate fingerprinting based indoor positioning algorithm. International Journal of Applied Engineering Research, 12, 86-90.

Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. IEEE Transactions on Information Theory, 13(1), 21-27.

Falsi, C., Dardari, D., Mucchi, L., & Win, M. Z. (2006). Time of arrival estimation for UWB localizers in realistic environments. EURASIP Journal on Applied Signal Processing, 2006, 1-13.

Félix, G., Siller, M., & Álvarez, E. N. (2016). A fingerprinting indoor localization algorithm based on deep learning. In Proceedings of the 2016 Eighth International Conference on Ubiquitous and Future Networks (ICUFN) (pp. 1006-1011). Vienna, Austria.

Hastie, T., Tibshirani, R., & Friedman, J. (2009). The Elements of Statistical Learning: Data Mining, Inference, and Prediction. Springer Science & Business Media.

Hosmer Jr, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). Applied Logistic Regression. Wiley.

Kanaris, L., Kokkinis, A., Liotta, A., & Stavrou, S. (2017). Fusing Bluetooth beacon data with Wi-Fi radiomaps for improved indoor localization. Sensors, 17(4), 812.

Khalajmehrabadi, A., Gatsis, N., & Akopian, D. (2017). Modern WLAN fingerprinting indoor positioning methods and deployment challenges. IEEE Communications Surveys & Tutorials, 19(3), 1974-2002.

Kim, K. S., et al. (2017). A scalable deep neural network architecture for multi-building and multi-floor indoor localization based on Wi-Fi fingerprinting. ArXiv preprint.

Kul, G., Özyer, T., & Tavli, B. (2014). IEEE 802.11 WLAN based real-time indoor positioning: Literature survey and experimental investigations. Procedia Computer Science, 34, 157-164.

Li, N., Chen, J., Yuan, Y., Tian, X., Han, Y., & Xia, M. (2016). A Wi-Fi indoor localization strategy using particle swarm optimization based artificial neural networks. International Journal of Distributed Sensor Networks, 12, 4583147.

Lim, H., et al. (2006). Impact of environmental factors on indoor localization using wireless sensor networks. In Proceedings of the 3rd Annual International Conference on Mobile and Ubiquitous Systems: Networking and Services (MobiQuitous) (pp. 1-10).

Liu, H., Darabi, H., Banerjee, P., & Liu, J. (2007). Survey of wireless indoor positioning techniques and systems. IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews), 37(6), 1067-1080.

Lorenzo, P. R., Nalepa, J., Kawulok, M., Ramos, L. S., & Paster, J. R. (2017). Particle swarm optimization for hyper-parameter selection in deep neural networks. Proceedings

of the ACM International Conference on Genetic and Evolutionary Computation, 481-488.

Meng, H., Yuan, F., Yan, T., & Zeng, M. (2019). Indoor positioning of RBF neural network based on improved fast clustering algorithm combined with LM algorithm. IEEE Access, 7, 5932-5945.

Mirjalili, S., & Lewis, A. (2016). The whale optimization algorithm. Advances in Engineering Software, 95, 51-67.

Mohammed, H. M., Umar, S. U., & Rashid, T. A. (2019). A systematic and meta-analysis survey of whale optimization algorithm. Computational Intelligence and Neuroscience, 2019, Article ID 8718571, 25 pages.

Nowicki, M., & Wietrzykowski, J. (2016). Low-effort place recognition with Wi-Fi fingerprints using deep learning. Springer International Publishing: Cham, Switzerland.

Obeidat, H., et al. (2021). A review of indoor localization techniques and wireless technologies. Wireless Personal Communications, 119(1), 289-327.

Paul, A. S., & Wan, E. A. (2009). RSSI-based indoor localization and tracking using sigma-point Kalman smoothers. IEEE Journal of Selected Topics in Signal Processing, 3(5), 860-873.

Patwari, N., & Wilson, D. R. (2011). RF ranging using low rate sign changes. In Proceedings of the 10th ACM/IEEE International Conference on Information Processing in Sensor Networks (IPSN) (pp. 82-93).

Qin, F., Zuo, T., & Wang, X. (2021). CCpos: WiFi fingerprint indoor positioning system based on CDAE-CNN. Sensors, 21, 1114.

Quinlan, J. R. (1986). Induction of decision trees. Machine Learning, 1(1), 81-106.

Russell, S. J., & Norvig, P. (2009). Artificial Intelligence: A Modern Approach (3rd ed.). Prentice Hall.

Saleem, F., & Wyne, S. (2016). WLAN-based indoor localization using neural networks. Journal of Electrical Engineering, 67, 299-306.

Seidel, E., & Rappaport, T. S. (1992). Site-specific propagation prediction for wireless in-building personal communication system design. IEEE Transactions on Vehicular Technology, 41(3), 322-328.

Song, X., et al. (2019). A novel convolutional neural network-based indoor localization framework with WiFi fingerprinting. IEEE Access, 7, 110698-110709.

Sutton, R. S., & Barto, A. G. (2018). Reinforcement Learning: An Introduction (2nd ed.). The MIT Press.

Wu, C., Yang, Z., Liu, Y., & Xi, W. (2013). WILL: Wireless indoor localization without site survey. IEEE Transactions on Parallel and Distributed Systems, 24(4), 839-848.

Wu, J., et al. (2012). Rethinking received signal strength for device-free passive localization. In Proceedings of the 10th International Conference on Mobile Systems, Applications, and Services (MobiSys) (pp. 99-112).

Yassin, A., Nasser, Y., Awad, M., Al-Dubai, A., Liu, R., Yuen, C., Raulefs, R., & Aboutanios, E. (2016). Recent advances in indoor localization: A survey on theoretical approaches and applications. IEEE Communications Surveys & Tutorials, 19(2), 1327-1346.

Zafari, F., Gkelias, A., & Leung, K. K. (2019). A survey of indoor localization systems and technologies. IEEE Communications Surveys & Tutorials, 21(3), 2568-2599.

Zhou, G., He, T., Krishnamurthy, S., & Stankovic, J. A. (2004). Impact of radio irregularity on wireless sensor networks. In Proc. ACM MobiSys, New York (pp. 125-138).

ÖZGEÇMİŞ

Yasin KAM

ÖĞRENİM BİLGİLERİ

Yüksek Lisans 2020-2023	Akdeniz Üniversitesi Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Ana Bilim Dalı, Antalya
Lisans 2012-2018	Süleyman Demirel Üniversitesi Mühendislik Fakültesi, Elektronik ve Haberleşme Mühendisliği Bölümü, Isparta

MESLEKİ VE İDARİ GÖREVLER

Stajyer 2016-2016	Türk Telekom Genel Müdürlüğü Türk Telekom Tobb, Ankara
Uzman 2021-Devam Ediyor	Mavi İleri Bilişim Teknolojileri ARGE Yazılım Ticaret Limited Şirketi Teknokent, Antalya