

**Wi-Fi TABANLI PARMAK İZİ YÖNTEMİ
KULLANARAK İÇ ORTAM
KONUMLANDIRMA**

Işıl KARABEY

Yüksek Lisans Tezi

Bilgisayar Mühendisliği Anabilim Dalı

Yrd. Doç. Dr. Levent BAYINDIR

2015

Her hakkı saklıdır

**ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**Wi-Fi TABANLI PARMAK İZİ YÖNTEMİ KULLANARAK
İÇ ORTAM KONUMLANDIRMA**

Işıl KARABEY

BİLGİSAYAR MÜHENDİLİĞİ ANABİLİM DALI

**ERZURUM
2015**

Her hakkı saklıdır



T.C.
ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



TEZ ONAY FORMU

Wi-Fi TABANLI PARMAK İZİ YÖNTEMİ KULLANARAK
İÇ ORTAM KONUMLANDIRMA

Yrd. Doç. Dr. Levent BAYINDIR danışmanlığında, Işıl KARABEY tarafından hazırlanan bu çalışma 08/10/2015 tarihinde aşağıdaki jüri tarafından Bilgisayar Mühendisliği Anabilim Dalı'nda Yüksek Lisans Tezi olarak **oybirliği/oy çokluğu** (.../...) ile kabul edilmiştir.

Başkan : Yrd. Doç. Dr. Levent BAYINDIR

İmza : 

Üye : Yrd. Doç. Dr. E. Argun ORAL

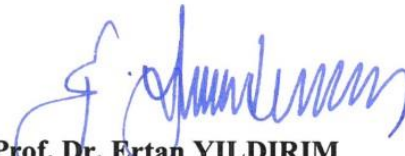
İmza : 

Üye : Yrd. Doç. Dr. Alev MUTLU

İmza : 

Yukarıdaki sonuç;

Enstitü Yönetim Kurulu 22/10/2015 tarih ve 41/1490 nolu kararı ile onaylanmıştır.


Prof. Dr. Ertan YILDIRIM
Enstitü Müdürü

Not: Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

ÖZET

Yüksek Lisans Tezi

Wi-Fi TABANLI PARMAK İZİ YÖNTEMİ KULLANARAK İÇ ORTAM KONUMLANDIRMA

Işıl KARABEY

Atatürk Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Yrd. Doç. Dr. Levent BAYINDIR

Günümüzde dış ortamlarda kullanıcıyı yönlendirmek amacıyla geliştirilmiş konumlandırma sistemleri, havaalanları, alışveriş merkezleri, hastaneler gibi kapalı ortamlarda da giderek yaygınlaşmaktadır. Dış ortamda GPS gibi küresel navigasyon teknolojileri büyük önem arz ederken, uydu bağlantılarının yokluğu sebebiyle bu teknoloji iç ortamlarda yeterli performansı gösterememektedir. Bu yüzden iç ortam konumlandırma için birçok yöntem geliştirilerek en az maliyette en yüksek doğruluk sağlanmaya çalışılmaktadır. Bu yöntemlerden parmak izi yöntemi, varolan sinyal kaynaklarını kullanabildiği ve cep telefonu gibi yaygın kullanılan cihazlar aracılığıyla uygulanabildiği için diğer iç ortam konumlandırma yöntemlerine göre öne çıkmaktadır. Bu tez çalışmasında, parmak izi yönteminde kullanılan yedi adet sınıflandırma yöntemi (k-en yakın komşu, Nâive Bayes, Rastgele Orman, Geri Yayılım, Destek Vektör Makineleri, Redpin, WASP), iki farklı ortamdan (ev ve işyeri) elde edilen iki farklı veri setine uygulanmıştır. Oluşturulan veri seti ve literatürde yer alan WASP yöntemi için hazırlanan veri seti; sınıflandırma yöntemleri aracılığıyla karşılaştırılmıştır. Bu yöntemlerin doğruluk yüzdeleri, farklı parametreler ile incelenmiş ve her iki veri setinde de birbirleri ile doğru orantılı grafikler elde edilmiştir. Rastgele Orman yöntemi iki veri setinde de oda seviyesinde %87 (iş yeri) ve %72 (ev) doğruluk oranları ile en iyi sonucu vermiştir. Elde edilen doğruluk yüzdeleri arasındaki farkın nedeni incelenmiştir.

2015, 100 sayfa

Anahtar Kelimeler: İç ortam konumlandırma, Wi-Fi tabanlı parmak izi yöntemi, Redpin, WASP

ABSTRACT

MS Thesis

INDOOR LOCALIZATION USING WI-FI FINGERPRINTING TECHNIQUE

Işıl KARABEY

Atatürk University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Assist. Prof. Dr. Levent BAYINDIR

Nowadays, localization systems developed in order to guide the user in outdoors are increasingly used in indoors such as airports, shopping malls, hospitals etc. While global navigation technologies such as GPS are effective in outdoors, due to lack of satellite links this technology can not perform adequately in indoor environments. Therefore many methods are developed for indoor localization targeting to provide the highest accuracy at least cost. Among these methods, fingerprinting method surpasses the others because it uses the existing signals in the environment and it can be applied via common used devices such as mobile phones. In this thesis, seven classification methods (k Nearest Neighbor, Naïve Bayes, Random Forest, Backpropagation, Support Vector Machine, Redpin, WASP) used in fingerprinting method were applied to two different datasets obtained from two different environments (home and business). Generated data set and WASP data set in literature were compared by classification methods. The accuracy percentages of these methods were examined with different parameters and proportional graphs were obtained in both datasets. In both datasets, Random Forest method gave the best results with 87% (business) and 72% (home) accuracy rate in room level. The cause of the difference in the accuracy percentages obtained from two datasets was examined.

2015, 100 pages

Keywords: Indoor localization, Wi-Fi based fingerprinting method, Redpin, WASP

TEŐEKKÜR

Bu tezin araştırma konusunun yürütülmesinde danışmanlık yaparak bana yol gösteren danışman hocam Sayın Yrd. Doç. Dr. Levent BAYINDIR başta olmak üzere çalışmalarım sırasında manevi desteklerini esirgemeyen annem, babam ve kardeşlerime, özellikle tavsiyeleriyle bana yol gösteren ablam Canan Nur KARABEY'e Őukranlarımı sunuyorum.

Ayrıca çalışma sürecimde yanımda olan değerli dostlarımdan mesai arkadaşım Pouneh ABDOLLAHI FARD'a, çocukluk arkadaşlarım Hatice ERTUĞRUL ve Gülşen YAYLALI'ya, meslektaşlarım Hilal KOÇ ve Dilruba GEYİKOĞLU'na en içten teşekkürlerimi sunuyorum.

Işıl KARABEY

Eylül, 2015

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
SİMGELER ve KISALTMALAR DİZİNİ.....	vi
ŞEKİLLER DİZİNİ.....	viii
ÇİZELGELER DİZİNİ.....	x
1. GİRİŞ.....	1
1.1. İç Ortam Konumlandırma Üzerine Çalışan Şirketler.....	3
1.2. İç Ortam Konumlandırma Uygulama Alanları.....	14
2. KAYNAK ÖZETLERİ.....	20
2.1. Konumlandırma.....	20
2.2. İç Ortam Konumlandırma.....	21
2.2.1. Performans ölçütleri.....	22
2.2.1.a. Doğruluk.....	22
2.2.1.b. Hassasiyet.....	22
2.2.1.c. Karmaşıklık.....	23
2.2.1.d. Ölçeklenebilirlik.....	23
2.2.1.e. Sağlamlık.....	24
2.2.1.f. Maliyet.....	24
2.3. İç Ortam Konumlandırma Teknolojileri.....	25
2.3.1. Kamera.....	26
2.3.2. Kızılötesi.....	27
2.3.3. Ses.....	28
2.3.4. WLAN/Wi-Fi.....	28
2.3.5. Bluetooth.....	29
2.3.6. Hücresel ağlar (GSM).....	30
2.3.7. RFID (Radio Frequency Identification).....	31
2.3.8. Ultra geniş bant.....	32
2.3.9. Yüksek hassasiyetli GPS/GNSS.....	33

2.3.10. Sanal uydular (Pseudolites).....	34
2.3.11. FM radyo	35
2.3.12. ZigBee	36
2.3.13. Hibrit teknolojiler	36
2.3.14. Eylemsizliğe dayalı navigasyon	39
2.3.15. Manyetik konumlandırma	39
2.3.16. Altyapı sistemleri	40
2.4. İç Ortam Konumlandırma Yöntemleri	41
2.4.1. Model tabanlı yöntemler	42
2.4.1.a. Yakınlık	42
2.4.1.b. Üçgenleme.....	43
2.4.2. Parmak izi yöntemi.....	44
2.5. Literatür Araştırmaları.....	46
3. MATERYAL ve YÖNTEM.....	54
3.1. Veri Toplama	54
3.2. Verileri Sınıflandırmada Kullanılan Sınıflandırma Yöntemleri.....	59
3.2.1. K-en yakın komşu (kNN)	60
3.2.2. Nâive Bayes (NB)	62
3.2.3. Geri yayılım yöntemi (GY)	63
3.2.4. Destek vektör makineleri (DVM).....	69
3.2.5. Rastgele orman (RO) yöntemi.....	71
3.2.6. Redpin	73
3.2.7. WASP (Weighted AP Similarity Positioning)	77
3.3. Redpin ve WASP Yöntemleri İçin Geliştirilen Uygulama	79
4. ARAŞTIRMA BULGULARI ve DENEYSEL SONUÇLAR	81
4.1. Değişen Parametre Değerlerine Göre Elde Edilen Grafikler	81
4.2. Oluşturulan Veri Seti ve WASP Veri Setinin Karşılaştırılması.....	86
5. SONUÇ ve ÖNERİLER.....	93
KAYNAKLAR	95
ÖZGEÇMİŞ	101

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

E_{Ap}	Eğitim Veri Setindeki Sinyal Gücü
T_{Ap}	Test Veri Setindeki Sinyal Gücü
N	Erişim Noktası Sayısı
δ	Sinyal Gücünün Değerine Göre 1-0 Sonucu Veren Fonksiyon
Π	İkili ve İşlemi
\oplus	İkili özel veya İşlemi
α	Benzer Erişim Noktası Sayısının Katsayısı
β	Benzer Olmayan Erişim Noktası Sayısının Katsayısı
γ	Benzerlik Fonksiyonunun Katsayısı
σ	Benzerlik Fonksiyonunda Kullanılan Ağırlık Değeri
ω	Benzerlik Fonksiyonunda Kullanılan Eşik Değer
ε	Epsilon
H	Yardımcı Fonksiyon
η	Geri Yayılım Yönteminde Kullanılan Öğrenme Katsayısı

Kısaltmalar

AR	Artırılmış Gerçeklik
BLE	Düşük Enerjili Bluetooth
CCD	Şarj Eşleştirmeli Cihaz
DVM	Destek Vektör Makineleri
FM	Frekans Modülasyonu
GSM	Mobil İletişim için Küresel Sistem
GY	Geri Yayılım Yöntemi
ISM	Sınai, Bilimsel ve Tıbbi Cihaz Bandı
kNN	K-En Yakın Komşu

NB	Näive Bayes
NCAP	Benzer Eriřim Noktalarının Sayısı
NNAP	Benzer Olmayan Eriřim Noktalarının Sayısı
PMI	Eriřim Noktalarının Her Bir Etiket ile İliřkili Olma Olasılıđını Hesaplayan Fonksiyon
RO	Rastgele Orman Yöntemi
RSS	Alınan Sinyal Gücü
RSSI	Alınan Sinyal Gücü Göstergesi
SIM	Benzerlik Fonksiyonu
WASP	Ađırlıklı Eriřim Noktası Benzerliđi Konumlandırma
WLAN	Kablosuz Yerel Alan Ađı
YSA	Yapay Sinir Ađı

ŞEKİLLER DİZİNİ

Şekil 1.1. İç ortam konumlandırma teknolojileri ve servislerine yapılan ve yapılacak olan tahmini harcamalar	2
Şekil 2.1. İç ortam konumlandırma teknolojilerine genel bir bakış.....	25
Şekil 2.2. Görülebilir ışınların dalga boyu ve frekans aralığı	26
Şekil 2.3. Kızılötesi dalgaların dalgaboyu ve frekans aralığı	27
Şekil 2.4. Ultrasonik sinyallerin dalgaboyu ve frekans aralığı	28
Şekil 2.5. Wi-Fi sinyallerinin dalgaboyu ve frekans aralığı	29
Şekil 2.6. Bluetooth sinyallerinin dalgaboyu ve frekans aralığı	30
Şekil 2.7. Hücresel ağların dalgaboyu ve frekans aralığı.....	31
Şekil 2.8. RFID'nin kullanıldığı dalgaboyu ve frekans aralıkları.....	31
Şekil 2.9. Ultra geniş bant teknolojisinin dalgaboyu ve frekans aralığı	32
Şekil 2.10. Ultra geniş bant ile diğer radyo frekans standartlarının karşılaştırılması	33
Şekil 2.11. GPS sinyallerinin dalgaboyu ve frekans aralığı.....	33
Şekil 2.12. Sanal uyduların GPS sistemindeki rolü	34
Şekil 2.13. FM radyo sinyallerinin dalgaboyu ve frekans aralığı	35
Şekil 2.14. ZigBee teknolojisinin dalgaboyu ve frekans aralıkları	36
Şekil 2.15. İç ortam konumlandırma yöntemleri	42
Şekil 2.16. Çevrim dışı (veri toplama) safhası.....	44
Şekil 2.17. Referans noktası ile erişim noktası arasındaki ilişki.....	45
Şekil 2.18. Çevrim içi (konumlandırma) safhası	46
Şekil 3.1. Veri setinin hazırlandığı evin krokisi	55
Şekil 3.2. Ortamdaki Wi-Fi sinyallerini listeleyip kaydetmeyi sağlayan android uygulama	56
Şekil 3.3. Veri toplama aracı akış diyagramı	58
Şekil 3.4. Bulunulan ortamın ismi ve o ortamda görülen Wi-Fi sinyallerinden oluşan veri seti.....	59
Şekil 3.5. K-en yakın komşu (kNN) yöntemi	61
Şekil 3.6. YSA'ya ait bir algılayıcının temel yapısı	63
Şekil 3.7. Çok katmanlı geri yayımlı yapay sinir ağı	64

Şekil 3.8. Geri yayılım yönteminin akış diyagramı	67
Şekil 3.9. DVM yönteminde karar sınırı ve kenar belirleme	69
Şekil 3.10. DVM yönteminde doğrusal olmayan sınıflandırma	70
Şekil 3.11. Doğrusal olarak ayırlamayan verilerin yüksek boyuta taşınması	70
Şekil 3.12. Rastgele orman yöntemi veri akış diyagramı	72
Şekil 3.13. kNN, Redpin ve WASP yöntemlerinin gerçekleştiği Java uygulaması.....	80
Şekil 4.1. k parametresine göre oluşturulan veri setinin sınıflandırma doğruluğu (Her k degeri için program 10 kez çalıştırılıp ortalama değerler alındı).....	81
Şekil 4.2. k parametresine göre WASP veri setinin sınıflandırma doğruluğu (Her k degeri için program 10 kez çalıştırılıp ortalama değerler alındı).....	82
Şekil 4.3. Ağaç sayısına göre oluşturulan veri setinin sınıflandırma doğruluğu (Her ağaç sayısı için program 10 kez çalıştırılıp ortalama değerler alındı) ...	83
Şekil 4.4. Ağaç sayısına göre WASP veri setinin sınıflandırma doğruluğu (Her ağaç sayısı için program 10 kez çalıştırılıp ortalama değerler alındı).....	84
Şekil 4.5. Gizli katmanda bulunan düğüm sayılarına göre oluşturulan veri setinin sınıflandırma doğruluğu (Her düğüm sayısı için program 10 kez çalıştırılıp ortalama değerler alındı)	85
Şekil 4.6. Gizli katmanda bulunan düğüm sayılarına göre WASP veri setinin sınıflandırma doğruluğu (Her düğüm sayısı için program 10 kez çalıştırılıp ortalama değerler alındı)	86
Şekil 4.7. Ayırt edici erişim noktalarının odalarda görülme yüzdeleri.....	90
Şekil 4.8. Eğitim verileri üzerinde sınıflandırma yöntemlerinin model oluşturma süresi (kNN, Redpin ve WASP için k=5 degeri alınmıştır).....	91
Şekil 4.9. Sınıflandırma yöntemlerinin test aşamasında harcadığı zaman (kNN, Redpin ve WASP için k=5 degeri alınmıştır)	92

ÇİZELGELER DİZİNİ

Çizelge 1.1. İç ortam konumlandırma üzerine çalışan şirketler ve geliştirdikleri çözümler.....	9
Çizelge 2.1. Mevcut konumlandırma teknolojilerinin karşılaştırılması.....	38
Çizelge 4.1. Sınıflandırma yöntemlerinde kullanılan parametrelerin varsayılan değerleri	87
Çizelge 4.2. Uygulanan yöntemlerin oluşturulan veri seti ve WASP veri seti için doğruluk yüzdeleri	88
Çizelge 4.3. Oluşturulan veri setinde erişim noktalarının odalarda görülme yüzdeleri.....	89

1. GİRİŞ


Son yıllarda popülerliği artarak önem kazanan iç ortam konumlandırma sistemleri, iç ortamlarda hareketli bir cihazın bulunduğu konumu tespit etme amacıyla kullanılan teknolojileri ve konumlandırma yöntemlerini içermektedir.

Dış ortamlarda kullanılan uydu tabanlı navigasyon sistemi gibi tek bir teknolojiye dayalı genel bir çözüm, iç ortamlar için henüz bulunamamıştır. GPS, GNSS/CORS olarak adlandırılan Küresel Uydu Sistemleri, dış ortamlarda yüksek doğrulukta ve gerçek zamanlı konum belirlemede en etkili çözüm iken; GPS uydularından alınan sinyaller çoğu engelden geçerken zayıfladığı için kentsel kanyonlarda, duvarlar, kapılar, binalar ve ağaçlara yakın yerlerde, iç ortam ve yeraltı ortamlarında etkili çalışmamaktadır (Farid *et al.* 2013). Bu nedenle iç ortam konumlandırma geçmiş yıllardan beri geliştirme ve araştırma odağı haline gelmiştir.

Teknolojinin gelişmekte olduğu modern çağda iç ortam konumlandırmaya hemen hemen her alanda ihtiyaç duyulmaktadır. İç ortamlarda konumlandırma; havaalanı, alışveriş merkezi, tren istasyonu, hastane, müze, üniversite gibi kapalı ortamlarda kullanıcıların konumlarının bilinmesi, bir mağazada aranan bir ürünün bulunabilmesi, mağazalardaki promosyon ve indirimlerden yararlanılabilmesi, bir AVM'de kullanıcının arabasını park ettiği yeri bulabilmesi (Lan 2014), ev ortamında yeri unutulmuş bir eşyanın bulunabilmesi (Huynh *et al.* 2014), görme engelli bir bireyin kapalı bir alanda otomatik yönlendirilmesi (Serrao *et al.* 2015) gibi günümüzde birçok alanda kullanılmaktadır.

Birçok alanda faaliyeti sürdürülen küresel iç ortam konumlandırma pazarı, IGate araştırma grubuna göre 2013 yılında 448,6 milyon dolar iken bu pazarın 2018 yılında 2,6 milyar dolara büyüyeceği tahmin edilmektedir (Babu and Yalamanchili 2014). Bu alanda en gelişmiş ülke olan Amerika'da, iç ortam konumlandırma için donanım, servis ve lisans ücretlerine yapılan harcamanın Opus araştırma grubuna göre, 2018 yılında 1,6 milyar dolara ulaşacağı tahmin edilmektedir (Sterling and Top 2014). Artan talep ve

elde edilen verim doğrultusunda daha iyi iç ortam konumlandırma sistemleri geliştirmek için her geçen yıl daha fazla harcama yapılmaktadır. Şekil 1.1'de iç ortam konumlandırma teknolojileri ve servislere yapılan harcamalar ve ileri yıllar için yapılan tahminler verilmektedir.



Şekil 1.1. İç ortam konumlandırma teknolojileri ve servislerine yapılan ve yapılacak olan tahmini harcamalar (Sterling and Top 2014)

İleride performansın daha da iyileştirilmesi ile birlikte iç ortam konumlandırma uygulamaları çok daha farklı boyutlarda kullanıma sunulacaktır (Mautz 2012). Aşağıda iç ortamlarda geliştirilen konum tabanlı servislerin kullanım alanlarına yer verilmiştir.

İç Ortamlarda Konum Tabanlı Servisler: Mobil cihaz ile içerik bağımlı bilgi erişimini sağlamak için coğrafi pozisyondan yararlanan konum tabanlı servisler toplu pazar için geliştirilmiş ticari uygulamalarda yer almaktadır. Bu servisler hem iç hem de dış ortamda günümüzde yaygın bir şekilde kullanılmaktadır. İç ortamlarda konum tabanlı servislere örnek olarak sinema, konser veya çevredeki olaylar hakkında emniyet bilgileri ya da mekân hakkında bilgi veren servisler verilebilir. Ayrıca konum tabanlı servisler, bir kamu binası içerisinde bulunan bir ofis ve ya alışveriş merkezinde kişiyi aradığı yere yönlendirmeyi, otobüs ya da tren istasyonlarında kullanıcıyı doğru otobüs durağına ya da doğru platforma yönlendirmeyi de sağlamaktadır. Bir mağaza ya da depo içerisinde ürünlerin yer tespiti, müşterilerin yanı sıra uygulama geliştiricisinin de ilgisini çekmektedir. Özellikle konum tabanlı reklamlar, konum tabanlı faturalama ve yerel arama hizmetleri yüksek ticari değere sahiptir.

TechNavio adlı piyasa araştırma şirketinin analistleri tarafından yapılan bir araştırmada, Amerika'da en iyi 33 adet iç ortam konum tabanlı servis şirketi bulunduğu bildirilmiştir (Anonymous 2003b). Bu şirketlerden bazıları iç ortam konumlandırma uygulamaları geliştirirken bazıları iç ortamlar için harita oluşturmaktadır. İç ortam konumlandırma alanında önemli bir konuma gelmiş, harita sağlayıcı ve uygulama geliştirici şirketler aşağıda alt başlıklar altında kısaca açıklanmıştır.

1.1. İç Ortam Konumlandırma Üzerine Çalışan Şirketler

Harita sağlayıcı şirketler: Google şirketi, önde gelen iç ortam konum servisi harita sağlayıcılarından biridir. Şirket ayrıca iç ortamlarda arkadaş bulma uygulaması üzerine de çalışmaktadır. Çoğunlukla havalanları, alışveriş merkezleri, perakende zincirleri, müzeler, kongre merkezleri, hastaneler, oteller, kütüphaneler, dini merkezler, spor tesisleri ve üniversitelerde konumlandırma üzerine yoğunlaşmıştır. Şirket daha hızlı oranda kullanıcı sayısını genişletmek için çeşitli perakende zincirler ile ortaklıklar geliştirmektedir.

Nokia şirketinin bir alt kuruluşu olan HERE şirketi dijital harita sağlayıcılarının liderlerinden biridir. Şirket, detaylı yol ağlarını temsil eden yüksek kaliteli ve doğru iç ortam haritaları üretmektedir. Harita ürününün ismi “HERE Destination Maps” olarak adlandırılmıştır. Şirket; Amerika, Çin ve Hindistan’a odaklanarak 2011 yılında birçok kapalı ortamın kat ve zemin haritalarını üretmeye başlamıştır. Bir diğer iç ortam konum servisi harita üreticilerinden Micello şirketi, dünya genelinde 15.000’den fazla zemin haritası ile son yıllarda hızla büyümektedir. Micello diğer iç ortam konum servis sağlayıcılar ile karşılaştırıldığında Amerika’da alışveriş merkezleri ve perakende satış alanlarının büyük bir kısmını kaplamıştır. Fakat Amerika dışında çok kısıtlı bir varlığı vardır. Ericsson’un iç ortam haritaları ve konumlandırma platformu, geliştiricilere kendi iç ortam haritalarını oluşturmak için araçlar sunar. Bütün bir sistem, harita geliştirme ortamı, android harita geliştirme arayüzü ve android Wi-Fi konumlandırma arayüzünü içerir. Harita geliştirme ortamı, kullanıcının kendi iç ortam haritasını oluşturmasına olanak verir. Android harita geliştirme arayüzü ise kişilerin kendi uygulamalarında birçok iç ortam haritasının entegre bir şekilde kullanılmasını sağlar.

Uygulama ve platform geliştirici şirketler: Apple şirketi, 2013 yılında 20 milyon dolar değerinde WifiSLAM uygulamasını üretime sunmakla birlikte üç boyutlu iç ortam konum servisi uygulamalarının gelişimi için de büyük miktarda yatırım yapmıştır (Anonymous 2003b). WifiSLAM uygulaması binalarda mevcut olan WLAN altyapısını kullanır. Sadece Wi-Fi sinyalleri aracılığıyla gerçek zamanda 2.5 m doğruluğa kadar ulaşmıştır (Anonymous 2013b). Apple şirketi, adım adım iç ortam navigasyonundan, yakınlık tabanlı sosyal ağ, ürün düzeyinde müşteri yönlendirme gibi çeşitli uygulamalar üzerinde de çalışmaktadır.

Kentsel alanlarda konumlandırma sağlamak için Wi-Fi konumlandırma sistem geliştiricisi olan Skyhook şirketi 2003 yılında Boston’da kurulmuştur. Skyhook’un patentli konumlandırma sistemi, Wi-Fi ile birlikte GPS, hücre kuleleri, IP adresleri ve cihaz sensörlerin birlikte kullanımı ile herhangi bir Macintosh işletim sistemli cihazda en hızlı ve doğru konumlandırma yapmayı amaçlamaktadır (Anonymous 2003a).

İç ortam konum servisi uygulamaları ve platform geliştiricilerinin öncülerinden biri olan Shopkick şirketi Amerika dışında çok kısıtlı varlığı olmasına rağmen, Nielsen araştırma hizmetlerine göre, burada geliştirilen uygulamalar 6 milyondan fazla kişi tarafından ilgi görüp en çok kullanılan alışveriş uygulamaları olarak seçilmiş ve dünya genelinde dördüncü olmuştur. Shopkick, 2013 yılında shopBeacon platformunu kullanarak büyük bir perakendeci ile ilk Apple iBeacon programını başlatmıştır (Anonymous 2010c). Bluetooth işaretçileri ile çalışan ve 2015 yılı sürümü ile Android ve IOS marketlerde yayınlanan ShopKick uygulaması, kullanıcının girdiği mağazaya göre ürün indirimlerinden haberdar etme, Macy, Target, Loreal ve Best Buy gibi ünlü markalarda ücretsiz hediye kartı sunma gibi özelliklere sahiptir. Bluetooth işaretçilerini kullanan Meridian Apps isimli diğer bir şirket, konum tabanlı servisler sunan bir mobil uygulama platform sağlayıcısıdır. HERE şirketi tarafından geliştirilen iç ortam konum servis haritalarını kullanan Microsoft şirketi ise, insanlara ve işletmecilere yardım eden çözümler, cihazlar, servisler ve yazılımlar sunma konusunda dünya genelinde güvenilir şirketlerden biridir. Şirket, Nokia şirketini satın aldığından beri iç ortam konum servisleri sağlamaktadır.

İç ortamlarda gerçek zamanlı konum sistemi sağlayıcılarının önde gelen isimlerden biri olan Ekahau, nesnelerin ve insanların konum takibi için Wi-Fi RFID etiketlerini kullanır. Şirketin Wi-Fi etiketleri çift yönlü iletişim sağlayarak nesneleri ve insanları izlemek için sağlık hizmetlerinden endüstriyel uygulamalara kadar kullanılır (Anonymous 2000a). Wi-Fi sinyalleri kullanarak gerçek zamanlı iç ortam konumlandırma pazarında önde gelen ve özellikle sağlık alanında gerçek zamanlı konum çözümleri üreten bir diğer şirket ise AeroScout adlı şirkettir. Bu şirket, konum çözümlerini Amerikan Hastanesi Derneği'nde uygulamıştır. Wi-Fi sinyalleri aracılığıyla kullanıcının arkadaşlarının konumunu bulmayı ve alışveriş merkezinde, havaalanı, kongre merkezleri gibi bina içlerinde kullanıcıyı yönlendirmeyi sağlayan Navizon şirketi ise 2005 yılında Amerika'da kurulan, kablosuz cihazların coğrafi konumu için konum tabanlı servisler sağlayan ve iç ortam konumlandırma öncü olan şirketlerden biridir (Anonymous 2005a). Arkadaş konumu bulma üzerine çalışan Sensewhere isimli diğer bir şirket, mobil cihazlarda konum tabanlı servisleri çalıştıran iç ortam

konumlandırma çözümleri sunar. GPS uydu verilerinin doğru sonuç vermediği kentsel alanlar ya da iç ortamlarda haritalanmış yazılım teknolojisiyle konum bilgisi sağlamaktadır. Şirketin portföyünde iç ortam haritalama ve arkadaş konum tespiti yapan Friendswhere isimli uygulama bulunmaktadır. Ayrıca şirketin geliştirdiği Snapp isimli uygulama kullanıcıların en ücra ortamda bile sosyal medya güncellemelerini yapabileceği bir uygulamadır. Şirketin geliştirdiği Adwhere isimli platform, GPS'in kapsama alanının düşük olduğu yerlerde potansiyel müşterilere kuponlar, çekler, akıllı bağlam bilinçli reklamlar sunan konum tabanlı bir platformdur (Anonymous 2009b).

Qualcomm şirketi 3G, 4G ve gelecek nesil kablosuz teknolojilerde dünyada öncü gelen şirketlerden biridir. Şirketin geliştirdiği Qualcomm Izat adlı uygulama, iç veya dış ortamda restoran, mağaza, benzin istasyonu gibi özel alanlara yönlendirme, araba sürerken yol tarifi veya havaalanı, alışveriş merkezi, müze gibi kapalı ortamlarda aranılan yeri bulma, kayıp olan bir nesneyi gerçek zamanlı bulabilme gibi birçok özelliğe sahiptir. En doğru konumu elde etmek için çeşitli mobil, ağ ve bulut teknolojilerini kullanır (Anonymous 2015f). Bilgi teknolojilerinin dünya çapında bir diğer lideri olan Cisco şirketinin konum kontrol protokolü, WLAN denetleyicilerinin basit ağ yönetim protokolü seçimini güçlendirir ve uzaktan ölçüm, tıkanma ve Wi-Fi etiket programları için yeni tanıtılan Cisco uyumlu uzantılar ile ilişkili acil bildirim özellikleri için ulaşım hizmeti verir.

CommScope şirketinin ürettiği en yeni konum teknolojilerinden GeoLENs ile firmalar, artık sosyal ağ ve kurumsal uygulamalarının yanı sıra kamu güvenliği iletişimi ve mobil pazarlama fırsatını bulmak için konum hedefli acil mesajlaşmayı destekleyebilmektedir. GeoLENs, servis sağlayıcının ağı tarafından desteklenen herhangi bir mobil konum yöntemini kullanır. Hükümet ve kamu hizmetleri için iletişim çözümleri sunan bir diğer şirket Teldio'dur. Şirket, herhangi bir bluetooth algılayıcı cihaz ile çalışanların takibi ve konumlandırılmasını sağlayan bir iç ortam konumlandırma sistemi sunmaktadır. Kullanıcı herhangi bir acil durumda kurum içinde, bu sistem aracılığıyla panik alarmı verip son konum bilgisini ilgili merkeze gönderebilmektedir (Anonymous 2008b).

2008 yılında Amerika’da kurulmuş olan Aisle411 şirketi, perakendeciler için önde gelen iç ortam konum platformu sağlayıcısıdır. Şirket, kullanıcının aradığını bulması ve indirimlerden faydalanması için ortamdaki Wi-Fi sinyallerini kullanarak geliştirilen bir mobil perakende navigasyon sistemi ve sosyal alış veriş platformu sunmaktadır. Bir diğer alış veriş platformu sunan ve şirket ismini alan FastMall uygulaması, çevrim dışı alış veriş navigasyonunda en iyi mobil platformu sağlamak için alış veriş tutkunları, ebeveynler, geliştiriciler, vizyon sahipleri ve mühendislerden oluşan bir çok kişi tarafından geliştirilmiştir. Fikir başlangıçta alışveriş merkezlerinde lavabo, asansör, mağaza isimlerinin bulunduğu yönlendirme tabelalarının çok karmaşık olduğunu düşünen FastMall’in kurucularından Sam Feuer’in eşi Amie tarafından ortaya atılmıştır. 2009 yılında geliştirilen FastMall, GPS, Wi-Fi ya da herhangi bir sinyal kullanmadan alış veriş merkezlerindeki restoranları, mağazaları, lavaboları bulabilmek için kullanıcıyı yönlendiren, topluma fayda sağlayan kullanıcı etkileşimli bir uygulamadır (Anonymous 2009c).

Manyetik alan tabanlı iç ortam konumlandırma teknolojisi sunan IndoorAtlas şirketi, bina içine giren manyetik anomaliler ve konum tespiti için cep telefonlarını kullanır. Mağaza indirimi, mobil oyun, lojistik verimliliği ya da bir alış veriş merkezinde ya da bir havaalanında kişinin aradığı yönü bulması gibi durumlarda iç ortam konumlandırma uygulamalarının farkındalığını oluşturmak için işletmelere ve bireylere bir araç kutusu sunmaktadır. Şirketin araç kutusu, coğrafi koordinat sistemi ile bina kat planını oluşturmak ve yönetmek için kullanıcıya bir çözüm sağlayan IndoorAtlas kat planlarını içerir. Harita oluşturucu, kat planlarının yanı sıra binaların manyetik haritalarını oluşturmak için kullanılan bir mobil uygulamadır.

2005 yılında California’da kurulan NearByNow adlı şirket, yakındaki mağazada olan ürünlerin yeri ve konumu, çevrim içi satın alma, kullanıcıyı son ürünler hakkında güncellenmiş bilgiler (son indirimler, markalar vs) ile bilgilendirme için mobil alış veriş uygulamaları oluşturur. Meijer şirketinin geliştirdiği “Meijer Find it” uygulaması ise iç ortamlarda market öğelerini bulmak için kullanılmaktadır. Şirket aynı zamanda uygulama üzerinden gerçek zamanlı reklam sağlamakta ve kullanıcının harcama

davranışını da takip etmektedir. Aranılan bir öğenin bulunmasının yanı sıra kullanıcı kendi yaşamını da kayıt altına almak isteyebilir. Bunun için geliştirilen Follow Me uygulaması iPhone, iPod Touch ve BlackBerry cihazlarda çalışabilmekte ve kullanıcının hayatını takip edebileceği ve kayıt altına alınan bir anısını kolaylıkla paylaşabileceği bir mobil platform sunmaktadır. Amerika'nın California eyaletinde kurulan bir diğer şirket olan Pole Star, popüler bir iç ortam konum servis platform sağlayıcısıdır (Anonymous 2008c). Şirketin iç ortam konumlandırma çözümü, Wi-Fi, GPS, Bluetooth, hareket sensörleri ve harita verilerinin birleşimi ile hibrit bir teknolojiye dayanmaktadır. iPhone ve Android uyumlu NAO Campus adında geliştirilen bu uygulama, alışveriş merkezlerinde, havaalanlarında, kongre merkezlerinde ve müzelerde kullanıcıyı yönlendirebilmektedir.

Signal360 isimli şirket, müşterilerle iletişim kurmak için kullanılan Android BLE ve Ibeacon destekli BLE standardının yanı sıra bulut tabanlı ve mobil bildirim platformları ile kullanıcıyı gittiği mağazaya göre gerçek zamanlı bilgilendiren bir platform içerir (Anonymous 2011a). Şirketin geliştirdiği IZIT uygulaması ile müşterilerin bulunduğu yerlere yakın mağazalar hakkında bilgi verilerek indirimlerden faydalanma, hangi mağazada ya da restoranda güne özel ne tür fırsatların olduğunu kullanıcıya bildirim yoluyla cep telefonu aracılığıyla sunar.

STMicroelectronics kontrol sistemleri, endüstriyel otomasyon, tüketici ürünleri, telekomünikasyon sistemlerini içeren birçok mikroelektronik uygulama geliştirmektedir. Şirket ürünü olarak iç ortamlarda park alanlarında veya tünellerde GPS sinyalinin doğru alınamadığı ortamlarda konumlandırma doğruluğu geliştiren, sensör tabanlı yaya parakete hesabı teknolojisi için ideal çözüm olan STA8088EXG isimli bir cihaz üretilmiştir (Anonymous 1987a). Endüstrinin en doğru ve detaylı iç ortam analitiklerini sunma üzerine yoğunlaşan bir diğer şirket olan WirelessWERX, tüketici davranışlarını konum analitikleriyle değerlendirir. Şirket, kullanıcının alışveriş yolu, bekleme süresi, trafik yoğunluğu, hangi ürünlere ilgi gösterdiği ve bölge, konum gibi diğer metrikleri içeren bir raporlama sunar. Böylece yüksek kalitede, kolay kullanımlı formatta ve hızlı bir şekilde tüketici konum verilerini analiz eder (Anonymous 2015h).

Böylece mağazalarda müşteri memnuniyetini ve satış oranını artırmaya yardımcı olan bir platform sağlanmaktadır.

Yukarıda bahsedilen şirketlerin yanısıra iç ortam konumlandırma üzerine çalışan birçok şirket bulunmaktadır. Opus araştırma grubunun yaptığı araştırma doğrultusunda iç ortam konumlandırma için çeşitli teknolojiler kullanan ve çözümler üreten şirket isimleri, kullandıkları teknolojiler, iç ortam konumlandırmaya sağladığı çözümler ve internet adresleri Çizelge 1.1’de verilmiştir.

Çizelge 1.1. İç ortam konumlandırma üzerine çalışan şirketler ve geliştirdikleri çözümler (Sterling and Top 2014)

Şirket Adı	Teknoloji/Sektör	Kategori	Web Sitesi
9Solutions	BLE / İç ortam konumlandırma	Yazılım	www.9solutions.com/ en/
AINSI	Eylemsizliğe dayalı/Pusula ile konumlandırma	Yazılım	ainsi.pro
AIONAV Systems Ltd	Eylemsizliğe dayalı konumlandırma	Yazılım	www.aionav.com/
aisle411	Wi-Fi parmak izi ile konumlandırma / Sensörler	Yazılım	aisle411.com
AisleFinder	Süpermarket uygulaması	Yazılım	aislefinder.com/
Apple	Wi-Fi parmak izi ile konumlandırma (WiFiSlam) / iBeacon	Yazılım	-
Bing Maps	İç ortam haritalama	Haritalama	www.bing.com/
BlinkSight	Çip seti, gerçek zamanlı konumlandırma sistemleri	Donanım	www.blinksight.com/
Boingo Wireless	Wi-Fi ağ sağlayıcı	Donanım	www.boingo.com/
BrickTrends	Mağaza içi analizler	Reklamcılık / Pazarlama	www.bricktrends.com / /
Broadcom	Çip ve kablosuz teknoloji	Donanım	www.broadcom.com/ products/features/GN SS.php

Çizelge 1.1. (devam)

BuildingLayer	İç ortam haritalama	Haritalama	buildinglayer.com/
ByteLight	İç ortam konumlandırma/LED	Yazılım	www.bytelight.com/
Catalina Marketing	Mobil, satın alma tabanlı etiketleme platformu	Reklamcılık / Pazarlama	www.catalinamarketing.com/
Cisco	Ağ ve kablosuz teknoloji	Donanım	www.blogs.cisco.com
Combain	Mobil konumlandırma	Yazılım	www.combain.com/
Critigen	İç ortam haritalama	Haritalama	www.critigen.com/
CSR	Sensör eritme çipi	Donanım	www.csr.com
Ekahau	Gerçek zamanlı konumlandırma sistemi (Wi-Fi üzerinden RFID)	Yazılım	www.ekahau.com/
Ericsson Labs	İç ortam konumlandırma platformu	Haritalama	labs.ericsson.com
ESRI	İç ortam konumlandırma, izleme, yönlendirme	Haritalama	http://www.esri.com/
Estimote	Bluetooth işaretçileri	Donanım	estimote.com/
Euclid	Veri odaklı analiz teknolojileri	Yazılım	euclidanalytics.com/about/
EveryFit	Wi-Fi parmak izi ile konumlandırma, Sensörler	Donanım	www.qmedichealth.com/
FastMall	İç ortam haritalama	Haritalama/ Tüketici uygulaması	fastmall.com/
FloorPlanMapper	Etkileşimli harita platformu	Haritalama	floorplanmapper.com/index.html
GISi Indoors	İç ortam konumlandırma ve konum analizleri	Yazılım	gisiindoors.com/
Glopos	İç ortam konumlandırma	Yazılım	www.glopos.com/
Google	İç ortam haritalama ve konumlandırma	Yazılım	maps.google.com/help/maps/indoormap/
Guardly	Wi-Fi parmak izi ile konumlandırma	Yazılım	www.guardly.com/
Guidebook	Mobil uygulama platformu	Tüketici uygulaması	guidebook.com/
HW Communications	Konumlandırma teknolojileri	Donanım	cyber.hwcomms.com/cyber/

Çizelge 1.1. (devam)

iInside	İç ortam konum analizleri	Yazılım	iinside.com/
Incomm	Alışveriş deneyimi / Mobil ödemeler	Yazılım	Incomm
Indoo.rs	Wi-Fi parmak izi ile konumlandırma / Manyetik alan	Yazılım	indoo.rs/
Indoor Atlas	Manyetik Alan	Yazılım	www.indooratlas.com/
IndoorGo	İç ortam navigasyon sistemleri	Yazılım	www.indoorgo.com/
IndoorOSM	İç ortam haritalama	Haritalama	indoorosm.uni-hd.de/
InMarket	Mağaza içi alışveriş platformu /iBeacon	Yazılım/Donanım	www.inmarket.com/
Insiteo	İç ortam konumlandırma	Yazılım	www.insiteo.com/joomla/index.php/en/
InvisiTrack	İşaretçiler/ 4G üzerinden konumlandırma	Yazılım/Donanım	www.invisitrack.com/index.html
iWay	İç ortam konumlandırma	Yazılım	www2.iway.nl/nl/index.php
Jiwire	Mobil reklamcılık ve veri platformu	Reklamcılık	www.jiwire.com/
Lighthouse Signal Systems	Wi-Fi parmak izi ile konumlandırma	Yazılım	lighthousesignal.com/
Locata	İç ortamda GPS ile konumlandırma	Haritalama	www.locata.com/
Loctronix	GPS ve konumlandırma sistemleri	Yazılım	www.loctronix.com/en/default.htm
MagicPlan	İç ortam kat planı uygulamaları	Haritalama / Tüketici uygulaması	floorplanner.com/magicplan
Mappedin	İç ortamlarda yön bulma	Yazılım	mappedin.com/
Maptive	Coğrafi konum analizleri	Haritalama	www.maptive.com/
Meridian	İç ortam konumlandırma / Mobil konum platformu	Yazılım	www.meridianapps.com/about
Micello	İç ortam haritalama	Haritalama	micello.com/
Microsoft (Bing)	İç ortam haritalama	Haritalama	bing.com/
Motorola Solutions	Kablosuz ağ çözümleri	Yazılım /Donanım	www.motorolasolutions.com//

Çizelge 1.1. (devam)

Movea	Hareket sensörü ve veri füzyon yazılımı	Yazılım	www.movea.com/
Navisens	Hareket sensör verisi	Yazılım	navisens.com/
Navizon	Wi-Fi ile üçgenleme teknolojisi	Yazılım	www.navizon.com/
NearBuy Systems	Konum tabanlı Wi-Fi analizleri	Yazılım	www.nearbuysystems.com/index.html
NewAer	Yaklaşma platformu	Yazılım	www.newaer.com/
NextNav	İç ortam/Kentsel konumlandırma	Donanım	www.nextnav.com/
Nokia/Here	İç ortam haritalama	Haritalama	here.com/
Omiimii	İç ortam konumlandırma platformu	Yazılım	www.omiimii.com/
Path Intelligence	Veri odaklı analiz teknolojileri	Yazılım	www.pathintelligence.com/
Placecast	Perakendeciler ve markalar için alışveriş alarmları	Reklamcılık / Pazarlama	placecast.net/
Placed	Konum analizleri	Reklamcılık / Pazarlama	www.placed.com/
PlaceIQ	Konum zekâsı ve analizler	Reklamcılık /Pazarlama	www.placeiq.com/
Point Inside	Ürün bulma uygulaması	Yazılım	www.pointinside.com/
Pole Star	İç ortam konumlandırma	Yazılım	www.polestar.eu/en/
Proximus Mobility	Yerel Pazarlama	Yazılım	proximusmobility.com/
Qbengo	Mobil iç ortam navigasyonu	Haritalama	www.qbengo.com/home
Qualcomm Atheros	Konum tabanlı servisler	Donanım/ Yazılım	qca.qualcomm.com/mobile-connectivity/location/
Qubulus	Radyo sinyalleri ile parmak izi tabanlı iç ortam konumlandırma	Yazılım	www.qubulus.com/
Quuppa	Bluetooth ve sensörlerle iç ortam konumlandırma	Yazılım	quuppa.com/
Radius Networks	Mobil yaklaşma platformu	Yazılım	www.radiusnetworks.com/index.html#home

Çizelge 1.1. (devam)

Razorfish	Mobil pazarlama ajansı	Reklamcılık /Pazarlama	www.razorfish.com/
Redpin	Açık kaynak iç ortam konumlandırma	Yazılım	redpin.org/index.html
Retailgence	Mağaza içi harcama çözümleri	Reklamcılık /Pazarlama	www.retailgence.com /
RetailNext	Mağaza içi analizler	Yazılım	www.retailnext.net/
Senion Lab	İç ortam konumlandırma ve navigasyon-sensör füzyonu	Yazılım	www.senionlab.com/
Sensewhere	İç ortam konumlandırma	Yazılım	www.sensewhere.com
Shopkick	shopBeacon / BLE	Yazılım/ Donanım	www.shopkick.com/
Skyhook	Wi-Fi sinyalleri ile üçgenleme çözümü	Yazılım	www.skyhookwireless.com/
Sonic Notify	Bluetooth teknolojisi	Yazılım	sonicnotify.com/
Swirl	Mağaza için mobil pazarlama platformu	Reklamcılık /Pazarlama	www.swirl.com/
Technion Indoor Map Screener	İç ortam konumlandırma haritaları	Haritalama	www.cs.technion.ac.il /~cs234313/Websites/W13/31/site/index.html
The Primacy	Dijital ajans	Reklamcılık /Pazarlama	www.theprimacy.com /
TruePostion	Hibrit kablosuz konumlandırma teknolojisi	Yazılım	www.trueposition.com/
Trusted Positioning	Sensörler/Kablosuz konumlandırma	Yazılım	www.trustedpositioning.com/
TRX Systems	İç ortam navigasyon sistemleri	Donanım/ Yazılım	www.trxsystems.com/
UbiSense	Gerçek zamanlı konumlandırma sistemleri	Donanım/ Yazılım	www.ubisense.net/en/
Verve	Mobil konum pazarlama	Reklamcılık /Pazarlama	www.vervemobile.com/
VisibleBrands	Reklamcılık ve veri ağı	Reklamcılık /Pazarlama	www.visbrands.com/
Visioglobe	İç ortam haritalama	Haritalama	visioglobe.com/

Çizelge 1.1. (devam)

WalkBase	Gelecek nesil perakende analizleri	Yazılım	www.walkbase.com/
Wanderful Media	Yerel keşif alış veriş platformu	Reklamcılık /Pazarlama	wanderful.com/
WhereLab	İç ortam konum platformu	Yazılım	where-lab.com/
Wifarer	İç ortam konumlandırma	Yazılım	www.wifarer.com/
WiFiSlam / Apple	İç ortam konumlandırma	Yazılım	-
Wilocate	Wi-Fi sinyalleri ile üçgenleme teknolojisi	Yazılım	wilocate.net/
WiseSec	Wi-Fi sinyalleri ile üçgenleme teknolojisi	Yazılım	-
xAd	Konum zekası ve analizler	Reklamcılık	www.xad.com/
YFind Technologies	Wi-Fi ağı	Donanım/ Yazılım	www.ruckuswireless.com
ZOS Communications	Wi-Fi sinyalleri ile üçgenleme teknolojisi / Cofrafi sınırlama	Yazılım	www.zoscomm.com/
ZuluTime	Wi-Fi sinyalleri ile üçgenleme teknolojisi	Yazılım	www.zulutimecorp.com/

1.2. İç Ortam Konumlandırma Uygulama Alanları

Ev Ortamı: Ev ortamında kaybolan eşyaların teşhisi, fiziksel mimik oyunları ve evde yerleşime dayalı hizmetler için iç ortam konumlandırma uygulamaları geliştirilmektedir. Ambient Assistant Living (AAL) sistemleri yaşlı bireylerin evlerinde gerçekleştirdiği günlük faaliyetlerinde bireylere yardım sağlar. AAL sistemlerinin temel bir fonksiyonu konum farkındalığıdır ve bu işlem bina içi konumlandırma işlevselliği gerektirmektedir. Evdeki uygulamalar; hayati işaretlerin izlenmesi gibi tıbbi izlemeler, acil durumların teşhisi ve düşme teşhisi gib birçok özellik içerebilir. Ayrıca kişiselleştirilmiş eğlence sistemleri (akıllı ses sistemleri) de evlerde kullanılan iç ortam konumlandırma uygulamaları arasındadır (Zetik *et al.* 2010).

Ortam Teşhisi ve Durumsal Farkındalık: Birçok faydalı fonksiyona sahip mobil araçlarda kullanıcının bulunduğu ortamdaki değişime bağlı olarak mobil cihazın da bu değişimle otomatik uyum sağlaması istenir. Böyle bir fonksiyonellik bireysel durumlarda yardım sağlayarak kullanıcıyı ilave çaba sarfetmeden bazı olumsuzluklardan kurtarabilir. Böyle bir otomatik uyuma imkân vermek için mobil kullanıcının bulunduğu ortamın mobil cihaz tarafından algılanması gerekir. Kullanıcının bulunduğu ortamı belirlemek için gereken en önemli ölçüt, mevcut coğrafi konumdur. Bu alanda iç ortam konumlandırma uygulaması olarak akıllı konferans rehberi yapılarak civardaki oditoryumlarda tartışılan konular hakkında kullanıcıya bilgi verilebilir.

Tıbbi Bakım: Hastanelerde tıbbi personelin acil durumlarda konumunun izlenmesi giderek daha fazla önem kazanmaktadır. Hastanelerdeki tıbbi uygulamalar, ayrıca hasta ve ekipmanın (örneğin hastaların düşüş teşhisi) izlenmesini de içerir. Kusursuz konumlandırma, ameliyat sırasında robotik yardımı için gereklidir. Mevcut analitik cihazlar yerine daha etkin ameliyat cihazları kullanılabilir.

Sosyal Ağ Oluşturma: Özellikle genç neslin ayrılmaz bir parçası haline gelen sosyal ağlar giderek her yaş grubunda sıklıkla kullanılır hale gelmektedir. Çünkü sosyal bütünleşme sosyal ağlarda yapılan iletişim ile gerçekleşmektedir. Aynı anda her yerde konumlandırma, sosyal ağ oluşturmada merkezi bir rol oynar. Örnek olarak ortak aktiviteleri koordine etmek için arkadaşların konumlandırılması verilebilir.

Çevresel İzleme: Çevresel izleme, ısı, basınç, nem, hava kirliliği, nesne ve yapıların deformasyonu gibi bazı olguları gözlemlemek için kullanılır. Bu parametreleri belli bir bina içi ya da bina dışı ortamda izlemek için çoklu sensör düğümleri, kablosuz sensör ağı olarak düzenlenir. Bir kablosuz sensör ağı, küçük, pahalı olmayan, uzaysal olarak dağıtılmış sınırlı işleme ve hesaplama kaynakları olan otonom düğümlerden ve kablosuz iletişim radyolarından oluşur. Düğümlerin konumunu bu sensör düğümlerinin arasındaki mesafe ve yakınlık bilgisinden çıkarmak için işbirlikçi konumlandırmaya adanmış algoritmalar geliştirilmiştir (Mautz *et al.* 2007).

Polis ve İtfaiyeciler: Bina içi konumlandırma sistemleri kanunların uygulanmasında, kurtarma hizmetlerinde ve yangın hizmetlerinde (örneğin yanan bir binadaki itfaiyecinin konumunun belirlenmesinde) önemli faydalar sağlar. Polis teşkilatı da hırsızlığın yapıldığı yerin anında teşhisi, olay sonrası incelemeler için çalıntı ürünlerin konumu, olay yeri kurtarma, konum sınırlama uygulamaları (örneğin, bir kişinin veya bir nesnenin izin verilmediği halde belli bir alanı terketmesi ile alarm çalması) gibi çok sayıda ilişkili uygulamadan yararlanmaktadır.

Akıllı Taşımacılık: Araçların park edilmesi için ayrılmış belirli alanlarda toplu kullanıcı uygulamaları, kullanıcılara otogar içinde yol rehberliği yapabilmektedir. Özellikle sürücüyü otogarda kalan tek bir park boşluğuna yönlendirmek ve oradan da binaya giriş yoluna yönlendirmek mümkün hale gelmektedir (Gusenbauer *et al.* 2010).

Endüstri: Mekanik mühendislik, tam otomatik imalata yönelik akıllı sistemlere doğru gelişmektedir. Pek çok endüstriyel uygulama için bina içi konum duyarlılığı robotik rehberlik, endüstriyel robotlar, robot işbirliği, akıllı fabrikalar-otomobil montaj hatlarında araç yardım sistemleri), otomatik izleme ve kalite kontrol için gerekli bir fonksiyonel unsurdur. İç ortam konumlandırma sistemleri, etiketlenmiş bakım araçlarını ve endüstriyel üretim ortamında fabrikaya dağılmış olan ekipmanı bulmaya yardımcı olur. Otomatik güvenlik sistemlerinin gelişmesi, akıllı işçi koruma ve çarpışmadan kaçınma, böyle bir sistemin konumlandırma kapasitesine dayanır.

Müzeler: Müzelerde, gözetim için ziyaretçi izleme ve ziyaretçi davranışını inceleme, konum tabanlı kullanıcı rehberliği ve ortama duyarlı tetiklenmiş bilgi servisleri gibi pek çok uygulama kullanılabilir. Piyasada geliştirilen bir çok uygulama (NAO Campus, Ibeacon, Infsoft vb.) müzelerde kullanıma sunulmuştur.

Finansal Kuruluşlar: Değerli belgelerin taşınması esnasında bir iç ortam izleme bileşeni gereklidir (Mautz 2012).

Lojistik ve Optimizasyon: Karmaşık sistemlerde süreç optimizasyonu amacıyla varlıkların ve çalışan kişilerin konumuna ilişkin bilgiye sahip olmak gerekir. Örneğin karmaşık bir depolama ortamında istenilen malları çabucak bulmak önemlidir. Doğru konumlandırmaya dayalı olarak her bir birimin izlenmesi mümkün olmaktadır. Konumlandırma; havalanlarında, limanlarda ve tren trafiğinde kargo yönetim sistemlerinin konumlandırılması için daha önce öngörülemez büyüklükte fırsatlar yaratır.

Yardıma Muhtaç İnsanlar için Rehberlik: Görme engeli olan kişilere yardım etmek üzere özel olarak tasarlanmış sistemler, tüm bina içi ve bina dışı ortamlarda kusursuzca çalışmalıdır. Korunmaya muhtaç kişilerin toplu taşımacılık ile bütünleşik şekilde yürütmesine yardımcı olmak için navigasyon sistemlerine genellikle ihtiyaç duyulmaktadır. Bu amaçla Serrao *et al.* 2015 yılında görme engelliler için bir iç ortam navigasyon sistemi geliştirmiştir.

Yapısal Sağlık Gözetimi: Beton içerisinde çelik güçlendiricilere yerleştirilmiş sensörler, basınç ölçümlerini yüksek güvenilirlikle yapabilirler. Pasif sensörlerle bütünleşik RFID'lere dayalı basınç algılama sistemleri; basınç değişimleri ile birlikte yüklenme ve bozulmadan kaynaklanan deformasyonu ölçebilir.

Araştırma ve Jeodezi: Bina içinin araştırılması yeniden inşanın yanı sıra yeni binaların oluşturulması ve geometrik görüntüsünü içerir. CAD, GIS ya da CityGML'ne veri girdisi için küresel referansa sahip konumlandırmaya ihtiyaç duyulur. Doğruluk gereksinimleri milimetreden santimetreye değişen bir çeşitlilik gösterir.

Yer altı İnşaatı: Tozlu, karanlık, nemli ve tünel açmak için bulunan sınırlı alana sahip ortamlarda (Schneider 2010) ve maden ocaklarında (Fink *et al.* 2010) özel konumlandırma gereksinimleri dikkate alınmalıdır.

Sahne Modelleme ve Haritalandırma: Sahne modelleme (doğal sahnelerin dijital üç boyutlu modeller olarak inşa edilmesi işlemi) optik sensörün kusursuz oryantasyonunu

gerektirir. İç ortam haritalandırma sistemleri, çeşitli görüşleri birleştirmek ve üç boyutlu nokta bulutları oluşturmak için kameranın pozisyonunu bilmeye ihtiyaç duyar. Sahne modelleme; bilgisayar animasyonu, sanal eğitim, fiziksel simülasyon için geometrik modelleme, tehlikeli yerlerin ve kültürel mirası koruma alanlarının haritalandırılması gibi çok çeşitli uygulamalar için yararlıdır.

Hareket Yakalama: Hareket yakalama fiziksel mimiklerin teşhisine ve vücut bölgelerini bulma ve takip etme yeteneğine dayanır. Bu tür teknolojiler, tıbbi çalışmalar ve animasyon filmleri için yararlıdır. Konum tabanlı oyunlar (egzersiz türü olarak oyun oynama-exergaming) vücut hareketinin veya izleyicilerin tepkisinin izlenmesine dayanır.

Artırılmış Gerçekliğe (Augmented Reality-AR) Dayalı Uygulamalar: Konumlandırma duyarlılığı, kullanıcının görüşü üzerine sesler ya da grafikler eklemek için giderek güçlü bir araç haline gelen ve çevre ile ilişkili mekânsal ve anlamsal bilgileri anlamak için kullanıcıya izin veren AR uygulamaları için çok büyük öneme sahiptir. AR için görme tabanlı navigasyon, Kim and Jun tarafından 2008 yılında geliştirilmiştir.

Yukarıda bahsedildiği gibi bir çok alanda önemli bir yere sahip olan iç ortam konumlandırma sistemlerinde, konum tespit işleminin yapılması için çok sayıda teknoloji var olmakla birlikte çoğu günümüzde yaygın olarak kullanılmamaktadır. Bugün en yaygın kullanılan iki teknoloji, genellikle güvenlik için bina içine yerleştirilmiş video kameraları ve ortamda bulunan Wi-Fi sinyalleridir (parmak izi ve ya üçgenleme yöntemi).

Bu tez çalışmasında hemen hemen her kapalı ortamda bulunan WLAN alt yapısı kullanılarak Wi-Fi sinyalleri ile iç ortam konumlandırma üzerine çalışmalar yapılmıştır. İç ortam konumlandırma yöntemlerinden parmak izi yöntemi kullanılarak bir apartman dairesinin birinci katında bulunan bir evin altı odasından Wi-Fi sinyalleri toplanmış ve oda seviyesinde konumlandırma işlemi yapılmıştır. Her oda için farklı zamanlarda

alınan 100 adet sinyal örneği ile bir veri seti oluşturulmuş ve bu veri setine çeşitli sınıflandırma yöntemleri uygulanmıştır. Ev ortamından elde edilen bu veri seti ile iş yerinden elde edilen ve literatürde bulunan bir veri seti, eşit koşullarda sınıflandırma yöntemleri aracılığı ile karşılaştırılmıştır. Sınıflandırma doğrulukları incelendiğinde ev ortamından elde edilen veri setinde daha düşük performans görülmüş ve bunun nedeni incelenmiştir.

Çalışmanın 2. bölümünde iç ortam konumlandırma hakkında bilgi verilerek bu alanda yapılan literatür çalışmalarından bahsedilmiştir. 3. Bölümde tez kapsamında yapılmış olan çalışmalar anlatılmaktadır. Tasarlanan veri toplama aracı ve veri setlerine uygulanan sınıflandırma yöntemleri ele alınmıştır. 4. bölümde yöntemlerden elde edilen bulgular karşılaştırılmıştır.

Sonuçlar ve Öneriler bölümünde ise yapılan çalışmalar özetlenerek en yüksek doğruluk oranı ile iç ortam konumlandırmada en yüksek performansı gösteren yöntem belirlenmiştir.

2. KAYNAK ÖZETLERİ

2.1. Konumlandırma

Konumlandırma, uzayda bir nesnenin konumunu belirleme sürecini ifade etmektedir. Konum bilgisi kullanıcı bağlamında (kullanıcı aktiviteleri, ulaşım modu, sosyal ilişkiler) en önemli unsurlardan biridir (Krumm 2010). Konum bilgisi, mutlak, göreceli ya da sembolik şekillerde ifade edilebilir. Mutlak bir konum, bulunulan ortamın adresi veya coğrafi koordinatlar gibi kesin bir pozisyon ile ifade edilir (Krumm 2010). Yüzyıllar boyunca insanlar kendi konumlarını belirlemek, yeni yerlere ulaşmak ve keşfetmek için gökyüzü nesnelere dayanarak yararlanmışlardır. Bir kaç yüz yıl önce, denizciler güneş ve yıldızlardan faydalanarak, herhangi bir özel cihaz kullanmadan konumlandırma işlemini gerçekleştirebilmişlerdir. 1920'li yıllarda kıyı tabanlı vericilerden alınan radyo sinyallerine dayalı konumlandırma sistemi denizciler tarafından kullanılmıştır (Pace *et al.* 1995). 1960 yıllarında ise ABD Savunma Bakanlığı tarafından Global Positioning System (GPS) adı verilen askeri amaçlar için uydu tabanlı konumlandırma sistemi geliştirilmeye başlanmıştır. 1983 yıllarında GPS teknolojisi yalnızca askeri bir sistem olmaktan çıkıp genel kullanım için uygun hale getirilmiştir. Dış ortamlarda gücünü gün geçtikçe artıran GPS teknolojisi, GPS uydularından alınan sinyal güçlerinin bina içlerinde genellikle zayıflamasından dolayı iç ortamlarda etkili çalışmamaktadır. Bu yüzden iç ortam konumlandırma için farklı çözümler arayışlarına girilmiştir.

Günümüzde modern teknoloji ile ilişkili birçok konumlandırma sistemi olmasına rağmen, maliyeti düşük ve herhangi bir özel cihaz kullanılmadan gerçekleştirilen sistemler daha fazla tercih edildiği için bu sistemler ile konumlandırma hatasını en aza indirmek hedeflenmektedir. İç ortam konumlandırma için genellikle yapay görme, lazer mesafe bulma ya da hücre tabanlı kablosuz ağ lokalizasyonuna dayalı yöntemler önerilmiştir.

2.2. İç Ortam Konumlandırma

İç ortam konumlandırma yöntemleri “özel algılayıcı sistemler” ve “ortamda var olan algılayıcı sistemler” olmak üzere iki gruba ayrılabilir (Bayındır ve Karabey 2014). Özel algılayıcı sistemlerin geliştirilmesi ve bu sistemlerin ortama veya insan vücuduna yerleştirilmesi konum kestirim hatasını minimuma indirme gibi avantajlara sahip olmakla birlikte sistemin kurulum ve donanım masrafları, kullanıcının yeni sisteme adaptasyonu, kullanıcının ihtiyaç duyduğu her anda kurulum gerektirmesi gibi dezavantajları içermektedir. Ortamda var olan algılayıcı sistemler ise kurulum masrafı ve ek donanım ihtiyacı gerektirmediğinden ve aynı zamanda kullanıcının her an yanında bulundurabileceği cihazlarda (cep telefonu, tablet vb.) bulunduğundan bireysel ve genel amaçlı kullanıma daha uygundur.

İç ortam konumlandırma sistemlerinde, özel algılayıcı sistemlerden kask (Beauregard 2006), ayağa (Widyawan *et al.* 2008; Angermann *et al.* 2012; Martin *et al.* 2014; Puyol *et al.* 2014) ve bel bölgesine (Shin *et al.* 2010; Colombo *et al.* 2014) monte edilen, bileklik (Hardegger *et al.* 2012; D'Souza *et al.* 2012; Salazar *et al.* 2013; Geng *et al.* 2013) vb. cihazlar kullanılmıştır. Bu algılayıcılar konumlandırma için iyi sonuçlar verse de gerçek hayatta kullanımı, kurulum masrafı ve vücuda entegre edilmesiyle oluşan istenmeyen görüntü sebebiyle mümkün olmamaktadır.

Bunların aksine cep telefonu, tablet gibi insan vücuduna monte edilmeden kullanılabilen algılayıcılar, GSM (Tian *et al.* 2013; Buyruk vd 2013), Wi-Fi (Bolliger 2008; Lin *et al.* 2009; Finkel *et al.* 2014; Hernandez *et al.* 2014; He and Chan 2014), Bluetooth (Altini *et al.* 2010; Okşar 2014; Mankotia *et al.* 2014), FM Radyo (Sungro *et al.* 2013; Chen *et al.* 2012; Moghtadaiee and Dempster 2014; Matic *et al.* 2010) gibi ortamda var olan sinyal kaynaklarını içerisinde bulundurup bu sinyalleri işleyebildiği için daha fazla tercih edilmektedir.

2.2.1. Performans ölçütleri

İç ortam konumlandırmada performans ölçütü olarak konum tespit doğruluğu ile birlikte hassasiyet, karmaşıklık, ölçeklenebilirlik, sağlamlık ve maliyet gibi ölçütler de değerlendirilmektedir. Bu ölçütler aşağıda alt başlıklar halinde detaylandırılmıştır.

2.2.1.a. Doğruluk

Doğruluk, konumlandırma sistemlerinin en önemli ölçütlerinden biridir. Bir konumlandırma sisteminin doğruluğu hedef nesneye ulaşabilmek için hesaplanmış en yakın noktalara göre belirlenir. Genellikle ortalama konum hatası, gerçek konum ile hesaplanmış konum arasındaki ortalama öklit mesafesi ile belirlenir (Liu *et al.* 2007). Ortalama konum hatası daha düşük olan sistemler daha yüksek doğruluğa sahiptirler. Daha yüksek doğruluk da daha doğru konumlandırma yapıldığını göstermektedir.

2.2.1.b. Hassasiyet

Doğruluk sadece ortalama mesafe hatası değerini dikkate alırken, konum hassasiyeti, sisteminin ne kadar sıklıkla çalıştığını ve konumlandırma sisteminin elde ettiği sonuçlar arasındaki tutarlılığı göz önüne alır (Yücel vd 2014). Bazı çalışmalarda da konum hassasiyeti, konumlandırma hatasındaki standart sapma olarak tanımlanmaktadır. Fakat genellikle gerçek konum ile tahmin edilen konum arasındaki mesafe hesabının kümülatif dağılımı olarak bilinmektedir (Disha 2013).

Mesafe hatalarının kümülatif olasılık fonksiyonları (CDF), sistemin hassasiyetini ölçmek için kullanılmaktadır. İki konumlandırma yöntemi karşılaştırıldığı zaman, doğrulukları aynı ise, yöntemlerin hassasiyetlerini incelemek için CDF grafiklerine bakılır. En yüksek olasılıklı değerlere ulaşan yöntem daha hızlıdır, çünkü o yöntemin mesafe hatası daha azdır. Konum hassasiyeti yüzde (%) formatında tanımlanır. Örnek verilirse, bir sistem 2.3 metrede %90 (2.3 m' deki mesafe hatası 0.9 m) ve 3.5 metrede %95 konum hassasiyetine sahip ise, diğer sistem de 2.3 metrede %50 ve 3.3 metrede

%95 oranında konum hassasiyetine sahip ise, daha yüksek hassasiyete sahip olan birinci sistem, daha kullanışlı olarak seçilir (Liu *et al.* 2007).

2.2.1.c. Karmaşıklık

Bir konumlandırma sisteminin karmaşıklığı donanım, yazılım ve işletim faktörlerine bağlanabilir. Yazılım karmaşıklığına örnek olarak sistemde kullanılan konumlandırma yöntemlerinin hesaplama karmaşıklığı verilebilir. Eğer yöntemlerin hesaplanması merkezi sunucu tarafında gerçekleşiyorsa, konumlandırma güçlü işleme kapasitesi ve yeterli güç kaynağından dolayı hızlıca hesaplanabilir (Liu *et al.* 2007). Eğer işlemler mobil birimde gerçekleşiyorsa, karmaşıklık etkileri belirgin hale gelebilir. Çünkü çoğu mobil birimler işlemci gücü ve uzun batarya ömrü açısından yoksundur. Bu yüzden konumlandırma sistemlerinde düşük karmaşıklığa sahip konumlandırma yöntemleri tercih edilmektedir. Yöntemlerin karmaşıklığına bağlı olarak hesaplama süresi de değişmektedir. Bir mobil cihaz yeni konuma doğru hareket ederken, sistem tarafından yeni konumun belirlenmesi sırasında oluşan hesaplama gecikmesine bağlı olarak konumlandırma doğruluğu da gecikmeye ters orantılı olarak değişmektedir.

2.2.1.d. Ölçeklenebilirlik

Sistemin daha geniş kapsama alanına sahip olması ve daha fazla sayıda konum istekleri ile çalıştığı zaman iyi performans göstermesi için ölçeklenebilirlik, hemen hemen her sistemde istenilen bir özelliktir (Farid *et al.* 2013). Bir konumlandırma sistemi, iki eksen üzerinde ölçeklemeye ihtiyaç duyabilir: (1) Coğrafya (2) Yoğunluk (Liu *et al.* 2007)

Coğrafi ölçek, sistemin kapsama alanı anlamına gelmektedir. Yoğunluk ise bir zaman diliminde birim coğrafik alan başına düşen birim sayısını gösterir. Geniş kapsama alanında ya da birimler bir alanda kalabalık olduğunda, kablosuz sinyal kanalları tıkanabilir ve yer tespitini gerçekleştirmek için daha fazla hesaplama ya da daha fazla iletişim altyapısı gerekebilir (Liu *et al.* 2007). Diğer bir ölçeklenebilirlik ölçütü ise sistemin uzay boyutudur. Mevcut sistemler, iki veya üç boyutlu uzaylarda nesne tespiti

yapabilirken, bazı sistemler sadece iki veya sadece üç boyutlu alanlarda kullanılabilir.

Düşük ölçeklenebilir bir konumlandırma sistemi tekrar düzeltilme ya da yeniden yapılandırılmaya maruz kalabilmektedir. Ölçeklenebilir bir konumlandırma sistemi ise büyük efor sarfetmeden çok sayıda etiketi işleyebilmektedir (Farid *et al.* 2013).

2.2.1.e. Sağlamlık

Sinyalin mevcut olmadığı, vericinin arızalandığı ya da daha önce görülmeyen RSS değerleri ya da aç karakterleri görüldüğü durumlarda, sistemin oluşabilecek hatalardan en az etkilenmesi, sistemin sağlamlığını ifade etmektedir (Yücel vd 2014).

2.2.1.f. Maliyet

Bir konumlandırma sisteminin maliyeti; ekstra altyapı, ek bant genişliği, alan, ağırlık, zaman, para, enerji ve dağıtılan teknolojinin maddesinden ortaya çıkmaktadır (Farid *et al.* 2013). Zaman faktörü, dağıtım dönemi sırasında araştırma ve kurulum süresini içermektedir. Mobil birimler, alan ve ağırlık kısıtlarına sahiptirler. Birim yoğunluğu ölçümü, alan maliyeti olarak kabul edilir. Eğer bir konumlandırma sistemi, var olan iletişim altyapısını yeniden kullanabiliyorsa, altyapı, ekipman ve bant genişliğinin bir kısmı kurtarılabilir (Farid *et al.* 2013).

Enerji de bir sistemin maliyeti için önemli bir faktördür. Bazı mobil birimler (elektronik eşya koruma (EAS) etiketleri ve sonradan adreslenen pasif RFID etiketleri) tamamen pasif enerjiye sahiptirler. Bu birimler sadece dış alanlara yanıt verirler ve bu nedenle sınırsız kullanım ömrüne sahiptirler (Liu *et al.* 2007). Diğer mobil birimler (şarj edilebilir bataryalı cihazlar), tekrar şarj olmadan birkaç saat kullanım ömrüne sahiptirler.

2.3. İç Ortam Konumlandırma Teknolojileri

İç ortam konumlandırma için geliştirilen teknolojiler, üç farklı ilke kullanılarak kategorilere ayrılabilir (Mautz 2012):

- Eylemsizliğe dayalı navigasyon (Inertial Navigation) (Açısal momentumu koruyan ivmeölçerler ve jiroskoplar)
- Mekanik dalgalar (duyulabilir ve ultrasonik dalgalar)
- Elektromanyetik dalgalar: görünür, kızılötesi, mikrodalga ve radyo spektrumu (Radyo spektrumundan yararlanan sistemler FM radyoları, radarlar, hücresel ağlar, WLAN (Wi-Fi), Bluetooth, ZigBee, RFID, ultra- geniş bant, yüksek duyarlı GNSS, sanal uydular (pseudolites) sistemlerini içermektedir).

İç ortam konumlandırmada kullanılan teknolojilerin genel bir sınıflandırılması Şekil 2.1'de gösterilmiştir.



Şekil 2.1. İç ortam konumlandırma teknolojilerine genel bir bakış


Aşağıda iç ortam konumlandırmada öne çıkan teknolojiler ayrı alt başlıklar altında incelenmiştir.

2.3.1. Kamera

Görüntü tabanlı iç ortam konumlandırma yaklaşımında kullanılan kameralar, geniş kapsamlı uygulama alanı olan bireysel ve ticari bir konumlandırma teknolojisidir. Çoğunlukla mağaza içi izleme teknolojisi olarak yaygın bir şekilde kurumlara sunulur (Sterling and Top 2014). “RetailNext” adlı firma, mağaza içi video görüntüsünden yararlanan lider bir firmadır ve aynı zamanda satış noktası verilerini ve sensörleri içeren diğer iç ortam veri teknolojilerini de kullanmaktadır (Sterling and Top 2014).

Görüntü tabanlı yöntemlerin başarısı, lazer gibi küçültülmüş ve geliştirilmiş sistemlerden ve detektörlerin kısmen gelişiminden (CCD - Charged Coupled Device sensörler) kaynaklanmaktadır. Ayrıca görüntü işleme için yöntemlerin giderek geliştirilmesinin yanı sıra hesaplama kapasiteleri ve veri iletim hızlarında da paralel olarak bir artış gözlenmektedir.

Kameralarından elde edilen görülebilir ışınların dalga boyu ve frekans aralığı Şekil 2.2’de verilmiştir.




Şekil 2.2. Görülebilir ışınların dalga boyu ve frekans aralığı

Konumlandırma için kullanılan kameralar, görüntüdeki hareket eden nesnelere bulmak için bir yere yerleştirilen sabit kameralar ve cep telefonlarında bulunan hareketli kameralar olmak üzere iki kategoride incelenebilir. Kameradan elde edilen görüntüler bir veri tabanında saklanır ve gerçek zamanlı görüntü ile veri tabanında kayıtlı görüntülerin karşılaştırması için renk histogramları, dalgacık ayrıştırma ve şekil eşleştirme gibi yöntemler kullanılır (Ravi *et al.* 2015).

2.3.2. Kızılötesi

Konumlandırma sistemlerinde yaygın kullanılan kablosuz teknolojilerden biri olan kızılötesi, nesnelerin ya da insanların tespiti ve takibi için; mobil cihaz, PDA ve televizyon gibi kablosuz ya da kablolu cihazlarda çeşitli yollarla kullanılmaktadır (Farid *et al.* 2013). Kızılötesi dalgaların dalgaboyu ve frekans aralığı Şekil 2.3'te gösterilmiştir.



Şekil 2.3. Kızılötesi dalgaların dalgaboyu ve frekans aralığı


Çoğu kızılötesi tabanlı kablosuz cihazlar, güçlü ışık kaynaklarından girişim olmadan iletilici ve alıcı arasında görüş açısı (line-of-sight) iletişim modunu kullanır. Sabit bir konumda olan alıcıya hareketli cihazın bilgilerinin gönderilmesi ile konum tespiti gerçekleşir (Kök 2009). Alıcılar genellikle hareketli cihazın bulunma ihtimali olan yerlere yerleştirilir. Aynı zamanda cihazın bilgilerini alıcıya gönderebilen kızılötesi vericileri de bina içerisine yerleştirilir. Hareketli cihaz, vericilerin sağladığı kızılötesi ışınları aldıktan sonra verici ile aynı odada bulunan hareketli cihazın konumu tespit edilmiş olur (Kök 2009).

Kızılötesi tabanlı cihazların hafif, küçük ve kolay taşınabilir olması ana avantajı olmasına rağmen, sistemlerin sınırlı kızılötesi algısına sahip olması, güneş ışığı ve florasan ışık girişiminden etkilenmesi ile konum tespitinde oluşan sorunlar, donanım ve bakım maliyetinin fazla olması, güvenlik ve gizlilik eksikliği gibi bir çok dezavantaja da sahiptir (Farid *et al.* 2013).

2.3.3. Ses

Ses, ortam üzerinden basınçlı bir salınım olan manyetik bir dalgadır. Konumlandırma sistemleri yayılım ortamı olarak hava ve yapı malzemesini kullanır.

Konumlandırma için ses dalgalarını kullanarak kurulmuş konseptlerde, robotlar üzerinde mobil düğümler ya da kullanıcılar tarafından giyilen etiketler aracılığıyla, tavan ya da duvara geçici olarak monte edilmiş statik düğümler ile aralarında mesafe ölçümü yapılarak kullanıcının ya da robotun konumu tespit edilir (Mautz 2012). En çok kullanılan ses sistemi ultrasonik tabanlı sistemlerdir. Ultrasonik sinyallerin dalga boyu ve frekans aralığı Şekil 2.4’te verilmektedir.




Şekil 2.4. Ultrasonik sinyallerin dalga boyu ve frekans aralığı

Ultrasonik sinyalleri 20KHz (insan kulağının duyma eşiği) ve üzerindeki ses sinyalleridir. Ultrasonik sinyalleri kullanan sistemler, alıcı ve vericilerin arasında mesafe hesabı yaparak üç boyutlu pozisyon belirler. Konum tespiti için üçgenleme yöntemi kullanılır. Bu sinyaller duvarlardan geçemediği için bir çok engelde geri yansır. Bu yüzden sinyalin ulaşma zamanı, uçuş zamanı gibi zaman ölçümleri kullanılarak da konumlandırma işlemi yapılmaktadır (Yücel vd 2014). Bilinen sistemler olan Active Bat (Anonymous 2015g) ve MIT Cricket (Priyantha *et al.* 2000), ultrasonik yayılım süresini kullanarak konumlandırma işlemini gerçekleştirmişlerdir.

2.3.4. WLAN/Wi-Fi

2.4 GHz ISM (Industrial, Scientific and Medical) bandında çalışan WLAN (Wireless Local Area Networks, IEEE 802.11) standardı son yıllarda kurumsal ve kamu kuruluşlarında popüler bir konumlandırma teknolojisi haline gelmiştir (Liu *et al.* 2007). Şekil 2.5’te frekans ve dalga boyu verilen Wi-Fi sinyalleri, çoğu bina içinde

bulduğundan ve hemen hemen her mobil cihazda mevcut olduğundan dolayı Wi-Fi sinyalleri ile konumlandırma sistemlerine talep gün geçtikçe artmaktadır. Wi-Fi sinyallerinin dalgaboyu ve frekans aralığı Şekil 2.5'te gösterilmektedir.




Şekil 2.5. Wi-Fi sinyallerinin dalgaboyu ve frekans aralığı

50 m ile 100 m aralığında kapsama alanı ve 11, 54 veya 108 Mbps bit hızına sahip bir standart olan IEEE 802.11, günümüzde yerel kablosuz ağa hakim olan bir standarttır (Liu *et al.* 2007). Bu yüzden konumlandırma için bir konum sunucusu ekleyerek var olan WLAN altyapısının kullanmak, bireysel ve ticari konumlandırma sistemleri için cazip hale gelmiştir. Çoklu Wi-Fi noktaları kullanılarak üçgenleme yöntemi ya da parmak izi yöntemi ile konum tespiti yapılabilir. En çok kullanılan Wi-Fi tabanlı parmak izi yönteminde mobil cihazdan alınan gerçek zamanlı sinyaller, önceden veri tabanında kayıt edilmiş sinyaller ile karşılaştırılarak konum tespiti yapılır. Meridian, Navizon, WiFiSlam (Apple tarafından geliştirilen), Cisco, PoleStar, Aisle411 ve daha bir çok sistem WLAN altyapısı kullanılarak geliştirilmiştir (Sterling and Top 2014).

2.3.5. Bluetooth

2.4 GHz ISM bantta çalışan bluetooth teknolojisi IEEE 802.15 standardına sahiptir. 1Mbps bit hızı ve 10-15 m kapsama alanına sahip olan bu teknoloji, WLAN ile karşılaştırıldığında daha düşük bit hızı ve kapsama alanına sahiptir (Liu *et al.* 2007). Cep telefonu, tablet ya da bilgisayar gibi çoğu mobil cihazda Wi-Fi bulunmakla birlikte gömülü bluetooth modülü de bulunmaktadır. Küçük boyut, düşük güç, düşük maliyet ve yüksek güvenlik özelliklerinden dolayı cihazlar arasında bilgi alış verişi için kullanıma elverişli bir teknolojidir (Farid *et al.* 2013). Bluetooth sinyallerinin dalgaboyu ve frekans aralığı Şekil 2.6'da gösterilmektedir.



Şekil 2.6. Bluetooth sinyallerinin dalgaboyu ve frekans aralığı


Her bluetooth etiketi konumlandırma için kullanılan benzersiz bir kimliğe sahiptir. İç ortamda belirli noktalara yerleştirilen bu bluetooth etiketlerinden alınan sinyal güçleri, hareketli cihaz ile bluetooth etiketleri arasındaki uzaklığı tahmin etmek için kullanılır. Sinyal gücü değerleri elde edildikten sonra üçgenleme yöntemi ile konum tahmin işlemi yapılır (Kök 2009).

Ucuz ve fazla güç gerektirmemesi bluetooth teknolojisinin konumlandırma sistemlerinde kullanımına avantaj sağlarken, her konum bulmada cihaz keşif prosedürünü çalıştırması ve bundan dolayı konumlandırma işleminin 10-30 saniye gecikmesi ve aynı zamanda bu durumun güç tüketimini artırması gibi dezavantajları da beraberinde getirmektedir (Farid *et al.* 2013). Ayrıca bluetooth ile konumlandırma işlemi için, bluetooth etiketlerinin konum tespiti yapılacak ortama yerleştirilmesi durumu da bu teknolojinin dezavantajları arasındadır.

2.3.6. Hücresel ağlar (GSM)

İç ortam konumlandırma sistemlerinde hücresel ağ teknolojisi olarak genellikle mobil cihazların GSM ağlarından yararlanılmaktadır. GSM ağları çoğu ülkede yaygın bir şekilde bulunmaktadır. 35 km büyüklüğünde hücre boyutları ile GSM kapsama alanı, WLAN kapsama alanından çok daha fazladır. Bu nedenle düşük doğrulukta olsa bile mobil kullanıcının yerini tespit etmek için GSM ağları, konum tabanlı servisler ve acil yardım gibi kitlesel market uygulamalarında kullanılır (Mautz 2012).

Bir mobil cihazı konumlandırmak için aktif bir çağrıya gerek yoktur. WLAN'ın aksine GSM, aynı frekansta çalışan diğer cihazlarla girişime uğramayan lisanslı bantlarda çalışır (Mautz 2009). Hücresel ağların dalgaboyu ve frekans aralığı Şekil 2.7'de gösterilmektedir.




Şekil 2.7. Hüresel ağların dalgaboyu ve frekans aralığı

Tüm mobil cihaz takip yöntemleri, cep telefonun konumunu tahmin etmek için radyo kulelerine monte edilmiş en yakın antenlerin konumunu kullanır (Disha 2013). Bu yöntemlerden en yaygın kullanılanı GSM tabanlı parmak izi yöntemi olmakla birlikte mesafe ve açı tabanlı GSM konumlandırma yöntemleri de kullanılmaktadır.

2.3.7. RFID (Radio Frequency Identification)

Bir RFID sistemi aktif alıcı-vericiler veya pasif etiketleri sorgulayan bir anten ile bir okuyucudan oluşur. Nesnelere otomatik tanıma, izleme ve yönetim amaçlı kullanılabilen RFID teknolojisi ile insanlara ya da nesnelere yerleştirilen RFID etiketlerinden yayılan veriler, radyo dalgaları aracılığıyla okuyucuya (RFID tarayıcı olarak da bilinir) iletilir (Mautz 2012). Bir RFID okuyucu RFID etiketlerinden yayılan bu verileri okuduktan sonra tedarik zinciri yöntemi ile bilgiler otomatik olarak kaydedilebilir. RFID teknolojisinin kullanıldığı dalgaboyu ve frekans aralıkları Şekil 2.8'de verilmektedir.



Şekil 2.8. RFID'nin kullanıldığı dalgaboyu ve frekans aralıkları

RFID okuyucuları ve etiketleri verileri almak ve iletmek için tanımlanmış bir radyo frekans ve protokolü kullanır (Disha 2013). RFID etiketleri aktif ve pasif olmak üzere iki sınıfa ayrılmıştır.


Pasif etiketler, batarya olmadan çalışırlar. İçerisinde pil kaynağı olmadığı için kendilerini okuyan cihazların antenlerinden oluşan elektrik alanı ile enerji elde ederler.

Bu yüzden hem ömürleri uzundur hem de aktif etiketlere göre daha az maliyetlidir. Bu avantajlara sahip olmakla birlikte okuma mesafesi 1-2 m aralığındadır ve bu etiketleri okuyacak olan okuyucuların maliyeti yüksektir (Disha 2013).

Aktif etiketler ise bir sorguya cevap olarak kendi kimliğini ya da ek bilgileri iletebilen küçük alıcı-vericilere sahiptir. Frekans aralıkları düşük ve yüksek frekans aralıkları dışında pasif RFID'ye benzerdir. Aktif etiketlerin avantajı daha uzak mesafelere (onlarca metre olabilir) küçük antenler ile erişebilmeleridir (Disha 2013).

2.3.8. Ultra geniş bant

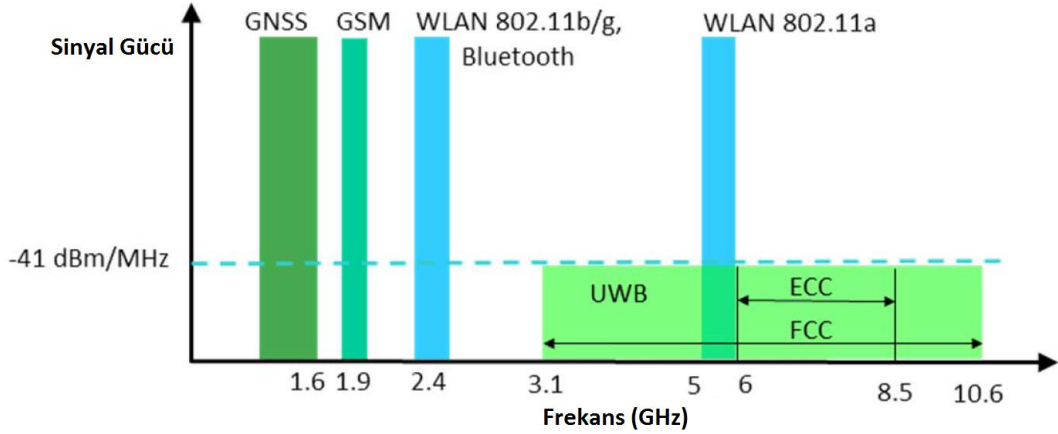
Sinyallerin çok yollu dağılmasına gösterdiği direnç ile konumlandırma doğruluğunu artıran ultra geniş bant, kısa mesafeler için kullanılan bir radyo teknolojisidir. Dağınık ve yayılmış dalgaları yakalayan alıcılar ve uyarıcı radyo dalga jeneratörü, ultra geniş bantın önemli öğeleridir (Mautz 2012). Ultra geniş bant teknolojisi kullanılan konumlandırma sistemlerinde klasik kablosuz teknolojilerden (RFID, WLAN vb.) 20-30 cm daha yüksek doğruluk elde edilmektedir (Farid *et al.* 2013). Dar bant teknolojisinin aksine ultra geniş bant dalgaları 500 MHz'den büyük bir frekans genişliğini işgal eder. Ultra geniş bant teknolojisinin dalgaboyu ve frekans aralığı Şekil 2.9'da gösterilmektedir.



Şekil 2.9. Ultra geniş bant teknolojisinin dalgaboyu ve frekans aralığı

Diğer radyo sinyalleri ile girişimi engellemek için, Amerika'da Federal İletişim Komisyonu (FCC), 3.1 GHz'den 10.6 GHz'e kadar frekans bandı aralığı ve -41.3 dBm/MHz güç yoğunluğuna eşdeğer sinyal gücü ile ultra geniş bantın lisanssız kullanımını sınırlamıştır (6 GHz ve 8.5 GHz arası Avrupa İletişim Komitesi (ECC)'ne göre sınırlandırılmıştır). Ultra geniş bant teknolojisinin ve diğer radyo frekans

standartlarının sinyal gücü ve frekans aralığı karşılaştırması Şekil 2.10'da gösterilmektedir.




Şekil 2.10. Ultra geniş bant ile diğer radyo frekans standartlarının karşılaştırılması

Bu teknoloji, iç ortamlarda sinyallerin çok yönlü dağılım sorununun azaltılmasını sağlayarak daha doğru konum tespitleri yapmakla birlikte ultra geniş bant donanımının maliyetli olması sebebiyle yaygın kullanıma sahip değildir (Kök 2009).

2.3.9. Yüksek hassasiyetli GPS/GNSS

GPS, nesnelere ya da insanların pozisyonunu ve yerini bulmak için geliştirilen uydu tabanlı en popüler sistemdir. Dünya çapında uydu ağı, mesafe ölçümlerinde büyük oranda doğruluk elde etmek için kullanılır. Bu sistem ile nesne konumları 1 m ile 5 m'ye kadar hesaplanabilmektedir (Koyuncu and Yang 2010). Fakat GPS'in bu özelliği dış ortamlar için geçerlidir. GPS alıcıları iç ortamda olduğu zaman uydu sinyallerinin engellerden geçerken zayıflamasından dolayı dış ortamlarda olduğu kadar iyi performans göstermemektedir. GPS sinyallerinin dalga boyu ve frekans aralığı Şekil 2.11'de koyu renk ile gösterilmektedir.




Şekil 2.11. GPS sinyallerinin dalga boyu ve frekans aralığı

GPS ile iç ortam konumlandırma işlemi için yüksek hassasiyete sahip GPS kullanılmaktadır. Yüksek hassasiyetli GPS alıcıları ile 3 katmanlı tuğla ile kaplanmış duvar üzerinden insanlar takip edilebilmektedir (Koyuncu and Yang 2010). Buna rağmen sinyallerin iç ortamdaki çoğu engelden geçerken yoğun bir şekilde zayıflama ve yansıma durumu olduğu için iç ortamlarda GPS'in konumlandırma doğruluğu düşüktür.

2.3.10. Sanal uydular (Pseudolites)

İngilizcede pseudo-satellites anlamına gelen sanal uydu teknolojisinin kısaltılmış formu literatürde "Pseudolites" şeklinde geçmektedir. GPS tarafından alınan sinyallere benzer olarak sanal gürültü kodları üreten toprak tabanlı işaretçilerdir (Mautz 2012). Genellikle bilinen pozisyonlarda dağıtılan sanal işaretçiler ile mesafe ölçümü yapılarak mobil alıcı birimlerinin konumu tahmin edilir.

Sanal uyduların temel amacı, uydu sinyallerinin devre dışı bırakılmış, sıkışmış ya da kolay mevcut olmadığı yerlerde (iç ortamlar örnek olarak verilebilir) ek GPS sinyalleri üreterek konum tespitinin daha doğru yapılmasına katkı sağlamaktır (Mautz 2015).




Şekil 2.12. Sanal uyduların GPS sistemindeki rolü (Anonymous 2015a)

Şekil 2.12’de görüldüğü gibi GPS uydularının görüş açılarının engellendiği alanlara GPS hizmeti sağlamak için, alıcının görüş açısında bulunan sanal uydu (Pseudolite) devreye girmektedir. Burada GPS sanal uyduları, GPS alıcılarının pozisyonlarını toplamak için kullandıkları GPS uydularından biri olarak faaliyet göstermektedir. Şekil 2.12 incelendiğinde, zeminden kaynaklanan engellerden dolayı sanal uydular olmadan GPS alıcılarının dört uyduyu elde etme imkânlarının olmadığı görülmektedir.

2.3.11. FM radyo

FM radyoları, frekansını değiştirerek bir taşıyıcı dalga üzerinden bilgi iletmek için Frekans Modülasyonu (FM) için ayrılmış köklü bir yayın teknolojisidir. Günümüzde hangi tür sinyal modülasyonu uygulanırsa uygulansın 87.5 MHz ile 108 MHz arasında frekans bandında çalışan herhangi bir radyo dalgası FM radyo anlamına gelir (Mautz 2012). FM radyo sinyallerinin dalgaboyu ve frekans aralığı Şekil 2.13’de koyu renk ile gösterilmektedir.



Şekil 2.13. FM radyo sinyallerinin dalgaboyu ve frekans aralığı


FM radyo yayın kuleleri aracılığıyla iletilen ses sinyalleri iç ortam navigasyonu için kullanılabilir. Bağımsız saat senkronizasyonuna sahip sinyal gücü tabanlı parmak izi yöntemi ile FM sinyalleri kullanarak konumlandırma işlemi yapılabilmektedir. Fakat model tabanlı yöntemler FM radyo sinyallerinin zamanlama bilgisi eksikliğinden dolayı uygulanamamaktadır (Mautz 2012). Düşük maliyet ve düşük güçlü donanım kullanımının mümkün olduğu ve alınan yüksek sinyal gücü gibi avantajlara sahip olan FM radyo sinyalleri, iç ve dış ortamda neredeyse her yerde kapsama alanı sağlayan radyo kule altyapısından yararlanır (Mautz 2012). Güvenlik ya da emniyet sebebiyle hassas alanlarda diğer RF teknolojileri tercih edilmemesine rağmen, FM radyo sinyalleri güvenlik gerektiren hassas alanlarda kullanılabilir. Bununla birlikte birçok mobil

cihazda FM radyo sinyallerinin hazır bir şekilde bulunması da bu teknolojinin bir diğer avantajıdır.

2.3.12. ZigBee

ZigBee, kısa ve orta menzilli iletişim için çözüm üreten gelişmekte olan bir kablosuz teknoloji standardıdır. Özellikle düşük güç tüketimi gerektiren büyük veri aktarımı gerektirmeyen uygulamalar için tasarlanmıştır. Boş alanda ZigBee düğümünün kapsama alanı 100 m'ye kadar çıkarken, iç ortamlarda 20 ile 30 m arasındadır (Mautz *et al.* 2012).

ZigBee teknolojisinin dalgaboyu ve frekans aralığı Şekil 2.14' de koyu renk ile gösterilmektedir.



Şekil 2.14. ZigBee teknolojisinin dalgaboyu ve frekans aralıkları

İki ZigBee düğümü arasındaki mesafe hesabı, genellikle RSSI değerleri ile gerçekleştirilir. ZigBee lisanssız ISM bantlarında çalıştığı için, radyo iletişimi bozabilen aynı frekansı kullanarak sinyal tiplerinin geniş bir alanından girişime açıktır (Farid *et al.* 2013).

2.3.13. Hibrit teknolojiler

Farklı birçok konumlandırma teknolojisinin bir arada kullanımı ile hareketli cihazın konumunu tespit etmek için geliştirilen teknolojilerdir. Konumlandırma doğruluğunu maksimuma çıkarmak ve mevcut bireysel yaklaşımların dezavantajlarını en aza indirmek için çeşitli hibrit teknolojiler kullanılmaktadır.

Parmak izi tabanlı iç ortam konumlandırma alanında yapılan literatür araştırmalarına göre ortamda var olan sinyal kaynakları tek başına kullanılmakla birlikte performansı artırma amaçlı bir çok sinyalin birlikte kullanıldığı ((FM ve Wi-Fi (Moghtadaiee *et al.* Dempster 2011), Wi-Fi ve Bluetooth (Galvan-Tejada *et al.* 2013), Wi-Fi ve GSM (Du *et al.* 2013), Wi-Fi, Bluetooth, 4G LTE, manyetik sinyaller (Mirowski *et al.* 2013)) hidrit konumlandırma teknolojileri de literatürde sıklıkla yer almaktadır.

Günümüzde satışa sunulan iç ortam konumlandırma sistemleri incelendiğinde ise Bluetooth ((Gruber *et al.* 2015; Meridian (Anonymous 2015e); Ibeacon (Anonymous 2014a); SmartIndoor (Anonymous 2015d), SenionLab (Anonymous 2010b)), Wi-Fi ((aisle411 (Anonymous 2008a), WiFiSlam (Anonymous 2013b, Indoora (Anonymous 2013a), Navizon (Anonymous 2005a), Point Inside (Anonymous 2009a)) gibi tek başına kullanılan teknolojilerin yanısıra Wi-Fi ve bluetooth (Insiteo (Anonymous 2015c)), Wi-Fi, GPS ve bluetooth ((NAO Campus (Anonymous 2008), Wifarer (Anonymous 2010a)), GSM, 3G/4G (LTE), Wi-Fi, manyetik alanlar, pusula, hava basıncı, barometre, ivmeölçer, jiroskop, Bluetooth ve GPS (Infsoft (Anonymous 2015b)), Wi-Fi, Bluetooth, hareketli mikro sensörler (ivmeölçer, jiroskop, manyetik sensörler) (Hsu *et al.* 2015) olmak üzere bir çok teknolojinin bir arada kullanıldığı sistemlere de rastlanmaktadır.

Konumlandırma için kullanılan mevcut konumlandırma teknolojilerinin karşılaştırılması Çizelge 2.1’de verilmiştir.

Çizelge 2.1. Mevcut konumlandırma teknolojilerinin karşılaştırılması (Farid *et al.* 2013)

Teknoloji	Doğruluk	Konumlandırma Yöntemi	Güç Tüketimi	Maliyet	Açıklamalar
GPS	6 m - 10 m	Variş Zamanı	Çok fazla	Yüksek	(1) Uydu tabanlı konumlandırma (2) İşlem ve hesaplama süresi yavaş (3) İç ortamlarda performansı düşük
Kızılötesi	1 m - 2 m	Yaklaşma, Variş Zamanı	Düşük	Orta	(1) Kısa mesafe tespiti (2) Çoklu yola duyarlı
Wi-Fi	1 m - 5 m	Yaklaşma, Variş Zamanı, Parmak izi ve RSSI yayılım modeli	Yüksek	Düşük	(1) Her yerde altyapısı mevcut (2) İlk kurulumu maliyetli (3) Çoklu yola az duyarlı
Ultrasonik	3 cm – 1 m	Variş Zamanı, Variş Açısı	Düşük	Orta	(1) Çevreye duyarlı (2) Çoklu yola duyarlı
RFID	1 m - 2 m	Yaklaşma, Variş Zamanı, RSSI yayılım modeli	Düşük	Düşük	(1) Cevap süresi yüksek (2) Manuel programlama
Bluetooth	2 m – 5 m	RSSI parmak izi ve RSSI yayılım modeli	Düşük	Yüksek	(1) Veri transfer hızı düşük (2) Hareketlilik kısıtına sahip
ZigBee	3 m – 5 m	RSSI parmak izi ve RSSI yayılım modeli	Düşük	Düşük	(1) Düşük veri iletim hızı (2) Düğümler yoğunlukla etkisiz
FM	2 m – 4 m	RSSI parmak izi	Düşük	Düşük	(1) Nesnelere daha az duyarlı (2) Sinyal güçlüdür, bu nedenle geniş alanları kapsar

2.3.14. Eylemsizliğe dayalı navigasyon

Eylemsizliğe dayalı bir navigasyon yöntemi olan parakete hesabı (dead reckoning), kullanıcıya konum bilgisi vermekle birlikte yürüdüğü güzergah bilgisini de vermektedir. Nesnelerin veya insanların bulunduğu bir önceki bilinen konuma göre bir sonraki konumu hesaplayan bir yer değiştirme fonksiyonu ile konum belirlenir. Robotlar, araçlar ve yayalar için kullanılan bu yöntemin yayalar için olanı, yaya parakete hesabı (pedestrian dead reckoning) olarak adlandırılmıştır. Yaya parakete hesabında yer değişim miktarını adım adım hesaplarken öncelikle her bir yeni hareketin adım olup olmadığı tespit edilmeli, tespit edilen adımın tahmini uzunluğu belirlenmeli ve son olarak kişinin hareket ettiği yön algılanıp yayanın yeni konumu belirlenmelidir (Bayındır ve Karabey 2014). Adım tespit ve adım uzunluğu tahmin yöntemleri ile sırasıyla yayanın yaptığı hareketin adım olup olmadığı, eğer adım ise bu adımın uzunluğu belirlenmektedir. Her iki yöntemde de ivmeölçer verileri kullanılırken yön tahmini için pusula gibi ek algılayıcılar kullanılabilir.

2.3.15. Manyetik konumlandırma

Eski yıllardan beri hayvanların dünyanın manyetik alanındaki yerel sapmaları kullanarak gideceği güzergâhı bulabildiklerine dair kanıtlar mevcuttur. Örneğin güvercin gibi bazı hayvanlar sadece dünyanın manyetik alan yönünü tespit etme değil, dünyanın manyetik alanının yerel sapmalarından kaynaklanan yerel ipuçlarından konum bilgisini de çıkarabilmektedir. Dünyanın sabit olmayan manyetik alanına benzer olarak bina içlerindeki manyetik alan da büyük oranda sabit değildir. Bina içlerindeki manyetik alan dalgalanmaları hem doğal hem de çelik ve betonarme yapıları, elektrikli güç sistemleri, elektrik-elektronik aletler ve endüstriyel cihazlar gibi el yapımı kaynaklardan ortaya çıkmaktadır. Bir binanın içindeki manyetik sensörler tarafından algılanan manyetik alan sapmalarının yaklaşık olarak durağan olduğu ve yeterli ölçüde yerel değişkenliğe sahip olduğu düşünüldüğünde; sapmalar, tekil parmak izi sağladıkları için iç ortam konumlandırmada kullanılmaktadır (Subbu *et al.* 2013).

2.3.16. Altyapı sistemleri

Bu teknolojiler, mevcut bina altyapısını ya da yapı malzemesinin içine gömülü ek altyapıyı kullanırlar. Bina altyapılarına gömülü bu teknolojiler ile geliştirilmiş iç ortam konumlandırma sistemleri, kullanıcının bilgisi dışında olabilir. Altyapı sistemlerine örnek olarak güç kabloları, yer karoları, floresan lambaları ve sızdıran besleyici kablolar verilebilir.

Güç kabloları ile konumlandırma, ortamda var olan elektrik şebekesine dayalı bir evde oda tespitini sağlayan parmak izi tabanlı bir yöntemdir (Mautz 2012). RFID çiplerinin yoğun dağıtımını gerektiren RFID sistemleri ile karşılaştırıldığında güç kabloları ile konumlandırmada bir binadaki var olan güç hattı alt yapısı kolaylıkla kullanılmaktadır. Güç kabloları ile konumlandırma ilkesi bir evde elektrik prizine takılı bir ara birim modülü tarafından üretilen çok az kHz ile 20MHz frekans aralığında modüle edilmemiş taşıyıcı dalga sinyallerinin olduğudur. Bu sinyaller pasif etiketler tarafından kablosuz olarak alınabilir ve enerji zengini geçici elektriksel gerilimlerden oluşur.

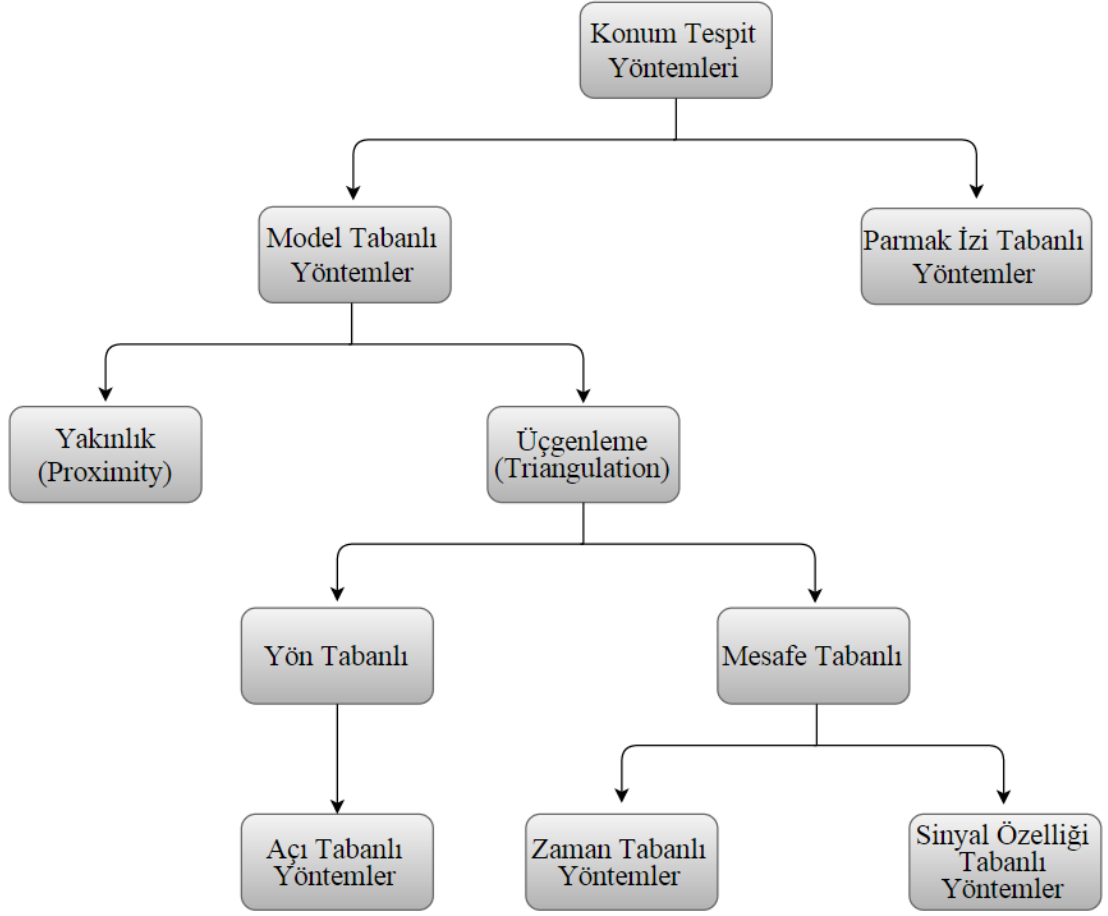
Birden fazla yer karosu kullanarak bireysel ve sade bir iç ortam takip uygulaması gerçekleştirilebilmektedir. Yer karolarının ana avantajı kullanıcı tarafından görülmemeleridir ve kullanıcıların herhangi bir etiket ile donatılmasına gerek kalmamasıdır. Genellikle sağlık sektöründe ve bireysel yardım hizmetlerinde kullanılan bu sistemler 2D ortamda duran bir insanı 1 m doğruluğa kadar tespit edebilmektedir (Mautz 2012). Bu yapı üzerine çalışan bir çok farklı sensör tekniği bulunmaktadır.

Bir bina içinde ortak bir ışık kaynağı olan floresan ışık tüplerini iç ortam konumlandırmada kullanmak mümkündür. Elektromanyetik dalgaları kullanarak boşluktaki optik veri iletimi ya da kızıl ötesi bantları, lamba akım modülasyonu ile etkinleştirilmektedir. Mobil platform üzerinde bir ışık sensörü, modüle edilmiş ışık kaynağından geçerken, sensörün konumu, en yakınındaki lambanın tekil kodunun okunması ile tespit edilir.

Bir sızdıran besleyici, binalarda ve yeraltı çevresinde radyo servisleri sağlamak için koridor boyunca dağıtılmış uzun bir koaksiyel kablodan oluşur. Adından da anlaşıldığı üzere bir sızdıran besleyici, uzunluğu doğrultusunda radyo sinyallerinin kablodan dışarı sızmasına izin verecek şekilde tasarlanmıştır. Bu teknoloji iletişim için tasarlanmış iken, sızdıran besleyici kabloların var olan alt yapısı, yayılan RF sinyallerine dayalı iç ortam konumlandırma için de kullanılabilir. İletişim için kablo boyunca homojen radyo sinyali kapsama alanı istenmesine rağmen, tüm kablo uzunluğu boyunca kaçınılmaz bir sinyal zayıflaması olmaktadır. Sinyal gücü kaybı, sinyal genliği ve konum arasında belirli bir ilişkiyi gösteren RSSI parmak izi haritası oluşturmak için kullanılabilir. Alıcının konumu, gerçek zamanlı alınan parmak izi ile veri tabanında daha önceden kaydedilmiş parmak izlerinin karşılaştırılması ile çevrim içi aşama sırasında belirlenebilmektedir. Sızdıran besleyicilerde RSSI kullanımının avantajı çevresel değişikliklere karşı dirençli olmasıdır. Sızdıran besleyici kablolar için kullanılan radyo teknolojileri GSM ve WLAN' dır (Mautz 2012).

2.4. İç Ortam Konumlandırma Yöntemleri

Akademik ve endüstriyel alanda iç ortam konumlandırma üzerine birçok yöntem geliştirilmiştir ve bu alanda yeni yöntemler geliştirilmeye devam edilmektedir. Yöntemler, model tabanlı ve parmak izi tabanlı olmak üzere Şekil 1'de görüldüğü gibi iki kategoriye ayrılmıştır. Üçgenleme, yaklaşma gibi model tabanlı yöntemler, mesafe üzerinden sinyal yayılım modeli oluşturmak için çeşitli geometrik modelleri kullanılır (Krumm 2010). Fakat sinyal yayılımı, hareket eden insanlar, kapı ve duvarlardan ötürü karmaşık sinyal zayıflaması ve sinyalin sönmesi gibi durumlarda güvenilir bir şekilde modellenemeyebilir. Parmak izi tabanlı yöntemler ise ortamda var olan sinyal kaynaklarından yararlanarak bir mobil cihazın yerini tespit etmek için çeşitli sınıflandırma yöntemlerini kullanır. Model tabanlı ve parmak izi tabanlı yöntemler aşağıda alt başlıklar halinde özetlenmiştir.



Şekil 2.15. İç ortam konumlandırma yöntemleri

2.4.1. Model tabanlı yöntemler

2.4.1.a. Yakınlık

Yakınlık, mobil cihazın yerini belirlemek için bilinen referans noktaların pozisyonunu kullanan basit bir yöntemdir. Mobil cihazın pozisyonu, en yakın referans noktaya bağlı olarak tespit edilir.

Yakınlık tabanlı sistemlerde cihaz tek bir referans nokta ya da birçok referans noktaya bağlı olarak tespit edilebilmektedir (Krumm 2010). Tek bir nokta tespit edildiğinde cihaz pozisyonunun, referans noktanın pozisyonu ile uyumlu olduğu varsayılır. Tek bir

referans noktaya baęlı tespit yapıldığı için yanlış konum tespiti olasılığı yüksektir. Fakat cihaz tarafından birden fazla referans nokta tespit edilirse, bu noktalarının konumlarının ortalaması alınmaktadır. Cihaz, sinyal gücü yüksek olan referans noktaya aęırlıklı olarak daha yakındır.

Bu yöntemin dezavantajı çevresel faktörlerden çabuk etkilenmesi, buna baęlı olarak referans noktalarının yakınlık tespitinin zor olmasıdır. Hareketli mobil cihazlar kendilerine en yüksek sinyal gücü deęerini saęlayan erişim noktası ile ilişkilendirilirler. Erişim noktalarının kapsama alanları ile sınırlı olması ve yayılma etkilerinden dolayı mobil cihaz, kendisine en yakın olmayan bir erişim noktasını en yakın olarak görebilir (Kök 2009). Bu durum yanlış konum tespitine sebep olmaktadır.

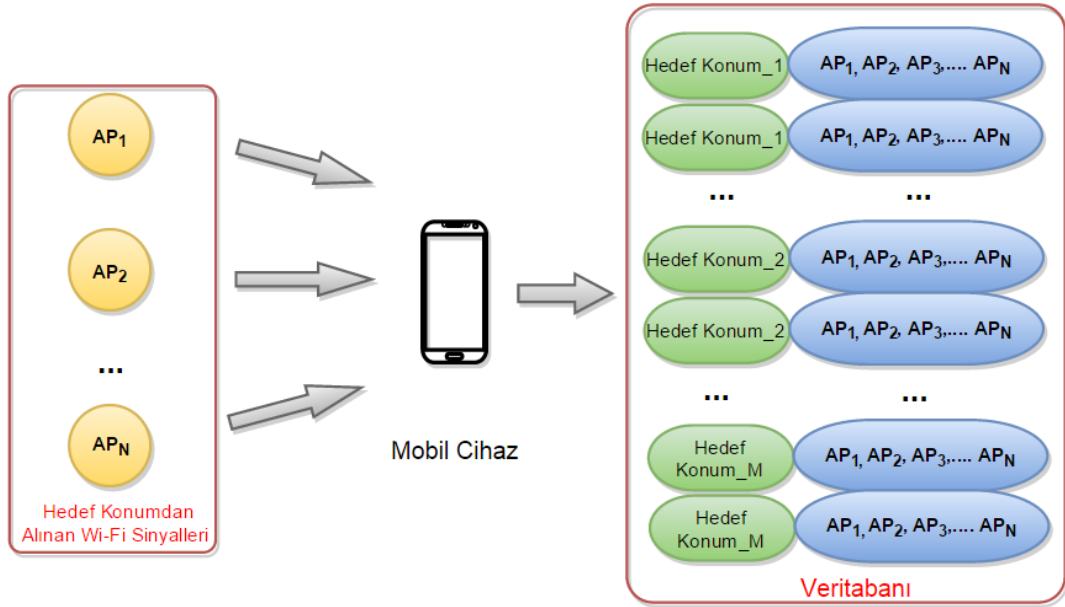
2.4.1.b. Üçgenleme

Üçgenleme yöntemi, *yön tabanlı* ve *mesafe tabanlı* olmak üzere iki şekilde uygulanmaktadır. Mesafe tabanlı yöntem, bilinen birçok referans nokta ve mobil cihaz arasındaki mesafeyi ölçmektedir (Krumm 2010). Mesafe hesabı için sinyalin varış zamanı ve sinyal gücünün zayıflaması gibi nitelikleri kullanmaktadır. Mesafe tabanlı yöntemlerde Sinyal Varış Zamanı, Sinyal Varış Zamanındaki Fark, Uçuş Zamanı gibi birçok zaman tabanlı tahminci kullanılır (Liu *et al.* 2007).

Açı tabanlı bir yöntem olan Varış Açısı Konumlandırma yöntemi ise sinyalin geliş yönünü dikkate alarak mobil cihaza ulaşan sinyallerin geliş açılarını hesaplar. Mobil cihaza ulaşan her erişim noktasının geliş açıları kesiştirilerek hareketli mobil cihazın konumu, bu kesişim noktası olarak belirlenir (Kök 2009). Bu yöntemde mobil cihazın görüş alanı içerisinde olmayan sinyaller kullanılamamaktadır. En büyük dezavantajı ise mobil cihaza gelen sinyallerin geliş açılarını hesaplamak için ek donanım gerektirmesidir (Kök 2009). Konumlandırma için ek donanım kullanımı da tercih edilen bir durum değildir.

2.4.2. Parmak izi yöntemi

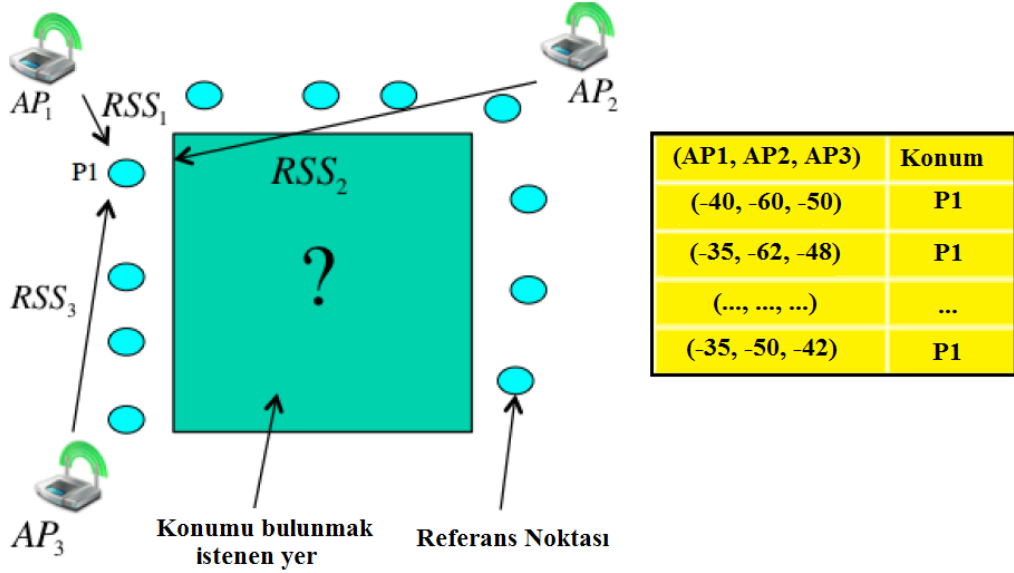
Parmak izi tabanlı yöntem, ortamda var olan sinyal kaynaklarını kullanarak mobil cihazın konumunu sınıflandırma yöntemleri aracılığıyla tespit eder. Parmak izi yöntemi, maliyeti düşük ve uygulama alanı geniş olduğundan dolayı iç ortamlarda daha fazla tercih edilmektedir. Parmak izi tabanlı iç ortam konumlandırma sistemleri, ortamda var olan sinyallerin kullanıldığı bir veri setinin oluşturulduğu çevrim dışı aşama ve konumlandırmanın gerçekleştirildiği çevrim içi aşama olmak üzere iki aşamadan oluşmaktadır. Veri toplama aşaması olarak da bilinen çevrim dışı aşama Şekil 2.16'da gösterilmiştir.



Şekil 2.16. Çevrim dışı (veri toplama) safhası

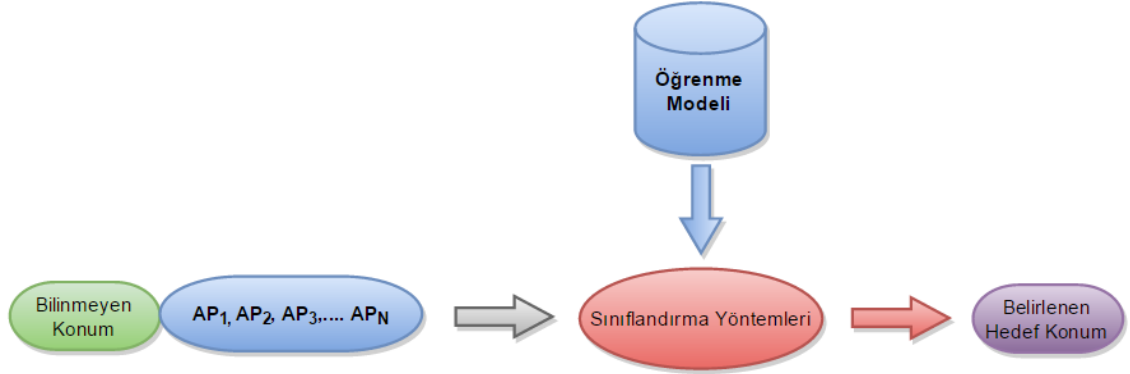
Konumlandırma işleminin başlangıcı olan bu aşama, bir mobil cihaz aracılığıyla bulunan ortamdaki görülen güçlü ve zayıf Wi-Fi sinyalleri, ortamın ismi (örneğin bir evin herhangi bir odası) ile birlikte bir veri setine kaydedilir. Bu veri setindeki her bir kayıt parmak izi olarak adlandırılır. Her bir parmak izinde, ortamda görülen Wi-Fi sinyallerinin ayırt edici ismi ve sinyal güçleri bulunur.

Mobil cihaz tarafından hedef konumdan alınan sinyal güçlerinin değerleri, erişim noktalarının yakınlığına göre değişmektedir. Ölçüm alınan referans nokta, bulunduğu konuma en yakın erişim noktasından en yüksek sinyal gücü değerini alırken, en uzak erişim noktasından en düşük değeri almaktadır. Konumlandırma işlemi de, mobil cihazın bulunduğu konuma en yakın erişim noktasının konumuna göre belirlenmektedir. Şekil 2.17’de P1 isimli referans noktası için verilen kayıt örneğinde, kendisine yakın olan erişim noktasından alınan sinyal gücünün diğer erişim noktalarına göre daha yüksek olduğu gösterilmektedir.



Şekil 2.17. Referans noktası ile erişim noktası arasındaki ilişki (Huang 2014)

İkinci aşama olan çevrim içi aşaması (Şekil 2.18) gerçek zamanlı uygulamalarda kullanıcının konumunu belirler. Konumu bilinmeyen bir sinyalin hangi odaya ait olduğunu belirlemek amacıyla, kullanıcının hareketi esnasında alınan sinyaller, birinci safhada oluşturulan veritabanındaki konumu bilinen sinyaller ile karşılaştırılır ve çeşitli sınıflandırma yöntemleri kullanılarak sinyalin ait olduğu konum tahmin edilir. Daha sonra sinyalin gerçekte ait olduğu konum ve tahmin edilen konumun birbirleriyle aynı olması durumuna göre sınıflandırma doğruluğu belirlenir.



Şekil 2.18. Çevrim içi (konumlandırma) safhası

2.5. Literatür Araştırmaları

Kablosuz teknolojileri kullanarak iç ortam konumlandırmada belirli bir seviyede başarı elde edilen bir çok çalışma yapılmıştır. Bu çalışmalarda kablosuz ağ sinyalleri tek başına kullanılmakla birlikte birden çok sinyalin kullanımı ile sınıflandırma başarıları artırılmıştır.

Bahl and Padmanabhan (2000), kullanıcı konumunu tespit eden ve kullanıcıyı takip eden RADAR isimli bir sistem önermişlerdir. Bu sistemde sınıflandırıcı olarak K-en yakın komşu yöntemi kullanılmıştır. Yazarlar kullanıcı konumunu tespit etmek için iki yaklaşım üzerine çalışmıştır. Birinci yaklaşım, çevrim dışı aşamasında Wi-Fi erişim noktalarının sinyal gücünü ölçmeye dayalıdır. Bu ölçümlerle kullanıcının hareket ettiği yönün, kullanılan en yakın komşu sayısının, erişim noktalarının sayısının ve gerçek zamanlı aşamada örnek sayısının konum tespit doğruluğunu etkileyeceği bildirilmektedir. İkinci yaklaşım ise sinyal yayılım modelidir. Dış ortamda kullanılan Rayleigh sönümlenme modeli ve Rician dağıtım modeli yerine duvar ve kat sönümlenme faktörü yayılım modeli kullanılmıştır. Bu modeller duvar ve katların sayısını dikkate alarak çalışmaktadır. Tasarlanan RADAR sisteminin doğruluğu 2-3 m civarındadır. Yazarların bir sonraki çalışmasında (Bahl and Padmanabhan 2000) ise Viterbi benzeri bir algoritma ile RADAR sistemi geliştirilmiştir. Sistemin %50'si 2,37-2,65 m civarında doğru sonuç verirken %90'ı 5,93- 5,97 m civarında sonuç vermiştir.

Wi-Fi sinyal güçlerinin kullanıldığı bir başka çalışmada (Youssef *et al.* 2003; Youssef and Agrawala 2004) Horus sistemi adı verilen bir sistem geliştirilmiş ve bu sistemde olasılık yöntemi kullanılarak konum tespiti için ortak bir kümeleme tekniği sunulmuştur. Her aday konumunun koordinatı, bir sınıf ya da kategoriye temsil etmektedir. Mesafe hatasını en aza indirmek için en yüksek olasılıklı L_i konumu seçilmektedir. Deneysel sonuçlar 2,1 m mesafede %90'dan daha fazla doğruluk elde edildiğini göstermiştir. Her örnekleme konumunda örneklerin sayısını artırmak, Gaussian dağılımının ortalama ve standart sapması için yapılan tahmini geliştireceği için doğruluğun da bu şekilde artırılabilir düşülmüştür. Olasılıksal yöntemler kullanılarak yapılan bir başka çalışmada (Roos *et al.* 2002) ofis binasının küçük bir bölgesi üzerinde grid tabanlı Bayes konum algılayıcı sistem geliştirilmiş ve %50'nin üzerinde 1,5 m alan içerisinde izleme ve konumlandırma doğruluğuna ulaşılmıştır. Olasılıksal yaklaşımın kullanıldığı ilk sistemlerden biri olan Nibble (Castro *et al.* 2001) adlı sistemde ise bir cihazın konumunu tespit etmek için Bayes ağlarının kullanıldığı bir Wi-Fi konum servisi geliştirilmiştir.

Baitti *et al.* (2002) yapay sinir ağları sınıflandırıcısını kullanarak bir konum tespit yöntemi önermişlerdir. Tek adımlı eğitim yöntemi ve çok katmanlı algılayıcı mimarisini kullanarak üç adet giriş birimi, sekiz adet gizli katman birimi ve iki çıkış birimi olmak üzere üç katmanlı mimari üzerinden çalışmışlardır. Farklı konumlardan elde edilen sinyal güçlerinden beş örnek alınarak 3 m'lik bir ortalama mesafe hatası almak için yeterli olduğunu ve eğitim örneklerinin sayısını artırmanın ortalama mesafe hatasının 1,5 m'ye azaltılacağını bildirmişlerdir. Saha *et al.* (2003) tarafından yapılan bir çalışmada ise olasılıksal yöntem ve en yakın komşu yöntemi ile yapay sinir ağları sınıflandırıcısı karşılaştırılmıştır. Deneysel sonuçlarda yapay sinir ağlarının %72 olasılıkla 1 m'lik bir hata verdiği belirtilmiştir.

Kablosuz konum algılama, robotların çeşitli sensörlerinden (GPS, sonar, görme, ultrasonik sensörleri vb.) verilen girdilerle mobil cihazın pozisyonun tespiti (robot konumlandırma), özel olarak çalışılan bir konu haline gelmiştir. Bir çok araştırmacı tarafından robot tabanlı ve izlemeye yardımcı kablosuz konumlandırma üzerine

çalışılmaktadır. Ladd *et al.* (2002; 2004) IEEE 802.11 altyapısını kullanarak grid tabanlı Bayes robot konumlandırma algoritmasını önermişlerdir. Algoritmanın ilk adımında bir ana bilgisayarda dokuz adet erişim noktasından alınan sinyallere dayalı olarak konum olasılığını hesaplamak için olasılıksal bir model kullanılmıştır. İkinci adımda ilk adımdaki sonuçları arıtmak ve mobil ana bilgisayarın konumundaki önemli değişimleri reddetmek için mobil kullanıcıların maksimum hız sınırı kullanılmıştır. İkinci adımın kullanılmış olsun veya olmasın ana bilgisayarların kendi konumlarını 1,5 m'ye kadar tahmin edebildiği görülmüştür. Siddiqui *et al.* (2003) tarafından yapılan çalışmada da Monte Carlo konumlandırma tenkiği kullanılarak bir önceki çalışmadaki (Ladd *et al.* 2002) sonuçlara benzer sonuçlar elde edilmiştir. Haeberlen *et al.* (2004) çok katlı bir ofis binasında var olan 802.11 ağının tamamı üzerinden topolojik lokalizasyon için pratik ve güçlü bir Bayes yöntemi sunmuştur. Yazarlar topolojik model kullanımının, bir çok konum tabanlı uygulamalar için konum doğruluğunu düşürmeden yerleştiricinin eğitim için gereken zamanı büyük ölçüde azalttığını gözlemlemişlerdir. Kontkanen *et al.* (2004) tarafından yapılan çalışmada yardımcı takip etme sistemi önerilmiştir ve bu sistem merkezi bir konum sunucusu üzerinden pozisyon bilgisi sağlamak için çevrim içi rakip öğrenme, stokastik karmaşıklık ve Bayes ağlarının birleşimi ile ticari bir kablosuz konum algılama sistemi haline gelen Ekahau sisteminin geliştirilmesinde kullanılmıştır. Xiang *et al.* (2004) tarafından önerilen bir sistemde daha yüksek doğruluk sağlamak için takip etme ve takip etmeme durumları arasında uyumlu geçiş olması için durum makinelerinin kullanıldığı bir izlemeye yardımcı konumlandırma algoritması ve sinyal yayılım modeli kullanılmıştır. Sistem, sabit pozisyon belirlemede %90 olasılıkla 2 m doğruluğa ve hareketli mobil cihazın konumunu belirlemede ise %90 olasılıkla 5 m doğruluğa ulaşmıştır. İlerleyen yıllarda Ekahau, RADAR gibi güçlü sistemler temel alınarak çalışmalar yapılmıştır. Place Lab ya da RADAR gibi bilinen sistemler temelli çalışan Redpin (Bolliger 2008) isimli sistem, tasarım ve zaman alıcı eğitim aşaması gerektirmeyecek şekilde çalıştırılmış ve ortamdaki Wi-Fi sinyalleri ile parmak izleri elde edilerek bu veriler üzerinden sınıflandırma işlemi yapılmıştır. Oda seviyesinde sınıflandırma yapan bu sistemde K-en yakın komşu yönteminde hesaplanan öklit mesafesi yerine farklı bir mesafe yöntemi geliştirilmiştir. Bir odada bir parmak izinin yeterli görüldüğü sistemde kullanıcıların yerini doğrulayan yeni parmak izlerini girebildiği bir arayüz oluşturulmuştur. Deneyler

sonucunda Redpin sistemi ile %90 oranında doğru oda tespiti yapıldığı görülmüştür. Lin *et al.* (2009) tarafından yapılan bir başka çalışmada Redpin sisteminde kullanılan mesafe fonksiyonuna ağırlıklı erişim noktası benzerliği adı verilen (daha fazla komşu eğitim örneklerinden gelen doğru yerleri tespit etmek) özellik eklenerek sınıflandırma doğruluğu artırılmıştır. Redpin üzerine geliştirilen bu sisteme WASP adı verilmiştir. Çalışmada her odadan en az yüz adet Wi-Fi sinyal örneği alınarak 1002 satırlık bir veri seti oluşturulmuş ve bu veri seti 10 katlamalı çapraz doğrulama yöntemi ile eğitim ve test verilerine ayrılmıştır. Bu veri seti DVM, NB, kNN, Redpin ve WASP yöntemleri kullanılarak test edilmiştir. Deneysel sonuçlarda %87 oranında oda seviyesinde en yüksek doğruluğa sahip yöntem WASP olmakla birlikte %81 doğruluk oranı ile Redpin ikinci en yüksek doğruluğa sahip yöntem olmuştur.

WLAN altyapısı üzerinde çalışılan sistemlerin çoğu sinyal gücünü kullanmakla birlikte AeroScout gibi bazı sistemler model tabanlı yöntemleri kullanırlar. AeroScout varış zamanı arasındaki farka dayalı olarak 802.11 standartını kullanır. Üç ya da daha fazla ayrı erişim noktasından alınan radyo sinyallerinin alıcıya ulaşma zamanlarına bağlı olarak konum tespiti yapılır. Bu şekilde Wi-Fi sinyalleri kullanılarak bir çok çalışma yapılmakla birlikte kablosuz teknolojilerden GSM, FM radyo, Bluetooth gibi teknolojiler ve kablosuz teknolojilerin bir arada kullanıldığı çalışmalar son yıllarda artmaktadır.

Tian *et al.* (2013) tarafından yapılan bir çalışmada, GSM ağlarından RSS parmak izleri ve destek vektör makineleri kullanılarak zaman içerisinde değişen konumlandırma performansı değerlendirilmiştir. Alınan sinyal tabanlı oda seviyesinde destek vektör makineleri (SVM) sınıflandırıcısı, bir aylık periyot içerisinde elde edilen eğitim ve test verilerinde çok yüksek sonuçlar elde etmesine rağmen zaman içerisinde performans düşüşü meydana gelmektedir. Bunu önlemek amacıyla güncellenmiş sınıflandırıcı elde etmek için, yeni toplanan etiketsiz verilerle ayırt edici fonksiyonun sürekli bir şekilde ayarlanmasını sağlayan bir yöntem önermişlerdir. Aynı ortamdan farklı aylarda birden fazla veri seti hazırlanarak “Transductive SVM” adı verilen sınıflandırma modelinin güncellenmesi sağlanmıştır. Deneysel sonuçlar, odaların tespitinde model, RSS

kaymalarının olduđu verilerden önce kullanıldığında %94'e kadar doğruluk oranına ulaşılabilmiştir. Performans düşüşünün komşu odalar arasında alınan sinyal güçlerinin birbirlerine yakın olmasından kaynaklandığı gözlemlenmiştir. Önerilen “Transductive SVM (TSVM)” adlı yöntem, kaybolan bu performansı önemli derecede iyileştirmiştir. Oluşturulan veri setlerinden SVM ile elde edilen performans %60.4 iken aynı veri setlerinde TSVM ile elde edilen performans %78.4 olmuştur.

Wi-Fi ve GSM sinyalleri ile birlikte çevreyi derinden algılamak için telefonun mikrofonu kullanılarak ortamın sesi ve kişilerin konuşmalarının analiz edildiği bir başka çalışmada (Du *et al.* 2013), kullanıcının konuşma sesi bilgisi ile kullanıcının bulunduğu konumun daha doğru belirlenebilmesi için güçlü AdaBoost toplu öğrenme algoritması önerilmiştir. 100 gönüllü tarafından farklı android mobil cihazlarla 2 aylık bir süre içerisinde 61 farklı iç ortamdan veri toplanmıştır. Aynı zamanda bir ekran tarafından konum takibi ve arkayüz sunucuda programa göre kullanıcı davranışı takip edilebilmektedir. Geliştirilen ses tespit algoritmasının performansının %94 oranında bulunduğu, Wi-Fi ve GSM teknolojisi kullanılarak bir çok farklı aday tarafından farklı sahnelerin oluşturulduğu sistemde ses bilgisi ile birlikte ortalama %90 oranında konumlandırma doğruluğuna ulaşılabilirdiği belirtilmiştir.

Var olan WLAN alt yapısı üzerinden oda seviyesinde iç ortam konumlandırma yapılan bir çalışmada (Buchman and Lung 2013), kNN algoritması gibi hesaplama yoğunluğu fazla olan maksimum hassasiyetle optimize edilmiş algoritmalar kullanılmaktadır. kNN gibi yöntemler, RSS haritasını kullandıkları için, RSS verilerinin bir çok faktörden (yansımalar, hareketler, kapı ve pencerenin kapanıp açılması vb.) etkilenmesinden dolayı lokalizasyon hatalarına sebep olmaktadır. Oda seviyesinde konumlandırma işleminde de odalar, duvarlarla ayrıldığı için radyo sinyallerinin duvarlardan dolayı sönümlenmesi durumu dezavantajdır. Bu yüzden çalışmada bir noktansa oda seviyesinde ayrılmış RSS desenleri kullanılmıştır. Kovaryans tabanlı parmak izi yönteminde eşleşmiş filtreleme kullanılarak sinyal işleme yöntemi uygulanmıştır. Eşleşmiş filtreleme; giriş sinyalinde bir şablonun varlığını tespit etmek için giriş sinyali ile şablon sinyalini ilişkilendirir. Karar, ilişkilendiricinin çıktısı ile eşik değeri karşılaştırılarak alınır. Eğer çıktı eşik değeri aşmış ise giriş sinyali ile şablon sinyali

eşleştirilir. Giriş sinyali, takip edilen cihazdan alınan n adet sinyal değeridir. Şablon sinyal ise çevrim dışı aşamasında kaydedilen ve etiketi bilinen sinyallerdir. Giriş sinyalinin son durumu eşleşen maksimum çıktıya göre belirlenmektedir. Yöntemde sırasıyla her odadan alınan RSS değerleri kaydedilmiştir, geçici oda şablonları oluşturulmuştur ve bu şablonlar gerçek oda şablonlarına dönüştürülmek için normalize edilmiştir. Geçici oda şablonları, kaydedilen RSS verilerinin ortalamalarından farkı alınarak belirlenmiştir. Oda şablonu formatında RSS okumalarını iletmek için hedef programlanmıştır. Daha sonra hedef oda şablonu ile tüm odaların şablonunun kovaryansı hesaplanmıştır. Son olarak hedef odanın sınıfı kovaryans değeri yüksek olana göre belirlenmiştir. Deneyde 8 adet erişim noktasından 6 tanesinde şablon ve giriş sinyali eşleşmiştir. 4 tanesinin çok yakın değerlerde eşleşmesi görülürken 2 tanesinde zıt işaretli olarak eşleşme görülmüştür. 2 tanesinde de giriş sinyalin şablonu tespit edilememiştir. Çalışmada az sayıda erişim noktası üzerinden test işlemi yapılmıştır. Daha iyi sonuç almak için bir odada görülen erişim noktası sayısının daha fazla olması gerektiği kanısına varılmıştır. Böylece bir ya da daha fazla sinyalde uzun vadeli değişimin doğru kararı etkilemeyeceği düşünülmektedir.

Oda seviyesinde lokalizasyonun yanı sıra ortalama mesafe hatasını tespit eden çalışmalar da bulunmaktadır. Ortalama mesafe hatası üzerine çalışılan bir çalışmada (Moghtadaiee *et al.* Dempster 2011) FM radyo sinyalleri ile parmak izi yöntemi temel alınarak konumlandırma doğruluğunu artırmak için deterministik yöntemlerden ağırlıklı K-en yakın komşu (KWNN) ve olasılıksal yöntemlerden histogram ve kernel birlikte kullanılmış, bu sisteme “SoOP (Utilizing Signals of Opportunity)” adı verilmiştir. Her iki yöntemde de tahmin edilen doğru konumların ortalaması alınarak yeni konum elde edilmiştir. Bir çok algoritma ortalama mesafe hatası (mean distance error- MDE), veri toplama zamanı, algılanan kanal numarası ve referans noktalarının sayısı olarak 4 perspektiften karşılaştırılmıştır. Kombine edilmiş bu yeni yöntemin 2,48 m ortalama mesafe hatası ile diğer yöntemlere göre en iyi yöntem olduğu belirlenmiştir. Çalışmanın diğer bir katkısı ise aynı testler Wi-Fi sinyalleri ile yapıldığında bir alanda Wi-Fi sinyalleri büyük değişime uğrayabildiği için FM sinyallerine göre daha az doğruluk edilmiştir. Fakat Wi-Fi ve FM radyo sinyallerinin birlikte kullanıldığı hibrit sistemde ortalama mesafe hataları dikkate alındığında %9’a kadar performans artışı gözlenmiştir.

Wi-Fi ve Bluetooth sinyallerinin birlikte kullanıldığı bir başka çalışmada (Galvan-Tejada *et al.* 2013) daha doğru mesafe ölçümü için Bluetooth sinyallerinden bir yayılım modeli algoritması geliştirilmiştir ve bu algoritma Wi-Fi sinyalleri ile birleştirilerek iç ortamda kullanıcının pozisyonu tespit edilmiştir. İlk önce yayılım modeli oluşturmak için Bluetooth'dan elde edilen bir RSSI değeri ile ilişkili mesafe ölçümleri alınmıştır ve Wi-Fi sinyalleri ile bilinen yayılım modeli kullanılarak bir mesafe hesaplanmıştır. Yani alıcının konumunu elde etmek için Wi-Fi ve Bluetooth'un birlikte kullanıldığı bir algoritma oluşturulmuştur. Bu algoritma, iç ortam konumlandırma için kullanılan 4 farklı yöntem ile (Wi-Fi ve GPS'in birlikte kullanılması, Bluepass, Trilateration ve Dinamik kalibrasyon) karşılaştırılmış ve 0,87 m oranında en düşük konum kestirim hatasına sahip olduğu gözlenmiştir. Wi-Fi ve Bluetooth sinyallerinin bir arada kullanıldığı bir başka çalışmada (Taniuchi *et al.* 2015), sırasıyla Wi-Fi ve Bluetooth sinyal güçlerinin alındığı mobil cihazlar arasındaki mesafe ve pozisyon tahmini, tahmin edilen mesafe ve pozisyonun güven değerini hesaplama ve son olarak olası konumlandırma hatalarını azaltmak için bir "spring model" (mobil cihazların konumlarının estetik bir şekilde grafik çizimi ile konumlandırılması) geliştirilmiştir. Deneysel sonuçlarda farklı sayıda odalar ve cihazlarla doğruluk oranının %3-%32 civarında arttığı gözlenmiştir. En iyi performans, 0,98 m ortalama konumlandırma hatası ile çoklu oda senaryosunda dört adet mobil cihazla ölçüm yapılan bir ortamda gerçekleşmiştir.

En iyi test RSS parmak izlerinin eşleştiği bir alan aramaya dayalı konumlandırma yönteminin (Best Matching Area-BMA) geliştirildiği bir başka çalışmada (Stella *et al.* 2014); WLAN, UMTS ve GSM ağları bir arada kullanılarak gerçek bir ortamda performans değerlendirmesi yapılmıştır. Önerilen bu yöntem temel olarak belirli bir eşik değere göre güçlü RSS değerlerinin çıkarımına dayanmaktadır. Önerilen yöntemin performansını doğru bir şekilde değerlendirmek amacıyla geliştirilen bu yeni yöntemle birlikte literatürde yer alan K-en yakın komşu, yapay sinir ağları, histogram tabanlı ve Gaussian kernel tabanlı yöntemlerin de performans analizleri yapılmıştır. Bu yöntemler, üç sinyal ağının ayrı ayrı kullanıldığı ve üçünün bir arada kullanıldığı sistemlere uygulanmış ve üç sinyalin bir arada kullanıldığı yöntemin 1,82 m konum tahmin hatası ile en iyi performansı gösterdiği gözlenmiştir.

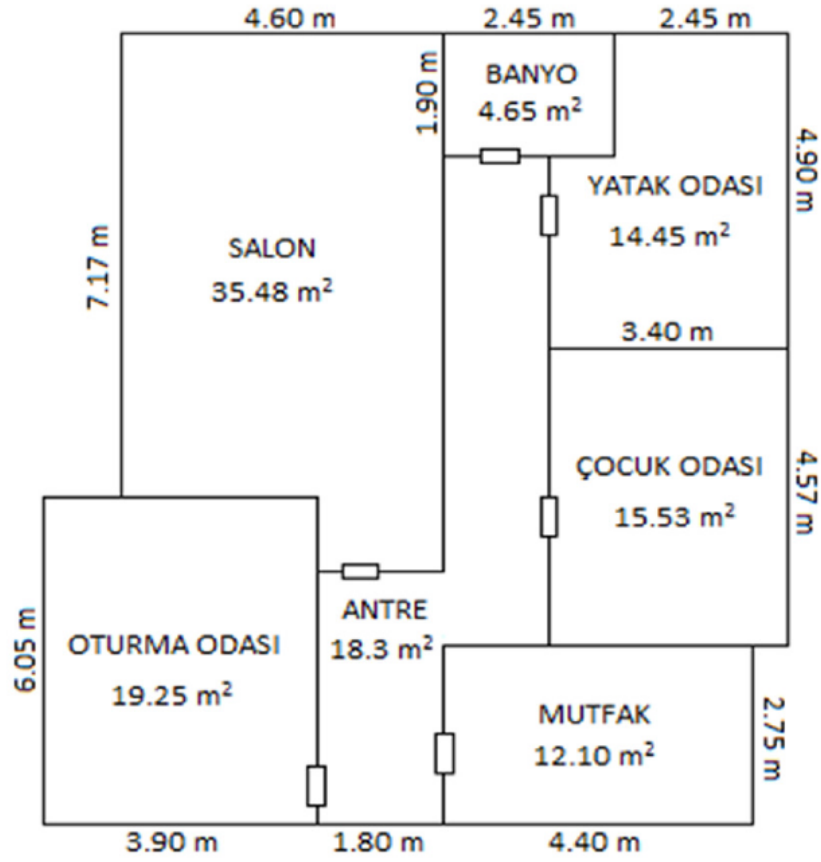
Wang *et al.* tarafından 2015 yılında yapılan bir başka çalışmada, parmak izi ile iç ortam konumlandırma yönteminde bulunan iki fazda farklı işlemler yapılarak eğri uydurma ve konum aramaya dayalı yeni bir şema geliştirilmiştir. Çevrim dışı fazında parmak izlerinin oluşturulduğu tüm alan alt alanlara bölünerek her alt alan için yeni bir parmak izi oluşturulmuştur. Daha sonra her alt alanda her verici için uyarlanmış RSS mesafe fonksiyonunu oluşturmak için eğri uydurma tekniği uygulanmıştır. İki aşamadan oluşan çevrim içi fazının ilk aşamasında mobil cihazın ait olduğu alt alanlar belirlenmiştir. İkinci aşamada da alt alanlarda toplam mesafe hatalarını azaltmak için kapsamlı arama ve gradyan düşüş arama olmak üzere iki konum arama yöntemi önerilmiştir. Konumlandırma sonuçlarının önerilen bu yöntemin klasik parmak izi tabanlı ve açı tabanlı konumlandırma yöntemlerine göre %20 oranla geliştiği gözlemlenmiştir. Geliştirilen yöntemin minimum konumlandırma hatası 1,97 m iken ortalama konumlandırma hatası, kullanılan cihazın türüne göre 2 ile 2,5 m arasında değişmektedir.

3. MATERYAL ve YÖNTEM

Bu tez çalışmasında iç ortamda oda seviyesinde konumlandırma yapabilmek için ortamdaki Wi-Fi sinyallerini kullanarak parmak izi tabanlı konumlandırma gerçekleştirilmiştir. İki farklı ortamdaki (ev ve iş yeri) elde edilen veri setlerine pek çok makine öğrenmesi yöntemi uygulanarak iki veri setinde oluşan doğruluk oranları farkı incelenmiştir. İş yeri veri seti olarak WASP çalışmasından elde edilen veri seti kullanılmış, ev veri seti de bir apartman dairesinin birinci katında bulunan bir dairede odalardan görülen sinyal bilgileri ile hazırlanmıştır. Ortam farklılığının iç ortam konumlandırmaya etkisini incelemek amacıyla her iki veri setinde de cep telefonlarından elde edilen Wi-Fi sinyallerinin ayırt edici isimleri ve sinyal güçleri kullanılmıştır. Veri setleri, k- en yakın komşu (kNN), Nâive Bayes (NBS), Geri Yayılım (GY), Destek Vektör Makinesi (DVM), Rastgele Orman (RO), Redpin ve WASP yöntemi olmak üzere 7 farklı yöntem ile test edilerek 10-katlamalı çapraz doğrulama yöntemi ile doğruluk yüzdeleri karşılaştırılmıştır.

3.1. Veri Toplama

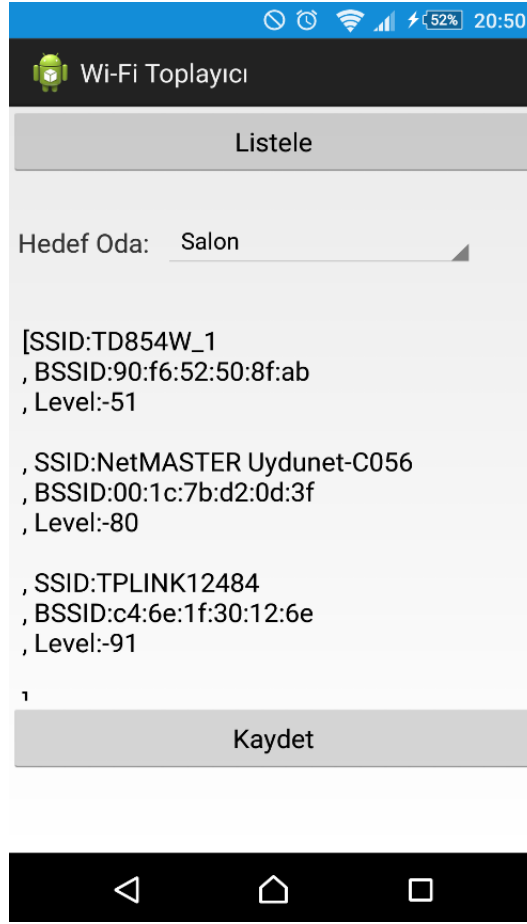
Wi-Fi sinyal bilgileri, apartman dairesinin birinci katında 6 odadan oluşan yaklaşık 140 m²'lik bir evden elde edilmiştir. Sony Z2 cep telefonunda bir Android uygulama gerçekleştirilerek verileri otomatik kaydetme işlemi yapılmıştır. Oluşturulan veri setinin hazırlandığı evin krokisi Şekil 3.1'de gösterilmiştir.



Şekil 3.1. Veri setinin hazırlandığı evin krokisi

Veri toplama aşamasında Oturma Odası, Mutfak, Salon, Yatak Odası, Banyo ve Çocuk Odası olmak üzere 6 odada deneyler yapılmıştır. Her bir odanın yeterli eğitim verisine sahip olması için 100'er örnek alınarak toplamda 600 adet veri kayıtları edilmiştir.

Bulunulan odada görülen erişim noktalarının sinyal güçlerini toplamak için tasarlanan uygulamanın ekran görüntüsü Şekil 3.2'de gösterilmiştir.

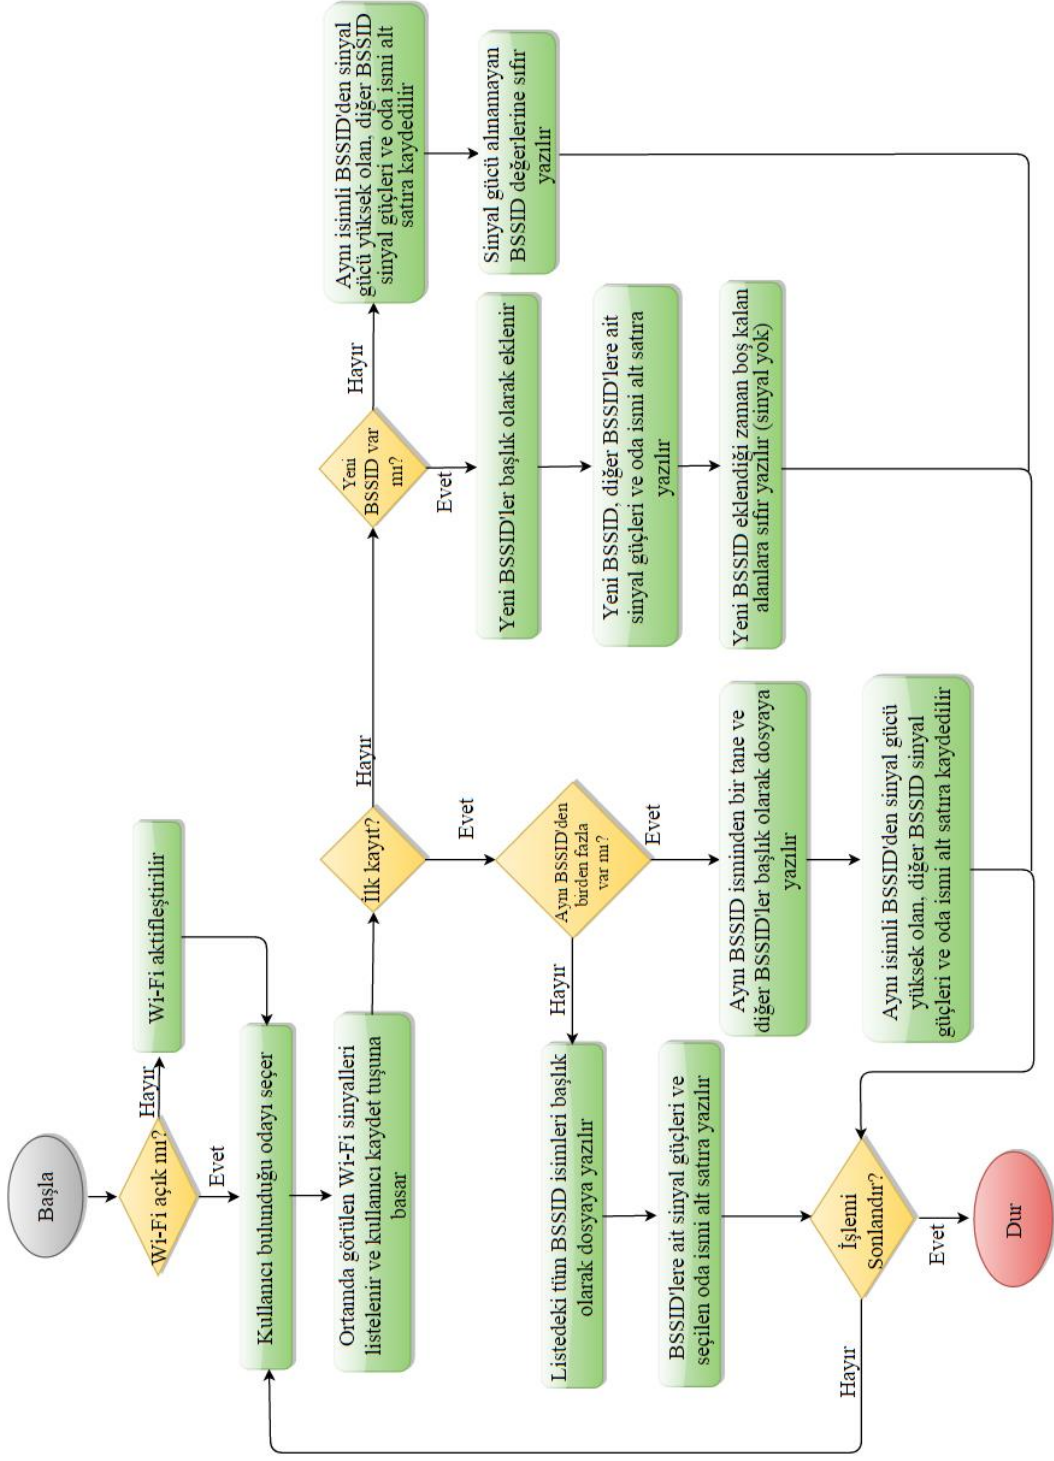


Şekil 3.2. Ortamdaki Wi-Fi sinyallerini listeleyip kaydetmeyi sağlayan android uygulama

Şekil 3.2’de görüldüğü gibi kullanıcı, bulunduğu odayı, hedef oda kısmında bulunan listeden seçip listele butonuna tıkladığı zaman, o ortamda görülen Wi-Fi erişim noktalarının SSID, BSSID ve sinyal güçleri ekranda listelenir. Uygulama, her bir ölçümde hedef odada görülen sinyallerin ayırt edici isimlerini (BSSID) sinyal güçleri ile birlikte kaydeder. İlk ölçümde listede görülen tüm BSSID’ler, başlık şeklinde veri setine kaydedilir. Başlık satırının bir alt satırına bu BSSID’lerden görülen sinyal güçlerinin değeri, seçilen hedef oda son sütunda olmak üzere kaydedilir. Daha sonra yapılan ölçümlerde dosya okuma işlemi yapılarak daha önce görülen BSSID’ler başlık olarak eklenmez. Yeni alınan BSSID’ler ayrı bir sütun olarak veri setine kaydedilir ve o BSSID’den sinyal gücü alınmayan önceki ve sonraki değerlere sıfır değeri atanır. Ölçüm sayısına bağlı olarak anlık görülen sinyal sayısı değişebilir. Bu yüzden veri

setinin belirli BSSID'ler belirlenerek oluşturulması yerine, her ortamda görülen BSSID'leri ve sinyal güçleri kaydedebilecek bir yöntem geliştirilmiştir. Uygulamada aynı SSID ve BSSID'ye sahip erişim noktasından farklı güçlerde sinyal değerleri listelenirse, sinyal gücünün en kuvvetli değeri alınarak veri setine kaydedilir.

Veri toplama için gerçekleştirilen uygulamanın akış diyagramı Şekil 3.3'de verilmiştir.



Şekil 3.3. Veri toplama aracı akış diyagramı

Android uygulama aracılığıyla otomatik oluşturulan veri setinin bir parçasının ekran görüntüsü Şekil 3.4’de görülmektedir.

AP1	AP2	AP3	AP4	AP5	AP6	AP7	AP8	AP9	AP10	AP11	AP12	AP13	Hedef Oda
0	0	0	86	0	0	0	0	0	0	0	0	0	0 Salon
0	80	0	76	0	0	0	0	0	0	0	0	0	0 Salon
69	52	0	87	0	0	0	91	0	0	0	0	0	0 Çocuk Odası
89	70	0	74	94	0	0	0	0	0	0	0	0	0 Salon
73	68	0	0	0	0	87	0	0	0	0	0	0	0 Mutfak
63	58	0	82	0	0	0	0	0	0	85	0	0	0 Çocuk Odası
88	78	0	72	90	0	0	0	0	0	0	0	0	0 Salon
0	68	0	83	85	0	0	0	88	0	0	0	0	0 Yatak Odası
0	85	0	84	88	0	0	0	0	0	0	0	0	0 Salon
66	59	0	0	0	0	0	0	0	0	0	0	0	0 Çocuk Odası
76	68	76	0	0	0	0	89	0	0	0	0	0	0 Mutfak
0	76	0	81	0	0	0	0	0	0	0	0	0	0 Oturma Odası
81	76	0	90	0	0	0	0	0	0	0	0	0	0 Oturma Odası
76	68	0	0	88	0	88	0	0	0	0	0	0	0 Yatak Odası
66	57	76	82	0	0	0	88	0	0	0	0	0	0 Çocuk Odası
83	86	0	0	89	0	0	0	0	0	0	0	0	0 Yatak Odası
74	61	0	0	0	0	89	0	0	0	0	0	0	0 Yatak Odası
76	66	0	0	84	0	0	0	0	0	90	0	0	0 Yatak Odası
91	70	0	84	89	0	0	0	0	93	0	92	0	0 Banyo
82	62	0	0	0	0	88	0	0	0	89	0	0	0 Yatak Odası
87	67	0	0	0	0	90	0	0	92	0	0	0	0 Yatak Odası
65	55	0	83	0	0	0	91	0	0	0	0	0	0 Çocuk Odası
0	79	0	83	87	0	0	0	0	0	0	0	0	0 Salon
74	54	0	0	85	0	0	0	0	0	0	0	0	0 Yatak Odası

Şekil 3.4. Bulunulan ortamın ismi ve o ortamda görülen Wi-Fi sinyallerinden oluşan veri seti

Şekil 3.4’de bir kısmı görülen veri seti, bir evin 6 odasından 100’er ölçüm alınarak hazırlanmıştır. Sinyal gücü alınan her BSSID ismi, AP₁, AP₂..., AP_N şeklinde veri setine otomatik bir şekilde kaydedilmiştir. Bulunulan ortamda bir erişim noktasından alınan sinyal gücü yok ise 0, var ise sinyal gücünün değeri yazılmıştır.

3.2. Verileri Sınıflandırmada Kullanılan Sınıflandırma Yöntemleri

Çevrim dışı aşamasında veri toplama işleminin gerçekleştiği parmak izi yönteminde, çevrim içi aşamasında konumu bilinmeyen sinyallerin sınıflarının belirlenmesi için birçok sınıflandırma yönteminden faydalanılmaktadır.

Bu çalışmada Wi-Fi sinyallerinden elde edilen büyük boyuttaki veri setinin analiz edilmesinde WEKA adı verilen makine öğrenmesi yöntemlerini içeren bir araç

kullanılmıştır. WEKA, Yeni Zellanda'daki Waikato Üniversitesi tarafından geliştirilmiş olup, makine öğrenmesi yöntemlerini bir arada barındıran, çeşitli uzantılarda dosya eklenip uygulanabilen, açık kaynak kodlu bir veri madenciliği programıdır (Witten *et al.* 2011). WEKA çeşitli veri ön işleme, sınıflandırma, regresyon, kümeleme, ilişkilendirme kuralları ve görselleştirme araçlarını içerir.

Verilerin sınıflandırılmasında WEKA programında yer alan K-en yakın komşu (kNN), Nâive Bayes (NB), Geri Yayılım (GY), Destek Vektör Makinesi ve Rastgele Orman (RO) yöntemlerinin yanısıra, iç ortam konumlandırma alanında büyük oranda performans artışı göstermiş olan Redpin (Bolliger 2008) ve WASP (Lin *et al.* 2009) yöntemleri, JavaFx platformu üzerinde uygulanmıştır. Kullanılan bu yöntemler aşağıda alt başlıklar halinde açıklanmıştır.

3.2.1. K-en yakın komşu (kNN)

Veri madenciliğinin en temel yöntemi olan K-en yakın komşu yönteminde, test kümesinden alınan bir örneği sınıflandırmak için, bu örneğin eğitim kümesindeki her bir örnek ile arasındaki mesafe hesaplanır. Daha sonra k tane en küçük mesafeli eğitim kümesi örneği seçilir ve bu örneklerde en sık görülen etiket, test örneğinin etiketi olarak belirlenir. Eğitim kümesi ile test kümesinden alınan örnek arasında yapılan vektörel hesaplamalar Euclidean, Manhattan, Edit, Chebyshev gibi mesafe fonksiyonları tarafından yapılmaktadır. Bu çalışmada en temel mesafe hesaplama yöntemi olan Öklit (Euclidean) mesafesi kullanılmıştır. Öklit mesafesi aşağıdaki gibi hesaplanmaktadır:


$E_{Ap_1}, E_{Ap_2} \dots E_{Ap_N}$: eğitim veri setindeki sinyal güçleri

$T_{Ap_1}, T_{Ap_2} \dots T_{Ap_N}$: test veri setindeki sinyal güçleri

N : erişim noktası sayısı

$$\sqrt{(T_{Ap_1} - E_{Ap_1})^2 + (T_{Ap_2} - E_{Ap_2})^2 + (T_{Ap_3} - E_{Ap_3})^2 + \dots + (T_{Ap_N} - E_{Ap_N})^2}$$

Hesaplanan mesafelere göre örnekler bir örnek uzayında Şekil 3.4'te görüldüğü gibi bir koordinat düzleminde bulunur. Seçilen k değerine göre sınıfı bilinmeyen örneğe en yakın k noktaya bakılarak "oylama" tekniği ile en fazla sayıda sınıf etiketi örneğin sınıf etiketi olarak belirlenir (Vinodhini *et al.* 2013).



Şekil 3.5. K-en yakın komşu (kNN) yöntemi (Anonymous 2015)

Şekil 3.5 üzerinden K-en yakın komşu yöntemi anlatılırsa; yeşil ile gösterilen örnek sınıfı bilinmeyen ve k değerine göre belirlenecek olan örnektir. k değeri 1 olarak belirlendiğinde yeşil örneğe en yakın mesafede olan kırmızı üçgen şeklinde gösterilen örneğin sınıfı, yeşil örneğin de sınıfı olarak belirlenmektedir. k değeri 3 verildiğinde, iki adet kırmızı üçgen örneği ile bir adet mavi kare örneğinin sınıfına bakılır. Aynı sınıfa ait olan kırmızı üçgen örnekleri daha fazla olduğu için test örneğinin sınıfı yine kırmızı üçgenin sınıfı olmaktadır.

Sınıflandırma yöntemlerinin performans değerlendirmesinde sadece doğruluk değil çalışma süresi de büyük önem taşımaktadır. Bir algoritmanın çalışma süresi, zaman karmaşıklığı olarak ifade edilmektedir. Bir programın zaman açısından performansını değerlendirmek için karmaşıklık ölçütlerinden en kötü durum işletim süresi (Worst-case Running Time) – O notasyonu yaygın olarak kullanılmaktadır.

K-en yakın komşu yönteminde d boyutlu bir örnek uzayında, n adet veri sayısında en yakın komşu sinyalin sınıfının bulunma süresi $O(d*n)$ olarak hesaplanmaktadır.

3.2.2. Nâive Bayes (NB)

Olasılıksal sınıflandırma yöntemlerinden biri olan Nâive Bayes yöntemi, etiketi bilinen (sınıflandırılmış) örnek verileri kullanarak etiketi bilinmeyen yeni bir verinin mevcut sınıflardan herhangi birine ait olma olasılığını hesaplar. Örneklerin hepsi aynı derecede öneme sahip olup bir özelliğin değeri diğer bir özellik değeri hakkında herhangi bir bilgi içermemektedir (Karakoyun ve Hacıbeyoğlu 2014).

Parmak izi şeklinde kaydedilen sinyaller üzerinde Nâive Bayes yöntemi uygulandığında; sınıf etiketi C olan her F_i özelliğinin şartlı olasılığı eğitim verisinden öğrenilir. Yani, C sınıf etiketi, F değerleri ise sinyal güçleri olmak üzere;

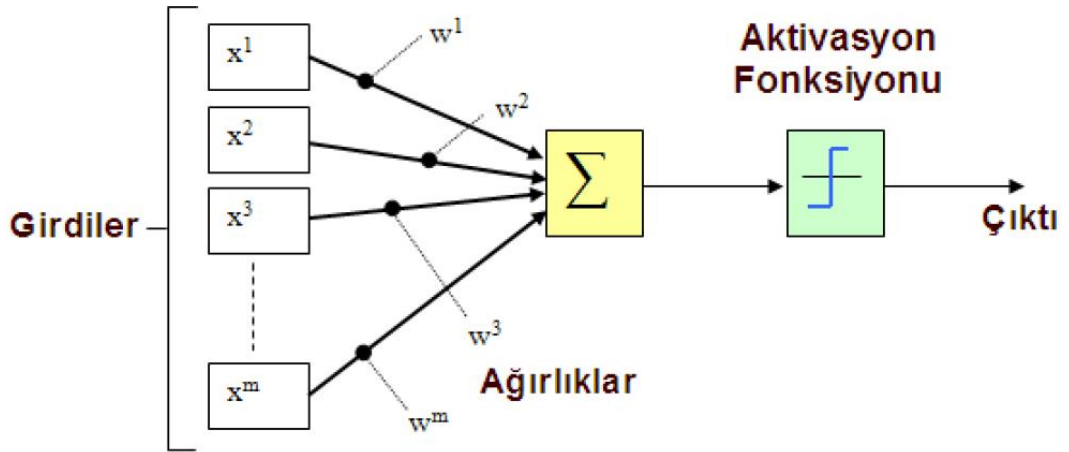
$$P(C | F_1, F_2, \dots, F_n) = \frac{P(C) P(F_1, F_2, \dots, F_n | C)}{P(F_1, F_2, \dots, F_n)}$$

işlemi ile sınıfı bilinmeyen bir sinyalin C sınıfına ait olma olasılığı bulunur. Sinyalin C sınıfına ait olma olasılığı, o sonuca etki eden tüm faktörlerin sonucu sağlama olasılıklarının çarpımıdır. Olasılık hesapları sonucunda sinyalin hangi sınıfa ait olduğu, en yüksek olasılık değerini veren sınıf olarak belirlenir (Vinodhini *et al.* 2013).

Nâive Bayes yönteminde n eğitim örneği sayısı ve v özellik sayısı olmak üzere zaman karmaşıklığı $O(n*v)$ olarak hesaplanmaktadır.

3.2.3. Geri yayılım yöntemi (GY)

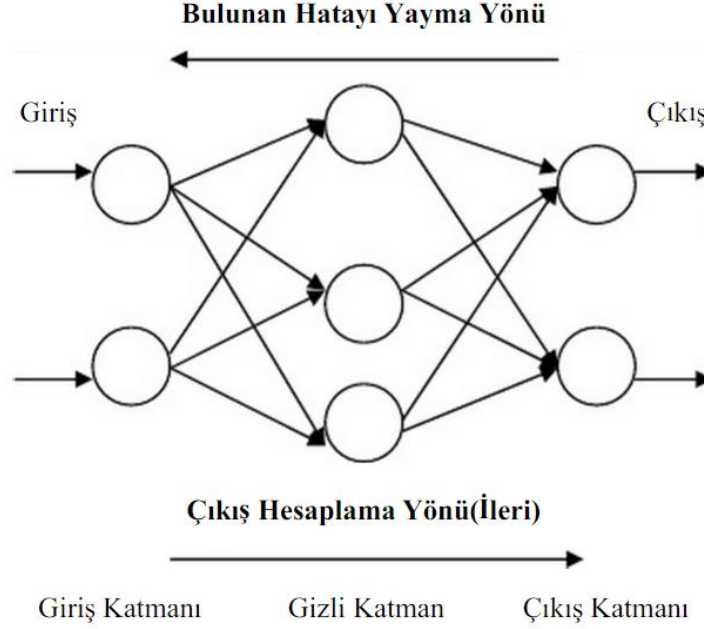
Yapay sinir ağları (YSA), insan beyninin biyolojik sinir hücrelerinden yola çıkılarak öğrenme yolu ile yeni bilgiler üretebilme yeteneğini otomatik olarak gerçekleştirme amaçlı geliştirilen bir makine öğrenmesi modelidir (Karakoyun ve Hacıbeyoğlu 2014). Şekil 3.6’ da temel yapısı gösterilen YSA’ da, işleme alınacak girdi verileri, bu verilere uygulanan ağırlıklar ve aktivasyon fonksiyonu ile hesaplanan çıktı değerleri bulunmaktadır.



Şekil 3.6. YSA’ya ait bir algılayıcının temel yapısı (Karakoyun ve Hacıbeyoğlu 2014)

YSA modellerinden biri olan geri yayılım yönteminde, en az bir hücrenin çıkışı, kendisine ya da diğer hücrelere giriş olarak verilir. Hataları çıkıştan girişe olmak üzere geriye doğru azaltmaya çalıştığı için geri yayılım adını almıştır (Russel *et al.* 2010). Bu ağ modelinde giriş, çıkış ve gizli katman (birden fazla olabilir) olmak üzere üç katman bulunmaktadır. Giriş katmanı, yapay sinir ağında işlenecek olan giriş verileridir. Bu katmanda giriş sayısı kadar nöron sayısı bulunmaktadır. Gizli katman, giriş katmanından alınan ağırlıklandırılmış veriyi “uygunluk fonksiyonu” ile işleyerek bir sonraki katmana veriyi iletir. Bu katmanda bulunan nöron sayısı, giriş verilerine göre hassas çıkışların elde edilmesi açısından önemlidir. Yani gereğinden az ya da çok nöron sayısı, verilerden doğru çıkış elde edilme olasılığını azaltır. Çıkış katmanı, gizli katmandan alınan veriyi ağırlıklandırılmış uygunluk fonksiyonu ile işleyerek çıkış değerini verir. Bu

katmandaki nöron sayısı, ağda işleme alınan her verinin çıkış sayısı kadardır. Şekil 3.7’de çok katmanlı geri yayımlı yapay sinir ağının yapısı verilmektedir.



Şekil 3.7. Çok katmanlı geri yayımlı yapay sinir ağı

Bir giriş verisi, çıkış katmanına ulaşmaya kadar çeşitli işlemlerden geçer. Bu işlemler sonucunda elde edilen çıktı ile gerçekte olması gereken çıktı karşılaştırılır. Bu değerler arasındaki fark, her çıktı düğümü için bir hata sinyali olarak hesaplanmaktadır (Russel *et al.* 2010). Çıkış katmanındaki her bir hücreye ait hata sinyallerinin karelerinin toplamı da uygunluk fonksiyonu olarak adlandırılmaktadır (Karadeniz *et al.* 2001). Hesaplanan bu hata sinyalleri, her çıktı düğümüne karşılık gelen ara katmandaki düğümlere aktarılır. Her gizli katmandaki düğümler toplam hatanın belirli bir kısmını bulunduracak şekilde giriş katmanına kadar ulaşır. Geri yayımlı bir öğrenme kuralı ile her bir katmandaki ağırlıklar ağ çıkışındaki hata seviyesine göre yeniden hesaplanmaktadır (Russel *et al.* 2010).

YSA eğitiminin k 'inci iterasyonunda çıkış katmanındaki i 'inci sinirinin çıkış değeri y_i , bu sinirden verilen istenilen değer d_i ile gösterilirse, i sinirinin hata sinyali (Karadeniz *et al.* 2001):

$$e_i = d_i - y_i(k)$$

dir. Uygunluk fonksiyonu da:

$$E = \frac{1}{2} \sum_i e_i^2(k) = \frac{1}{2} \sum_i (d_i - y_i(k))^2$$

denklemleri ile ifade edilir. Geri yayılım yönteminin amacı uygunluk fonksiyonunu minimum değere indirmektir. Uygunluk fonksiyonu yapay sinir ağına verilen ağırlık değerlerine bağlı olduğundan, bu yöntem ağırlıkların geri yayımlı bir şekilde değiştirilmesi ile en uygun değerlerin elde edilmesini hedeflemektedir. Her bir w_{ij} ağırlık değerinin değişme miktarı gradyan-azalma yöntemi olarak adlandırılan aşağıda verilen denklem ile bulunmaktadır (Karadeniz *et al.* 2001):

$$\Delta w_{ij} = -\eta \frac{\partial E(\vec{w})}{\partial w_{ij}}$$

Formülde bulunan η öğrenme katsayısıdır.

Gerilim yayılım yönteminde her bir iterasyon, ileri ve geri yayılım olmak üzere iki aşamadan oluşur. İleri yayılım aşamasında yapay sinir ağına verilen giriş sinyallerine karşılık gelen çıkış sinyallerinin değerleri hesaplanır. Geri yayılım aşamasında ise çıkış sinyallerinde oluşan hatalar hesaplanır ve sinir ağındaki ağırlıklar yeniden düzenlenerek yeni çıkış sinyal değerleri üretilir. Yapay sinir ağındaki ağırlık değişimi:

$$\Delta w_{ij} = \eta \delta_j y_i$$

denklemleri ile hesaplanmaktadır. δ_j , çıkış katmanı sinirleri için:

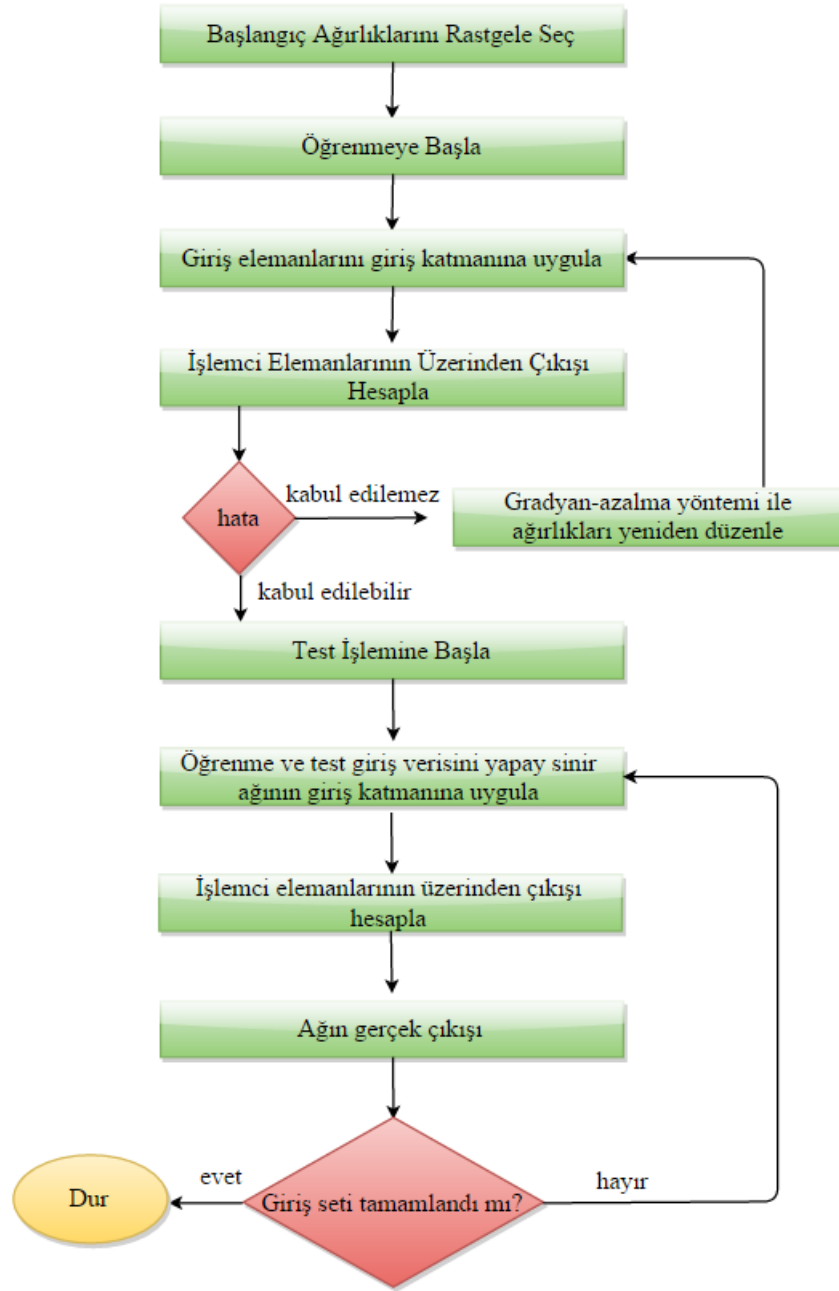
$$\delta_j = e_j(k) f'_j$$

Gizli katmanlarda bulunan sinirler için:

$$\delta_j = f'_j \sum_m \delta_m w_{mj}$$

olarak hesaplanır. Burada f'_j , sinirin aktivasyon fonksiyonudur. Bu hesaplamalar ile hata sinyallerinin sinir ağının çıkışından girişine doğru akışı gerçekleşir.

Geri yayılım yönteminin veri akış diyagramı Şekil 3.8'deki gibidir.



Şekil 3.8. Geri yayılım yönteminin akış diyagramı (Sağıroğlu vd 2003)

YSA'nın eğitiminde giriş katmanı ile gizli katman arasına rastgele atanan ağırlıklar önem taşımaktadır. Rastgele atanan bu ağırlıklar ile eğitime hangi noktadan başlanacağı belirlenir ve bu noktanın gerçek çözüme uzaklığı ya da yakınlığı, başlangıçta belirlenen değerlere doğrudan bağlıdır. Diğer bir önemli nokta ise eğitimin sürdürülme süresidir. Eğitime işlemi için sabit bir eğitim sayısı sonucunda elde edilen hatayı kabul etmek ya

da belirli miktardaki hata toleransını göze alarak o hata değerinden daha düşük hata elde edene kadar eğitimi sürdürmek olarak iki seçenek bulunmaktadır (Ataseven 2013).

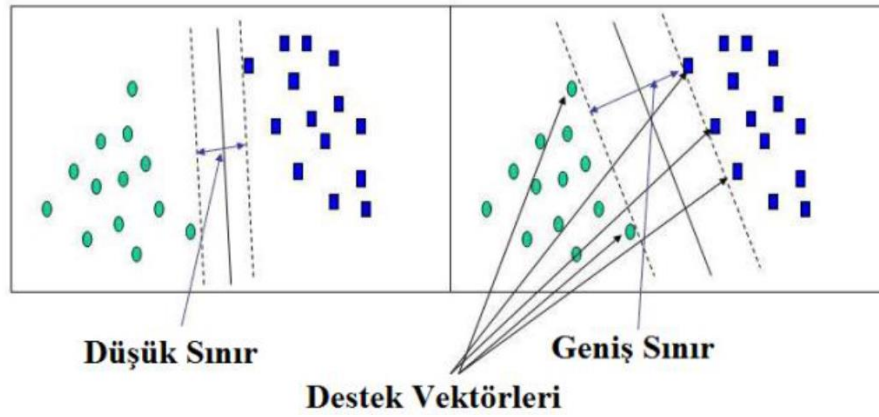
YSA'nın eğitiminde sonucu etkileyecek diğer bir parametre de η öğrenme katsayısıdır. Bu katsayı, bağlantı ağırlıklarının değişim miktarını belirler. Her zaman birden küçük ve pozitif değerler alması gereken öğrenme katsayısı kullanılan örneklerin benzerliklerine göre değişim göstermelidir. Eğer kullanılan örnekler birbirlerine çok benzer ise η 0,8 – 0,9 civarında değerler verilebilir. Böylelikle eğitim zamanı kısaltılmış olur. Fakat örnekler yeterince tutarlı değil ise oluşacak gürültülerden korunmak için öğrenme katsayısı 0,2 – 0,1 arasında olmalıdır. Örnekler hakkında herhangi bir tahmin yok ise ortalama bir değer alınmalıdır (Ataseven 2013).

Bu çalışmada WEKA'nın yapay sinir ağlarında varsayılan değer olarak eğitim zamanı 500 (veriler üzerinden geçme sayısı) alınmıştır. Eğitim zamanı 5, 10, 50 ve 100 katına çıkarıldığında elde edilen sonuçlarda büyük değişiklikler (en fazla %0,2 oranında artış) gözlenmemiştir. Bu yüzden 500 iterasyonunun bu çalışma için yeterli olduğu tespit edilmiştir. Öğrenme katsayısı olarak da ortalama bir değer olan ve WEKA'da varsayılan olarak verilen 0,3 değeri kullanılmıştır.

Çok katmanlı bir algılayıcının eğitim aşamasında hesaplama karmaşıklığına etki eden bir çok faktör bulunmaktadır. i giriş düğümlerinin sayısı, k gizli katmandaki düğümlerin sayısı ve o da çıkış düğümlerinin sayısı olmak üzere eğitim safhasının baskın faktörü ağırlıklardır. Tam bağlantılı durum için $k*i$ sayısı kadar ağırlık girişten gizli katmandaki düğümlere bağlanır. $k*o$ sayısı kadar ağırlık da gizli katmandaki düğümlerden çıkış düğümlerine bağlanır. Bu hesaplama toplamda $k*(i + o)$ adet ağırlık belirlendiğini gösterir. Tüm gizli katman için $O(i*k*o)$ süresi geçmektedir. Toplamda geri yayımlı bir yapay sinir ağında tek devirli bir eğitim, $O(i*o*k + k*o)$ ya da $O(k * o * (i+1))$ zaman almaktadır (Istook and Martinez 2002)


3.2.4. Destek vektör makineleri (DVM)

Destek vektör makineleri negatif örnekler ile pozitif örnekleri birbirlerinden ayırmak için hiper düzlemler şeklinde ifade edilebilen sınıflandırma, regresyon ve aykırı belirleme için kullanılabilen desen sınıflandırıcılarıdır. İstatistiksel öğrenme teorisi ve yapısal risk minimizasyonuna dayanır. Eğitim aşamasında farklı sınıflara ait örnekleri optimal düzeyde ayıran bir karar sınırı belirlenir. Bu sınırın çizileceği yer farklı grupların üyelerine en uzak olan yer olmalıdır (Karakoyun ve Hacıbeyoğlu 2014). Bu karar sınırı doğrusal ya da doğrusal olmadan ayrılabilir. Doğrusal olarak ayırma işleminde karar sınırı, verileri ayırabilecek sonsuz sayıda bir çok doğrudan kenarı en büyük yapacak olan doğru olarak belirlenir (Abe 2010). Karar sınırı ve herhangi bir örnek arasındaki en yakın mesafe kenar olarak tanımlanmıştır. Şekil 3.9'da gösterilen destek vektörlerde noktalı gösterilen çizgiler en yakın vektörler arasında mesafeyi ayıran çizgiye paralel bir şekilde çizilir. Noktalı çizgiler arasındaki genişlik kenarı belirler. Kenar genişliğini belirleyen vektörler de destek vektörlerdir (Karakoyun ve Hacıbeyoğlu 2014).



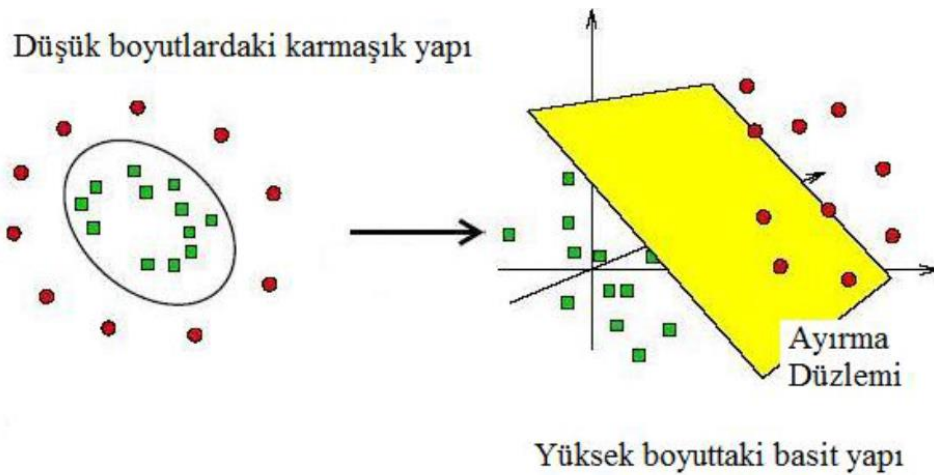
Şekil 3.9. DVM yönteminde karar sınırı ve kenar belirleme (Karakoyun ve Hacıbeyoğlu 2014)

Verilerin uzayda dağınık bir şekilde bulunduğu durumlarda Şekil 3.10'daki gibi doğrusal olmayan bir eğri uydurulur.



Şekil 3.10. DVM yönteminde doğrusal olmayan sınıflandırma (Karakoyun ve Hacibeyoğlu 2014)

Doğrusal olmayan ayrılma işleminde eğri uydurma yerine veri, haritalama yöntemi ile orijinal girdi uzayından daha yüksek boyuttaki bir uzaya aktarılır. Bu boyutta sınıflandırma hatasını en aza indirgeyen çoklu düzlem araştırılır (Abe 2010). Böylece rastgele belirlenen doğrusal olmayan bir çizgiden çok daha tutarlı sonuçlar elde edilir. Şekil 3.11’de doğrusal olarak ayrılamayan verilerin yüksek boyuttaki uzaya aktarılması görsel olarak ifade edilmiştir.



Şekil 3.11. Doğrusal olarak ayrılamayan verilerin yüksek boyuta taşınması (Karakoyun ve Hacibeyoğlu 2014)

DVM yöntemi eğitim aşamasında kuadratik optimizasyon yöntemlerini kullandığı için zaman karmaşıklığı $O(n^3)$ şeklindedir. Burada n eğitim veri setinin boyutudur.

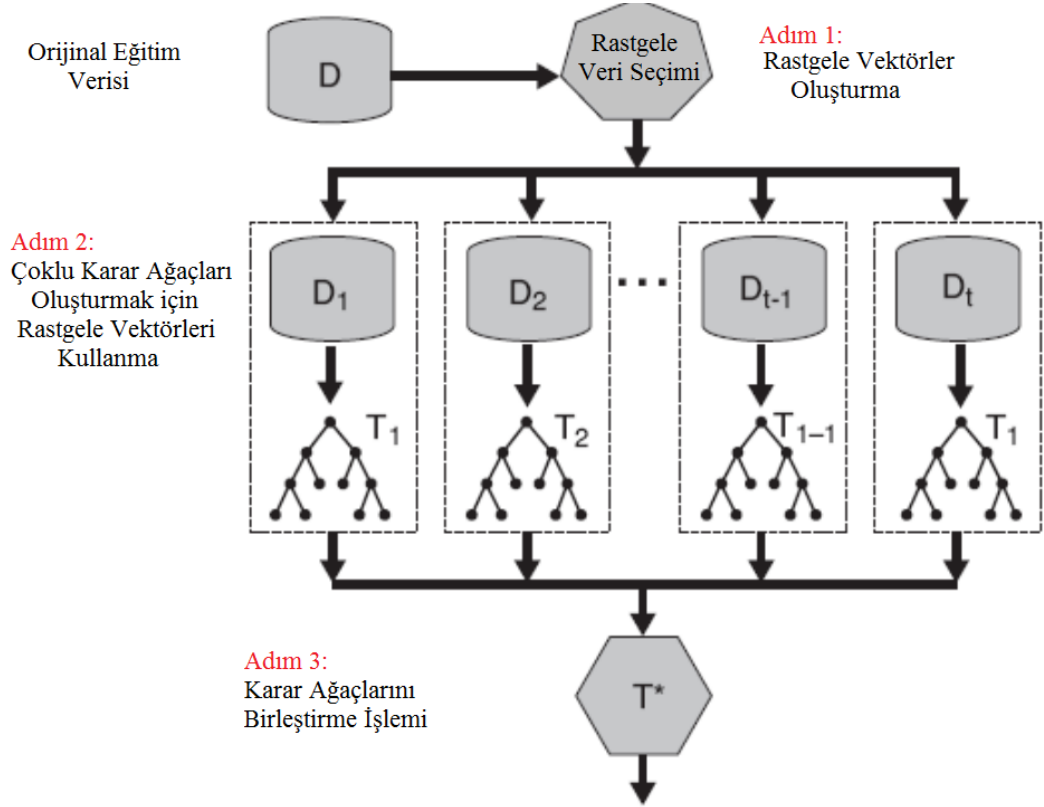
3.2.5. Rastgele orman (RO) yöntemi

Ağaç yapılı sınıflandırıcıların toplamından oluşan rastgele orman yöntemi, ağaç topluluğunda bulunan ve kullanıcı tarafından belirlenen K adet ağaçtan her ağaç üzerinde giriş vektörünü inceleyerek giriş vektöründen yeni nesneyi sınıflandırır. Her ağaç, sınıflandırma sonucunda verilen giriş vektöründe bir birim oy ataması yapar. Bu yöntemde ormandaki tüm ağaçlar üzerinden en çok oya sahip sınıflandırma seçilir (Guo *et al.* 2004).

Ağaç topluluğu oluşturulurken; eğitim veri setindeki N adet örnek sayısı N sayıda durumla rastgele olarak yer değiştirilerek ağaç oluşturmaktadır. Her düğümde m tahminleyici, M adet giriş değerlerinden rastgele seçilir ($m < M$) ve bu m tahminleyici üzerinde en iyi bölme, düğümü ayırmak için kullanılır (Guo *et al.* 2004). Bu m değeri ormanın büyümesi sırasında sabit tutulur. En iyi dallanma kriteri, gini indeksi ile hesaplanır ve hesaplanan değere göre veri seti her düğümde iki dala ayrılır (Akman vd 2011). En yakın optimal değerlere ulaşmak için varsayılan m değeri M sayısının karekökü olarak belirlenmiştir ($m = \sqrt{M}$). Her ağaç, mümkün olan en geniş ölçüde budama işlemi olmadan büyür.

Mevcut ağaç için eğitim seti, yer değiştirme ile örnekleme yoluyla oluşturulduğunda, durumların yaklaşık üçte biri örnek dışında bırakılır. Dışarıda kalan veriler sınıflandırma hatasını tahmin etmek için test seti olarak kullanılır. Bu yüzden test verisinin hata oranını tahmin etmek için bir test veri setine veya katlamalı bölme yöntemlerine ihtiyaç yoktur. Dışarıda kalan bu veriler üzerinden test işlemi tarafsız olarak yapılır. Test işlemi esnasında tüm ağaçlar, ayrılan bu test verisi ile test edilerek hata oranları hesaplanır. Daha sonra bu hata oranlarının ortalaması alınarak karar ormanının hatası hesaplanır. Karar ormanının hata oranına göre tüm ağaçlara ağırlık verilir. Hata oranı ile ağaca verilen ağırlık değeri ters orantılı olarak işlenmektedir.

Belirlenen ağırlıklara göre en yüksek oya sahip ağaç, sınıf tahmini olarak belirlenir (Akman vd 2011). Rastgele orman yönteminin basit bir akış diyagramı Şekil 3.12’de verilmiştir.



Şekil 3.12. Rastgele orman yöntemi veri akış diyagramı

Rastgele orman yönteminin mevcut sınıflandırma yöntemleri ile karşılaştırıldığında daha doğru sonuçlar vermesi, büyük boyutlu veri setleri üzerinde etkili bir şekilde çalışabilmesi, kayıp verilerin tahmini için etkili bir yöntem olması ve verilerin büyük bir kısmı eksik olduğunda doğruluğunu koruması, sınıflandırma için önemli olan özellikleri tahmin edebilmesi ve diğer yöntemlere göre gürültüye karşı güçlü olması gibi bir çok özelliğinden dolayı popüler bir sınıflandırma yöntemidir.

Budanmamış bir karar ağacının tamamını oluşturmak için gerekli zaman karmaşıklığı $O(v * n \log(n))$ şeklindedir. Burada n , kayıt sayısı iken v , özellik sayısıdır. Karar ağaçlarından oluşan rastgele orman yönteminde ise oluşturmak istenilen ormandaki

ağaç sayısı (n_{tree}) ve her düğümde kaç tane değişkenin örnekleneceği (m_{try}) önemlidir. Her düğümde örneklenecek değişken sayısı hesaba katıldığında bir ağacın zaman karmaşıklığı $O(m_{try} * n \log n)$ olmaktadır. Çok sayıda ağacın oluşturulması için elde edilen zaman karmaşıklığı ise $O(n_{tree} * m_{try} * n \log(n))$ 'dir. En kötü durum analizinde ağacın derinliğinin $O(\log n)$ olacağı varsayıldığında çoğu durumda ağacın oluşturulma süreci bu süreden önce gerçekleşir ve bu süreyi tahmin etmek zordur. Rastgele orman yönteminde ağacın derinliği belirli bir miktarda sınırlandırılabilir. Ağaç derinliği kullanıcı tarafından maksimum p seviyesinde sınırlandırıldığında elde edilen zaman karmaşıklığı $O(n_{tree} * m_{try} * p * n)$ şeklindedir.

3.2.6. Redpin

Bolliger (2008) tarafından geliştirilen Redpin adlı sistem, mobil cihazlarda gerçekleştirilen parmak izi tabanlı bir iç ortam konumlandırma sistemidir. Bu sistemin temel prensibi Place Lab on Radar gibi bilinen sistemler üzerine temellendirilmiş olmasıdır. Redpin ile cihaz üzerinde Wi-Fi erişim noktaları, Bluetooth ve GSM sinyal gücünü tespit etmek mümkündür. Ayrıca sistemi kullanırken zaman alıcı eğitim safhasını ihmal etmek için metotlar geliştirilmiştir ve folksonomy yaklaşımı kullanılmıştır. Folksonomy, kullanıcı tarafından oluşturulan elektronik etiketlerden türetilen bir sınıflandırma sistemidir. Ayrıca bu yaklaşım, sistemin hızlı bir şekilde çevresel değişikliklere adapte olmasını sağlar. Yer değiştiren erişim noktaları, çevresel değişikliğe örnek olarak verilebilir.

Bilinen parmak izi tabanlı iç konumlandırma sistemlerinde çevrim içi ve çevrim dışı aşama olmak üzere iki aşama kullanılırken Redpin'de çevrim dışı aşama olan veri toplama aşaması gerektirmeden ortam değişikliğine hızlı uyum sağlayabilecek yeni bir yaklaşım sunulmuştur. Bolliger, eğitim aşaması olarak da bilinen çevrim dışı aşamanın, çevresel değişikliklerden dolayı tekrar tekrar yapıldığı için küçük bir alanda bile çok zaman kaybettiğini belirtmiştir.

Parmak izi tabanlı Redpin sistemi tasarlanırken aşağıdaki maddelerin gerçekleşmesine önem verilmiştir:

- Herkesin sahip olduğu bir donanımı kullanmak (cep telefonu, tablet vs.)
- Yapım esnasında herhangi bir özel yazılım kurulumu gerektirmemesi
- Bakımı ve kurulumunun kolay olması
- Oda seviyesinde en iyi doğruluğu sağlamak
- Çevre değişikliklerine uyum sağlayabilecek bir sistem olması

Bu sistemin en önemli özelliği, iç ortam konumlandırma sistemi olarak kullanıcı etkileşimli olması (kullanım ve kurulum kolaylığının olması) ve herkes tarafından erişilebilir açık kaynak lisans altında piyasaya sürülmesidir.

Redpin mimarisi (1) Algılayıcı (2) Yer Belirleyici olmak üzere iki bileşenden oluşmaktadır. Algılayıcı bileşeninde parmak izi oluşturmak için farklı kablosuz cihazlar hakkında bilgi toplanır. Bu bileşenin mobil cihazlar üzerinde çalışması zorunludur. Algılayıcı ölçümünde GSM, Wi-Fi, Bluetooth olmak üzere 3 farklı sinyal kaynağı ölçülmüştür. Ayrıca mümkün olduğunda farklı kaynakların sinyal değerleri okunmaya çalışılmıştır. Bluetooth cihazları her zaman kısa sürede tespit edilemediğinden ölçümler aynı anda ve aynı yerde alınsa bile farklılık gösterebilmektedir. Bu üç sinyal tipinin birleştirilmesinin en büyük avantajı gerçek ölçümler ile sistemin çalışma performansının test edilebilmesidir.

Merkezi sunucu tarafından çalışan yer belirleyici bileşeni, algılayıcı bileşeninde ölçülen parmak izlerini veri tabanında saklar ve mobil cihazın yerini tespit etmeyi sağlayan sınıflandırma yöntemini içerir.

Redpin sisteminde kullanılan sınıflandırma yönteminin temeli k-en yakın komşu (kNN) yöntemine dayanmaktadır. Redpin yöntemi erişim noktalarının görünür ve görünür olmayışına odaklanmıştır. kNN yönteminde sınıfı bilinmeyen bir örnek ile eğitim setindeki örnekler arasında mesafe hesabı yapılırken genellikle Öklit mesafesi

kullanılmaktadır. Öklit mesafesinde sadece sinyal gücünün değerlerine göre vektörel olarak yakınlık hesabı yapılırken Redpin yönteminde benzer (NCAP) ve benzer olmayan (NNAP) erişim noktalarının sayısı ve erişim noktalarının benzerliği (SIM) göz önüne alınarak yeni bir fonksiyon geliştirilmiştir. Bu yöntemde mesafe fonksiyonunun formülü aşağıdaki gibidir (Finkel *et al.* 2014):

$$Redpin(E_{Ap}, T_{Ap}) = \alpha NCAP(E_{Ap}, T_{Ap}) + \beta NNAP(E_{Ap}, T_{Ap}) + \gamma SIM(E_{Ap}, T_{Ap})$$

$E_{Ap_1}, E_{Ap_2} \dots E_{Ap_N}$: eğitim veri setindeki sinyal güçleri

$T_{Ap_1}, T_{Ap_2} \dots T_{Ap_N}$: test veri setindeki sinyal güçleri

N : erişim noktası sayısı

NCAP ve NNAP değerleri ile veri setinde bulunan sinyal gücü değerlerine göre erişim noktalarının benzer olup olmadığına bakılır. NCAP eğitim ve test kümesinden alınan sinyal örneklerinde benzer sinyallere sahip erişim noktalarının sayısını verirken, NNAP benzer olmayan sinyallere ait erişim noktalarının sayısını hesaplar. Bu değerlerin hesaplanmasında δ fonksiyonu kullanılır. δ fonksiyonu, sinyal gücü 0'dan farklı ise 1, değilse 0 döndürecek şekilde aşağıdaki gibi tanımlanmıştır:

$$\delta(Ap) = \begin{cases} 0, & \text{Eğer } Ap = 0 \\ 1, & \text{Eğer } Ap \neq 0 \end{cases}$$

δ fonksiyonu ile sinyal gücünün olup olmadığına bakıldıktan sonra \sqcap ve \oplus işareti ile eğitim ve test kümesinden alınan örneklerin değerleri işleme alınır. \sqcap işareti ikili VE (AND) işlemine, \oplus işareti ise ikili ÖZELVEYA (XOR) işlemine karşılık gelmektedir. NCAP VE NNAP fonksiyonlarının açılımı aşağıdaki gibidir (Finkel *et al.* 2014):

$$NCAP(E_{Ap}, T_{Ap}) = \sum_{i=1}^N \delta(E_{Ap_i}) \cap \delta(T_{Ap_i})$$

$$NNAP(E_{Ap}, T_{Ap}) = \sum_{i=1}^N \delta(E_{Ap_i}) \oplus \delta(T_{Ap_i})$$

NCAP benzer olan erişim noktalarını tespit ettiği için, eğitim ve test örnekleri δ fonksiyonu sonucunda aynı değerleri alıyorsa toplam değere 1 eklenir (erişim noktalarının benzer olduğunu gösterir), farklı değerler alıyorsa 0 eklenir. NNAP fonksiyonunda ise benzer olmayan erişim noktalarına bakıldığı için değerler aynı ise 0, farklı ise 1 eklenmektedir ve N adet ölçüm sayısı kadar bu işlem devam etmektedir.

Benzer ve benzer olmayan erişim noktalarının sayısının hesaplanmasından sonra iki sinyalin benzerliğini ölçen benzerlik fonksiyonu (*SIM*) ve yardımcı *H* fonksiyonu Redpin'in kaynak kodundan (Bolliger 2008) aşağıdaki gibi elde edilmiştir.

$$SIM(E_{Ap}, T_{Ap}) = \begin{cases} 1, \text{Eğer } H(E_{Ap}, T_{Ap}) > 1 \\ -1, \text{Eğer } H(E_{Ap}, T_{Ap}) < -1 \\ H(E_{Ap}, T_{Ap}) \text{ diğer durumlar} \end{cases}$$

$$H(E_{Ap}, T_{Ap}) = \sigma \left(\frac{E_{Ap}}{|E_{Ap} - T_{Ap}|} - \frac{E_{Ap}}{\omega} \right)$$

σ ve ω parametleri benzerlik fonksiyonunda kullanılan ağırlık ve eşik değerleridir ve *SIM* sonucunun yüksek olması, iki sinyalin benzerliğinin yüksek olduğunu gösterir.

α , β ve γ katsayıları (Tablo 1) ile çarpılarak elde edilen bu üç değer toplamı, test kümesinden alınan değer ile eğitim kümesinden alınan değer arasındaki mesafe hesabı olarak tanımlanmıştır. Öklit mesafesinde verilen k değerine göre en küçük değerde k adet örneğe bakılırken, Redpin yönteminde sinyallerin ve erişim noktalarının benzerliğine bakıldığı için benzerlik oranı fazla olan test kümesindeki örneğe daha yakın olarak belirlenmektedir. Bu yüzden verilen k değerine göre k tane en büyük

vektörel mesafeli örneğe bakılır. k adet örnekten en fazla sayıda geçen sınıf etiketi, test örneğinin sınıf etiketi olarak belirlenir.

Redpin yönteminin ana avantajı iki sinyal çiftinin karşılaştırılmasında benzerlik fonksiyonunun kullanılmasıdır, bu yöntemin aksine DVM gibi geometrik sınıflandırıcılarda iki öge karşılaştırıldığı zaman sadece mevcut bilgiler kullanılmaktadır (Finkel *et al.* 2014).

kNN tabanlı bir yöntem olan Redpin yönteminde d boyutlu bir örnek uzayında, n adet veri sayısında bilinmeyen bir sinyalin sınıfının bulunma süresi $O(d*n)$ olarak hesaplanmaktadır.

3.2.7. WASP (Weighted AP Similarity Positioning)

WASP (Lin *et al.* 2009), eğitim verisindeki sinyaller ile etiketi bilinmeyen, gerçek zamanlı alınan test sinyallerini eşleştirirken en yakın eğitim verisinin pozisyonunu kullanıcının mevcut pozisyonu olarak kullanan, Redpin yöntemine dayalı bir yöntemdir.

Sinyal dalgalanmasının etkisini azaltmak için bir yerdeki erişim noktalarının görünümü her zaman aynı değildir. Çünkü çevresel değişimler aynı yerde Wi-Fi sinyallerinin dalgalanmasına sebep olurlar. Bu yüzden bir yerde daha çok görünen Wi-Fi sinyalleri bu yöntemde ağırlandırılmıştır. Yani bir Wi-Fi sinyalinin bir yerde görülme sıklığına göre ağırlıklandırılmış erişim noktaları bulunmaktadır (Lin *et al.* 2009).

WASP yönteminde Redpin'de gerçekleştirilen işlemlerle birlikte ağırlıklı erişim noktalarının benzerliğine bakılmıştır. Bir ortamda sıklıkla bulunan erişim noktaları tespit edilerek iç ortamlarda oluşan sinyal dalgalanmalarının etkisi azaltılmaya çalışılmıştır. WASP yönteminin mesafe fonksiyonunun genel formülü aşağıdaki gibidir (Lin *et al.* 2009):

$$WASP(E_{Ap}, T_{Ap}) = \alpha NCAP(E_{Ap}, T_{Ap}, L) + \beta NNAP(E_{Ap}, T_{Ap}, L) + \gamma SIM(E_{Ap}, T_{Ap})$$

WASP yönteminde Redpin yönteminden farklı olarak NCAP ve NNAP fonksiyonlarına parmak izinin L konumunda olup olmadığını hesaplayan olasılık fonksiyonu eklenmiştir. Bu fonksiyonların açılımı aşağıdaki gibidir Finkel *et al.* 2014):

$$NCAP(E_{Ap}, T_{Ap}, L) = \sum_{i=1}^N \delta(E_{Ap_i}) \cap \delta(T_{Ap_i}) \times PMI(L, i)$$

$$NNAP(E_{Ap}, T_{Ap}, L) = \sum_{i=1}^N \delta(E_{Ap_i}) \oplus \delta(T_{Ap_i}) \times PMI(L, i)$$

Erişim noktalarının her bir etiket ile ilişkili olma olasılığı PMI fonksiyonu ile hesaplanmaktadır. PMI fonksiyonunun açılımı aşağıdaki gibidir (Finkel *et al.* 2014):

$$PMI(L, AP) = \log \frac{P(\text{Location} = L, \text{AccessPoint} = AP)}{P(\text{Location} = L)P(\text{AccessPoint} = AP)}$$

PMI parametrelerinden L, hesaplanacak olasılıkla kullanılan sinyalin etiketi (sınıfı), AP ise L ortamında görülme sıklığını tespit etmek için ele alınan erişim noktasıdır.

PMI fonksiyonunun payında bulunan olasılık fonksiyonunun açılımı (Finkel *et al.* 2014):

$$P(\text{Location} = L, \text{AccessPoint} = AP) = \frac{\sum_{f \in \text{Parmakizleri}} \delta(AP, f) \delta(f, L)}{\sum_{f \in \text{Parmakizleri}} \sum_{i \in AP} \delta(i, f)}$$

PMI fonksiyonunun paydasında bulunan olasılık değerlerinin açılımı:

$$P(\text{Location} = L) = \frac{\sum_{f \in \text{Parmakizleri}} \text{Loc}(f) = L}{\sum_{f \in \text{Parmakizleri}} 1}$$

$$P(\text{AccessPoint} = AP) = \frac{\sum_{f \in \text{Parmakizleri}} \sum_{i \in AP} i = AP}{\sum_{f \in \text{Parmakizleri}} \sum_{i \in AP} \delta(i, f)}$$

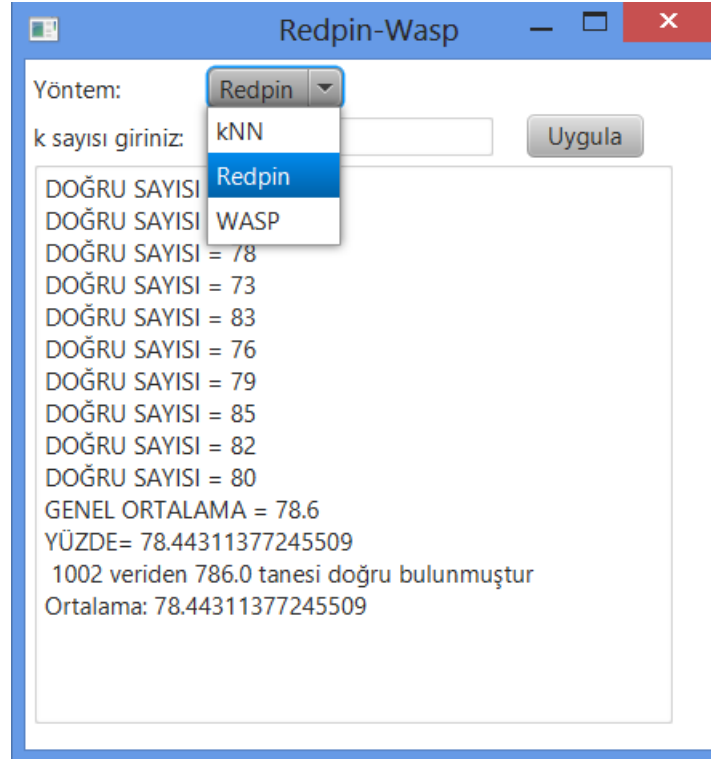
PMI değeri sayesinde test edilen her erişim noktasının eğitim verisindeki sınıfa ait olma olasılığı hesaplanır. Seçilen k değerine göre mesafe fonksiyonundan elde edilen en büyük değerler göz önüne alınır. kNN yönteminde, k değerine göre sınıfı bilinmeyen örneğe en yakın mesafede k noktaya bakılırken, WASP yönteminde sonucunda elde edilen mesafe değerlerinden k adet en büyük değerın etiketine bakılır ve ‘‘oylama’’ tekniđi ile en fazla sayıda olan sınıf etiketi, örneđin sınıf etiketi olarak belirlenir.

Redpin tabanlı bir yöntem olan WASP yönteminde de Redpin yönteminde olduđu gibi d boyutlu bir örnek uzayında, n adet veri sayısında bilinmeyen bir sinyalin sınıfının bulunma süresi $O(d*n)$ olarak hesaplanmaktadır.

3.3. Redpin ve WASP Yöntemleri İçin Geliştirilen Uygulama

k -en yakın komşu (kNN) yöntemine dayalı iki yöntem olan, sırasıyla Bolliger ve Lin ve arkadaşları tarafından geliştirilen Redpin ve WASP yönteminde, kNN’de kullanılan Öklit mesafesi yerine, parmak izi tabanlı iç ortam konumlandırma performansını artırmaya yönelik mesafe fonksiyonları oluşturulmuştur.

Oluşturulan veri seti ve WASP veri setine uygulanan Redpin ve WASP yöntemlerinin gerçekleştirildiđi JavaFX arayüzü Şekil 3.12’de gösterilmiştir.



Şekil 3.13. kNN, Redpin ve WASP yöntemlerinin gerçekleştiği Java uygulaması

Bu uygulamada da diğer yöntemlerde olduğu gibi 10 katlamalı çapraz doğrulama yöntemi uygulanmıştır. Veri seti 10 parçaya bölünüp her bir parça sırasıyla test verisi olarak kullanıldığı için her parça için ayrı ayrı doğruluk sayısı bulunmuştur. Test edilen veriler değiştiği için doğruluk sayısında da farklılıklar gözlenmektedir. Bulunan 10 adet doğruluk sayısının toplanıp 10'a bölümü ile genel ortalama değeri bulunmaktadır. Veri setinde bulunan veri sayısı ve doğru bulunan toplam veri sayısı kullanılarak doğruluk yüzdesi hesaplanmaktadır.

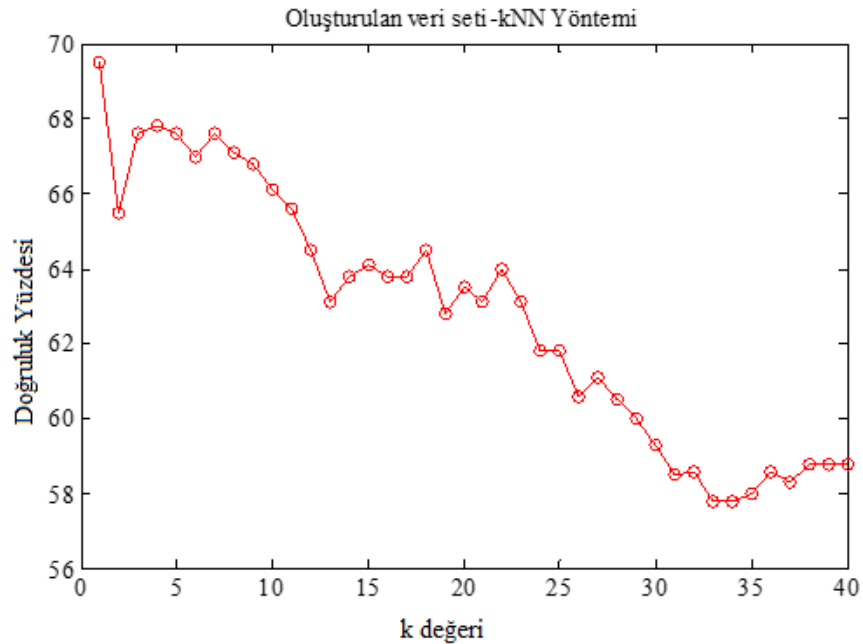
Yöntemlerin 10 defa çalıştırılması sonucunda Şekil 3.11'de görülen tek bir sonuç gibi dokuz tane daha sonuç ekrana yazılacaktır. Ortalama sonuç da yöntemin on kez çalıştırılması sonucunda elde edilen on farklı doğruluk yüzdesinin ortalamasının alınması ile bulunur.

4. ARAŞTIRMA BULGULARI ve DENEYSEL SONUÇLAR

Çalışmada iç ortam konumlandırma performansını test etmek için bir evin altı odasından toplanan Wi-Fi sinyalleri ile bir veri seti hazırlanmış, literatür araştırmaları sonucu iş yerinden elde edilen WASP veri seti ile karşılaştırılmış ve elde edilen sonuçlar yorumlanmıştır.

4.1. Değişen Parametre Değerlerine Göre Elde Edilen Grafikler

Bir evin altı odasından alınan sinyal güçleri ile oluşturulan veri setine K-en yakın komşu yöntemi uygulandığında, sınıflandırma doğruluğunun k parametresine göre gösterdiği değişim Şekil 4.1’de görülmektedir.



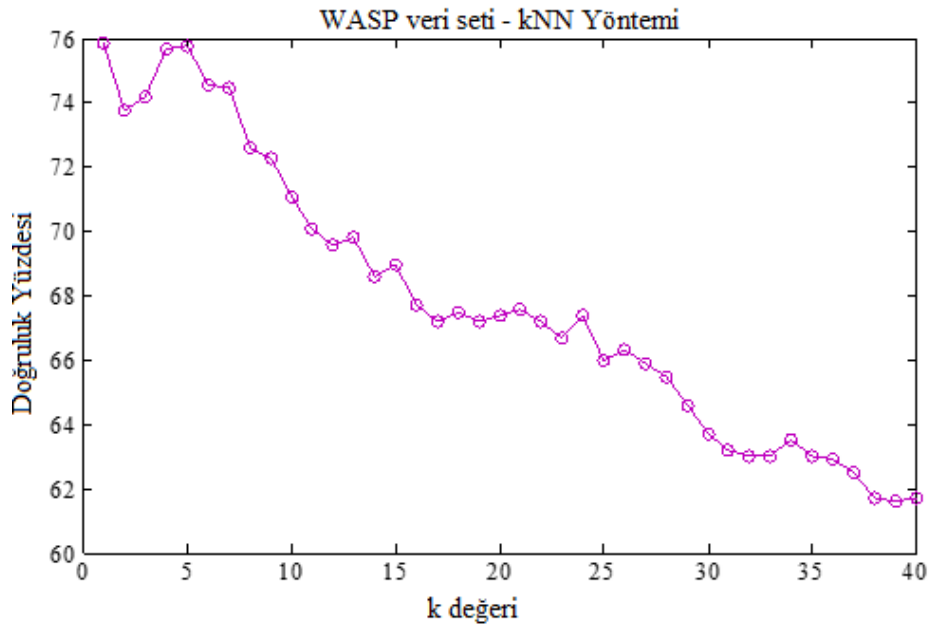
Şekil 4.1. k parametresine göre oluşturulan veri setinin sınıflandırma doğruluğu

*Her k değeri için program 10 kez çalıştırılıp ortalama değerler alındı

k=1 değerinde %69,5 oranı ile en yüksek performansı gösteren K-en yakın komşu yönteminde, sınıfı bilinmeyen test örneğinin kendisine en yakın mesafedeki örneğin

sınıfına ait olma oranının daha fazla olduğu görülmektedir. 2'den 25'e kadar verilen parametre değerlerinde genel olarak sınıflandırma doğruluğunda azalış görülmekte ve $k=40$ 'a doğru sabitlenmektedir.

Aynı şekilde WASP veri seti üzerinde de k parametresi 1'den 40'a kadar değiştirildiğinde Şekil 4.2'deki gibi bir grafik elde edilmiştir.




Şekil 4.2. k parametresine göre WASP veri setinin sınıflandırma doğruluğu

*Her k değeri için program 10 kez çalıştırılıp ortalama değerler alındı

Oluşturulan veri setinde olduğu gibi WASP veri setinde de $k=1$ olduğunda sınıflandırma doğruluğu %75,9 ile en yüksek oranda bulunmuştur. 1'den 40'a kadar verilen parametre değerlerinde bazı değerlerde daha yüksek doğruluk elde edilse de genel olarak bir düşüş görülmektedir ve 40'a yaklaştıkça %61 civarında sınıflandırma doğruluğunun sabitleştiği görülmektedir.

Rastgele Orman yönteminde ağaç sayısına bağlı olarak oluşturulan veri setinden elde edilen doğruluk yüzdelerinin değişimi incelendiğinde Şekil 4.3'te görüldüğü gibi belirli ağaç sayısından sonra sınıflandırma doğruluğu sabit bir oranda kalmaktadır. Ağaç sayısı 1'den başlatılarak her ağaç sayısı için WEKA'da bulunan seed (kaynak) değeri 10 adet

farklı ve rastgele şekilde değiştirilerek edilen sonuçların ortalamaları grafiğe aktarılmıştır.




Şekil 4.3. Ağaç sayısına göre oluşturulan veri setinin sınıflandırma doğruluğu

*Her ağaç sayısı için program 10 kez çalıştırılıp ortalama değerler alındı

Ağaç sayısı 6'ya kadar verildiğinde yöntemin doğruluk oranının %70'in altında, 6'dan 50'ye kadar verildiğinde ise %70-%72 civarında birbirine yaklaşık doğruluk oranlarının elde edildiği görülmüştür. Bu sonuç da rastgele orman yönteminde gereğinden fazla ağacın sınıflandırma doğruluğuna bir katkısı olmayacağını, budama yöntemi ile ağaçların devre dışı bırakılıp gerekli ağaçlar üzerinden sınıflandırmanın yapıldığını göstermektedir.

WASP veri seti üzerinde Rastgele Orman yönteminde ağaç sayısına bağlı olarak elde edilen sınıflandırma doğruluğu yüzdeleri de Şekil 4.4'te verilmiştir.




Şekil 4.4. Ağaç sayısına göre WASP veri setinin sınıflandırma doğruluğu

*Her ağaç sayısı için program 10 kez çalıştırılıp ortalama değerler alındı

Şekil 4.4’de görüldüğü gibi 1’den 10’a kadar verilen ağaç sayısı değerlerinde sınıflandırma doğruluğunda artış gözlenirken ağaç sayısının 30 ve daha fazla olduğu değerlerde sınıflandırma doğruluğunun yaklaşık %86-%87 oranı ile sabit kaldığı gözlenmektedir.


Rastgele orman yönteminde olduğu gibi geri yayılım yönteminde de farklı kaynak değerlerine göre her düğüm sayısı için yöntem 10 kez çalıştırılıp sonuçların ortalaması alınmış ve Şekil 4.5’deki grafik elde edilmiştir.



Şekil 4.5. Gizli katmanda bulunan düğüm sayılarına göre oluşturulan veri setinin sınıflandırma doğruluğu

*Her düğüm sayısı için program 10 kez çalıştırılıp ortalama değerler alındı

Gizli katmandaki düğüm sayısının azlığı sınıflandırma doğruluğunu olumsuz etkilemektedir. Oluşturulan veri seti için düğüm sayısının 1 verildiği yöntemde sınıflandırma doğruluğu %43,9 oranında iken düğüm sayısının 2 verildiği yöntemde %56,5 doğruluk oranı elde edilmiş ve bir düğüm yaklaşık %12 oranında bir doğruluk oranı farklı oluşturmuştur. Düğüm sayısının giderek artırıldığı geri yayılım yönteminde 15 düğümden sonra sınıflandırma doğruluğunun yaklaşık %69-%70 oranlarında sabit kaldığı görülmektedir. Aynı şekilde Şekil 4.6'da görülen grafikte WASP veri seti için düğüm sayısı 1 verildiğinde %38,1 oranında çok düşük bir doğruluk yüzdesi elde edilirken düğüm sayısı 2 verildiğinde %52,1 doğruluk yüzdesi elde edilerek %14 oranında bir doğruluk artışı gözlenmektedir.



Şekil 4.6. Gizli katmanda bulunan düğüm sayılarına göre WASP veri setinin sınıflandırma doğruluğu

*Her düğüm sayısı için program 10 kez çalıştırılıp ortalama değerler alındı

1'den 10'a kadar düğüm sayısı artırıldıkça sınıflandırma doğruluğunda artış gözlenmiştir. Bu değerler arasında artış oranı düğüm sayısı arttıkça azalmaktadır. Örnek verilecek olursa düğüm sayısı 9 iken %76,3 oranında bir doğruluk yüzdesi elde edilirken düğüm sayısı 10 olduğunda %76,8 oranında doğruluk yüzdesi bulunmuştur. Düğüm sayısının 10 ile 35 arası olduğu durumlarda sınıflandırma doğruluğu yüzdeleri %77-%79 arasında az bir oranda değişmektedir.

4.2. Oluşturulan Veri Seti ve WASP Veri Setinin Karşılaştırılması

Bu çalışmada Lin ve arkadaşlarının geliştirdiği WASP (Lin *et al.* 2009) yönteminin testi için kullanılan ve bir kampüs binasında 9 odadan oluşan, yaklaşık 900 m²'lik bir iş yerinden elde edilen veri seti (Çalışmada bu veri setine WASP veri seti adı verilmiştir) ile 6 odadan oluşan yaklaşık 140 m²'lik bir evden oluşturulan veri seti kullanılmıştır. Veri setlerinde sırasıyla 1002 ve 600 adet sinyal ölçümü bulunmaktadır.

İki veri setini sınıflandırırken 10-katlamalı çapraz doğrulama yöntemi kullanılmıştır. k-katlamalı çapraz doğrulama yönteminde veri setinin bir kısmı eğitim, bir kısmı test için ayrılır. Belirlenen k değerine göre veri seti eşit olarak k parçaya bölünür. Bu parçalardan birisi test için seçilip kalanı eğitim için kullanılır. Test edilen parçada, sınıfı bilinmeyen örneklerin kaçının doğru sınıflandırıldığı sonucu elde edilmektedir. Bu şekilde her parça test işlemi için kullanılıp elde edilen k adet değer toplamının k sayısına bölünmesi ile tüm sonuçların ortalaması alınır. Böylece tüm parçalar test ve eğitim için kullanıldığından verimli bir sınıflandırma işlemi yapılmaktadır. En çok kullanılan çapraz doğrulama yöntemi 10-katlamalı (k=10) olduğu için bu çalışmada da veri setinin 10 parçaya bölünmesi tercih edilmiştir.

Verileri sınıflandırmada kullanılan makine öğrenmesi yöntemlerinin varsayılan parametreleri Çizelge 4.1’de gösterilmiştir.

Çizelge 4.1. Sınıflandırma yöntemlerinde kullanılan parametrelerin varsayılan değerleri (Karabey and Bayındır 2015)

Algoritma	Varsayılan Değer
kNN	k=1
	mesafe fonksiyonu=öklit mesafesi
Redpin, WASP	$\alpha = 1$
	$\beta = -0.4$
	$\gamma = 0.2$
	$\sigma = 0.2$
	$\omega = 10$
Destek Vektör Makinesi	c=1.0
	çekirdek=PolyKernel
	tolerans=0.001
	$\epsilon = 1.0E-12$
Geri Yayılım	gizli katmandaki nöron sayısı=15
	öğrenme oranı=0.3
	momentum=0.2
	Eğitim safhasının sayısı=500
Rastgele Orman	ağaç sayısı=50

Çizelge 4.1’de varsayılan parametreleri verilen makine öğrenmesi yöntemlerinin oluşturulan veri seti ve WASP veri seti üzerinde uygulanması sonucunda elde edilen doğruluk yüzdeleri Çizelge 4.2’de gösterilmiştir.

Çizelge 4.2. Uygulanan yöntemlerin oluşturulan veri seti ve WASP veri seti için doğruluk yüzdeleri

Oluşturulan Veri Seti	Yöntem	k=1	k=2	k=3	k=4	k=5
	kNN	%68	%66	%66	%66	%65
	Redpin	%66	%63	%66	%66	%68
	WASP	%67	%65	%67	%68	%69
	NBS	%55				
	DVM	%65				
	GY	%68				
	RO	%72				
WASP veri seti		k=1	k=2	k=3	k=4	k=5
	kNN	%75	%71	%73	%71	%71
	Redpin	%78	%75	%79	%78	%78
	WASP	%83	%81	%85	%85	%86
	NBS	%62				
	DVM	%74				
	GY	%78				
	RO	%87				

Çizelge 4.2’de görülen sonuçlar, sınıflandırma yöntemlerinin 10 kez uygulanması sonucu elde edilen doğruluk yüzdelerinin ortalaması alınarak bulunmuştur.

İki veri seti için doğruluk oranları karşılaştırıldığında sınıflandırıcıların ev ortamında oluşturulan veri setinde, WASP veri setine göre daha düşük performans gösterdiği görülmektedir. Bu farkın nedenini araştırmak amacıyla veri setlerindeki görünür erişim noktaları (sıfırdan farklı sinyal değeri veren erişim noktaları) incelenmiştir. Çizelge 4.3’de oluşturulan veri setinde odalarda görülen erişim noktaları yüzdeleri verilmiştir. Her oda için 100 adet veri toplandığı için her erişim noktasının toplamda görülme sayısı, yüzde cinsinden bulunmuştur. Koyu renk ile yazılmış yerler, ayırt edici erişim noktalarına karşılık gelmektedir. Ayırt edici erişim noktaları, görünür erişim noktası

oranı %30'un üzerinde olan erişim noktaları olarak tanımlanmaktadır (Lin *et al.* 2009).

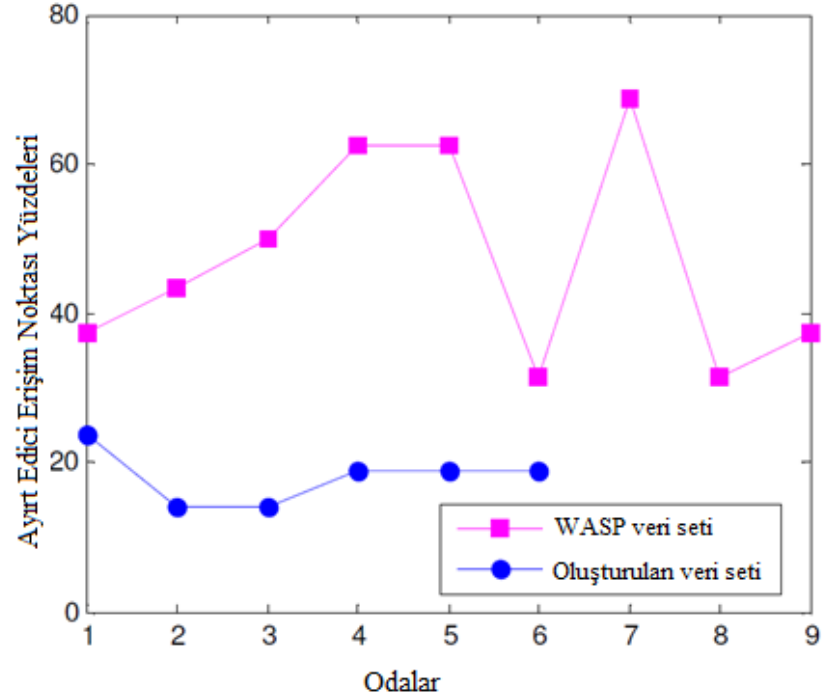
Örneğin "Mutfak" için ayırt edici erişim noktaları Ap1, Ap2, Ap3, Ap4 ve Ap11'dir.

Çizelge 4.3. Oluşturulan veri setinde erişim noktalarının odalarda görülme yüzdeleri.

Erişim Noktaları	Mutfak	Salon	Oturma Odası	Cocuk Odası	Yatak Odası	Banyo
Ap1	%99	%22	%50	%100	%89	%70
Ap2	%100	%95	%100	%97	%100	%100
Ap3	%31	%1	%2	%20	%10	%9
Ap4	%42	%95	%93	%63	%30	%92
Ap5	%0	%61	%2	%8	%34	%50
Ap6	%0	%0	%4	%0	%0	%0
Ap7	%8	%0	%0	%6	%35	%10
Ap8	%0	%0	%1	%3	%0	%10
Ap9	%1	%3	%7	%0	%0	%0
Ap10	%5	%0	%0	%1	%8	%2
Ap11	%41	%0	%1	%36	%12	%2
Ap12	%13	%0	%0	%0	%0	%0
Ap13	%22	%0	%0	%3	%5	%1
Ap14	%15	%0	%0	%0	%0	%0
Ap15	%2	%0	%0	%0	%0	%0
Ap16	%2	%0	%0	%0	%0	%0
Ap17	%0	%0	%0	%4	%10	%0
Ap18	%0	%0	%0	%0	%6	%8
Ap19	%3	%0	%0	%11	%19	%12
Ap20	%0	%0	%0	%0	%0	%9
Ap21	%0	%0	%0	%6	%0	%0

*Ayırt edici erişim noktaları koyu renk ile gösterilmiştir.


Ayırt edici erişim noktası yüzdelerinin iki veri setinde karşılaştırılması sonucunda, Şekil 4.7'de verilen grafiğe bakıldığında, oluşturulan veri setinin tüm odalarında WASP veri setine göre çok daha düşük yüzdelerle sahip olduğu görülmüştür.



Şekil 4.7. Ayırt edici erişim noktalarının odalarda görülme yüzdeleri

*WASP veri seti için odalar, sırasıyla: Rm211, Rm212, W Lounge, W Hallway, Cafe, Lounge, E Hallway, E Lounge ve Rm213 iken, oluşturulan veri seti için odalar, sırasıyla: Mutfak, Salon, Oturma Odası, Çocuk Odası, Yatak Odası ve Banyo

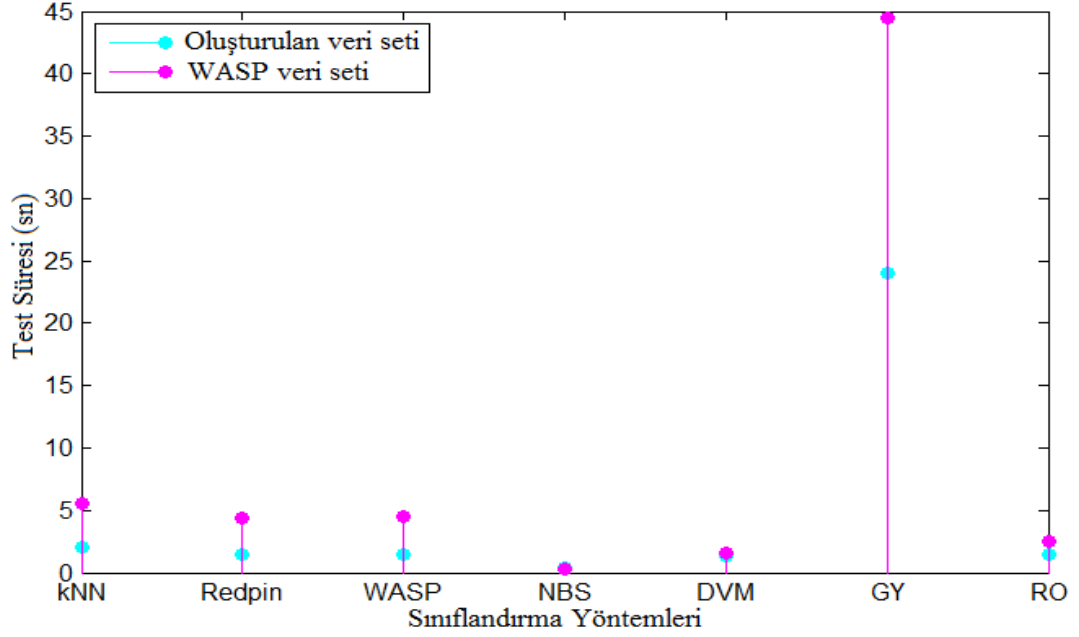
Sınıflandırma yöntemlerinin doğruluğu ve çalışma süreleri arasındaki ilişkiyi tespit etmek amacıyla her iki veri seti için de, Şekil 4.8'de yöntemlerin eğitim verileri üzerinden model oluşturma süreleri ve Şekil 4.9'da yöntemlerin test işlemi sırasında harcadığı süreler hesaplanmıştır.



Şekil 4.8. Eğitim verileri üzerinde sınıflandırma yöntemlerinin model oluşturma süresi
*kNN, Redpin ve WASP için k=5 değeri alınmıştır

Şekil 4.8’de görüldüğü gibi kNN, Redpin, WASP ve NBS yöntemlerinin eğitim aşaması olmadığı için model oluşturma süreleri sıfır olarak bulunmuştur. Geri yayılım yöntemi, her iki veri setinde de en uzun sürede model oluşturan yöntem olmuştur. Yöntemde yapay sinir ağının giriş, çıkış ve gizli katmanları oluşturulmakla birlikte giriş değerleri ile gizli katman arasında rastgele ağırlıklar belirlenmektedir. Bu yüzden bu yöntemin eğitim safhası diğer yöntemlere göre daha uzun sürelidir.

İç ortam konumlandırma gerçekte zamanlı konum belirlenirken, konumu bilinmeyen bir sinyalin sınıfı, çevrim dışı safhasında oluşturulmuş bir öğrenme modelinde bulunan konumu bilinen sinyaller üzerinden hesaplandığı için, test aşamasında geçen süre iç ortam konumlandırma için önemlidir. Bu yüzden yöntemlerin eğitim ve test işlemi sırasındaki çalışma süreleri ayrı ayrı hesaplanmıştır. Şekil 4.9’da test işlemi sırasında yöntemlerin çalışma süreleri gösterilmektedir.



Şekil 4.9. Sınıflandırma yöntemlerinin test aşamasında harcadığı zaman

*kNN, Redpin ve WASP için k=5 değeri alınmıştır

Yöntemlerin test aşamasında harcadığı süreler incelendiğinde her iki veri seti için de en iyi performansı gösteren Rastgele Orman (RO) yönteminin Naive Bayes (NB) ve Destek Vektör Makineleri (DVM) dışında diğer yöntemlerden çok daha hızlı çalıştığı görülmüştür. NB yöntemi, doğrusal zamanlı bir sınıflandırıcı olduğu için yöntemler içerisinde en hızlı yöntem olmasına rağmen sınıflandırma doğruluğu, RO ve diğer yöntemlere göre oldukça düşüktür. RO ve WASP yönteminden sonra her iki veri seti için de üçüncü en yüksek performansı gösteren Geri Yayılım (GY) yönteminde, geriye doğru hata sinyali hesaplanıp giriş değerlerine her aşamada rastgele ağırlıklar verildiği için çalışma süresi uzundur. Çizelge 4.1’de verilen varsayılan parametre değerlerine göre yöntemler çalıştırıldığında, oluşturulan veri seti ve WASP veri setinde geri yayılım yöntemi, sırasıyla 24,05 ve 44,46 saniye süre zarfında test işlemini gerçekleştirmektedir (Şekil 4.9). Bu süre, gerçek zamanlı bir konum bulmada kullanıcıyı yanıltabilir. Çünkü gerçek zamanlı bir konumlandırmada kullanıcının anlık yer tespiti için çok kısa bir süre gerekmektedir. Geri yayılım yöntemi ile kullanıcının anlık bulunduğu yerin hesaplandığı süre içerisinde, kullanıcının yer değiştirme ihtimali yüksektir. Bu yüzden bu yöntem, iç ortam konumlandırmada performansı yüksek olsa da süre açısından değerlendirildiğinde gerçek zamanlı uygulamalarda sorun oluşturabilir.

5. SONUÇ ve ÖNERİLER

Bu tez çalışmasında iç ortam konumlandırma yöntemlerinden parmak izi yöntemi, farklı ortamlardan elde edilen iki veri setine (WASP: iş yeri, oluşturulan veri seti: ev), yedi farklı sınıflandırma yöntemi kullanılarak uygulanmıştır. Elde edilen sonuçlar, daha önce WASP veri setinin kullanıldığı sonuçlar ile yakın olmakla beraber, oluşturulan veri setinden elde edilen sonuçların belirgin bir şekilde daha düşük doğruluk oranına sahip olduğu görülmüştür. Bu farkın, veri setlerinin farklı ortamlarda oluşturulmasından ve buna bağlı olarak ev ortamında oluşturduğumuz veri setinde ayırt edici erişim noktası yüzdelерinin (Şekil 4.1) WASP (Lin *et al.* 2009) veri setine göre düşük olmasından kaynaklandığı öngörülmektedir.

Veri setlerine uygulanan sınıflandırma yöntemlerinde çalışma zamanı ve doğruluk yüzdeleri açısından karşılaştırıldığında Rastgele Orman yönteminin iç ortam konumlandırma için uygun bir yöntem olduğu düşünülmektedir. Her iki veri setinde de sırasıyla %72 ve %87 (oluşturulan veri seti - WASP veri seti) doğruluk oranı ile Rastgele Orman yöntemi en yüksek performansa sahip yöntem olmuştur. İkinci en yüksek performansa sahip yöntem ise sırasıyla %69 ve %78 (oluşturulan veri seti - WASP veri seti) doğruluk oranı ile WASP yöntemi olmuştur. Gerçek zamanlı bir iç ortam konumlandırma sisteminde anlık yer tespiti için doğruluk kadar yöntemlerin çalışma zamanı önemlidir. Bu çalışma kapsamında verileri sınıflandırmada kullanılan yöntemler arasından Nâive Bayes yöntemi ile en düşük sürede sonuca ulaşılsa da doğruluk yüzdesi açısından da en düşük performanslı yöntem olarak belirlenmiştir. Çalışma hızı NB ve DVM'den sonra sırasıyla 1,46 sn ve 2,48 sn (oluşturulan veri seti - WASP veri seti) süre ile en yüksek olan Rastgele Orman yöntemi, sınıflandırma başarısı bakımından da en yüksek doğruluk yüzdesine sahip yöntemdir. Her ne kadar Geri Yayılım yöntemi de Rastgele Orman yönteminden sonra yüksek doğruluğa sahip yöntemlerden biri olsa da sırasıyla 24,05 sn ve 44,46 sn (oluşturulan veri seti - WASP veri seti) süre ile çalışma hızı en düşük olan yöntemdir.

İleri çalışmalarda Wi-Fi sinyalleri ile birlikte odalar arası geçiş zamanı gibi ekstra bilgiler kullanarak iç ortam konumlandırma performansının artırılması planlanmaktadır.

KAYNAKLAR

- Abe, S., 2010. Support Vector Machine for Pattern Classification. Second Edition, Springer, 471 p, London
- Akman M., Genç Y., ve Ankarali H. 2011. Random Forests Yöntemi ve Sağlık Alanında Bir Uygulama. Türkiye Klinikleri Biyoistatistik Dergisi, 3(1), 36–48.
- Altini, M., Brunelli, D., Farella, E., and Benini, L., 2010. Bluetooth Indoor Localization with Multiple Neural Networks, Wireless Pervasive Computing (ISWPC), pp. 295-300.
- Angermann, M. and Robertson, P., 2012. FootSLAM: Pedestrian Simultaneous Localization and Mapping Without Exteroceptive Sensors- Hitchhiking on Human Perception and Cognition. Proceedings of the IEEE, 100, 1840-1848.
- Anonymous, 1987a. <http://www.st.com/web/en/home.html> (07/08/2015)
- Anonymous, 2000a. <http://www.ekahau.com/> (07/08/2015)
- Anonymous, 2003a. <http://www.skyhookwireless.com/> (07/08/2015)
- Anonymous 2003b. <http://www.technavio.com/blog/top-33-indoor-location-based-services-lbs-companies-in-the-us> (15/08/2015)
- Anonymous, 2005a. <https://www.navizon.com/> (05/08/2015)
- Anonymous, 2008a. <http://aisle411.com/> (07/08/2015)
- Anonymous, 2008b. <http://teldio.com/products/ips/> (07/08/2015)
- Anonymous, 2008c. <http://www.polestar.eu/en/> (07/08/2015)
- Anonymous, 2009a. <http://www.pointinside.com/> (05/08/2015)
- Anonymous, 2009b. <http://sensewhere.com/> (08/08/2015)
- Anonymous, 2009c. <http://www.fastmall.com/> (08/08/2015)
- Anonymous, 2010a. <http://www.wifarer.com/airports> (10/08/2015)
- Anonymous, 2015a. <http://www.wirelessdictionary.com/Wireless-Dictionary-GPS-Pseudo-Satellite-Pseudolites-Definition.html> (10/08/2015)
- Anonymous, 2010b. <http://senionlab.com/> (10/08/2015)
- Anonymous, 2010c. <https://www.shopkick.com/> (10/08/2015)
- Anonymous, 2011a. <http://www.signal360.com/> (05/08/2015)
- Anonymous, 2013a. <http://www.indoora.com/> (30/06/2015)
- Anonymous, 2013b. <https://angel.co/wifislam> (30/06/2015)
- Anonymous, 2014a. <http://www.ibeacon.com.tr/> (10/08/2015)
- Anonymous, 2015b. <http://www.infsoft.com/Products/Indoor-Navigation> (30/06/2015)
- Anonymous, 2015c. <http://www.insiteo.com/joomla/index.php/en/> (10/08/2015)
- Anonymous, 2015d. <http://smartindoor.com/> (10/08/2015)
- Anonymous 2015e. <http://meridianapps.com/> (10/08/2015)
- Anonymous 2015f. <http://www.qca.qualcomm.com/products/qualcomm-izat/> (12/08/2015)
- Anonymous 2015g. <http://www.cl.cam.ac.uk/research/dtg/attarchive/bat/> (07/08/2015)
- Anonymous 2015h. <https://www.dtrek.com/solution/view/20> (18/08/2015)
- Anonymous 2015i. https://en.wikipedia.org/wiki/K-nearest_neighbors_algorithm (28/09/2015)
- Babu, V., and Yalamanchili, A. 2014. Indoor Positioning System (IPS) using Beacons. IGATE Global Solution

- Bahl P., and Padmanabhan, V.N., 2000. RADAR: An in-building RF-based user location and tracking system. *IEEE INFOCOM 2000*, vol. 2, 775–784
- Bahl, P. and Padmanabhan, V.N. Enhancements to the RADAR user location and tracking system. Microsoft Corp., Tech. Rep. MSR-TR- 2000–12
- Battiti, R., Nhat, T. L., and Villani, A. 2002. Location-aware computing: A neural network model for determining location in wireless LANs. Tech. Rep. DIT-02–0083
- Bayındır, L., Karabey, I. 2014. Yaya Parakete Hesabında Kullanılan Adım Tespit ve Adım Uzunluğu Tahmin Yöntemlerinin Bir Değerlendirmesi. *Elektrik-Elektronik- Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu*, 753-757, Bursa
- Beauregard, S., 2006. A Helmet-Mounted Redestrian Dead Reckoning System. *Applied Wearable Computing (IFAWC)*, 3, 1-11, Bremen, Germany
- Buchman, A. and Lung, C., 2013. Received Signal Strength based Room Level Accuracy Indoor Localisation Method. *4th IEEE International Conference on Cognitive Infocommunications*, Budapest, Hungary, 103-108
- Bolliger, P., Redpin, <http://redpin.org>, 04.01.2015
- Bolliger, P., 2008. Redpin- Adaptive, Zero-Configuration Indoor Localization through User Collaboration, Mobile Entity Localization and Tracking in GPS-less Environments. *First International Workshop*, 55-60
- Buyruk, H., Keskin, A.K., Şendil, Ş., Çelebi, H., Partal, H., İleri, Ö., Zeydan, E., and Ergüt, S., 2013. RF Fingerprinting Based GSM Indoor Localization. *Signal Processing and Communications Applications Conference (SIU)*, 1-4.
- Castro, P., Chiu, P., Kremenek, T., and Muntz, R.R., 2001. A probabilistic room location service for wireless networked environments. *3rd International Conference Ubiquitous Computing*, Atlanta, GA, 18–34
- Chen, Y., Lymberopoulos, D., Liu, L., and Priyantha, B., 2012. FM-based Indoor Localization. *Proceedings of the 10th international conference on Mobile systems, applications, and services*, pp. 169-182. ACM.
- Colombo, A., Fontanelli, D., Macii, D. and Palopoli, L. 2014. Flexible Indoor Localization and Tracking Based on a Wearable Platform and Sensor Data Fusion. *IEEE Transactions on Instrumentation and Measurement*, 63, 864-876.
- Disha, A. 2013. A Comparative Analysis on Indoor Positioning Techniques and Systems. *International Journal of Engineering Research and Applications*, 3 (2), 1790-1796.
- Du, J., Chen, W., Liu, Y., Gu, Y. and Liu, H. 2013. Catch You as I Can: Indoor Localization via Ambient Sound Signature and Human Behavior. *International Journal of Distributed Sensor Networks*, 2013, 1-16.
- D'Souza, M., Ros, M. and Karunanithi, M. 2012. An Indoor Localisation and Motion Monitoring System to Determine Afflicted Patients in Aged Care. *Electronic Journal of Health Informatics*, 7 (2), 1-8.
- Farid, Z., Nordin, R. and Ismail, M., 2013. Recent Advances in Wireless Indoor Localization Techniques and System. *Journal of Computer Networks and Communications*, 2013, 1-12
- Finkel, A., Harwood, A., Gaunt, H., and Antig, J., 2014. Optimizing Indoor Location Recognition Through Wireless Fingerprinting At the Ian Potter Museum of Art.

- International Conference on Indoor Positioning and Indoor Navigation (IPIN), Korea.
- Fink, A., Beikirch, H., Voß, M. and Schröder, C. 2010. RSSI-based Indoor Positioning Using Diversity and Inertial Navigation. Proceedings of the 2010 International Conference on Indoor Positioning and Indoor Navigation (IPIN), September 15–17, 2010 Campus Science City, ETH Zurich, Switzerland.
- Galvan-Tejada, C. E., Carrasco-Jimenez, J. C. and Brena, R.F, 2013. Bluetooth-WiFi based combined positioning algorithm, implementation and experimental evaluation. 3rd Iberoamerican Conference on Electronics Engineering and Computer Science, Procedia Technology, 7, 37–45
- Geng, Y., Deng, H. and Pahlavan, K. 2013. Modeling the effect of human body on TOA ranging for indoor human tracking with wrist mounted sensor. Wireless Personal Multimedia Communications (WPMC), 1-6.
- Guo, L., Ma, Y., Cukic, B., and Singh, H. 2004. Robust Prediction of Fault-Proneness by Random Forests. Software Reliability Engineering (ISSRE), 417-428.
- Gusenbauer, D., Isert, C. and Krösche, J. 2010. Self-Contained Indoor Positioning on Off-The-Shelf Mobile Devices. Proceedings of the 2010 International Conference on Indoor Positioning and Indoor Navigation (IPIN), September 15–17, 2010 Campus Science City, ETH Zurich, Switzerland.
- Guo, L., Ma, Y., Cukic, B. and Singh, H., 2004. Robust Prediction of Fault-Proneness by Random Forests. Software Reliability Engineering (ISSRE), 417-428
- Gruber, B., Krainz, M., Berger, R. and Burgess, T.T. and Schöndorfer, <http://indoo.rs/> (29/06/2015)
- Haeberlen, A., Flannery, E., Ladd, A. M., Rudys, A., Wallach, D.S., and Kavraki, L. E., 2004. Practical robust localization over large-scale 802.11 wireless networks. 10th ACM Int. Conf. Mobile Comput. Netw., Philadelphia, PA, 70–84
- Hardegger M., Roggen, D., Mazilu, S., Tröster, G. 2012. ActionSLAM: Using location-related actions as landmarks in pedestrian SLAM, Indoor Positioning and Indoor Navigation (IPIN), 1-10.
- Hernandez, N., Ocana, M., Alonso, J., and Kim, E., 2014. WiFi-based Indoor Localization and Tracking of a Moving Device. Ubiquitous Positioning Indoor Navigation and Localization Based Service (UPINLBS), pp. 281-289.
- He, S., and S.H. Chan, Gray., 2014. Sectjunction: Wi-Fi Indoor localization based on Junction of Signal Sectors. IEEE Communications (ICC), pp. 2605-2610.
- Huynh, S., Parry, D., Fong, A.C.M. and Tang J. 2014. Novel RFID and Ontology based Home Localization System for Misplaced Objects. IEEE Transactions on Consumer Electronics, 60, 402-410.
- Huang, H., 2014. Post Hoc Indoor Localization Based on RSS Fingerprint in WLAN. Ms Thesis, Master of Science in Electrical and Computer Engineering, 1-68.
- Hsu, G., Oh, B., Taylor, A., Walters, E. and Zils, J., <http://www.pnicorp.com/> (30/06/2015)
- Istook E., and Martinez T. 2002. Improved Backpropagation Learning In Neural Networks with Windowed Momentum. International Journal of Neural Systems, 12 (3), 303-318.
- Karabey, I., and Bayındır, L. 2015. An Evaluation of Fingerprint-based Indoor Localization Techniques. Signal Processing and Communications Applications Conference (SIU), 2254-2257, Malatya

- Karakoyun, M., ve Hacıbeoğlu, M. 2014. Biyomedikal Veri Kümeleri ile Makine Öğrenmesi Sınıflandırma Algoritmalarının İstatistiksel Olarak Karşılaştırılması. DEU Mühendislik Fakültesi Mühendislik Bilimleri Dergisi, 16 (48), 30-42
- Karadeniz, M., Yüncü, S. and Aydemir, M.T., 2001. Asenkron Motorlarda Stator Direncinin Yapay Sinir Ağları ile Tahmini. Elektrik-Elektronik-Bilgisayar Mühendisliği 9. Ulusal Kongresi, Bursa.
- Kontkanen, P., Myllymaki, P., Roos, T., Tirri, H., Valtonen, K, and Wettig, H., 2004. Topics in Probabilistic Location Estimation in Wireless Networks. 15th IEEE Symp. Pers., Indoor, Mobile Radio Commun., Barcelona, Spain, vol. 2, 1052–1056
- Koyuncu, H., and Yang, S. H. 2010. A Survey of Indoor Positioning and Object Locationing Systems. IJCSNS International Journal of Computer Science and Network Security, 10 (5), 121-127, Loughborough.
- Kim, J. and Jun, H.S. 2008. Vision-Based Location Positioning using Augmented Reality for Indoor Navigation. IEEE Transaction on Consumer Electronics, vol. 54, no. 3, pp. 954–962.
- Krumm, J. (Editor), Ubiquitous Computing Fundamentals. CRC Press, Microsoft Corporation Redmond, Washington, U.S.A, 2010.
- Kök, İ.Ş., 2009. Bina İçi Konumlandırma Sistemi. TOBB Ekonomi ve Teknoloji Üniversitesi, Bilgisayar Mühendisliği Yüksek Lisans Tezi.
- Ladd, A. M., Bekris, K. E., Marceau, G., Rudys, A., Kavraki, L. E., and Wallach, D. S., 2002. Using Wireless Ethernet for Localization. IEEE/RJS Int. Conf. Intell. Robots Syst., 2002, vol. 1, pp. 402– 408
- Ladd, A. M., Bekris, K. E., Rudys, A., Kavraki, L. E., and Wallach, D.S. 2004. On the feasibility of using wireless ethernet for indoor localization. IEEE Trans. Robot, 20 (3), 555–559
- Lan, K. 2014. An intelligent driver location system for smart parking. Expert System with Applications, 41, 2443-2456.
- Lin, H., Zhang, Y., Griss, M., and Landa, I., 2009. WASP: An Enhanced Indoor Locationing Algorithm for a Congested Wi-Fi Environment. Mobile Entity Localization and Tracking in GPS-less Environments, Second International Workshop, Vol. 5801, pp. 183-196.
- Liu, H., Darabi, H., Banerjee, P., and Liu, J. 2007. Survey of Wireless Indoor Positioning Techniques and Systems. IEEE Transactions on Systems, Man, and Cybernetics-Part C: Applications and Reviews, Vol:37, No:6, pp. 1067-1080.
- Martin, H., Besada, J.A., Bernardos, A.M., Metola, E. and Casar, J.R. 2014. Simplified Redestrian Tracking Filters with Positioning and Foot-Mounted Inertial Sensors. International Journal of Distributed Sensor Networks, 2014, 1-18.
- Mautz, R. and Ochieng, W.Y. 2007. A Robust Indoor Positioning and Auto-Localisation Algorithm. Journal of Global Positioning Systems, vol. 6, no. 1, pp. 38–46.
- Mankotia, D., Panjab Univ., Chandigarh, India ; Agrawal, S., Singh, S., 2014. Error Minimization in Bluetooth based Indoor Localization of Mobile Robot using Cuckoo Search Algorithm. IEEE Medical Imaging, m-Health and Emerging Communication Systems (MedCom), pp. 283-288.
- Mautz, R. 2012. Indoor Positioning Technologies. Habilitation Thesis, ETH Zurich, 1-128

- Matic, A., Popleteev, A., Osmani, V., and Mayora-Ibarra, O., 2010. FM Radio for Indoor Localization with Spontaneous Recalibration. *Pervasive and Mobile Computing* 6, pp. 642-656.
- Moghtadaiee, V. and Dempster, A.G., 2014. Indoor Location Fingerprinting Using FM Radio Signals. *Broadcasting*, 60 (2).
- Okşar, İ., 2014. A Bluetooth Signal Strength Based Indoor Localization Method, *Systems. Signals and Image Processing (IWSSIP)*, pp. 251-254.
- Pace, S., Frost, G. P., Lachow, I., Frelinger, D. R., Fossum, D., Wasseem, D., Pinto, M. M. 1995. *The Global Positioning System: Assessing National Policies*. RAND Corporation
- Priyantha, N. B., Chakraborty, A., and Balakrishnan, H. 2000. The Cricket Location-Support System. 6th ACM International Conference on Mobile Computing and Networking (ACM MOBICOM), Boston.
- Puyol, M.G., Bobkov, D., Robertson, P. and Jost, T. 2014. Pedestrian Simultaneous Localization and Mapping in Multistory Buildings Using Inertial Sensors. *IEEE Transactions on Intelligent Transportation Systems*, 15, 1714-1727
- Ravi, N., Shankar, P., and Frankel, A. 2005. Indoor Localization Using Camera Phones. *Mobile Computing Systems and Applications*, 2006. WMCSA '06. Proceedings, 1-7, Orcas Island.
- Roos, T., Myllymaki, P., Tirri, H., Misikangas, P., and Sievanan, J., 2002. A probabilistic approach to WLAN user location estimation. *Int. J. Wireless Inf. Netw.*, vol. 9, no. 3, pp. 155–164.
- Russell, S. and Norvig, P., 2010. *Artificial Intelligence A Modern Approach*. Third Edition, Prentice Hall, 1152 p, Upper Saddle River, New Jersey 07458.
- Sağiroğlu, Ş.; Beşdok E. & Erler, M. 2003. *Mühendislikte Yapay Zeka Uygulamaları I: Yapay Sinir Ağları*. Kayseri: Ufuk Kitap Kıratsiye-Yayıncılık.
- Salazar, A.S., Aguliar, L. and Licea, G. 2013. Estimating Indoor Zone-Level Location using Wi-Fi RSS Fingerprinting based on Fuzzy Inference System. *Mechatronics, Electronics and Automotive Engineering (ICMEAE)*, 178-184, Morelos, Mexico.
- Saha, S., Chaudhuri, K., Sanghi, D., and Bhagwat, P., 2003. Location determination of a mobile device using IEEE 802.11b access point signals. *IEEE Wireless Commun. Netw. Conf.*, vol. 3, 1987–1992.
- Schneider, O. 2010. Requirements for Positioning and Navigation in Underground Constructions. *Proceedings of the 2010 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, September 15–17, 2010 Campus Science City, ETH Zurich, Switzerland.
- Serrao, M., Shahrabadi, S., Moreno, M., Jose, J.T., Rodrigues, J.I. and du Buf, J.M.H. 2015. *Computer Vision and GIS for the navigation of blind persons in buildings*. Universal Access in the Information Society, Springer, Berlin.
- Shin S.H., Park, C.G. and Choi, S. 2010. New Map-Matching Algorithm Using Virtual Track for Pedestrian Dead Reckoning. *Electronics and Telecommunications Research Institute Journal*, 32 (6), 891-900.
- Siddiqi, S., Sukhatme, G. S., and Howard, A., 2003. Experiment in Monte-Carlo localization using WiFi signal strength. in *Proc. Int. Conf. Adv. Robot.*, Combra, Portugal, 210–223

- Sterling, G., and Top, Gerek. 2014. Mapping the Indoor Marketing Opportunity. Opus Research, Inc.
- Stella, M., Russo, M. and Begušić, D. 2014. Fingerprinting based localization in heterogeneous wireless networks. *Expert Systems with Applications*, Elsevier, 41 (15), 6738-6747.
- Sungro Y., Kyunghan, L., and Injong, R., 2013. FM based indoor localization via automatic fingerprint DB construction and matching. 11th Annual International Conference on Mobile Systems, Applications, and Services (MobiSys '13). ACM, New York, NY, USA, 207- 220.
- Subbu, K.P., Gozick, B., and Dantu, R. 2013. LocateMe: Magnetic-fields-based Indoor Localization using Smartphones. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 4 (4), ACM New York, NY, USA.
- Tian, Y. and Denby, B., Ahriz, I. and Roussel, P. 2013. Practical Indoor Localization using Ambient RF. *Instrumentation and Measurement Technology Conference (I2MTC)*, 1125- 1129, Minneapolis, MN.
- Taniuchi, D., Liu, X., Nakai, D. and Maekawa, T., 2015. Spring Model Based Collaborative Indoor Position Estimation With Neighbor Mobile Devices. *IEEE Journal of Selected Topics in Signal Processing*, 9 (2), 268-277.
- Wang, B., Zhou, S., Liu, W. and Mo, Y., 2015. Indoor Localization Based on Curve Fitting and Location Search Using Received Signal Strength. *IEEE Transactions on Industrial Electronics*, 62 (1), 572-582.
- Widyawan, Klepal, M. and Beauregard, S. 2008. A Backtracking Particle Filter for Fusing Building Plans with PDR Displacement Estimates. 5th Workshop on Positioning, Navigation and Communication (WPNC'08), 5, 207-212, Hannover.
- Xiang, Z., Song, S., Chen, J., Wang, H., Huang, J., and Gao, X., 2004. A WLAN based indoor positioning technology. *IBM J. Res. Develop.* [Online]. Erişim Adresi: <http://researchweb.watson.ibm.com/journal/rd/485/xiang.html>
- Youssef, M., Agrawala, A., and Udaya Shankar A., 2003. WLAN location determination via clustering and probability distributions. *IEEE International Conference Pervasive Computing Communications*, pp. 143–151.
- Youssef, M. and Agrawala. A. K., 2004. Handling samples correlation in the Horus system. *IEEE INFOCOM*, Hong Kong, vol. 2, pp. 1023– 1031
- Yücel, H., Yazıcı, A., ve Edikan, R. 2014. İç Ortam Konumlandırma Sistemleri Üzerine Bir Derleme. 2nd *Signal Processing and Communication Applications Conference (SIU)*, 1267-1270.
- Zetik, R., Shen, G. and Thomä, R. 2010. Evaluation of Requirements for UWB Localization Systems in Home-Entertainment Applications, *Proceedings of the 2010 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, September 15–17, pp. 1-8, Zurich Campus Science City, ETH Zurich, Switzerland.

ÖZGEÇMİŞ

Işıl KARABEY 1990 yılında Erzurum'da doğdu. İlk, orta ve lise öğrenimini Erzurum'da tamamladı. 2009-2013 yılları arasında Gazi Üniversitesi Bilgisayar Mühendisliği bölümünde lisans derecesini aldı. Mezuniyetinin ardından 2013 yılında Atatürk Üniversitesi'nde yüksek lisans eğitimine başladı. 2014 yılında Atatürk Üniversitesi'nde araştırma görevlisi olarak göreve başladı. Atatürk Üniversitesi'nde 9 aylık bir çalışma sürecinden sonra Erzurum Teknik Üniversitesi'nde araştırma görevlisi olarak göreve başladı ve halen bu görevi sürdürmektedir.