

T.C.
GEBZE YÜKSEK TEKNOLOJİ ENSTİTÜSÜ
MÜHENDİSLİK ve FEN BİLİMLERİ ENSTİTÜSÜ

GSM VE Wİ-Fİ SİNYAL GÜCÜ TABANLI KONUMLANDIRMA
SİSTEMİNİN GELİŞTİRİLMESİ VE PERFORMANS ANALİZİ

AHMET BACAK
YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

GEBZE
2014

T.C.
GEBZE YÜKSEK TEKNOLOJİ ENSTİTÜSÜ
MÜHENDİSLİK ve FEN BİLİMLERİ ENSTİTÜSÜ

GSM VE Wİ-Fİ SİNYAL GÜCÜ TABANLI
KONUMLANDIRMA SİSTEMİNİN
GELİŞTİRİLMESİ VE PERFORMANS
ANALİZİ

AHMET BACAK
YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

DANIŞMANI
YRD. DOÇ. DR. HASARİ ÇELEBİ

GEBZE
2014



**GEBZE YÜKSEK
TEKNOLOJİ ENSTİTÜSÜ**

YÜKSEK LİSANS JÜRİ ONAY FORMU

GYTE Mühendislik ve Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 02/06/2014 tarih ve 2014/34 sayılı kararıyla oluşturulan jüri tarafından 03/06/2014 tarihinde tez savunma sınavı yapılan AHMET BACAK'ın tez çalışması BİLGİSAYAR MÜHENDİSLİĞİ Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI) : Yrd. Doç. Dr. Hasari ÇELEBİ

ÜYE

: Yrd. Doç. Dr. Yakup GENÇ

ÜYE

: Yrd. Doç. Dr. Hakan Paşa PARTAL

ONAY

GYTE Mühendislik ve Fen Bilimleri Enstitüsü Yönetim Kurulu'nun
..... tarih ve/..... sayılı kararı.

İMZA/MÜHÜR

ÖZET

Günümüzde bina dışında en yaygın olarak kullanılan konumlandırma sistemi GPS'dir. GPS bina dışında çok geniş alanda herhangi bir objenin konumunu kestirebilir. Ancak, GPS uydularla bağlanma problemleri yüzünden bina içi ortamlarda kullanılamamaktadır. İç ortamlarda, yaygın olarak kabul gören bir sistem hala günümüzde ortaya konulamamıştır.

Bu tez çalışmasında bu problem ele alınmış ve gerçek zamanlı bir bina içi konum belirleme sistemi geliştirilmiştir. Konumunu belirlemek için kullanıcıların ayrı bir cihaz taşımak istememeleri ve mobil telefonlarının kullanımı yaygınlaştığı için, mobil telefon tabanlı konum belirleme sistemi geliştirilmiştir. Bu kapsamda sistemin geliştirilmesinde aynı anda birçok baz istasyonu erişebildiğinden LG Nexus 4 mobil telefonu kullanılması tercih edilmiştir. Gebze Center alışveriş merkezinin farklı iki katındaki yeterince büyük bir alanda, mobil kullanıcının konumu kestirilmiştir.

Bu çalışmada, alınan sinyal gücü tabanlı RF parmak izi yaklaşımı kullanılmıştır. Sinyal kaynaklarından yayılan GSM ve Wi-Fi RSS verilerini toplamak için android uygulama geliştirilmiştir. Toplanan RSS verileriyle farklı makine öğrenmesi algoritmalarının, eğitim verisi toplanma süresinin, referans nokta sayısının, referans sinyal türü gibi pratik faktörlerin konumlandırma sistemi üzerindeki etkileri araştırılmıştır. Son olarak, konumlandırma hassasiyetini artırmak için birçok farklı yaklaşım önerilmiştir. Bu yaklaşımlar GSM ve Wi-Fi referans noktalarından elde edilen RSS verilerinin birleştirilmesi, eğitim verilerinin tekli ve çiftli koordinatlar olarak iki gruba ayrılması, RSS değerlerinden yeni bilgiler üretilmesi, algoritmalarının yeniden karar vermesi ve sanal eğitim verilerinin üretilmesi yaklaşımlarıdır.

Anahtar Kelimeler: RF Parmakizi, Alınan Sinyal Gücü(RSS), Bina içi Konum Belirleme.

SUMMARY

Nowadays, The GPS is the most widely used localization system in outdoor environments. The GPS estimate the location of an object in outdoor environments. However, It can't be used indoor environments due to lack of connecting to GPS satellites. There is no an acceptable localization system for indoor environments.

Therefore, In this thesis study, this problem is considered and developed a real time localization system for indoor environments. Considering that the users don't like carry a seperate device for location estimation and widespread usage of mobile devices, we developed the indoor localization system based on mobile devices. Therefore ,we selected to use LG Nexus 4 due to its capability of accessing to multiple base stations simultaneously. The location of mobile users is estimated at Gebze Center shopping mall in two different floor enough large area.

In this study, Received signal strength based RF fingerprinting approach is used. For such system we developed an android application for collecting GSM and Wi-Fi RSS data from signal sources. By using the collected data, the effects of different machine learning algorithms, the time of training data collection, number of measurement grid, and signal type on the performance of the localization system are studied. Finally, several solutions are suggested to increase the location accuracy of mobile users. These approaches are include combining Wi-Fi and GSM RSS data, dividing training data into two groups, generating new information from RSS data making new algorithmic decision and generating virtual training data.

Key Words: RF Fingerprinting, Received Signal Strength(RSS), Indoor Localization.

TEŞEKKÜR

Beni büyütüp bugünlere getiren, maddi ve manevi her türlü desteği sağlayan başta annem olmak üzere aileme ve yüksek lisans eğitimimde ve akademik hayatımda desteğini ve yardımlarını hiçbir zaman esirgemeyip bilgisi ile bu tez çalışmama yardımcı olan danışmanım Yrd. Doç. Dr. Hasari Çelebi'ye, sonsuz teşekkürlerimi sunarım.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	iv
SUMMARY	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
SİMGELER ve KISALTMALAR DİZİNİ	x
ŞEKİLLER DİZİNİ	xi
TABLolar DİZİNİ	xii
1. GİRİŞ	1
2. LİTERATÜR TARAMASI	3
2.1. Sinyal Metriklerine Göre Konumlandırma Yaklaşımları	3
2.1.1. Sinyalin Varış Zamanı	3
2.1.2. Sinyalin Varış Zamanı Arasındaki Fark	4
2.1.3. Sinyalin Varış Açısı	4
2.1.4. Sinyalin Gücü	5
2.2. Konum Belirleme Yöntemleri	6
2.2.1. Geometrik Yöntemler	6
2.2.2. Maliyet Fonksiyonu Minimizasyonu	6
2.2.3. RF Parmakizi Yaklaşımı	6
2.3. İç Ortam Konum Belirlemede Kullanılan Başlıca Sinyal Tipleri	7
2.3.1. RFID	7
2.3.2. Ultrasonik Sinyaller	8
2.3.3. Bluetooth	8
2.3.4. UWB	9
2.3.5. Wi-Fi	9
2.4. Literatürde Daha Önce Bina İçİ Çalışmaları İle Yapılan Tez Çalışmaların Karşılaştırılması	10
2.5. Tezdeki Katkılar	10
3. KONUM BELİRLEME SİSTEMİ	12
4. VERİ TOPLAMA VE DÜZENLEME	14

5. MAKİNE ÖĞRENMESİ YÖNTEMLERİ VE YAPAY SİNİR AĞLARI	
ALGORİTMALARI	20
5.1. Makine Öğrenmesi Algoritmaları	20
5.1.1. BayesNet	20
5.1.2. SVM	21
5.1.3. KNN	22
5.1.4. Karar Ağaçları	23
5.2. Yapay Sinir Ağları Algoritmaları	24
5.2.1. Çok Katmanlı Perceptron	25
5.2.2. RBF Ağı	26
6. DENEYSEL SONUÇLAR	28
6.1. 10 Noktada Yapılan Test Sonuçları	28
6.2. 40 Noktada Yapılan Test Sonuçları	29
6.3. 100 Noktada Yapılan Test Sonuçları	33
6.3.1. Makine Öğrenmesi Algoritmalarının Etkisi	33
6.3.2. Eğitim Verisi Toplanma Süresinin Etkisi	35
6.3.3. Referans Nokta Sayısının Etkisi	36
6.3.4. Referans Sinyal Türünün Etkisi	38
6.3.5. Test Verisi Gününün Etkisi Ve Algoritmalarının Konum Kestirme Performanslarının Belirlenmesi	39
6.4. 100 Nokta İçin Konum Kestirme Doğruluk Oranının Artırılması İçin Yapılan Çalışmalar	42
6.4.1. GSM Ve Wi-Fi Referans Noktalarının Birleştirilmesi	42
6.4.2. Eğitim Verileri Toplanma Aralığının Değiştirilmesi	43
6.4.3. RSS Değerlerinden Yeni Bilgiler Üretilmesi	46
6.4.4. Sınıfları Tekli Ve Çiftli Koordinatlar Olmak Üzere İki Gruba Ayırma	47
6.4.5. Algoritmalarının Yeniden Karar Vermesi	49
6.5. 200 Noktada Yapılan Test Sonuçları	50
6.6. Yapay Sinir Ağları Ve Regresyon Algoritmalarının Sonuçları	51
6.7. Mevsimsel Etkilerinin Araştırılması	54
6.8. Sanal Eğitim Verisi Üretme Yaklaşımı	55
7. SONUÇ	60

KAYNAKLAR	61
ÖZGEÇMİŞ	65
EKLER	66

SİMGELER ve KISALTMALAR DİZİNİ

<u>Simgeler ve</u>	<u>Açıklamalar</u>
<u>Kisaltmalar</u>	
AOA	: Ultra Geniş Band
GPS	: Küresel Yer Belirleme Sistemi
GSM	: Mobil İletişim İçin Küresel Sistem
RF	: Radyo Frekansı
RKO	: Rastgele Karar Ormanı
RSS	: Alınan Sinyal Gücü
SVM	: Destek Vektör Makinesi
TOA	: Geliş Zamanı
UWB	: Ultra Geniş Band
Wi-Fi	: Kablosuz Ağ Bağlantısı

ŞEKİLLER DİZİNİ

<u>Sekil No:</u>	<u>Sayfa</u>
2.1: TOA yaklaşımı.	4
2.2: AOA yaklaşımı.	5
3.1: Geliştirilen konum belirleme sisteminin görüntüsü.	13
3.2: Konum belirleme sistemi diyagramı.	13
4.1: 100 noktada Wi-Fi sinyalleriyle farklı referans nokta sayıları denenerek yapılan sonuçların CDF'leri.	14
4.2: Toplanan RSS verilerinin arff dosya formatına dönüştürüldükten sonraki görünümü.	16
4.3: Bir günde 24 saat boyunca en güçlü GSM hücresinden elde edilen sinyal gücünün saat olarak ortalaması.	17
4.4: 40 Noktada RSS verisi toplanan noktalar.	17
4.5: 100 Noktada RSS verisi toplanan noktalar.	18
4.6: 200 Noktada RSS verisi toplanan noktalar.	19
5.1: Lineer olarak Fisher Diskriminantı algoritmasıyla ayrılabilen veri.	21
5.2: SVM algoritmasındaki farklı çekirdek fonksiyonları.	22
5.3: Bir yapay sinir ağı modelinin görüntüsü.	25
5.4: a) MLP algoritmasının sınıfları ayırma yaklaşımı, b) RBF Network algoritmasının sınıfları ayırma yaklaşımı.	27
6.1: 100 noktada Wi-Fi sinyalleriyle farklı algoritmalar denenerek yapılan sonuçların CDF'leri.	35
6.2: 100 noktada Wi-Fi sinyalleriyle farklı eğitim verileri denenerek yapılan sonuçların CDF'leri.	36
6.3: 100 noktada Wi-Fi sinyalleriyle farklı referans nokta sayıları denenerek yapılan sonuçların CDF'leri.	37
6.4: 100 noktada farklı referans sinyal türleri denenerek yapılan sonuçların CDF'leri.	39
6.5: Örnek bir RSS verisi kaydı.	46

TABLÖLAR DİZİNİ

<u>Tablo No:</u>	<u>Sayfa</u>
4.1: Toplanan RSS verilerinin veritabanındaki ilk görünümü.	15
4.2: Toplanan RSS verilerinin düzenlendikten sonraki görünümü.	15
6.1: 10 noktada GSM sinyalleri ile algoritmalarının etkisini gözlemlemek için yapılan test sonuçları tablosu.	28
6.2: 10 noktada Wi-Fi sinyalleri ile algoritmalarının etkisini gözlemlemek için yapılan test sonuçları tablosu.	29
6.3: 40 noktada GSM sinyalleri ile algoritmalarının etkisini gözlemlemek için yapılan test sonuçları tablosu.	30
6.4: 40 noktada Wi-Fi sinyalleri ile eğitim verisinin etkisini gözlemlemek için yapılan test sonuçları tablosu.	31
6.5: 40 noktada Wi-Fi sinyalleri ile referans nokta sayısının etkisini gözlemlemek için yapılan test sonuçları tablosu.	32
6.6: 100 noktada GSM sinyalleri yapılan makine öğrenmesi algoritmalarının etkisini gözlemlemek için yapılan test sonuçları tablosu.	33
6.7: 100 noktada Wi-Fi sinyalleri ile makine öğrenmesi algoritmalarının etkisini gözlemlemek için yapılan test sonuçları tablosu.	34
6.8: 100 noktada Wi-Fi sinyalleri ile eğitim verisinin etkisini gözlemlemek için yapılan test sonuçları tablosu.	35
6.9: 100 noktada Wi-Fi sinyalleri ile referans nokta sayısının etkisini gözlemlemek için yapılan test sonuçları tablosu.	37
6.10: 100 noktada referans sinyal türünün etkisini gözlemlemek için yapılan test sonuçları tablosu.	38
6.11: 100 noktada farklı günler test verileri olarak düzenlendikten sonra elde edilen sonuçlar tablosu.	41
6.12: 100 noktada 10 çapraz geçiş yapılarak elde edilen algoritmanın performansları sonuçları tablosu.	42
6.13: 100 noktada GSM ve Wi-Fi RSS verilerinin birleştirilme yaklaşımının sonuçları tablosu.	42

6.14:	100 noktada RSS eğitim verilerinin tekilleştirme yaklaşımının sonuçları tablosu.	44
6.15:	100 noktada GSM RSS eğitim verilerinin tekilleştirme yaklaşımının sonuçları tablosu.	45
6.16:	100 noktada RSS verilerinden yeni bilgiler üretme yaklaşımının sonuçları tablosu.	46
6.17:	100 noktada sınıfları tekli ve çiftli koordinatlar olmak üzere iki gruba ayırma yaklaşımının sonuçları tablosu.	49
6.18:	100 noktada algoritmaların yeniden karar vermesi yaklaşımının sonuçları tablosu.	49
6.19:	200 noktada yapılan test sonuçları tablosu.	51
6.20:	Yapay sinir ağları ve regresyon algoritmaları ile 10 noktada yapılan test sonuçları tablosu.	52
6.21:	Yapay sinir ağları ve regresyon algoritmaları ile 20 noktada yapılan test sonuçları tablosu	52
6.22:	Yapay sinir ağları ve regresyon algoritmaları ile 40 noktada yapılan test sonuçları tablosu.	53
6.23:	Konum kestirmede mevsimlerin etkisi.	54
6.24:	Konum kestirmede mevsimlerin etkisinin azaltılması.	55
6.25:	Sanal eğitim verisi üretme yaklaşımının 7 noktadaki sonuçları tablosu.	55
6.26:	Sanal eğitim verisi üretme yaklaşımının 7 noktadaki sonuçları tablosu.	57
6.27:	Sanal eğitim verisi üretme yaklaşımının 38 noktadaki sonuçları tablosu.	57
6.28:	Sanal olarak üretilen eğitim verilerinin orijinal eğitim verileri birleştirilmesi yaklaşımının sonuçları tablosu	59

1. GİRİŞ

İç ortam konumlandırma sistemleri son yıllarda artarak önem kazanan bir alan olmuştur. Bu ihtiyacın ortaya çıkmasında AVM, havaalanı, hastane vb. büyük kapalı alanların artması, yaygınlaşan otomasyon teknolojileri ve yaygınlaşan mobil cihazların etkisi büyüktür. Kullanıcı hareketlerinin izlenebilmesi, AVM’lerde hangi mağaza ya da ofislerde daha fazla zaman geçirdiklerinin bilinebilmesi beraberinde mobil kullanıcıların konumlarının bilinmesi gerekliliğini ortaya koymuştur. Dış ortamda konumlandırma uygulamalarında GPS baskındır. Ancak GPS iç ortamlarda uydularla bağlantı problemlerinden dolayı kullanılamamaktadır. İç ortam konumlandırmada yaygın olarak kabul edilen bir çözüm henüz ortaya konulmadığından ötürü, akademik olarak iç ortamlarda konum belirleme problemi sıcak bir konu olarak devam etmektedir. Bu yapılan tez çalışması kapsamında, mobil telefonların kullanımları da yaygınlaştığı göz önünde bulundurularak, mobil kullanıcının bir alışveriş merkezindeki konumu tespit edilmeye çalışılmıştır. Yapılan çalışmada maliyeti en az olan yaklaşımlarından biri olan, alınan sinyal gücü tabanlı RF parmakizi yaklaşımı tercih edilmiştir. Alınan sinyal gücü tabanlı RF parmakizi yaklaşımında, bina içi ortamdan algılanan Wi-Fi, GSM, 3G gibi farklı kablosuz haberleşme ağlarındaki sinyal güçleri kullanılarak konum tespit işlemi gerçekleştirilir. Yapılan tez çalışması kapsamında, konum belirlemek için GSM ağı üzerinden gelen RSSI ve AVM’deki modemlerden gelen Wi-Fi RSSI değerlerinden yararlanılmıştır. GSM ve Wi-Fi sinyal türlerinin konum kestirimindeki başarımları, WEKA kütüphanesindeki farklı makine öğrenmesi algoritmalarıyla elde edilmiştir. Referans noktası ve eğitim verileri toplanma süresinin konumlandırma sisteminin performansı üzerindeki etkileri de araştırılmıştır.

Bu tez çalışması şu şekilde organize edilmiştir. II. Bölümde, literatür taramasına yer verilmektedir. İlk olarak literatürde yer alan başlıca konumlandırma yaklaşımları anlatılmaktadır. İç ortam konum belirlemede, kullanılan ölçüm çeşitlerine ve sinyal tiplerine yer verilmektedir. Konumlandırma yaklaşımları karşılaştırılarak tez çalışması kapsamında kullanılan RF parmakizi yaklaşımının niçin kullanıldığına da yer verilmektedir. Bu bölümün sonunda ise, yapılan tez çalışmasının katkıları anlatılmaktadır. III. Bölümde, geliştirilen konum belirleme sistemi detaylarıyla anlatılmaktadır. IV. Bölümde veri toplama işleminin nasıl yapıldığı detaylarıyla

anlatılmaktadır. V. Bölümde tez çalışmasında kullanılan makine öğrenmesi algoritmaları ve yapay sinir ağıları algoritmaları ilgili temel bilgiler yer almaktadır. VI. bölümde, 40, 100, 200 noktada alışveriş merkezinden toplanan GSM ve Wi-Fi RSS ölçüm verileri kullanılarak elde edilen farklı algoritmalar, farklı referans noktaları ve farklı eğitim veri toplanma sürelerinde konum kestirim başarımları sonuçları verilmektedir. Ayrıca, bu bölümde konum hatasının azalması için test edilip önerilen yaklaşımlar yer almaktadır. Bu yaklaşımlar, sinyal türlerinin birleştirilmesi, sinyal güç değerlerinden yeni bilgilerinin üretilmesi, algoritmalarının yeniden karar vermeleri şeklindedir. Son olarak da eğitim verileri toplanma süresini azaltmak için önerilen sanal eğitim verileri üretme yaklaşımına yer verilmektedir.

2. LİTERATÜR TARAMASI


Bir konumlandırma sisteminde, konum tespiti alınacak cihazdan alınan bazı bilgiler kullanılarak kullanıcının konum bilgisine dönüştürülür. Bu bilgiler sinyal kaynağın gücü, açısı, zamanı gibi metrikler olabilir. Kullandığı sinyal metriklerine göre, literatürde var olan yöntemler Sinyalin Geliş Açısı, Sinyalin Varış Zamanı, Sinyalin Varış Zamanı Arasındaki Fark, Alınan Sinyal Gücü olarak sınıflandırılabilir [1]-[3]. Literatürde yer alan konum belirleme yöntemleri geometrik yöntemler, RF parmakizi yaklaşımı ve maliyet fonksiyonu minimizasyonu olarak sınıflandırılabilir. Literatürde bina içinde konum kestirmek için kullanılan başlıca sinyal tipleri RFID, Wi-Fi, Bluetooth, UWB, Ultrasonik sinyaller şeklindedir [4].

2.1. Sinyal Metriklerine Göre Konumlandırma Yaklaşımları

2.1.1. Sinyalin Varış Zamanı

Sinyalin varış zamanı konumlandırma yöntemi, hareketli bir cihazdan gönderilen ve baz istasyonları tarafından alınan sinyalin geliş sürelerini ele alarak konum kestiriminde bulunur. Bu yaklaşımda, hareketli bir cihazdan gönderilen sinyaller baz istasyonları tarafından dinlenir. Baz istasyonu tarafından elde edilen sinyallerin zaman bilgileri alınır. Bu zaman bilgileri ile daireler tanımlanır. Konumu tespit edilecek objenin bu dairelerin kesişim noktasında olduğu kabul edilir [5-7]. Şekil 2.1’de [8] bu yaklaşımının kullanılmasıyla konumun daireler çizilerek bulunmasının görüntüsü görülmektedir.

TOA yaklaşımının diğer sinyal metriklerine yaklaşımlarına göre güvenilirliği en yüksek olan yöntemdir. Ancak alıcı ile vericiler arasında senkronizasyonun çok iyi bir şekilde ayarlanması gerekmektedir [7]. Bu yöntemi kullanmak için şebekeye, LMU (Location Measurement Unit) adı verilen donanımlardan kurulması gerekmektedir [3]. Ek donanım gerektirmesi nedeniyle maliyetli bir çözümdür. Bu sebepten dolayı ticari uygulamalarda pek tercih edilmemektedir.



Şekil 2.1: TOA yaklaşımı.


2.1.2. Sinyalin Varış Zamanı Arasındaki Fark

Varış zamanı arasındaki fark yaklaşımı (TDOA) alıcılara ulaşan sinyalin geliş sürelerindeki farkları kullanır. Sinyalin geliş hızı olan ışık hızı ile sinyalin geliş zamanının çarpılmasıyla erişim noktalarına olan uzaklık hesaplanır. Elde edilen varış zamanı arasındaki fark bilgileri kullanılarak sinyallerin yayıldığı cihaz ile alıcılar arasında hiperbollar çizilir. Alıcı sayısı kadar olan hiperbolların kesişimi sinyal gönderen cihazın yeri olarak kabul edilir [9], [10].

2.1.3. Sinyalin Varış Açısı

Varış açısı konumlandırma yaklaşımında hareketli cihazın yeri, sinyal kaynaklarından gelen sinyallerinin açıları kullanılarak hesaplanır. Bu yaklaşımı kullanmak için yönlü antenler kullanılmalıdır [3]. Sinyallerin geliş açısı sinyal güç değerleri ve sinyal varış zamanları kullanılarak elde edebilirler. Geliş açısı değeri ile referans noktası ve hareketli cihaz arasına çizgiler çizilir. Tahmin edilen konum ise hareketli cihazın konumu olarak kabul edilir [11]-[13]. Şekil 2.2’de [3] bu

yaklaşımının kullanılmasıyla konumunun çizgiler çizilerek bulunmasının görüntüsü görülmektedir.



Şekil 2.2: AOA yaklaşımı.

2.1.4. Sinyalin Gücü

Sinyal kaynağına yaklaştıkça sinyal gücü değeri artarken, sinyal kaynağından uzaklaştıkça sinyal gücü değeri azalır. Sinyal gücü değerleri bina içindeki birçok etkenden etkilenir. Duvar, kapı, insan ve sıcaklık ve nem gibi hava koşullarından sinyal gücü etkilenebilir. Ancak sinyal gücünün elde edilmesi diğer sinyal metriklerine göre daha kolaydır.

Yapılan tez çalışmasında, ortamdaki sinyal gücünü elde etmek diğer sinyal metriklerine göre daha kolay olduğu için alınan sinyal gücü (RSSI) metrik olarak seçilmiştir.

2.2. Konum Belirleme Yöntemleri

2.2.1. Geometrik Yöntemler

Geometrik yöntemler üçgenleme, daire kesişimi, hiperbol kesişimi şeklindedir. Üçgenleme yönteminde, üçgenin bir köşesi, hesaplanmak istenen konum olup bilinen diğer kenar uzunlukları ve açı değerleri birlikte kullanılarak üçgenin bilinmeyen köşesi hesaplanır [4].

Daire kesişiminde, mesafe ölçümleri ile bilinen noktalar daireler oluşturulur ve dairelerin kesişimi hesaplanarak konum bulunur. Mesafe ölçümü ile denklem sistemi oluşur ve en küçük kareler ile ölçüm hatalarından kaynaklanan konum hatası azaltılır. Hiperbol kesişimi TDOA sinyal metriğinde kullanılan konum belirleme yöntemidir. Daire kesişimi yöntemine benzer şekilde mesafelere göre tanımlanan hiperbollerin kesişim noktası hesaplanarak konum bulunur.

2.2.2. Maliyet Fonksiyonu Minimizasyonu

Bu yöntemde konum hatası bir maliyet fonksiyonu olarak ifade edilir. Konum hatası minimize edilmeye çalışılır. Konum hataları sıfır ortalamalı ve gaussian dağılıma sahipse maliyet fonksiyonu minimizasyonu kolaylaşmaktadır ancak dağılım her zaman sıfır ortalamalı ya da gaussian dağılıma sahip olmayabilir. Ortaya konulan maliyet fonksiyonuna göre iteratif yaklaşımlar, doğrusallaştırma, sezgisel algoritmalar gibi farklı matematiksel çözümler ile konum hatası minimize edilmektedir [4].

2.2.3. RF Parmakizi Yaklaşımı

Alınan sinyal gücü tabanlı RF parmakizi yaklaşımında, bina içi ortamda bulunan Wi-Fi, GSM, 3G gibi farklı kablosuz haberleşme ağlarını kullanarak gerçekleştirilebilir. [14]-[21]'de yapılan çalışmalarda RF parmakizi yaklaşımı kullanılarak yapılmıştır. RF parmakizi yaklaşımı test ve eğitim aşaması olmak üzere iki aşamadan oluşmaktadır. Bina içinde konumu belirlenecek noktalardan, çeşitli sinyal güç değerleri alınır ve veritabanı oluşturulur. Daha sonra başka bir zaman elde

edilen sinyal güçleri ile veritabanındaki sinyal güç değerleriyle karşılaştırılarak çeşitli makine öğrenmesi algoritmalarına göre en yüksek olasılığa sahip olan nokta bulunur ve tahmini nokta olur.

- Avantajları:

- Yüksek hassasiyette konum bilgisi sağlamaya imkan tanır.
- Ek donanım gerektirmez. Maliyeti en az olan yöntemdir.

- Dezavantajları:

- Her yeni ortam için veritabanı oluşturmak.
- Ortamdaki değişikliklere göre veritabanını güncellemek.

RF parmakizi yaklaşımı temel olarak ortamdaki sinyal gücü kullanır. Sinyalinin geliş zamanı ve açısı gibi metrikleri elde etmek için ek donanımlar gerekir. Sinyal gücünü kullanarak, daire kesişimi metodunu kullanmak için sinyal kaynaklarının yerinin bilinmesi gerekir. RF parmakizi yaklaşımında sinyal kaynaklarını yerinin bilinmesine gerek yoktur.

2.3. İç Ortam Konum Belirlemede Kullanılan Başlıca Sinyal Tipleri

2.3.1. RFID

RFID bir okuyucu ve bir etiketten meydana gelen otomatik bir tanıma sistemidir. Etiketin içinde bir mikroçip ve mikroçipi saran bir anten bulunmaktadır. Okuyucu ile etiket arasında, elektromanyetik dalgalar vasıtasıyla iletişim kurulmaktadır. Okuyucunun yaydığı elektromanyetik dalgalar, bir enerji olarak çiple buluşup onu harekete geçirmekte ve etiketten okuyucuya veri transferi yapılmaktadır. Tüm bunlar belli bir mesafede, herhangi bir temas olmadan ve kablolu olarak gerçekleşmektedir [22]. Okuyucu aldığı veri dalgasını sayısal dalga biçimine dönüştürerek bilgisayara aktarmaktadır. RFID, takip edilmek istenilen nesnenin üzerinde hareketlidir ve okuyucular ise bina içerisinde önceden belirlenmiş

konumlara sabitlenmektedir. RFID taşıyıcısından alınan RSSI değerleri kullanılarak konum kestirimi yapılmaktadır. RSSI değerlerini elde edebilmek için taşıyıcıdan alınan sinyal gücünü ölçebilen özellikte okuyuculara ihtiyaç vardır. RFID iç ortam konum belirlemede yaygın olarak kullanılan bir sinyal türüdür.

[23]-[33]'de yapılan çalışmalar da RFID sinyal türü kullanılarak iç ortamlarda konum belirlemeye çalışılmıştır.

2.3.2. Ultrasonik Sinyaller

Ultrasonik sinyaller insan kulağının duyma eşiği olan 20KHz üzerindeki ses sinyalleridir. Ultrasonik sinyallerin yayılma hızı ses hızıdır (340m/s). Bu hız RF sinyallere göre çok düşüktür. Ultrasonik sinyaller için uçuş zamanı, ulaşma zamanı farkı gibi zaman ölçümleri basit sistemler ile yapılabilir. Ultrasonik sinyallerin zaman senkronizasyonundaki hassasiyet ihtiyacı nispeten düşüktür.

Ultrasonik sinyaller duvar vb. engellerden geçemezler bu sebepten ötürü yalnızca oda ayrımı için kullanılırlar. Hastane ve bebek kreşi gibi özel ortamlarda ise radyasyonun olası olumsuz etkileri sebebi ile radyo dalgaları kullanan sistemler tercih edilmemektedir [4]. Hastanelerde ultrasonik sinyaller tercih edilmektedir.

2.3.3. Bluetooth

Bluetooth, kablosuz, kısa mesafeli, ses ve veri haberleşmesini sağlamak için oluşturulan teknolojidir. Frekans bandı 2.4 GHz ile 2.48 GHz arasındadır. Bu frekans bandının kullanımı lisanssız olup endüstriyel, bilimsel ve medikal (ISM) bant olarak adlandırılmaktadır [34].

Bluetooth tabanlı yer tespit sistemlerinde alınan sinyal gücü seviyeleri, yerleri bilinen Bluetooth cihazlarına olan uzaklıkları tahmin etmek için kullanılabilir [3].

- Avantajları:

- Günümüzde PDA, cep telefonu, tablet vb. pek çok mobil cihazda bluetooth cihazları yaygın olarak kullanılmaktadır.

- Bluetooth teknolojisi gürültüye dayanıklıdır. Radyo frekanslı ortamlarda tam verimli bir şekilde çalışabilir.
- Bluetooth cihazlarının maliyeti düşüktür.
- Enerji tüketimi azdır.

- Dezavantajları:

- Bluetooth cihazların elde edebildikleri sinyal gücü değerleri, bağlantının kabul edilir, çok zayıf veya çok güçlü seviyede olduğunu belirten bilgilerdir.

2.3.4. UWB

UWB sinyalleri genellikle 1ns altında ultra kısa süreli ve düşük görev çevrimine sahip palslerdir. Bu palsler 3.1 GHz'den 10.6GHz'e kadar çok geniş bir frekans bandını kaplayabilir. UWB sinyallerinin engellerden geçmeleri diğer radyo sinyallerine göre yüksektir. UWB sinyalleri ile hassas şekilde uçuş zamanı, uçuş zamanı farkı ölçümleri yapılabilir. Bina içi konumlandırma sistemlerinde tahminlerin doğruluk oranını düşüren en büyük etken sinyallerin çok yollu dağılmasıdır. Bu sorunun giderilmesinde ultra geniş bant teknolojisi kullanılabilir. Ultra geniş bant sistemlerinin en büyük avantajı, konumlandırma sistemlerinde diğer teknolojilere göre daha doğru tahminlerin yapılmasını sağlamasıdır. Bu sistemler hassas zaman senkronizasyonuna ihtiyaç duyduğundan karmaşık ve pahalı sistemlerdir. Bu nedenle kullanımları çok yaygın değildir [3], [4].

2.3.5. Wi-Fi

Wi-Fi (IEEE 802.11), 2.4GHz ISM bantta ve 5GHz bantta veri aktarımı için oluşturulmuş bir standart olup son yıllarda kablosuz internet bağlantısı için son derece yaygınlaşmıştır. Wi-Fi dizüstü bilgisayarlar, mobil telefonlar ve diğer taşınabilir cihazların yakınlarındaki kablosuz erişim noktaları aracılığıyla yerel alan ağına bağlanabilmesini sağlar. Günümüzde bu yaklaşım yeni bir altyapı kurma yükünü hafiflettiği için oldukça yaygınlaşmaya başlamıştır. Wi-Fi alınan sinyal gücü kullanarak konum belirleme yapılabilir.

Artık hemen hemen tüm telefonların Wi-Fi teknolojileri desteklemeleri ve özellikle alışveriş merkezi gibi alanlarda Wi-Fi teknolojisinin yaygınlaşmış olması yeniden altyapı kurma gereksinimi ortadan kaldırır. GSM teknolojisi tüm telefonlarda olan bir teknolojidir. Bu sebeplerden ötürü yapılan tez çalışması kapsamında GSM ve Wi-Fi sinyal türlerinin kullanılması tercih edilmiştir.

2.4. Literatürde Daha Önce Bina İçi Çalışmaları İle Yapılan Tez Çalışmaların Karşılaştırılması

İncelenen RF parmakizi yaklaşımı kullanılarak literatürde var olan yalnızca bir kaç çalışmada gerçek bir mobil telefonun konumu belirlenmeye çalışılmıştır. [19]'da yapılan çalışma 2010 yılında gerçekleştirilmiştir. Bu çalışmanın bina içinde RF parmakizi yaklaşımı kullanılarak literatürde ilk kez mobil telefon kullanıcının konumunu bulmaya çalışan ilk araştırma olduğunu anlatılmaktadır. Bunun dışında, incelenen hiçbir çalışmada RF parmakizi yaklaşımının dezavantajı olan veri toplama süreçlerini uzun olması için çözüm sunulmamıştır.

Ayrıca, RF parmakizi yaklaşımı kullanılarak yapılan çalışmalarda yalnızca sinyal gücü değerleri kullanılmıştır. Yapılan tez çalışmasında RF parmakizi yaklaşımındaki konum hassasiyetini artırmak için, sinyal gücü değerlerinden yeni özellikler oluşturulmuştur.

2.5. Tezdeki Katkılar

RF parmakizi yaklaşımı kullanılarak geliştirilen konumlandırma sisteminde çeşitli değişkenlerin etkisi araştırılmış ve konum belirleme sisteminin performansını daha artırmak için bazı yaklaşımlar önerilmiştir.

- Çevre koşullarının (hava sıcaklığı) sinyal güçlerine etkisi araştırılmıştır.
- Makine öğrenmesi algoritmalarının etkisi araştırıldı. En uygun makine algoritması belirlenmiştir.
- Eğitim verisi toplanma süresinin etkisi araştırılmıştır. Ne kadar eğitim verisi süresinin gerekli olduğu tespit edilmiştir.

- Referans nokta sayılarının etkisi araştırılmıştır. Ne kadar referans noktasının yeterli olduğu tespit edilmiştir.
- Referans sinyal türünün etkisi araştırılmıştır.
- Biri kış, diğeri ilkbahar mevsiminde olmak üzere farklı zamanlarda veri toplanarak mevsimsel etkiler araştırılmıştır.
- Verilerin tekilleştirilmesi, sinyal güçlerinden yeni bilgiler üretilmesi, algoritmalarının yeniden karar vermesi, sinyal türlerinin birleştirilmesi yaklaşımları önerilerek konum hatası azaltılmıştır.
- RF parmakizi yaklaşımın önemli bir dezavantajı veri toplama sürelerinin uzun sürmesidir. Bu yapılan tez çalışmasında, bu problem de ele alınmış ve tüm noktalardan veri toplamadan, veri toplanmayan noktalarda sanal eğitim verisi üretme yaklaşımı önerilmiştir.

3. KONUM BELİRLEME SİSTEMİ


Yapılan tez çalışması kapsamında, alışveriş merkezindeki mobil kullanıcıların hareketlerinin izlenebilmesi, hangi mağaza ve ofislerin önünde daha fazla zaman geçirdiklerinin bilinmesi, hangi rotaları izlediklerinin belirlenebilmesi için bina içi konumlandırma sistemi geliştirilmiştir. Kullanıcının bulunduğu konumunun tipik olarak en fazla 2-3 metre uzağında olmak üzere belirlenmesi gerekir. Tez çalışması kapsamında geliştirilen konumlandırma sisteminde kullanıcının konumunu kestirebilmek için RF parmakizi yaklaşımı kullanılmıştır. Geliştirilen sistemde, LG Nexus 4 telefonu kullanılmıştır. LG Nexus 4 telefonu etraftaki GSM ve Wi-Fi verilerini toplama özelliği bulunmasından dolayı tercih edilmiştir.

LG Nexus 4 telefonu aracılığıyla GSM ve Wi-Fi RSS verilerini toplamak için bir android uygulama geliştirilmiştir. LG Nexus 4 telefonu kullanılarak toplanan GSM ve Wi-Fi RSS verileriyle veritabanı oluşturulmuştur. Geliştirilen konumlandırma sistemin çalışması aşağıda maddeler halinde açıklanmaktadır.

- Mobil kullanıcının alışveriş merkezinde konumunu farklı bir zamanda tespit etmek amacıyla, referans noktasını ve bu referans noktasından elde edilen sinyal güçleri, sunucu olan telefon numarasına sms yolu ile gönderilmesi sağlanmıştır.
- Bilgisayara takılı 3G USB modem aracılığıyla, sunucu SIM kartın içindeki RSS ve referans değerlerini içeren kısa mesajlar java dilinde smslib kütüphanesi kullanılarak okunmuştur.
- Sim kartın içerisindeki okunan RSS ve referans değerleriyle, daha önce toplanan eğitim verileri kullanılarak, çeşitli makine öğrenmesi algoritmasıyla kullanıcının konumu kestirilmiştir. Şekil 3.1 'de geliştirilen konum belirleme sisteminin görüntüsü görülmektedir.
- Kullanıcıların bulundukları konumların gösterilmesi, katlarda izledikleri rotaların görselleştirilmesi ve sunucu ekranında takibi için java dilinde Abstract Window Toolkit(AWT) paketi kullanılarak daha önce belirlenen noktalara göre AVM haritası çizilmiştir. Kullanıcının izlediği rotada AWT kullanılarak geliştirilen AVM haritasında gösterilmiştir. Şekil 3.2'de konum belirleme sisteminin diyagramı görülmektedir.




Şekil 3.1: Geliştirilen konum belirleme sisteminin görüntüsü.



Şekil 3.2: Konum belirleme sistemi diyagramı.

4. VERİ TOPLAMA VE DÜZENLEME

GSM ve Wi-Fi RSS verilerini toplamak için, aynı anda birçok GSM ve Wi-Fi sinyal kaynağından gelen sinyal güç değerleri elde edebildiği için LG Nexus 4 telefonu kullanılmıştır. LG Nexus 4 telefonu Android işletim sistemine sahip akıllı bir telefondur. LG Nexus 4 telefonu kullanılarak, GSM ve Wi-Fi RSS verilerini toplamak için bir android uygulama geliştirilmiştir. Gebze Center alışveriş merkezinden daha önce belirlenen noktalardan belirli süre kadar kalınarak GSM ve Wi-Fi RSS verileri toplanmıştır. RSS verilerin toplanması aşamasında kullanıcının bulunduğu konum bilgisi de eklenmiştir. Toplanan GSM ve Wi-Fi RSS verileri ve kullanıcının bulunduğu koordinat bilgisiyle beraber LG Nexus 4 telefonun iç hafızasında iki ayrı dosyaya yazılmıştır. Daha sonra ise PostgreSQL veritabanına toplanan GSM ve Wi-Fi RSS verileri aktarılmıştır. PostgreSQL veritabanında toplanan bu RSS verileri düzenlenmiştir. Şekil 4.1’de RSS verileri toplanma sürecinin diyagramı görülmektedir.



Şekil 4:1: RSS verilerinin toplanması ve düzenlenmesinin diyagramı.

Tablo 4.1’de RSS verilerinin dosyadan veritabanına aktarıldığındaki ilk görünümü görülmektedir. Tablo 4.2’de ise PostgreSQL veritabanındaki bu RSS verilerin düzenlendikten sonraki hali görülmektedir.

Tablo 4.1: Toplanan RSS verilerinin veritabanındaki ilk görünümü.

olcum_tarihi character varying(50)	cell_id1 integer	ana_olcum1 integer	cell_id2 integer	diger_olcum2 integer	cell_id3 integer	diger_olcum3 integer
20140111_150918.836	5581	-65	17172	-59	5582	-71
20140111_150919.334	5581	-65	17172	-59	5582	-71
20140111_150919.836	5581	-65	17172	-59	5582	-71
20140111_150920.338	5581	-65	17172	-59	5582	-71

Tablo 4.2: Toplanan RSS verilerinin düzenlendikten sonraki görünümü.

olcum_tarihi character varying(50)	17172_cell integer	5581_cell integer	5582_cell integer	57482_cell integer	17171_cell integer	57434_cell integer
20140111_150918.836	-59	-65	-71	-83	-83	-115
20140111_150919.334	-59	-65	-71	-83	-83	-115
20140111_150919.836	-59	-65	-71	-83	-83	-115
20140111_150920.338	-59	-65	-71	-83	-83	-115

Tablo 4.2 ve 4.3’de görüldüğü üzere cell_id, RSS şeklinde olan veriler tüm cell_id ve RSS değerleri veritabanının ayrı bir sütunu olacak şekilde düzenlenmiştir. Bu düzenlemeyi yaptıktan sonra, veritabanından RSS verilerini içeren tablo, önce csv dosya formatına daha sonra ise arff dosya formatına dönüştürülmüştür. Şekil 4.2’de toplanan RSS verilerinin arff dosya formatına dönüştürüldükten sonraki görünümü görülmektedir.

GSM ve Wi-Fi sinyalleri çevre koşullarından etkilendiği için toplanan verilerinin bir kısmını eğitim ve bir kısmı test verisi kullanmakta yerine ayrı bir zamanda tüm noktalardan 30 saniye boyunca toplanan veriler test verisi olarak kullanılmıştır. Aynı noktadan farklı bir defa değil de farklı zamanlarda da veri toplamamızın nedeni, GSM ve Wi-Fi sinyallerinin çevre koşullarından etkilenmesidir.

```

@RELATION 11_12_13Ocak17GSMBazEgitim

@ATTRIBUTE baz1 numeric
@ATTRIBUTE baz2 numeric
@ATTRIBUTE baz3 numeric
@ATTRIBUTE baz4 numeric
@ATTRIBUTE baz5 numeric
@ATTRIBUTE baz6 numeric
@ATTRIBUTE baz7 numeric
@ATTRIBUTE baz8 numeric
@ATTRIBUTE baz9 numeric
@ATTRIBUTE baz10 numeric
@ATTRIBUTE baz11 numeric
@ATTRIBUTE baz12 numeric
@ATTRIBUTE baz13 numeric
@ATTRIBUTE baz14 numeric
@ATTRIBUTE baz15 numeric
@ATTRIBUTE baz16 numeric
@ATTRIBUTE baz17 numeric


@ATTRIBUTE class {3_0-0,3_0-1,3_0-2,3_0-3,3_0-4,3_0-5,3_0-6,3_0-7,3_0-8,3_0-9,3_0-10,3_0-11,3_0-12,3_0-13,

@DATA
20140111_150918.836,-59,-65,-71,-83,-83,-115,-115,-115,-115,-91,-81,-115,-115,-115,-115,-115,3_0-0
20140111_150919.334,-59,-65,-71,-83,-83,-115,-115,-115,-115,-91,-81,-115,-115,-115,-115,-115,3_0-0
20140111_150919.836,-59,-65,-71,-83,-83,-115,-115,-115,-115,-91,-81,-115,-115,-115,-115,-115,3_0-0
20140111_150920.338,-59,-65,-71,-83,-83,-115,-115,-115,-115,-91,-81,-115,-115,-115,-115,-115,3_0-0

```

Şekil 4.2: Toplanan RSS verilerinin arff dosya formatına dönüştürüldükten sonraki görünümü.

Şekil 4.3’de bir günde aynı noktadan 24 saat boyunca en güçlü GSM hücresinden elde edilen sinyal gücü saat olarak ortalaması verilmektedir. Saat 16-17 arası sinyal gücü ortalaması -62.35 dBm iken, saat 17-18 arası sinyal gücü ortalaması -71.88 dBm’dir. Aynı günde, aynı noktadan 1 saat fark olsa bile elde edilen sinyal güçleri ortalamaları arasında ciddi farklar bulunabilmektedir. Bu farkın nedeni hava şartları ve çevre koşullarıdır. Hata payını azaltmak ve daha doğru sonuçlar vermesi açısından tüm noktalardan aynı günde iki kez veri toplanmıştır. Farklı günlerde de aynı noktadan veri toplanması yaklaşımı tercih edilmiştir.




Şekil 4.3: Bir günde 24 saat boyunca en güçlü GSM hücresinden elde edilen sinyal gücünün saat olarak ortalaması.

Veri toplamak için AVM'nin 2 metre aralıklarla olan 40,100, 200 noktadan veri toplanmıştır. Şekil 4.4'de farklı iki kattaki RSS verisi toplanan 40 nokta görülmektedir. 2. Kat ve 3.kattaki 2 metre aralıklarla olan 0_0, 0_1, ..., 0_19 olmak üzere her bir katta 20 noktadan toplamda ise 40 noktadan RSS verileri toplanmıştır.

0_0	Boşluk				
0_1					
.					
.					
0_11					
0_12	1_12	.	.	.	8_12
0_13	1_13	.	.	.	8_13
0_14	1_14	2_14	.	.	8_14
0_15	1_15	.	.	.	8_15
.	Boşluk				8_16
.					.
0_19					.
.					8_29
0_30	1_30	.	.	.	8_30
0_31	1_31	2_31	.	.	8_31
0_32	1_32	.	.	.	8_32
0_33	1_33	.	.	.	8_33


Şekil 4.4: 40 noktada RSS verisi toplanan noktalar.

Şekil 4.5’de farklı iki kattaki RSS verisi toplanan 100 nokta görülmektedir. 2. Kat ve 3.kattaki 2 metre aralıklarla olan 0_0, 0_1, ..., 0_33 ve 8_15,8_16,..., 8_30 olmak üzere her bir katta 50 noktadan toplamda ise 100 noktadan RSS verileri toplanmıştır.

0_0	Boşluk				
0_1					
.					
.					
0_11					
		Yürüyen Merdiven			
0_12	1_12	.	.	.	8_12
0_13	1_13	.	.	.	8_13
0_14	1_14	2_14	.	.	8_14
0_15	1_15	.	.	.	8_15
0_16	Boşluk				8_16
.					.
.					.
0_29					8_29
0_30	1_30	.	.	.	8_30
0_31	1_31	2_31	.	.	8_31
0_32	1_32	.	.	.	8_32
0_33	1_33	.	.	.	8_33

Şekil 4.5: 100 noktada RSS verisi toplanan noktalar.

Şekil 4.6’da farklı üç kattan RSS verisi toplanan 200 nokta görülmektedir. 1.kat, 2.kat ve 3.kattaki 2 metre aralıklarla olan 0_0, 0_1, ..., 0_33, 8_14,8_15,..., 8_32 ve 1_14, 2_14,..., 8_14 ve 1_31, 2_31, ..., 8_31 olmak üzere her bir katta 67 noktadan toplamda ise 200 noktadan RSS verileri toplanmıştır.

0_0	 Boşluk				
0_1					
.					
.					
0_11					
0_12	1_12	.	.	.	8_12
0_13	1_13	.	.	.	8_13
0_14	1_14	2_14	.	.	8_14
0_15	1_15	.	.	.	8_15
0_16	Boşluk				8_16
.					.
.					.
0_29					8_29
0_30	1_30	.	.	.	8_30
0_31	1_31	2_31	.	.	8_31
0_32	1_32	.	.	.	8_32
0_33	1_33	.	.	.	8_33

Şekil 4.6: 200 noktada RSS verisi toplanan noktalar.

5. MAKİNE ÖĞRENMESİ YÖNTEMLERİ VE YAPAY SİNİR AĞLARI ALGORİTMALARI

Sınıflama, benzer özellikteki nesnelerin önceden etiketlenmiş gruplara atanması işlemidir. Veriyi gruplamak ve tahmin yapmak amacıyla sınıflandırma işlemi gerçekleştirilebilir. Konum belirleme problemi her bir noktadan toplanan sinyal güçlerini o sınıfa ait özellik olduğunu ve her bir noktanın ayrı bir sınıf olduğu düşünülürse, bu problem sınıflandırma problemi olarak ele alınıp, yapay sinir ağları ve makine öğrenmesi teknikleri çözülebilir. Yapılan tez çalışmasında WEKA kütüphanesinde bulunan farklı makine öğrenmesi ve yapay sinir ağları algoritmaları test edilmiştir.

5.1. Makine Öğrenmesi Algoritmaları

Makine öğrenmesi metodları geçmişteki verileri kullanarak veriye en uygun modeli bulmaya çalışan tekniklerdir. Yeni gelen verileri de bu modele göre analiz edip ve sonuç üretirler. Karar ağaçları, en yakın komşu algoritmaları, Destek Vektör Makineleri, BayesNet ve Navie Bayes gibi olasılıksal algoritmalar, yapay sinir ağları ve regresyon algoritmaları yaygın olarak kullanılan algoritmalarlardır. Yapılan tez çalışması kapsamında yaygın olarak kullanılan bu algoritmalar test edilmiştir.

5.1.1. BayesNet

Bayes teoremi stokastik (rassal) bir sürece bağlı olarak ortaya çıkan rastgele bir A olayı ile diğer rastgele B olayı için marjinal olasılıklar ve koşullu olasılıklar arasındaki ilişkiyi tanımlayan bir teoremdir. Bu ilişkiyi ilk kez Thomas Bayes ortaya atmış ve 5.1 eşitliğini önermiştir.

$$P(A|B) = P(B|A).P(A)/P(B) \quad (5.1)$$

Bayes ağı sıklıkla çok terimli verinin ayrık ve sürekli değişkenlerle modellenmesi için kullanılır. Bayes algoritması, çözümün olasılık dağılımı kestirimi önermesini kullanır. Çok değişkenli veriyi modellemek için kullanılan dağılım

teknikleri kestirimine yeni aday oluşturmak amacıyla Bayes ağırları kullanılır. Bayes ağırları modellenmiş verideki değişkenler arasındaki ilişkiyi şifreler [35].

- Avantajları:


- Ortak dağılımının kestirimi amacıyla veri modellemeyi kullanır.
- Problem hakkında herhangi bir ön bilgi gerektirmez.

- Dezavantajları:

- Bayes ağı karmaşık olasılık dağılımı gösterebilir.
- Yakınsama hakkında bilgi vermek zordur. Bazı durumlarda oluşmaz ve bazen yanlış çıktı verebilir.

5.1.2. SVM

SVM (Destek Vektör Makinesi) sınıfların birbirlerine en yakın örneklerini bularak bu sınıflarının örneklerini ayırıcı dik uzaklıklarını maksimize etmeyi amaçlar. Lineer olarak ayrılabilen verileri sınıflandırmak için Fisher Diskriminantı algoritması kullanılabilir. Bu algoritma SVM algoritmalarının en basit halidir. Şekil 5.1’de lineer olarak ayrılabilen bir veri seti görülmektedir. SVM algoritmaların sahip oldukları en önemli özellik çekirdek fonksiyonu içermeleridir. Bu fonksiyonun görevi doğrusal olarak ayrılamayan veriyi, daha yüksek boyuta taşıyarak bir düzlem ile ayrılmasını sağlamaktadır. Şekil 5.2’de x_i ve x_j gibi özelliklerine bağlı lineer, RBF ve polinom çekirdek fonksiyonlarının ifadeleri görülmektedir [36].



Şekil 5.1: Lineer olarak Fisher Diskriminantı algoritmasıyla ayrılabilen veri.

Lineer Kernel:	$K(x_i, x_j) = x_i \cdot x_j$
Polinom Kernel:	$K(x_i, x_j) = (1 + x_i \cdot x_j)^p$
RBK Kernel:	$K(x_i, x_j) = \exp(-0.5 * (\ x_i - x_j\ ^2))$

Şekil 5.2: SVM algoritmasındaki farklı çekirdek fonksiyonları.

- Avantajları:

- Genelde birçok farklı problem üzerinde doğruluğu yüksek çıktı verir.
- Karmaşık karar sınırlarını modelleyebilir.
- Çok sayıda bağımsız değişkenle çalışabilir.
- Hem lineer olarak ayrılan hem doğrusal olarak ayrılamayan verilere uygulanabilir.
- Algoritmanın ezberlemesi problemi birçok farklı makine öğrenmesi algoritmalarından daha azdır.

- Dezavantajları:

- Olasılıksal tahminler üretemezler.

5.1.3. KNN

Uzaklığa dayalı sınıflandırma tekniklerinden en popüler olanı KNN (En Yakın Komşu) algoritmasıdır. Gelen örneğin hangi sınıfa ait olduğunu tespit etmek için aşağıdaki adımlar sırasıyla uygulanır.

- Öncelikle k değeri belirlenir.
- Gelen örnek tüm örnekler arasındaki mesafe hesaplanır. Bu mesafe metriği olarak genelde öklit uzaklığı şeklindedir.
- Hesaplanan tüm uzaklıklar küçükten büyüğe doğru sıralanır.
- K değerine göre en çoğunluğu sağlayan sınıf hedef sınıf olarak kabul edilir.

- Avantajları:

- Eğitim verisini n fazla olduğu durumlarda yüksek başarı sağlanabilir.
- Gürültüye dayanıklıdır.

- Dezavantajları:

- k değerini belirlemek gerekir.
- Tüm eğitim örnekleri için uzaklık hesaplandığı için hesaplama maliyeti çok yüksektir. Kd-ağaçları gibi indeksleme özelliğine sahip algoritmalarla bu hesaplama maliyeti düşürülebilir [37].

5.1.4. Karar Ağaçları

Karar ağaçları, verileri ağaç yapısı formunda olan sınıflandırma tekniğidir. Karar ağaçları algoritmaları giriş verisinin bir kümeleme algoritması yardımıyla ardışıl olarak gruplara bölünmesine dayanır. Grubun tüm elemanları aynı sınıf etiketine sahip olana kadar kümeleme işlemi derinlemesine devam eder. Karar verme ağaçları iki farklı yaklaşımla geliştirilebilir. Bu iki yaklaşım entropiye dayalı ID3 ve regresyona dayalı C4.5 şeklindedir.

ID3, sadece kategorik veri ile çalışan bir yöntemdir. Her iterasyonun ilk adımında veri örneklerine ait sınıf bilgilerini taşıyan vektörün entropisi belirlenir. Daha sonra özellik vektörlerinin sınıfa bağımlı entropileri hesaplanarak ilk adımda hesaplanan entropiden çıkartılır. Bu şekilde elde edilen değer ilgili özellik vektörüne ait kazanç değeridir. En büyük kazançta sahip özellik vektörü ağacın o iterasyonda belirlenen dallanmasını gerçekleştirir [38].

C 4.5, ID3 algoritmasının nümerik özellik içeren veriye uygulanabilen şeklidir. ID3'ten tek farkı nümerik özelliklerin kategorik hale getirilebilmesini sağlayan bir eşikleme yönteminin de var olmasıdır. Nümerik özellik vektöründeki tüm değerler ikili olarak ele alınarak ortalamaları eşik olarak denir. Hangi eşik değerinde bilgi kazanımı en iyi ise o değer seçilir. Seçilen eşığe göre özellik vektörü kategorize edilir [38].

- Avantajları:

- Küçük ağaçları yorumlamak kolaydır.
- Anlaşılabilir kurallar oluşturulabilir.
- Devamlı ve ayırık nitelik değerleri için kullanılabilir.

- Dezavantajları:

- Sürekli nitelik değerlerini tahmin etmekte çok başarılı değildir.
- Sınıf sayısı fazla ve öğrenme kümesi örnekleri sayısı az olduğunda model oluşturma çok başarılı değildir.

Yapılan tez çalışmasında karar ağacı türü olan J48 algoritmaları ve Rastgele Karar Ormanı algoritmaları uygulanmıştır.

J48, budanmış veya budanmamış C4.5 karar ağacı üretmek için tanımlanan algoritmadır. Böl ve fethet algoritması her yaprak tek sınıf durumu içerene kadar veya iki durumun farklı sınıflara ait olmalarına rağmen her bir öznelik için aynı değerlere sahip olduğu daha fazla bölünmenin imkânsız olduğu duruma kadar veriyi parçalara ayırır [35].

Rastgele Karar Ormanı, ağaç kestirimcilerin kombinasyonu olarak rastgele ormanlar tanımlar. Her bir ağaç bağımsız örneklenen ve ormandaki tüm ağaçlar için aynı dağılımlı rasgele vektörün değerlerine dayanır. Ormanlar için genelleme hatası ormandaki ağaç sayısı arttıkça limite yakınsar [35].


5.2. Yapay Sinir Ağları Algoritmaları

Yapay sinir ağları basit biyolojik sinir sisteminin çalışma şekli simüle edilerek tasarlanan programlama yaklaşımıdır. Simüle edilen sinir hücreleri içerirler ve bu nöronlar çeşitli şekillerde birbirlerine bağlanarak ağı oluştururlar. Bu ağlar öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma, öğrenme, hafızaya alma gibi yeteneklere sahiptirler. YSA kullanılarak makinelere öğrenme, genelleme yapma, sınıflandırma, tahmin yapma ve algılama gibi yetenekler kazandırılmıştır. Herhangi bir yapay sinir ağı girdiler, ağırlıklar, toplama fonksiyonu ve aktivasyon

fonksiyonu olmak üzere 4 temel parçadan oluşur. Şekil 5.3'te bir yapay sinir ağının modelinin görüntüsü yer almaktadır [39].

Girdiler, bir yapay sinir hücresine gelen bilgilerdir. Bu bilgiler diğer sinir hücrelerinden veya dış ortamlardan gelebilir. Dış ortamlardan gelen bilgiler, ağın öğrenmesi aşamasında eğitim verisi örnekler tarafından gelmektedir.

Ağırlıklar, gelen bilgilerin hücre üzerindeki etkisini belirleyen değerlerdir. Bilgiler, bağlantılar üzerindeki ağırlıklar üzerinden hücreye girmekte ve ağırlıklar yapay sinirde girdi olarak kullanılacak değerlerin matematiksel katsayısını göstermektedirler.



Şekil 5.3: Bir yapay sinir ağı modelinin görüntüsü.

Toplama fonksiyonu, hücreye gelen net girdiyi hesaplayan fonksiyondur. Genellikle eşik değerlerin toplamı veya girişlerin kendi ağırlıklarıyla çarpımının toplamı eşik değer toplamı şeklinde olabilir.

Aktivasyon fonksiyonu, yapay sinir hücresinin çıkışını belirler. Bu çıkış toplama fonksiyonundan gelen girdiyi işlenerek hesaplanır. Transfer fonksiyonu olarak da adlandırılabilir. Doğrusal olan ve doğrusal olmayan birçok farklı aktivasyon fonksiyonları vardır. Genellikle doğrusal olmayan fonksiyonları ağlarda tercih edilmektedir.

5.2.1. Çok Katmanlı Perceptron

Perceptron birçok değeri girdi olarak alıp tek bir çıktı üretir. Çıktıyı oluştururken girdi ağırlıklarına uygun olarak bir lineer kombinasyon oluşturulur ve bazı lineer

olmayan etkinleştirme fonksiyonu yoluyla çıktılarına yerleştirilir. Tüm ağırlık değerleri, eğim azaltma denilen bir yöntemin hata fonksiyonunu minimize etmesiyle bulunur. Hesaplanan hata, nöronun çıkışından girişine doğru giderken aktivasyon fonksiyonunun türevine maruz kalır. Fonksiyonun türevine uygulanan hata değeri tüm ağırlıklara, giriş değerleri oranında dağıtılır.

Çok-katmanlı perceptron (Multi-Layer Perceptron – MLP), genellikle statik geri yayılma ile eğitilen ileri-beslemeli bir ağıdır. Bu tür ağlar, statik örüntü sınıflandırması gerektiren birçok sayıda uygulamada kendilerine yer edinmişlerdir.

- Avantajları:

- Kullanımlarının kolaydır.
- Herhangi bir girdi/çıkı haritasını tahmin edebilmeleridir.

- Dezavantajları:

- Eğitimlerinin yavaştır.
- Büyük miktarda eğitim verisine gereksinimlerinin olmasıdır.

5.2.2. RBF Ağı

Sınıflandırma için olası en iyi durum, iki ayrı sınıfa ait veri noktalarının doğrusal olarak ayrılabilmesi durumudur. Fakat gerçek veri kümelerinde bu her zaman mümkün olmayabilir. Önerilen makine öğrenmesi yöntemlerinin birçoğu doğrusal sınıflandırmadan yola çıkarak geliştirildikleri için, doğrusal olmayan veri kümeleri için çözüm bulamazlar. Örnekleri kendi boyutlarında çözmek yerine veri, sınıfların doğrusal olarak ayrılabilceği yeni bir üst boyuta taşınarak çözülebilir. Bu işleme haritalama adı verilir. Genellikle bir çekirdek fonksiyonu doğrusal olarak ayrılamayan x özellik değerlerini doğrusal olarak ayrılabilir şekle getirir.


Çapsal tabanlı fonksiyon (RBF) ağları eğitimci öğrenme yapan ileri beslemeli ağlardır. Genel olarak her biri RBF fonksiyonu içeren nöronlardan oluşan tek gizli katman kullanılır. Eğitimleri geri yayılıma benzer olsa da MLP ağlarından daha hızlı

eğitilirler. Çapsal tabanlı fonksiyonlar sayesinde durağan olmayan girişlere sahip problemlerden daha az etkilenir [40].

Bir RBF ağında bilinmeyen ve eğitim ile öğrenilmesi gereken dört önemli parametre vardır.

- Gizli katmandaki nöron sayısı
- Her nöronun prototip koordinatı
- Her nöronun prototip çapı
- Çıkış ağırlıkları

RBF ağ yapısı incelendiğinde MLP ağ modeliyle bazı benzerlikler fark edilir. Özellikle çıkış katmanındaki doğrusal yapıdaki benzerlik sayesinde RBF ağının eğitiminde geri yayılım algoritmasından yararlanılabilir. Şekil 5.5'te görüldüğü gibi MLP ağı lineer olarak sınıfları ayırırken RBF ağlarının iki boyutta verileri ayırdığı görülmektedir.



Şekil 5.4: a) MLP algoritmasının sınıfları ayırma yaklaşımı, b) RBF Network algoritmasının sınıfları ayırma yaklaşımı.

6. DENEYSEL SONUÇLAR

6.1. 10 Noktada Yapılan Test Sonuçları

Tablo 6.1’de 10 farklı noktada GSM sinyalleriyle farklı makine öğrenmesi algoritmaları uygulanarak elde edilen sonuçlar görülmektedir. Eğitim verisi toplanma süresi her bir noktadan 3 dakikadır. Referans nokta sayısı 7’dir. Test verileri farklı bir günde her bir noktadan 30 saniye boyunca toplanan RSS verilerinden seçilmiştir.

Tablo 6.1: 10 noktada GSM sinyalleri ile algoritmalarının etkisini gözlemlemek için yapılan test sonuçları tablosu.

Algoritma	0(m)	2(m)	4(m)	6(m)	8(m)	16(m)	Ortalama Hata(m)
BayesNet	0.49	0.76	0.81	0.86	0.90	0.95	2.8
SVM	0.55	0.76	0.82	0.88	0.91	0.97	2.5
RKO	0.41	0.62	0.69	0.75	0.79	0.93	4.2
KNN	0.47	0.75	0.82	0.87	0.90	0.96	2.8
J48	0.39	0.65	0.79	0.85	0.86	0.96	3.2

En doğru sonucu veren üç algoritmanın konum hassasiyeti doğruluk oranları sırasıyla SVM, BayesNet, KNN şeklindedir. SVM algoritması uygulandığında, 0.55 olasılıkla tam eşleşme, 0.76 olasılıkla 2 metre ve altı konum hassasiyeti, 0.82 olasılıkla 4 metre ve altı konum hassasiyeti ve 2.5 metre ortalama hata elde edilmiştir. BayesNet algoritması uygulandığında, 0.49 olasılıkla tam eşleşme, 0.76 olasılıkla 2 metre ve altı konum hassasiyeti, 0.81 olasılıkla 4 metre ve altı konum hassasiyeti ve 2.8 metre ortalama hata elde edilmiştir. KNN algoritması uygulandığında, 0.47 olasılıkla tam eşleşme, 0.75 olasılıkla 2 metre ve altı konum hassasiyeti, 0.82 olasılıkla 4 metre ve altı konum hassasiyeti ve 2.8 metre ortalama hata elde edilmiştir.

Tablo 6.2’de 10 farklı noktada Wi-Fi sinyalleriyle farklı makine öğrenmesi algoritmaları uygulanarak elde edilen sonuçlar görülmektedir. Eğitim verisi toplanma süresi her bir noktadan 3 dakikadır. Referans nokta sayısı 7’dir. Test verileri farklı bir günde her bir noktadan 30 saniye boyunca toplanan RSS verilerinden seçilmiştir.

Tablo 6.2: 10 noktada Wi-Fi sinyalleri ile algoritmalarının etkisini gözlemlemek için yapılan test sonuçları tablosu.

Algoritma	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
BayesNet	0.70	0.84	0.85	0.89	0.97	2.1
SVM	0.65	0.82	0.83	0.88	0.97	2.3
RKO	0.62	0.76	0.80	0.88	0.97	2.5
KNN	0.65	0.81	0.83	0.87	0.97	2.4
J48	0.61	0.77	0.79	0.88	0.97	2.6

En doğru sonucu veren üç algoritmanın konum hassasiyeti doğruluk oranları sırasıyla BayesNet, SVM, KNN şeklindedir. BayesNet algoritması uygulandığında, 0.70 olasılıkla tam eşleşme, 0.84 olasılıkla 2 metre ve altı konum hassasiyeti, 0.85 olasılıkla 4 metre ve altı konum hassasiyeti ve 2.1 metre ortalama hata elde edilmiştir. SVM algoritması uygulandığında, 0.65 olasılıkla tam eşleşme, 0.82 olasılıkla 2 metre ve altı konum hassasiyeti, 0.83 olasılıkla 4 metre ve altı konum hassasiyeti ve 2.3 metre ortalama hata elde edilmiştir. KNN algoritması uygulandığında, 0.65 olasılıkla tam eşleşme, 0.81 olasılıkla 2 metre ve altı konum hassasiyeti, 0.83 olasılıkla 4 metre ve altı konum hassasiyeti ve 2.4 metre ortalama hata elde edilmiştir.

6.2. 40 Noktada Yapılan Test Sonuçları

Tablo 6.3’de 40 farklı noktada GSM sinyalleriyle farklı makine öğrenmesi algoritmaları kullanılarak elde edilen sonuçlar görülmektedir. Eğitim verisi toplanma süresi her bir noktadan 3 dakikadır. Referans nokta sayısı 17’dir. Test verileri farklı bir günde her bir noktadan 30 saniye boyunca toplanan RSS verilerinden seçilmiştir.

Tablo 6.3: 40 noktada GSM sinyalleri ile algoritmalarının etkisini gözlemlemek için yapılan test sonuçları tablosu.

Algoritma	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
BayesNet	0.20	0.46	0.59	0.82	0.91	5.7
SVM	0.20	0.47	0.60	0.79	0.90	5.9
RKO	0.16	0.37	0.49	0.67	0.83	7.9
KNN	0.14	0.36	0.51	0.70	0.83	7.3
J48	0.16	0.36	0.48	0.69	0.81	7.9

En doğru sonucu veren üç algoritmanın konum hassasiyeti doğruluk oranları sırasıyla BayesNet, SVM, KNN şeklindedir. BayesNet algoritması uygulandığında, 0.20 olasılıkla tam eşleşme, 0.46 olasılıkla 2 metre ve altı konum hassasiyeti, 0.59 olasılıkla 4 metre ve altı konum hassasiyeti ve 5.7 metre ortalama hata elde edilmiştir. SVM algoritması uygulandığında, 0.20 olasılıkla tam eşleşme, 0.47 olasılıkla 2 metre ve altı konum hassasiyeti, 0.60 olasılıkla 4 metre ve altı konum hassasiyeti ve 5.9 metre ortalama hata elde edilmiştir. KNN algoritması uygulandığında, 0.14 olasılıkla tam eşleşme, 0.36 olasılıkla 2 metre ve altı konum hassasiyeti, 0.51 olasılıkla 4 metre ve altı konum hassasiyeti ve 7.3 metre ortalama hata elde edilmiştir.

Tablo 6.4’de 40 farklı noktada Wi-Fi sinyalleriyle eğitim verisinin toplanma süresinin etkisini gözlemlemek amacıyla farklı makine öğrenmesi algoritmaları uygulanarak elde edilen sonuçlar görülmektedir. Eğitim verisi toplanma süresi her ir noktadan 1, 2 ve 3 dakika olarak değişmektedir. Referans nokta sayısı 10’dur. Test verileri farklı bir günde her bir noktadan 30 saniye boyunca toplanan RSS verilerinden seçilmiştir.

En iyi sonucu BayesNet algoritması vermiştir. 1 dakikalık eğitim verilerinde BayesNet algoritması uygulandığında, 0.26 olasılıkla tam eşleşme, 0.53 olasılıkla 2 metre ve altı konum hassasiyeti, 0.68 olasılıkla 4 metre ve altı konum hassasiyeti ve 5.6 metre ortalama hata elde edilmiştir. 2 dakikalık eğitim verilerinde BayesNet algoritması uygulandığında, 0.31 olasılıkla tam eşleşme, 0.63 olasılıkla 2 metre ve altı konum hassasiyeti, 0.80 olasılıkla 4 metre ve altı konum hassasiyeti ve 3.5 metre ortalama hata elde edilmiştir. 3 dakikalık eğitim verilerinde BayesNet algoritması uygulandığında, 0.35 olasılıkla tam eşleşme, 0.66 olasılıkla 2 metre ve altı konum

hassasiyeti, 0.83 olasılıkla 4 metre ve altı konum hassasiyeti ve 3.3 metre ortalama hata elde edilmiştir.

Tablo 6.4: 40 noktada Wi-Fi sinyalleri ile eğitim verisinin etkisini gözlemlemek için yapılan test sonuçları tablosu.

Algoritma	Eğitim Verisi Süresi	0(m)	2(m)	4 (m)	8 (m)	16(m)	Ortalama Hata(m)
Bayes Net	1 dakika	0.26	0.53	0.68	0.80	0.90	5.6
	2 dakika	0.31	0.63	0.80	0.92	0.96	3.5
	3 dakika	0.35	0.66	0.83	0.91	0.96	3.3
SVM	1 dakika	0.26	0.56	0.72	0.90	0.96	4.1
	2 dakika	0.25	0.53	0.71	0.87	0.94	4.7
	3 dakika	0.30	0.63	0.84	0.93	0.97	3.3
RKO	1 dakika	0.21	0.54	0.68	0.83	0.93	5.2
	2 dakika	0.28	0.61	0.75	0.88	0.94	4.4
	3 dakika	0.29	0.59	0.74	0.87	0.93	4.7
J48	1 dakika	0.22	0.55	0.68	0.79	0.90	5.7
	2 dakika	0.21	0.51	0.66	0.82	0.90	5.8
	3 dakika	0.25	0.56	0/70	0.82	0.91	5.5
KNN	1 dakika	0.22	0.49	0.63	0.82	0.92	5.7
	2 dakika	0.19	0.45	0.61	0.79	0.91	6.2
	3 dakika	0.28	0.53	0.66	0.80	0.90	5.9

Tablo 6.5’de 40 farklı noktada Wi-Fi sinyalleriyle referans nokta sayısının etkisini gözlemlemek amacıyla farklı makine öğrenmesi algoritmaları uygulanarak elde edilen sonuçlar görülmektedir. Eğitim verisi toplanma süresi her bir noktadan 2 dakikadır. Referans nokta sayısı 8, 10 ve 12 olmak üzere değişmektedir. Test verileri farklı bir günde her bir noktadan 30 saniye boyunca toplanan RSS verilerinden seçilmiştir.

Tablo 6.5: 40 noktada Wi-Fi sinyalleri ile referans nokta sayısının etkisini gözlemlemek için yapılan test sonuçları tablosu.

Algoritma	Referans Nokta Sayısı	0(m)	2(m)	4 (m)	8 (m)	16(m)	Ortalama Hata(m)
Bayes Net	8	0.27	0.58	0.76	0.89	0.95	4.2
	10	0.31	0.63	0.80	0.92	0.96	3.5
	12	0.32	0.65	0.81	0.93	0.97	3.1
SVM	8	0.26	0.53	0.71	0.87	0.93	4.7
	10	0.27	0.58	0.78	0.93	0.97	3.7
	12	0.29	0.62	0.81	0.94	0.98	3.4
RKO	8	0.26	0.56	0.72	0.85	0.93	4.8
	10	0.28	0.61	0.75	0.88	0.94	4.4
	12	0.25	0.58	0.72	0.86	0.92	4.9
J48	8	0.20	0.49	0.64	0.81	0.90	6.0
	10	0.21	0.51	0.66	0.82	0.90	5.8
	12	0.22	0.52	0.65	0.82	0.89	5.9
KNN	8	0.19	0.41	0.61	0.77	0.88	6.6
	10	0.19	0.45	0.62	0.80	0.91	6.2
	12	0.21	0.45	0.66	0.82	0.94	5.4

En iyi sonucu BayesNet algoritması vermiştir. 8 referans noktasında BayesNet algoritması uygulandığında, 0.27 olasılıkla tam eşleşme, 0.58 olasılıkla 2 metre ve altı konum hassasiyeti, 0.76 olasılıkla 4 metre ve altı konum hassasiyeti ve 4.2 metre ortalama hata elde edilmiştir. 10 referans noktasında BayesNet algoritması uygulandığında, 0.31 olasılıkla tam eşleşme, 0.63 olasılıkla 2 metre ve altı konum hassasiyeti, 0.80 olasılıkla 4 metre ve altı konum hassasiyeti ve 3.5 metre ortalama hata elde edilmiştir. 12 referans noktasında BayesNet algoritması uygulandığında, 0.32 olasılıkla tam eşleşme, 0.65 olasılıkla 2 metre ve altı konum hassasiyeti, 0.81 olasılıkla 4 metre ve altı konum hassasiyeti ve 3.1 metre ortalama hata elde edilmiştir.

6.3. 100 Noktada Yapılan Test Sonuçları

6.3.1. Makine Öğrenmesi Algoritmalarının Etkisi

Tablo 6.6’da 100 farklı noktada GSM sinyalleriyle farklı makine öğrenmesi algoritmaları uygulanarak elde edilen sonuçlar görülmektedir. Eğitim verisi toplanma süresi her bir noktadan 3.5 dakikadır. Referans nokta sayısı 17’dir. Test verileri farklı bir günde her bir noktadan 30 saniye boyunca toplanan RSS verilerinden seçilmiştir.

Tablo 6.6: 100 noktada GSM sinyalleri yapılan makine öğrenmesi algoritmalarının etkisini gözlemlemek için yapılan test sonuçları tablosu.

Algoritma	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
BayesNet	0.24	0.42	0.51	0.62	0.71	9.7
SVM	0.21	0.36	0.46	0.56	0.69	10.7
RKO	0.15	0.28	0.36	0.48	0.60	13.8
KNN	0.13	0.26	0.34	0.45	0.58	13.9
J48	0.12	0.27	0.34	0.46	0.62	13.4

En doğru sonucu veren üç algoritmanın konum hassasiyeti doğruluk oranları sırasıyla BayesNet, SVM, J48 şeklindedir. BayesNet algoritması uygulandığında 0.24 olasılıkla tam eşleşme, 0.42 olasılıkla 2 metre ve altı konum hassasiyeti, 0.51 olasılıkla 4 metre ve altı konum hassasiyeti ve 9.7 metre ortalama hata elde edilmiştir. SVM algoritması uygulandığında 0.21 olasılıkla tam eşleşme, 0.36 olasılıkla 2 metre ve altı konum hassasiyeti, 0.46 olasılıkla 4 metre ve altı konum hassasiyeti ve 10.7 metre ortalama hata elde edilmiştir. J48 algoritması uygulandığında 0.12 olasılıkla tam eşleşme, 0.27 olasılıkla 2 metre ve altı konum hassasiyeti, 0.34 olasılıkla 4 metre ve altı konum hassasiyeti ve 13.4 metre ortalama hata elde edilmiştir.

Tablo 6.7’de 100 farklı noktada Wi-Fi sinyalleriyle farklı makine öğrenmesi algoritmaları uygulanarak elde edilen sonuçlar görülmektedir. Eğitim verisi toplanma


süresi her bir noktadan 3.5 dakikadır. Referans nokta sayısı 17’dir. Test verileri farklı bir günde her bir noktadan 30 saniye boyunca toplanan RSS verilerinden seçilmiştir.

Tablo 6.7: 100 noktada Wi-Fi sinyalleri ile makine öğrenmesi algoritmalarının etkisini gözlemlemek için yapılan test sonuçları tablosu.

Algoritma	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
BayesNet	0.31	0.60	0.77	0.91	0.95	3.6
SVM	0.32	0.61	0.77	0.90	0.93	3.8
RKO	0.21	0.44	0.60	0.74	0.82	7.1
KNN	0.18	0.39	0.54	0.69	0.81	7.6
J48	0.16	0.37	0.50	0.64	0.74	9.1

Şekil 6.1’de bu beş algoritmanın CDF konum kestirim başarımları hata sonuçları görülmektedir. En doğru sonucu veren üç algoritmanın konum hassasiyeti doğruluk oranları sırasıyla BayesNet, SVM, RKO şeklindedir. BayesNet algoritması uygulandığında, 0.31 olasılıkla tam eşleşme, 0.60 olasılıkla 2 metre ve altı konum hassasiyeti, 0.77 olasılıkla 4 metre ve altı konum hassasiyeti ve 3.6 metre ortalama hata elde edilmiştir. SVM algoritması uygulandığında, 0.32 olasılıkla tam eşleşme, 0.61 olasılıkla 2 metre ve altı konum hassasiyeti, 0.77 olasılıkla 4 metre ve altı konum hassasiyeti ve 3.8 metre ortalama hata elde edilmiştir. RKO algoritması uygulandığında, 0.21 olasılıkla tam eşleşme, 0.44 olasılıkla 2 metre ve altı konum hassasiyeti, 0.60 olasılıkla 4 metre ve altı konum hassasiyeti ve 7.1 metre ortalama hata elde edilmiştir.

Genel olarak BayesNet algoritması konum kestirmede en iyi sonucu vermiştir. SVM algoritması da BayesNet algoritmasına yakın sonuçlar vermiştir. BayesNet ve SVM algoritmalarından elde edilen konum kestirme hata başarımları sonuçları ile diğer üç algoritmanın konum kestirme sonuçları arasında ciddi farklar bulunmaktadır.



Şekil 6.1: 100 noktada Wi-Fi sinyalleriyle farklı algoritmalar denenerek yapılan sonuçların CDF'leri.

6.3.2. Eğitim Verisi Toplanma Süresinin Etkisi


Tablo 6.8'de 100 farklı noktada Wi-Fi sinyalleriyle eğitim verisinin toplanma süresinin etkisini gözlemek amacıyla BayesNet algoritması uygulanarak elde edilen sonuçlar görülmektedir. Eğitim verisi toplanma süresi 1, 2.5 ve 3.5 dakika olarak değişmektedir. Referans nokta sayısı 17'dir. Test verileri farklı bir günde her bir noktadan 30 saniye boyunca toplanan RSS verilerinden seçilmiştir.

Tablo 6.8: 100 noktada Wi-Fi sinyalleri ile eğitim verisinin etkisini gözlemek için yapılan test sonuçları tablosu.

Algoritma	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
3.5	0.31	0.61	0.77	0.91	0.95	3.6
2.5	0.27	0.56	0.72	0.86	0.93	4.3
1.0	0.22	0.45	0.61	0.79	0.87	6.0

1 dakikalık eğitim verilerinde BayesNet algoritması uygulandığında, 0.22 olasılıkla tam eşleşme, 0.45 olasılıkla 2 metre ve altı konum hassasiyeti, 0.61 olasılıkla 4 metre ve altı konum hassasiyeti ve 6.0 metre ortalama hata elde edilmiştir. 2.5 dakikalık eğitim verilerinde BayesNet algoritması uygulandığında, 0.27 olasılıkla tam eşleşme, 0.56 olasılıkla 2 metre ve altı konum hassasiyeti, 0.72

olasılıkla 4 metre ve altı konum hassasiyeti ve 4.3 metre ortalama hata elde edilmiştir. 3.5 dakikalık eğitim verilerinde BayesNet algoritması uygulandığı altı konum hassasiyeti, 0.77 olasılıkla 4 metre ve altı konum hassasiyeti ve 3.6 metre ortalama hata elde edilmiştir. Bir noktadan 3.5 dakika boyunca toplanan eğitim verilerinde konum kestirmede en doğru sonuçları verdiği gözlenmiştir. Makine öğrenmesi algoritmalarının daha doğru sonuçları vermesi açısından yeterince eğitilmeleri gerekmektedir. Bir noktadan 1 dakika ve 2.5 dakika boyunca toplanan eğitim verilerinin algoritmalarını yeterince eğitlemediklerinden dolayı 3.5 dakika boyunca toplanan eğitim verileri konum kestirmede en doğru sonucu vermiştir.




Şekil 6.2:100 noktada Wi-Fi sinyalleriyle farklı eğitim verileri denenerek yapılan sonuçların CDF'leri.

6.3.3. Referans Nokta Sayısının Etkisi

Tablo 6.9'da 100 farklı noktada Wi-Fi sinyalleriyle referans nokta sayısının etkisini gözlemlemek amacıyla farklı makine öğrenmesi algoritmaları uygulanarak elde edilen sonuçlar görülmektedir. Eğitim verisi toplanma süresi 3.5 dakikadır. Referans nokta sayısı 10, 12, 14, 17 olmak üzere değişmektedir. Test verileri farklı bir günde her bir noktadan 30 saniye boyunca toplanan RSS verilerinden seçilmiştir.

Tablo 6.9: 100 noktada Wi-Fi sinyalleri ile referans nokta sayısının etkisini gözlemlemek için yapılan test sonuçları tablosu.

Algoritma	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
17	0.31	0.61	0.77	0.91	0.95	3.6
14	0.28	0.57	0.73	0.88	0.93	4.1
12	0.27	0.54	0.70	0.83	0.89	4.9
10	0.25	0.52	0.66	0.79	0.87	5.5



Şekil 6.3: 100 noktada Wi-Fi sinyalleriyle farklı referans nokta sayıları denenerek yapılan sonuçların CDF'leri.

En iyi sonucu BayesNet algoritması vermiştir. 10 referans noktasında BayesNet algoritması uygulandığında, 0.25 olasılıkla tam eşleşme, 0.52 olasılıkla 2 metre ve altı konum hassasiyeti, 0.66 olasılıkla 4 metre ve altı konum hassasiyeti ve 5.5 metre ortalama hata elde edilmiştir. 12 referans noktasında BayesNet algoritması uygulandığında, 0.27 olasılıkla tam eşleşme, 0.54 olasılıkla 2 metre ve altı konum hassasiyeti, 0.70 olasılıkla 4 metre ve altı konum hassasiyeti ve 4.9 metre ortalama hata elde edilmiştir. 14 referans noktasında BayesNet algoritması uygulandığında, 0.28 olasılıkla tam eşleşme, 0.57 olasılıkla 2 metre ve altı konum hassasiyeti, 0.73 olasılıkla 4 metre ve altı konum hassasiyeti ve 4.1 metre ortalama hata elde edilmiştir. 17 referans noktasında BayesNet algoritması uygulandığında, 0.31 olasılıkla tam eşleşme, 0.61 olasılıkla 2 metre ve altı konum hassasiyeti, 0.77

olasılıkla 4 metre ve altı konum hassasiyeti ve 3.6 metre ortalama hata elde edilmiştir.


6.3.4. Referans Sinyal Türünün Etkisi

Tablo 6.10'da 100 farklı noktada GSM, Wi-Fi, GSM-Wi-Fi farklı sinyal türleriyle referans sinyal türünün etkisini gözlemlemek için BayesNet algoritması uygulanarak elde edilen sonuçlar görülmektedir. Eğitim verisi toplanma süresi 3.5 dakikadır. Referans nokta sayısı 17'dir. Test verileri farklı bir günde her bir noktadan 30 saniye boyunca toplanan RSS verilerinden seçilmiştir.

Tablo 6.10: 100 noktada referans sinyal türünün etkisini gözlemlemek için yapılan test sonuçları tablosu.

Algoritma	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
Wi-Fi GSM	0.37	0.66	0.81	0.92	0.95	3.2
Wi-Fi	0.31	0.61	0.77	0.91	0.95	3.6
GSM	0.24	0.42	0.51	0.62	0.72	9.7

En iyi sonucu GSM ve Wi-Fi referans sinyal türlerinin birleştirilmesi sonucundan elde edilmiştir. 15 Wi-Fi ve 2 GSM referans noktalarından elde edilen veriler birleştirilerek ve BayesNet algoritması uygulandığında, 0.37 olasılıkla tam eşleşme, 0.66 olasılıkla 2 metre ve altı konum hassasiyeti, 0.81 olasılıkla 4 metre ve altı konum hassasiyeti ve 3.2 metre ortalama hata elde edilmiştir. Yalnızca Wi-Fi sinyalleriyle BayesNet algoritması uygulandığında, 0.31 olasılıkla tam eşleşme, 0.61 olasılıkla 2 metre ve altı konum hassasiyeti, 0.77 olasılıkla 4 metre ve altı konum hassasiyeti ve 3.6 metre ortalama hata elde edilmiştir. Yalnızca GSM sinyalleriyle BayesNet algoritması uygulandığında, 0.24 olasılıkla tam eşleşme, 0.42 olasılıkla 2 metre ve altı konum hassasiyeti, 0.51 olasılıkla 4 metre ve altı konum hassasiyeti ve 9.7 metre ortalama hata elde edilmiştir.



Şekil 6.4: 100 noktada farklı referans sinyal türleri denenerek yapılan sonuçların CDF'leri.

Wi-Fi RSS verilerini kullanmanın GSM 7 komşu hücre yaklaşımındaki RSS verilerini kullanmaya göre konum kestirmede çok daha başarılı olduğu gözlenmiştir. GSM 7 komşu hücre yaklaşımında, anlık olarak en fazla 7 GSM referans noktasından RSS verisi toplanabilirken, Wi-Fi yaklaşımında ise anlık olarak RSS verisini toplanabilecek 7 referans noktası gibi bir sınırlama mevcut değildir. Bu sebepten dolayı, Wi-Fi referans noktalarını kullanmak konum kestirmede daha başarılı olmuştur. Yalnızca Wi-Fi RSS değerlerini referans olarak kullanmak yerine zayıf Wi-Fi referans noktalarına yerine güçlü GSM referans noktalarını kullanmanın başarıyı artırdığı saptanmıştır.

6.3.5. Test Verisi Gününün Etkisi Ve Algoritmalarının Konum Kestirme Performanslarının Belirlenmesi

11, 12, 13, 14 Ocak'ta 100 noktadan her bir noktadan toplam 4 dakika boyunca veri toplanmıştır. 11 Ocak günü her bir noktadan 1.5 dakika, 12 Ocak günü her bir noktadan 1 dakika, 13 Ocak günü her bir noktadan 1 dakika ve 14 Ocak günü her bir noktadan 0.5 dakika boyunca veri toplanmıştır. Daha önce elde edilen sonuçlarda 11, 12, 13 Ocak'ta her bir noktadan toplanan 3.5 dakika veri eğitim verisi olarak düzenlenip ve 14 Ocak'ta her bir noktadan toplanan veriler test verisi olarak düzenlenerek sonuçlar elde edilmiştir. Algoritmaların gerçek performansını

belirlemek için 11, 12, 13 Ocak'taki veriler de test verisi olarak düzenlenmiştir. Elde edilen sonuçlar Tablo 6.11'de görülmektedir. Eğitim verileri farklı bir günde toplan verilerden seçilmiştir. Örneğin, 11 Ocak verileri test verileri olarak düzenlendiğinde, 12, 13 ve 14 Ocak'taki veriler eğitim verisi olarak düzenlenip testler yapılmıştır. Elde edilen sonuçlar, 15 Wi-Fi ve 4 GSM referans noktasındaki RSS verileri kullanılarak elde edilmiştir.

En iyi performansı veren algoritma tüm günlerde BayesNet algoritması vermiştir. 11 Ocak günü test verilerinde BayesNet algoritması uygulandığında, 0.33 olasılıkla tam eşleşme, 0.63 olasılıkla 2 metre ve altı konum hassasiyeti, 0.76 olasılıkla 4 metre ve altı konum hassasiyeti ve 4.2 metre ortalama hata elde edilmiştir. 12 Ocak günü test verilerinde BayesNet algoritması uygulandığında, 0.38 olasılıkla tam eşleşme, 0.66 olasılıkla 2 metre ve altı konum hassasiyeti, 0.80 olasılıkla 4 metre ve altı konum hassasiyeti ve 3.2 metre ortalama hata elde edilmiştir. 13 Ocak günü test verilerinde BayesNet algoritması uygulandığında, 0.35 olasılıkla tam eşleşme, 0.66 olasılıkla 2 metre ve altı konum hassasiyeti, 0.81 olasılıkla 4 metre ve altı konum hassasiyeti ve 3.4 metre ortalama hata elde edilmiştir. 14 Ocak günü test verilerinde, BayesNet algoritması uygulandığında, 0.42 olasılıkla tam eşleşme, 0.71 olasılıkla 2 metre ve altı konum hassasiyeti, 0.81 olasılıkla 4 metre ve altı konum hassasiyeti ve 2.6 metre ortalama hata elde edilmiştir. Test verisi günü olarak 11 Ocak günü seçildiğinde, elde edilen konum hatasının yüksek olmasının nedeni bu gündeki eğitim verisi toplanma süresinin diğer günlerden az olmasıdır. 11 Ocak günü test verisi olduğunda, eğitim verisi toplanma süresi 2.5 dakika olmaktadır. Test verisi günü olarak 14 Ocak günü seçildiğinde, elde edilen konum hatasının düşük olmasının nedeni bu gündeki eğitim verisi toplanma süresinin diğer günlerden fazla olmasıdır. 14 Ocak günü test verisi olduğunda, eğitim verisi toplanma süresi 3.5 dakika olmaktadır. Algoritmaların performanslarının ölçmek için 10 çapraz geçerleme kullanılarak sonuçlar elde edilmiştir. 10 çapraz eşleşme, eğitim verisi 10 eşit parçaya bölünerek 10 eşit parçanın 1'i test diğerleri eğitim verisi olarak kabul edilip 10 kez çalıştırılır. Böylece tüm eğitim veri setinin her bir elemanı test verisi olarak kullanılmış ve eğitim ve test verileri her bir çalıştırmada değiştirilmiş olur. Bu 10 çalıştırmanın ortalaması alınarak sonuçlar elde edilir. Elde edilen sonuçlar Tablo 6.12'de görülmektedir.

Tablo 6.11: 100 noktada farklı günler test verileri olarak düzenlendikten sonra elde edilen sonuçlar tablosu.

Algoritma	Test Verisi günü	0 (m)	2 (m)	4 (m)	8 (m)	16 (m)	Ortalama Hata(m)
Bayes Net	11 Ocak	0.33	0.63	0.76	0.87	0.89	4.2
	12 Ocak	0.38	0.66	0.80	0.91	0.96	3.2
	13 Ocak	0.35	0.66	0.81	0.91	0.94	3.4
	14 Ocak	0.42	0.71	0.85	0.95	0.97	2.6
	Ortalama	0.37	0.67	0.81	0.91	0.94	3.6
SVM	11 Ocak	0.33	0.64	0.78	0.86	0.88	4.5
	12 Ocak	0.35	0.62	0.74	0.87	0.94	4.0
	13 Ocak	0.36	0.65	0.81	0.91	0.94	3.5
	14 Ocak	0.40	0.67	0.81	0.91	0.95	3.4
	Ortalama	0.36	0.65	0.79	0.89	0.92	3.9
RKO	11 Ocak	0.22	0.47	0.60	0.71	0.78	7.7
	12 Ocak	0.20	0.41	0.53	0.66	0.77	8.7
	13 Ocak	0.22	0.45	0.57	0.70	0.78	7.9
	14 Ocak	0.24	0.48	0.62	0.75	0.83	6.7
	Ortalama	0.22	0.45	0.58	0.71	0.79	7.7
J48	11 Ocak	0.25	0.52	0.68	0.80	0.85	5.7
	12 Ocak	0.28	0.54	0.67	0.82	0.89	5.3
	13 Ocak	0.27	0.53	0.67	0.80	0.86	5.5
	14 Ocak	0.29	0.57	0.70	0.85	0.91	4.8
	Ortalama	0.27	0.54	0.68	0.82	0.88	5.3
KNN	11 Ocak	0.24	0.51	0.65	0.76	0.82	6.4
	12 Ocak	0.25	0.49	0.64	0.79	0.88	5.8
	13 Ocak	0.22	0.46	0.61	0.75	0.85	6.4
	14 Ocak	0.23	0.46	0.60	0.74	0.84	6.6
	Ortalama	0.24	0.48	0.63	0.76	0.85	6.3

Tüm algoritmalarının performansının arttığı söylenebilir. En iyi performansı KNN ve RKO vermektedir. KNN algoritması uygulandığında 0.93 olasılıkla tam eşleşme, 0.96 olasılıkla 2 metre ve altı konum hassasiyeti, 0.97 olasılıkla 4 metre ve altı konum hassasiyeti ve 0.4 metre ortalama hata elde edilmiştir. Farklı günde kalabalık ve hava sıcaklığı, nem gibi çevre koşulları vb. faktörler etki ederek her bir noktadan elde edilen RSS verilerine etki etmektedir. Bu çevresel koşullarının etkisini gürültü etkisi olarak kabul edebilirse, Tablo 6.12 'de elde edilen sonuçlar gürültünün algoritmalarının performansını ciddi derecede olumsuz etkilediğini göstermektedir. Tablo 6.11'de elde edilen sonuçlar da referans alınarak, BayesNet ve

SVM algoritmalarının gürültüye en fazla dayanıklı algoritmalar olduğunu ve KNN RKO, J48 algoritmalarının gürültüden çok fazla etkilendiklerini göstermektedir.

Tablo 6.12: 100 noktada 10 çapraz geçirme yapılarak elde edilen algoritmanın performansları sonuçları tablosu.

Algoritma	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
BayesNet	0.78	0.86	0.91	0.95	0.98	1.1
SVM	0.65	0.79	0.88	0.94	0.97	1.6
RKO	0.93	0.95	0.97	0.99	1.0	0.5
KNN	0.93	0.96	0.97	0.99	1.0	0.4
J48	0.82	0.89	0.95	0.97	0.99	0.8

6.4. 100 Nokta İçin Konum Kestirme Doğruluk Oranının Artırılması İçin Yapılan Çalışmalar

6.4.1. GSM Ve Wi-Fi Referans Noktalarının Birleştirilmesi

LG Nexus 4 telefonu kullanılarak aynı anda GSM ve Wi-Fi RSS verileri toplanmıştır. Veriler toplanırken ölçüm zamanı bilgisi de toplanan verilere eklenmiştir. Ölçüm zamanı bilgisi kullanılarak sinyal güç ortalaması yüksek olan ve tüm noktalardan sinyal gücü elde edilebilen GSM referans noktalarıyla, Wi-Fi referans noktalarıyla birleştirilerek konum hatası azaltılmıştır. Bu kapsamda yapılan test sonuçları Tablo 6.13’de görülmektedir. Tablo 6.13’deki test sonuçları 15 Wifi + 4 güçlü GSM referans noktaları kullanılarak elde edilmiştir. Konum kestirmede başarıyı ciddi denilebilecek bir oranda %20-40 oranında artırmıştır.

Tablo 6.13: 100 noktada GSM ve Wi-Fi RSS verilerinin birleştirilme yaklaşımının sonuçları tablosu.

Algoritma	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
BayesNet	0.42	0.71	0.85	0.95	0.97	2.6
RKO	0.26	0.50	0.63	0.76	0.83	6.6
KNN	0.23	0.46	0.60	0.74	0.84	6.6

Bu yaklaşım kullanılmadan önce, BayesNet algoritması uygulandığında, 0.31 olasılıkla tam eşleşme, 0.61 olasılıkla 2 metre ve altı konum hassasiyeti, 0.77 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 3.6 metre ortalama hata elde edilmiştir. Bu yaklaşım kullanıldığında ise, BayesNet algoritmasında 0.42 olasılıkla tam eşleşme, 0.71 olasılıkla 2 metre ve altı konum hassasiyeti, 0.85 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 2.6 metre ortalama hata elde edilmiştir.

Bu yaklaşım kullanılmadan önce, Rastgele Karar Ormanı algoritması uygulandığında, 0.21 olasılıkla tam eşleşme, 0.44 olasılıkla 2 metre ve altı konum hassasiyeti, 0.66 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 7.1 metre ortalama hata elde edilmiştir. Bu yaklaşım kullanıldığında ise, Rastgele Karar Ormanı algoritmasında 0.26 olasılıkla tam eşleşme, 0.50 olasılıkla 2 metre ve altı konum hassasiyeti, 0.63 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 6.6 metre ortalama hata elde edilmiştir.

Bu yaklaşım kullanılmadan önce, En Yakın Komşu algoritmasında 0.18 olasılıkla tam eşleşme, 0.39 olasılıkla 2 metre ve altı konum hassasiyeti, 0.54 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 7.5 metre ortalama hata elde edilmiştir. Bu yaklaşım kullanıldığında ise, En Yakın Komşu algoritmasında 0.23 olasılıkla tam eşleşme, 0.46 olasılıkla 2 metre ve altı konum hassasiyeti, 0.60 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 6.6 metre ortalama hata elde edilmiştir.

6.4.2. Eğitim Verileri Toplanma Aralığının Değiştirilmesi

Yapılan tez çalışması kapsamında, GSM ve Wi-Fi RSS verilerini toplanma aralığı 0.5 saniye olarak belirlenmiştir. Bu aralığın küçük olması aynı saniye içerisinde sinyal kaynaklarından yayılan sinyal güçlerinin aynı olma ihtimali çok yüksek olduğundan, aynı olan kayıtların sayısının artmasına neden olur. Bu durum, çevre koşulları ve gürültünün çok etkili olduğu konum belirleme problemi için konum hatasının artmasına neden olabilir. Eğitim verileri toplanma aralığını artırmak aynı olan kayıtların sayısını azaltır. GSM ve Wi-Fi eğitim verilerinde toplanma aralığı 0.5 saniyeden 1 saniye artırılarak, 1 saniye içerisinde toplanan iki verinin yalnızca bir tanesi alınarak testler yapıldı. Bu yaklaşım kullanıldıktan sonra elde

edilen konum kestirme sonuçları Tablo 6.14’de görülmektedir. Bu yaklaşım, konum kestirmede başarıyı artırmıştır. Bunun nedeni ise makine öğrenmesi algoritmalarının ezberleme problemini engellemesidir. Tablo 6.15’de ise bu yaklaşımının GSM sinyalleri üzerinde kullanılmasıyla elde edilen sonuçlar görülmektedir.

Tablo 6.14:100 noktada RSS eğitim verilerinin tekilleştirme yaklaşımının sonuçları tablosu.

Algoritma	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
BayesNet	0.44	0.73	0.85	0.94	0.98	2.4
RKO	0.30	0.56	0.69	0.81	0.87	5.4
KNN	0.27	0.53	0.68	0.80	0.88	5.3

Bu yaklaşım kullanılmadan önce, BayesNet algoritmasında 0.42 olasılıkla tam eşleşme, 0.71 olasılıkla 2 metre ve altı konum hassasiyeti, 0.85 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 2.6 metre ortalama hata elde edilmiştir. Bu yaklaşım kullanıldığında ise, BayesNet algoritmasında 0.44 olasılıkla tam eşleşme, 0.73 olasılıkla 2 metre ve altı konum hassasiyeti, 0.85 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 2.4 metre ortalama hata elde edilmiştir.

Bu yaklaşım kullanılmadan önce, Rastgele Karar Ormanı algoritmasında 0.26 olasılıkla tam eşleşme, 0.50 olasılıkla 2 metre ve altı konum hassasiyeti, 0.63 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 6.6 metre ortalama hata elde edilmiştir. Bu yaklaşım kullanıldığında ise, Rastgele Karar Ormanı algoritmasında 0.30 olasılıkla tam eşleşme, 0.56 olasılıkla 2 metre ve altı konum hassasiyeti, 0.69 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 5.4 metre ortalama hata elde edilmiştir.

Bu yaklaşım kullanılmadan önce, En Yakın Komşu algoritmasında 0.23 olasılıkla tam eşleşme, 0.46 olasılıkla 2 metre ve altı konum hassasiyeti, 0.60 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 6.6 metre ortalama hata elde edilmiştir. Bu yaklaşım kullanıldığında ise, , En Yakın Komşu algoritmasında 0.27 olasılıkla tam eşleşme, 0.53 olasılıkla 2 metre ve altı konum hassasiyeti, 0.68 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 5.3 metre ortalama hata elde edilmiştir.

Tablo 6.15: 100 noktada GSM RSS eğitim verilerinin tekilleştirme yaklaşımının sonuçları tablosu.

Algoritma	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
BayesNet	0.24	0.42	0.50	0.61	0.73	9.6
RKO	0.19	0.31	0.40	0.51	0.65	12.5
KNN	0.16	0.28	0.38	0.50	0.64	12.8

Bu yaklaşım kullanılmadan önce, GSM sinyallerinde, BayesNet algoritmasında 0.23 olasılıkla tam eşleşme, 0.42 olasılıkla 2 metre ve altı konum hassasiyeti, 0.51 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 9.7 metre ortalama hata elde edilmişti. Bu yaklaşım kullanıldığında ise, BayesNet algoritmasında 0.24 olasılıkla tam eşleşme, 0.42 olasılıkla 2 metre ve altı konum hassasiyeti, 0.50 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 9.6 metre ortalama hata elde edilmiştir.

Bu yaklaşım kullanılmadan önce, GSM sinyallerinde Rastgele Karar Ormanı algoritması uygulandığında, 0.15 olasılıkla tam eşleşme, 0.28 olasılıkla 2 metre ve altı konum hassasiyeti, 0.36 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 13.8 metre ortalama hata elde edilmişti. Bu yaklaşım kullanıldığında ise, Rastgele Karar Ormanı algoritmasında 0.19 olasılıkla tam eşleşme, 0.31 olasılıkla 2 metre ve altı konum hassasiyeti, 0.40 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 12.5 metre ortalama hata elde edilmiştir.

Bu yaklaşım kullanıldığında ise, En Yakın Komşu algoritmasında 0.13 olasılıkla tam eşleşme, 0.26 olasılıkla 2 metre ve altı konum hassasiyeti, 0.34 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 13.9 metre ortalama hata elde edilmiştir. Bu yaklaşım kullanıldığında ise, En Yakın Komşu algoritmasında 0.16 olasılıkla tam eşleşme, 0.28 olasılıkla 2 metre ve altı, 0.38 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 12.8 metre ortalama hata elde edilmiştir. Eğitim verileri toplanma aralığı 0.5 saniye 1 saniyeye çıkarıldığında konum hatası azalmıştır. Tipik olarak eğitim verileri toplanma aralığı 1 saniye olarak seçilebilir.

6.4.3. RSS Değerlerinden Yeni Bilgiler Üretilmesi

Yalnızca sinyal güç değerlerine bakmanın yanında, konumu belirlenecek noktalarda referans noktalarından hangisinin güçlü olduğu bilgisi kullanılarak konum kestirme başarısı artırır. Yapılan çalışma kapsamında, en güçlü ve en zayıf sinyal güç ortalamasına sahip referans noktaları hariç tutulmuştur. 16 Wi-Fi referans noktalarından en güçlü ve en zayıf sinyal güç ortalamasına sahip referans noktaları çıkartılarak 14 Wi-Fi referans noktası kullanılarak anlamlı bilgi üretilmiştir. Bu 14 Wi-Fi referans noktaları iki gruba ayrılmıştır. Her bir referans noktasına 1-14'e kadar id verilmiştir. Daha sonra ise 7'şerli iki gruptan en güçlü sinyal ve ikinci en güçlü sinyal gücüne sahip referans noktalarının id'leriyle yeni bilgiler üretilmiştir. Bu bilgiler sanki yeni bir referans noktasıymış gibi testler yapılmıştır. Bu yaklaşımın konum kestirme sonuçları Tablo 6.16'da görülmektedir.

Tablo 6.16: 100 noktada RSS verilerinden yeni bilgiler üretme yaklaşımının sonuçları tablosu.

Algoritma	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
BayesNet	0.46	0.74	0.87	0.95	0.98	2.3
RKO	0.30	0.57	0.71	0.82	0.89	5.1
KNN	0.28	0.54	0.69	0.81	0.90	5.0

mapavri character varyi	kralteknik character var	hacioglu character var	asak2222 character var	airties character var	tudors character var	flormar character var
-83	-110	-81	-81	-82	-79	-67
-83	-110	-80	-81	-82	-80	-69

Şekil 6.5: Örnek bir RSS verisi kaydı.

Örnek kayıtlarımız Şekil 6.5 'de görülen gibi olsun. “mapavri” referans noktası 1, “flormar” referans noktasına 7 numaralı id verecek şekilde tüm referans noktalarına id'ler verilsin. En güçlü sinyal gücüne sahip referans noktası “flormar”dır. İkinci güçlü referans noktası “hacioglu”dır. Oluşturulan iki yeni sütunun ilkinin değeri 7, diğerinin değeri 3 olmaktadır.

Bu yaklaşımının sonucunda test edilen tüm makine öğrenmesi algoritmalarında konum kestirme hassasiyetini artırmıştır.

Bu yaklaşım kullanılmadan önce, BayesNet algoritmasında 0.44 olasılıkla tam eşleşme, 0.73 olasılıkla 2 metre ve altı konum hassasiyeti, 0.85 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 2.4 metre ortalama hata elde edilmiştir. Bu yaklaşım kullanıldığında ise, BayesNet algoritmasında 0.46 olasılıkla tam eşleşme, 0.74 olasılıkla 2 metre ve altı konum hassasiyeti, 0.87 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 2.3 metre ortalama hata elde edilmiştir.

Bu yaklaşım kullanılmadan önce, Rastgele Karar Ormanı algoritmasında 0.30 olasılıkla tam eşleşme, 0.56 olasılıkla 2 metre ve altı konum hassasiyeti, 0.69 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 5.4 metre ortalama hata elde edilmiştir. Bu yaklaşım kullanıldığında ise, Rastgele Karar Ormanı algoritmasında 0.30 olasılıkla tam eşleşme, 0.57 olasılıkla 2 metre ve altı konum hassasiyeti, 0.71 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 5.1 metre ortalama hata elde edilmiştir.

Bu yaklaşım kullanılmadan önce, En Yakın Komşu algoritmasında 0.27 olasılıkla tam eşleşme, 0.53 olasılıkla 2 metre ve altı konum hassasiyeti, 0.68 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 5.3 metre ortalama hata elde edilmiştir. Bu yaklaşım kullanıldığında ise, En Yakın Komşu algoritmasında 0.28 olasılıkla tam eşleşme, 0.54 olasılıkla 2 metre ve altı konum hassasiyeti, 0.69 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 5.0 metre ortalama hata elde edilmiştir.

6.4.4. Sınıfları Tekli Ve Çiftli Koordinatlar Olmak Üzere İki Gruba Ayırma

Algoritmalarda 1 metre, 3 metre, 5 metre gibi ara değerlerde konum kestirim başarısı artırmak için, noktaları iki ayrı gruba bölme yaklaşımı kullanılabilir. Bu yaklaşım da nokta ve en yakın komşusu farklı iki grupta yer almalıdır. Örneğin, 2 metre aralıklarla ölçülmüş noktalarımız 2_0-0 ,2_0-1, 2_0-2, ...2_0-33 şeklinde olsun. 2_0-0 noktasının en yakın komşusu 2_0-1, 2_0-1 noktasının en yakın komşusu 2_0-2 olsun. Çift noktalar 2_0-0, 2_0-2, 2_0-4...,2_0-32 ve tek noktalar 2_0-1 ,2_0-3...,2_0-29, 2_0-33 olmak üzere iki ayrı gruba ayrılır. Gelen test örneğin, hangi noktada olduğunu tespit etmek için bu iki ayrı grupta ayrı şekilde tahmin edilir. Daha

sonra çözüm ise ayrı ayrı olarak tahmin edilen bu iki noktanın ortası olarak kabul edilir. Bu yaklaşımda tam eşleşen hiçbir test örneği mevcut değildir. Ancak 1 metre, 3 metre ve 5 metre gibi ara değerlerdeki konum kestirim başarısını ciddi oranda artırmaktadır. Bu yaklaşımı daha güçlendirmek için ayrı ayrı gruptaki noktalara komşularını eklemek konum kestirim başarısı daha da artırmaktadır. Örneğin 2_0-0 noktasına 2_0-1 örneklerini ekleyip bu iki sınıfın örneklerini 2_0-0 olarak değerlendirmek konum kestirmede başarısını artırmıştır. İki ayrı grupta tahmin edildiğinde tahmin sonucu elde edilen iki nokta arası mesafenin 2 metre, 6 metre gibi kabul edilebilir seviyelerde olması gerekir. Eğer tahmin edilen noktalar arası mesafe 6 metreyi geçiyorsa bir problem olduğu düşünülebilir. Yaklaşımımızı daha da güçlendirmek için 6 metre eşik değerini geçmesi halinde iki gruba ayırma yaklaşımımızın sınıflandırmasında bir yanlışlık olduğu varsayılarak, iki gruba ayırmadan test örnekleri sınıflandırılır. Eşik değeri koyma yaklaşımını, iki gruba ayırma yaklaşımının konum kestirme başarısını daha da artırmıştır. Bu yaklaşımın konum kestirme sonuçları Tablo 6.17’de görülmektedir. Sınıfları tek ve çift olmak üzere iki gruba ayırma yaklaşımını kullanmadan önce, BayesNet algoritmasında 0.46 olasılıkla 1 metre ve altı konum hassasiyeti, 0.74 olasılıkla 3 metre ve altı konum hassasiyeti, 0.87 olasılıkla 5 metre ve altı konum hassasiyeti elde edilirken, 2.3 metre ortalama hata elde edilmiştir. İki gruba ayırma yaklaşımı kullanıldığında ise, BayesNet algoritmasında 0.54 olasılıkla 1 metre ve altı konum hassasiyeti, 0.81 olasılıkla 3 metre ve altı konum hassasiyeti, 0.89 olasılıkla 5 metre ve altı konum hassasiyeti elde edilirken, 2.9 metre ortalama hata elde edilmiştir. İki gruba ayırma yaklaşımımızı komşu sınıfları ekleyerek güçlendirdiğimizde ise, BayesNet algoritmasında 0.57 olasılıkla 1 metre konum hassasiyeti, 0.81 olasılıkla 3 metre ve altı konum hassasiyeti, 0.91 olasılıkla 5 metre ve altı konum hassasiyeti elde edilirken, 2.7 metre ortalama hata elde edilmiştir. İki gruba ayırma yaklaşımını ve komşu sınıfları ekleme yaklaşımlarını 6 metre gibi eşik değeri koyarak güçlendirildiğinde ise, BayesNet algoritmasında 0.57 olasılıkla 1 metre ve altı konum hassasiyeti, 0.84 olasılıkla 3 metre ve altı konum hassasiyeti, 0.93 olasılıkla 5 metre ve altı konum hassasiyeti elde edilirken, 2.6 metre ortalama hata elde edilmiştir.

Tablo 6.17: 100 noktada sınıfları tekli ve çiftli koordinatlar olmak üzere iki gruba ayırma yaklaşımının sonuçları tablosu.

Algoritma	0(m)	1(m)	2(m)	3(m)	4(m)	5(m)	16(m)	Ortalama Hata(m)
BayesNet	0.46	0.46	0.74	0.74	0.87	0.87	0.98	2.3
Bölmeleme +Komşu +Eşik	0.01	0.57	0.57	0.84	0.84	0.93	0.98	2.6
Bölmeleme +Komşu	0.00	0.57	0.57	0.81	0.81	0.91	0.98	2.7
Bölmeleme	0.00	0.54	0.54	0.81	0.81	0.89	0.99	2.9

6.4.5. Algoritmalarının Yeniden Karar Vermesi

15 Wi-Fi, 4 GSM ve 4 maksimum sinyal referans noktaları id'lerinden oluşan toplam 23 tane referans noktası kullanılarak BayesNet algoritmasıyla 0.87 olasılıkla 4 metre ve altı konum hassasiyeti elde edilmişti. Bu sonuç, tahmin edilen noktanın 4 metre uzağında olma olasılığının 0.87 olduğunu belirtir. Aranan konumun, ilk tahmin edilen noktanın 4 metre uzağında olma ihtimalinin 0.87 olduğunu belirtir. Bu durumda ilk tahmin edilen nokta ve 4 metre uzağındaki noktalar için yeniden tahmin yapıldığında konum hatası azalabilir. Algoritmaların yeniden karar vermesi yaklaşımı, ilk tahmin edilen noktanın solunun ve sağının 4 metre uzağında bulunan 5 nokta için yeniden tahmin edilmesi yaklaşımıdır. Örnek olarak İlk olarak 2_0-2 noktası tahmin edildiğini varsayılırsa, bu noktanın 4 metre uzağındaki 2_0-0, 2_0-1, 2_0-2, 2_0-3, 2_0-4 noktaların için ikinci kez algoritmalar tarafından tahmin yapar. Bu yaklaşımın konum kestirme sonuçları Tablo 6.18'de görülmektedir.

Tablo 6.18: 100 noktada algoritmaların yeniden karar vermesi yaklaşımının sonuçları tablosu.

Algoritma	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
BayesNet	0.46	0.74	0.87	0.96	0.98	2.3
Yeni Karar	0.47	0.75	0.88	0.96	0.98	2.2

Algoritmalarının yeniden karar verme yaklaşımını kullanmadan önce, BayesNet algoritmasında 0.46 olasılıkla tam eşleşme, 0.74 olasılıkla 2 metre ve altı konum hassasiyeti, 0.87 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 2.3 metre ortalama hata elde edilmiştir. Bu yaklaşım kullanıldığında ise, BayesNet algoritmasında 0.47 olasılıkla tam eşleşme, 0.75 olasılıkla 2 metre ve altı konum hassasiyeti, 0.88 olasılıkla 4 metre ve altı konum hassasiyeti elde edilirken, 2.2 metre ortalama hata elde edilmiştir. Algoritmalarının yeniden karar vermesinin daha iyi sonuçlar vermesinin nedeni, tahmin ederken doğru olma ihtimali düşük olan sınıflara bakılmaz. İkinci tahminde yalnızca doğru olma ihtimali yüksek olan sınıflara bakılır.

6.5. 200 Noktada Yapılan Test Sonuçları

Tablo 6.19’da 200 farklı noktada GSM ve Wi-Fi sinyalleriyle farklı makine öğrenmesi algoritmaları uygulanarak elde edilen sonuçlar görülmektedir. Eğitim verisi toplanma süresi her bir noktadan toplam 3 dakikadır. Referans nokta sayısı 23’dir. Bu referans noktaların 19 tanesi Wi-Fi ve 4 GSM referans noktasıdır. Test verileri farklı bir günde her bir noktadan 30 saniye boyunca toplanan RSS verilerinden seçilmiştir.

En doğru sonucu veren üç algoritmanın konum hassasiyeti doğruluk oranları sırasıyla BayesNet, SVM, KNN şeklindedir. BayesNet algoritması uygulandığında 0.31 olasılıkla tam eşleşme, 0.54 olasılıkla 2 metre ve altı konum hassasiyeti, 0.66 olasılıkla 4 metre ve altı konum hassasiyeti ve 5.5 metre ortalama hata elde edilmiştir. SVM algoritması uygulandığında 0.26 olasılıkla tam eşleşme, 0.48 olasılıkla 2 metre ve altı konum hassasiyeti, 0.59 olasılıkla 4 metre ve altı konum hassasiyeti ve 8.0 metre ortalama hata elde edilmiştir. KNN algoritması uygulandığında 0.17 olasılıkla tam eşleşme, 0.35 olasılıkla 2 metre ve altı konum hassasiyeti, 0.47 olasılıkla 4 metre ve altı konum hassasiyeti ve 9.1 metre ortalama hata elde edilmiştir.

Tablo 6.19: 200 noktada yapılan test sonuçları tablosu.

Algoritma Türü	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata (m)
BayesNet	0.31	0.54	0.66	0.79	0.92	5.5
SVM	0.26	0.48	0.59	0.72	0.86	8.0
KNN	0.17	0.35	0.47	0.65	0.84	9.1
RKO	0.16	0.33	0.43	0.60	0.80	10.2
J48	0.12	0.26	0.36	0.53	0.73	12.2

Sınıf sayısının artması konum hatasının artmasına sebep olmuştur. BayesNet algoritması ile diğer algoritmalar arasındaki farklar artmıştır. 200 noktada başarıyı artırmak için tüm noktalardan daha çok süreli veri toplamak gerekir. Bunun dışında 100 noktada konum hassasiyetini artırmak için yapılan algoritmaların yeniden karar vermesi, sinyal güçlerinden yeni bilgilerin üretilmesi vb. yaklaşımlar kullanılarak konum hatası azaltılabilir.

6.6. Yapay Sinir Ağları ve Regresyon Algoritmalarının Sonuçları

Yapay sinir ağları ve regresyon algoritmalarının etkisini görmek için de testler yapılmıştır. Yapay sinir ağlarının ve regresyon algoritmalarının yavaş çalışması sebebiyle 40 noktadan toplanan veriler eğitim verileri olarak seçilmiştir. Eğitim verileri 13 Aralık günü toplanan verilerden seçilmiştir. Test verileri 15 Aralık gününde farklı bir günde her bir noktadan 30 saniyede toplanan verilerden seçilmiştir. Elde edilen sonuçlar 10 Wi-Fi referans noktasındaki RSS verileri kullanılarak elde edilmiştir.

Yapay sinir ağları ve regresyon algoritmalarını içerecek şekilde 10, 20, 40 noktadaki sonuçlar sırasıyla Tablo 6.20, 6.21 ve 6.22’de görülmektedir. 10 noktada, Logistic algoritması uygulandığında 0.44 olasılıkla tam eşleşme, 0.88 olasılıkla 2 metre ve altı konum hassasiyeti, 0.97 olasılıkla 4 metre ve altı konum hassasiyeti, 1.5 metre ortalama hata elde edilmiştir. Çok katmanlı perceptron algoritması uygulandığında 0.44 olasılıkla tam eşleşme, 0.82 olasılıkla 2 metre ve altı konum hassasiyeti, 0.93 olasılıkla 4 metre ve altı konum hassasiyeti, 1.7 metre ortalama hata elde edilmiştir. RBF ağı algoritması uygulandığında 0.44 olasılıkla tam

eşleşme, 0.81 olasılıkla 2 metre ve altı konum hassasiyeti, 0.91 olasılıkla 4 metre ve altı konum hassasiyeti, 1.9 metre ortalama hata elde edilmiştir. BayesNet algoritması uygulandığında 0.44 olasılıkla tam eşleşme, 0.86 olasılıkla 2 metre ve altı konum hassasiyeti, 0.98 olasılıkla 4 metre ve altı konum hassasiyeti, 1.5 metre ortalama hata elde edilmiştir.

Tablo 6.20: Yapay sinir ağları ve regresyon algoritmaları ile 10 noktada yapılan test sonuçları tablosu.

Algoritma Türü	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
Logistic	0.44	0.88	0.97	0.98	1.0	1.5
SimpleLogistic	0.46	0.90	0.98	0.99	1.0	1.5
MLP	0.44	0.82	0.93	0.99	1.0	1.7
RBF Network	0.44	0.81	0.91	0.98	1.0	1.9
BayesNet	0.44	0.86	0.98	0.99	1.0	1.5
SVM	0.43	0.89	0.99	1.0	1.0	1.4

Tablo 6.21: Yapay sinir ağları ve regresyon algoritmaları ile 20 noktada yapılan test sonuçları tablosu.

Algoritma Türü	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
Logistic	0.37	0.73	0.84	0.99	1.0	2.3
SimpleLogistic	0.38	0.75	0.86	0.98	1.0	2.2
MLP	0.33	0.70	0.88	0.96	0.99	2.5
RBFNetwork	0.33	0.69	0.86	0.96	0.99	2.6
BayesNet	0.35	0.68	0.82	0.98	1.0	2.6
SVM	0.33	0.72	0.86	0.98	1.0	2.4

20 noktada, Logistic algoritması uygulandığında 0.37 olasılıkla tam eşleşme, 0.73 olasılıkla 2 metre ve altı konum hassasiyeti, 0.84 olasılıkla 4 metre ve altı konum hassasiyeti, 2.3 metre ortalama hata elde edilmiştir. Çok katmanlı perceptron algoritması uygulandığında 0.33 olasılıkla tam eşleşme, 0.70 olasılıkla 2 metre ve altı konum hassasiyeti, 0.88 olasılıkla 4 metre ve altı konum hassasiyeti, 2.5 metre ortalama hata elde edilmiştir. RBF Ağı algoritması uygulandığında 0.33 olasılıkla tam eşleşme, 0.69 olasılıkla 2 metre ve altı konum hassasiyeti, 0.86 olasılıkla 4 metre ve altı konum hassasiyeti, 2.6 metre ortalama hata elde edilmiştir. BayesNet

algoritması uygulandığında 0.35 olasılıkla tam eşleşme, 0.68 olasılıkla 2 metre ve altı konum hassasiyeti, 0.82 olasılıkla 4 metre ve altı konum hassasiyeti, 2.6 metre ortalama hata elde edilmiştir.

Tablo 6.22: Yapay sinir ağları ve regresyon algoritmaları ile 40 noktada yapılan test sonuçları tablosu.

Algoritma Türü	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
Logistic	0.40	0.70	0.85	0.94	0.98	2.8
SimpleLogistic	0.38	0.68	0.83	0.93	0.98	3.0
MLP	0.35	0.62	0.77	0.89	0.93	4.3
RBFNetwork	0.32	0.62	0.77	0.91	0.94	3.9
BayesNet	0.35	0.68	0.81	0.92	0.96	3.3
SVM	0.27	0.61	0.77	0.92	0.95	3.8

40 noktada, Logistic algoritması uygulandığında 0.40 olasılıkla tam eşleşme, 0.70 olasılıkla 2 metre ve altı konum hassasiyeti, 0.85 olasılıkla 4 metre ve altı konum hassasiyeti, 2.8 metre ortalama hata elde edilmiştir. Çok Katmanlı Perceptron algoritması uygulandığında, 0.35 olasılıkla tam eşleşme, 0.62 olasılıkla 2 metre ve altı konum hassasiyeti, 0.77 olasılıkla 4 metre ve altı konum hassasiyeti, 4.3 metre ortalama hata elde edilmiştir. RBF Ağı algoritması uygulandığında 0.32 olasılıkla tam eşleşme, 0.62 olasılıkla 2 metre ve altı konum hassasiyeti, 0.77 olasılıkla 4 metre ve altı konum hassasiyeti, 3.9 metre ortalama hata elde edilmiştir. BayesNet algoritması uygulandığında 0.35 olasılıkla tam eşleşme, 0.68 olasılıkla 2 metre ve altı konum hassasiyeti, 0.81 olasılıkla 4 metre ve altı konum hassasiyeti, 3.3 metre ortalama hata elde edilmiştir.

Sınıflandırma problemleri için kullanılan başlıca algoritmalarından olan Çok Katmanlı Perceptron ve RBF Ağı algoritmaları iyi sonuçlar vermiştir. BayesNet algoritması yapay sinir ağlarına göre daha iyi sonuçlar vermiştir. Logistic ve Simple Logistic regresyon algoritmaları diğer algoritmalara göre daha iyi sonuçlar vermiştir.

6.7. Mevsimsel Etkilerinin Araştırılması

Tablo 6.23’de 100 farklı noktada Wi-Fi sinyalleriyle mevsimlerin etkisini gözlemlemek farklı mevsimlerde toplanan test verileriyle farklı makine öğrenmesi algoritmaları uygulanarak elde edilen sonuçlar görülmektedir. Eğitim verisi toplanma süresi her bir noktadan 3.5 dakikadır. 11,12, 13 Ocak’ta toplanan veriler eğitim verileri olarak seçilmiştir. Referans nokta sayısı 15’dir.

Tablo 6.23: Konum kestirmede mevsimlerin etkisi.

Algoritma	Test Verisi Günü	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
Bayes Net	14Ocak	0.39	0.69	0.83	0.94	0.98	2.8
	11Nisan	0.21	0.44	0.56	0.68	0.89	7.4
	14Nisan	0.25	0.54	0.69	0.85	0.95	4.7
SVM	14Ocak	0.37	0.64	0.80	0.91	0.97	3.3
	11Nisan	0.18	0.40	0.52	0.62	0.81	8.2
	14Nisan	0.23	0.51	0.65	0.80	0.93	5.5
KNN	12Ocak	0.23	0.46	0.62	0.76	0.91	6.1
	11Nisan	0.12	0.28	0.39	0.52	0.74	11.1
	14Nisan	0.17	0.40	0.53	0.69	0.87	7.5
RKO	14Ocak	0.25	0.48	0.63	0.78	0.91	6.4
	11Nisan	0.13	0.28	0.36	0.48	0.71	12.4
	14Nisan	0.15	0.34	0.43	0.59	0.77	10.7
J48	14Ocak	0.19	0.39	0.54	0.69	0.85	7.9
	11Nisan	0.09	0.22	0.30	0.40	0.60	14.6
	14Nisan	0.14	0.30	0.42	0.56	0.73	11.1

14 Ocak günü test verilerinde BayesNet algoritması uygulandığında, 0.39 olasılıkla tam eşleşme, 0.69 olasılıkla 2 metre ve altı konum hassasiyeti, 0.83 olasılıkla 4 metre ve altı konum hassasiyeti, 2.8 metre ortalama hata elde edilmiştir. 11 Nisan günü test verilerinde BayesNet algoritması uygulandığında, 0.21 olasılıkla tam eşleşme, 0.44 olasılıkla 2 metre ve altı konum hassasiyeti, 0.56 olasılıkla 4 metre ve altı konum hassasiyeti, 7.4 metre ortalama hata elde edilmiştir. 14 Nisan günü test verilerinde BayesNet algoritması uygulandığında, 0.25 olasılıkla tam eşleşme, 0.54 olasılıkla 2 metre ve altı konum hassasiyeti, 0.69 olasılıkla 4 metre ve altı konum hassasiyeti, 4.7 metre ortalama hata elde edilmiştir.

Diğer algoritmalar mevsimler farklı olduğunda hava sıcaklığı, nem gibi çevre koşulları değişmektedir. Çevre koşullarının konum belirleme başarısında ciddi bir etkisinin var olduğu tespit edilmiştir. Bu etkiyi azaltmak için iki yaklaşımda bulunabilir. Birinci yaklaşım, hava sıcaklığı gibi çevresel faktörlerin ne yönde etkiledikleri tespit edilerek modelleme yapılabilir. İkinci yaklaşımsa eğitim verilerine farklı zamanlarda ölçülmüş veriler eklenerek, çevre koşulların etkisi azaltılabilir. 11,12,13 Ocak eğitim verilerine 11 Nisan toplanan veriler eklenmiş. Konum belirleme hatasının azaldığı gözlenmiştir.

Tablo 6.24: Konum kestirmede mevsimlerin etkisinin azaltılması.

Algoritma Türü	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
BayesNet	0.29	0.58	0.71	0.85	0.94	4.4
SMO	0.27	0.55	0.67	0.80	0.90	5.4
KNN	0.17	0.41	0.54	0.70	0.86	7.4
RKO	0.16	0.36	0.46	0.60	0.78	10.0
J48	0.16	0.35	0.46	0.61	0.80	9.1

BayesNet algoritması uygulandığında 0.29 olasılıkla tam eşleşme, 0.58 olasılıkla 2 metrel ve altı konum hassasiyeti, 0.71 olasılıkla 4 metre ve altı konum hassasiyeti, 4.4 metre ortalama hata elde edilmiştir. Bu yaklaşım çevre koşulların olumsuz etkisini azaltarak tüm algoritmalarının daha doğru sonuçlar dönmesini sağlamıştır.

6.8. Sanal Eğitim Verisi Üretme Yaklaşımı

Veri toplama süreçleri RF parmakizi yaklaşımının en büyük dezavantajıdır. Sinyal kaynağı ile mesafenin artması sinyal kaynağından alıcının aldığı sinyal gücü değeri azalır. Mesafe ile sinyal gücü arasında doğrusal bir ilişki olduğu varsayılarak bazı noktalardan veri toplanmadan o noktalardan veri toplanmış gibi sanal eğitim verisi üretme yaklaşımında bulunabilir. Sanal eğitim verisi üretme yaklaşımın 7, 19, 38 noktadaki sonuçları sırasıyla Tablo 6.25, 6.26, 6.27’de görülmektedir. Üretilen eğitim verilerinde 2. kat ve 3.kat 0-0,0-2,0-4 gibi çift koordinatlar ölçülen verilerden seçilmiştir. 0-1,0-3,0-5 gibi tekli koordinatlardaki veriler, çiftli koordinatlardaki eğitim verileri kullanılarak oluşturulmuştur. Örneğin, 0-0 ve 0-2 koordinatlardaki

ölçülen veriler kullanılarak 0-1 noktasındaki veriler oluşturulmuştur. Sanal RSS verileri üretilirken aritmetik ortalama kullanılmıştır. Örneğin 0-0 noktasında bir referans noktasından -60 dBm, 0-2 noktasından -70 dBm değeri elde edilmişse, 0-1 noktasından o anda elde edilen RSS değeri $(-60+-70)/2=-65$ dBm olarak kabul edilmiştir.

Tablo 6.25: Sanal eğitim verisi üretme yaklaşımının 7 noktadaki sonuçları tablosu.

Algoritma	Eğitim Verisi Türü	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
Logistic	Orjinal	0.41	0.92	0.98	1.0	1.0	1.4
	Üretilen	0.54	0.92	0.99	1.0	1.0	1.1
SVM	Orjinal	0.49	0.92	0.99	1.0	1.0	1.2
	Üretilen	0.54	0.93	0.99	1.0	1.0	1.1
MLP	Orjinal	0.41	0.90	0.97	1.0	1.0	1.4
	Üretilen	0.56	0.92	1.0	1.0	1.0	1.0
BayesNet	Orjinal	0.45	0.90	0.97	0.99	1.0	1.4
	Üretilen	0.35	0.82	0.96	1.0	1.0	1.8
KNN	Orjinal	0.41	0.88	0.97	1.0	1.0	1.4
	Üretilen	0.46	0.88	0.97	1.0	1.0	1.4
RKO	Orjinal	0.47	0.87	0.96	1.0	1.0	1.4
	Üretilen	0.46	0.90	0.98	1.0	1.0	1.3
J48	Orjinal	0.49	0.85	0.95	0.99	1.0	1.5
	Üretilen	0.41	0.80	0.94	1.0	1.0	1.7

38 noktada orijinal eğitim verilerinde Logistic algoritması uygulandığında, 0.30 olasılıkla tam eşleşme, 0.64 olasılıkla 2 metre ve altı konum hassasiyeti, 0.80 olasılıkla 4 metre ve altı konum hassasiyeti, 3.5 metre ortalama hata elde edilmiştir. Üretilen eğitim verilerinde Logistic algoritması uygulandığında, 0.27 olasılıkla tam eşleşme, 0.63 olasılıkla 2 metre ve altı konum hassasiyeti, 0.79 olasılıkla 4 metre ve altı konum hassasiyeti, 4.0 metre ortalama hata elde edilmiştir. Orijinal eğitim verilerinde SVM algoritması uygulandığında, 0.25 olasılıkla tam eşleşme, 0.53 olasılıkla 2 metre ve altı konum hassasiyeti, 0.72 olasılıkla 4 metre ve altı konum hassasiyeti, 5.4 metre ortalama hata elde edilmiştir. Üretilen eğitim verilerinde SVM algoritması uygulandığında 0.21 olasılıkla tam eşleşme, 0.54 olasılıkla 2 metre ve altı konum hassasiyeti, 0.70 olasılıkla 4 metre ve altı konum hassasiyeti, 4.9 metre ortalama hata elde edilmiştir. Diğer algoritmalarda ise Orijinal eğitim verileri

kullanılarak elde edilen sonuçlar ile üretilen eğitim verilerindeki sonuçlar yakındır. Sonuçların en uzak olduğu algoritma BayesNet algoritmasıdır.

Tablo 6.26: Sanal eğitim verisi üretme yaklaşımının 19 noktadaki sonuçları tablosu.

Algoritma	Eğitim Verisi Türü	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
Logistic	Orjinal	0.43	0.83	0.95	0.99	1.0	1.7
	Üretilen	0.42	0.78	0.92	0.98	0.99	1.9
SVM	Orjinal	0.37	0.77	0.92	0.99	1.0	2.0
	Üretilen	0.36	0.75	0.89	0.98	0.99	2.1
Multilayer Perceptron	Orjinal	0.33	0.76	0.91	0.96	0.99	2.4
	Üretilen	0.26	0.73	0.89	0.97	0.99	2.5
BayesNet	Orjinal	0.37	0.77	0.91	0.98	0.99	2.1
	Üretilen	0.29	0.63	0.81	0.95	0.98	3.0
KNN	Orjinal	0.30	0.69	0.83	0.95	0.99	2.9
	Üretilen	0.27	0.64	0.84	0.95	0.98	3.2
RKO	Orjinal	0.40	0.79	0.93	0.99	1.0	1.8
	Üretilen	0.34	0.73	0.89	0.98	1.0	2.2
J48	Orjinal	0.33	0.69	0.87	0.96	0.99	2.5
	Üretilen	0.28	0.65	0.87	0.97	0.99	2.6

Tablo 6.27: Sanal eğitim verisi üretme yaklaşımının 38 noktadaki sonuçları tablosu.

Algoritma	Eğitim Verisi Türü	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
Logistic	Orjinal	0.30	0.64	0.80	0.93	0.96	3.5
	Üretilen	0.27	0.63	0.80	0.89	0.94	4.0
SVM	Orjinal	0.25	0.53	0.72	0.85	0.90	5.4
	Üretilen	0.21	0.54	0.70	0.85	0.93	4.9
Multilayer Perceptron	Orjinal	0.27	0.58	0.74	0.86	0.92	4.9
	Üretilen	0.19	0.51	0.67	0.81	0.89	6.0
BayesNet	Orjinal	0.22	0.56	0.73	0.84	0.90	5.1
	Üretilen	0.20	0.47	0.64	0.80	0.90	5.8
KNN	Orjinal	0.19	0.49	0.64	0.81	0.89	6.2
	Üretilen	0.17	0.48	0.66	0.81	0.90	5.9
RKO	Orjinal	0.27	0.63	0.82	0.90	0.94	3.8
	Üretilen	0.23	0.59	0.77	0.89	0.93	4.3
J48	Orjinal	0.26	0.58	0.76	0.89	0.94	4.1
	Üretilen	0.23	0.54	0.72	0.87	0.91	5.0

Bazı noktalardan sanal eğitim verisi üretme yaklaşımıyla elde edilen sonuçlar gerçek eğitim verilerindeki sonuçlarına yakındır. Bu sonuçlardan tüm noktalardan veri toplanmadan da aynı konum hassasiyetine başarısına ulaşılmasının mümkün olduğunu göstermiştir. Sanal eğitim verisi üretme yaklaşımını konum hassasiyeti başarısını artırmak içinde kullanılabilir. Aynı test verileri üzerinde, 2. kat ve 3. kattaki 0-1,0-3,0-5,..0-17 tekli koordinatlarındaki toplam 18 noktada orijinal eğitim verileri ve orijinal eğitim verilerinin üretilen verilerle birleştirilerek elde edilen eğitim verileri sonuçları Tablo 6.28’de görülmektedir. 18 noktada orijinal eğitim verilerinde Logistic algoritması uygulandığında 0.49 olasılıkla tam eşleşme, 0.81 olasılıkla 4 metre ve altı konum hassasiyeti, 4.8 metre ortalama hata elde edilmiştir. Üretilen eğitim verilerinde Logistic algoritması uygulandığında 0.57 olasılıkla tam eşleşme, 0.89 olasılıkla 4 metre ve altı konum hassasiyeti, 2.7 metre ortalama hata elde edilmiştir. Orijinal eğitim verilerinde SVM algoritması uygulandığında 0.48 olasılıkla tam eşleşme, 0.85 olasılıkla 4 metre ve altı konum hassasiyeti, 4.0 metre ortalama hata elde edilmiştir. Üretilen eğitim verilerinde SVM algoritması uygulandığında 0.53 olasılıkla tam eşleşme, 0.86 olasılıkla 4 metre ve altı konum hassasiyeti, 3.5 metre ortalama hata elde edilmiştir. Diğer algoritmalar bu yaklaşım konum hassasiyeti başarısını artırmıştır. En olumlu etkilediği algoritma bir regresyon yöntemi olan Logistic algoritmasıdır.

Tablo 6.28: Sanal olarak üretilen eğitim verilerinin orijinal eğitim verileri birleştirilmesi yaklaşımının sonuçları tablosu.

Algoritma	Eğitim Verisi Türü	0(m)	2(m)	4(m)	8(m)	16(m)	Ortalama Hata(m)
Logistic	Orjinal	0.49	0.49	0.81	0.86	0.91	4.8
	Orjinal+ Üretilen	0.57	0.57	0.89	0.94	0.96	2.7
SVM	Orjinal	0.48	0.48	0.85	0.88	0.93	4.0
	Üretilen	0.53	0.53	0.86	0.90	0.93	3.5
Multilayer Perceptron	Orjinal	0.53	0.53	0.81	0.85	0.90	4.9
	Orjinal+ Üretilen	0.59	0.59	0.85	0.91	0.94	3.3
BayesNet	Orjinal	0.45	0.45	0.79	0.86	0.91	4.7
	Orjinal+ Üretilen	0.52	0.52	0.82	0.87	0.92	4.2
KNN	Orjinal	0.41	0.41	0.73	0.85	0.91	5.3
	Orjinal+ Üretilen	0.39	0.39	0.72	0.85	0.90	5.8
Random Forest	Orjinal	0.49	0.49	0.88	0.94	0.96	3.2
	Orjinal+ Üretilen	0.54	0.54	0.86	0.92	0.95	3.3
J48	Orjinal	0.52	0.52	0.82	0.88	0.94	4.0
	Orjinal+ Üretilen	0.52	0.52	0.85	0.91	0.94	3.6

7. SONUÇ

Bu tez çalışmasında iç ortamlar için, ortamdaki sinyal kaynaklarından yayılan GSM ve Wi-Fi sinyal güçleri kullanılarak konum bilgisinin tespit edilmesi için bir sistem geliştirilmiştir. Geliştirilen konumlandırma sisteminde, ortamdaki GSM ve Wi-Fi verilerini toplamak için LG Nexus 4 mobil telefonu kullanılmıştır. LG Nexus 4 telefonu ile GSM ve Wi-Fi RSS verilerini toplamak için Android uygulaması geliştirilmiştir. Geliştirilen konumlandırma sistemi ek donanıma ihtiyaç duymamaktadır. Geliştirilen konumlandırma sisteminde RF parmakizi yaklaşımı kullanılmıştır.

Ayrıca, yapılan tez çalışması kapsamında, Gebze Center alışveriş merkezinden 2 metre aralıklarla 40, 100 ve 200 noktada toplanan RSS değerleri kullanılarak performans analizi ve testler yapılmıştır. Makine öğrenmesi algoritmalarının, eğitim verisi toplama süresinin, referans nokta sayısının ve referans sinyal türü gibi pratik faktörlerinin konumlandırma sisteminde üzerinde etkileri araştırılmıştır. Test edilen makine öğrenmesi algoritması arasında en iyi performansı BayesNet algoritmasının verdiği gözlemlenmiştir. Ayrıca, referans nokta sayısının ve eğitim verisi toplama süresinin artması konum hatasını azaltmıştır. Sinyal türü olarak, Wi-Fi sinyal türü GSM sinyal türüne göre konum kestirmede daha iyi sonuçlar vermiştir. Konum hatasını azaltmak için ve konumlandırma sisteminin performansını artırmak için bazı yaklaşımlar önerilmiştir. Bu yaklaşımlar, sinyal türlerinin birleştirilmesi, algoritmaların yeniden karar vermesi, sinyal güçlerinden yeni referans noktalarının elde edilmeleri ve sanal eğitim verileri üretme yaklaşımlarıdır. Bu yaklaşımların hepsinin ayrı ayrı konum hatasını düşürdüğü gözlemlenmiştir.

Bu tez çalışmasında ele alınan iç ortam konum tespiti problemi için, yaygın olarak kabul görmüş bir sistem henüz günümüzde ortaya konulamamıştır. Testlerin yılın farklı zamanlarında, birçok farklı telefonda, çok büyük alanda, eğitim verisi toplama süresinin kısa olacak şekilde yapılması oldukça önemlidir. Ayrıca, geliştirilecek konumlandırma sisteminin, ek donanımlara ve haberleşme altyapısına ihtiyacının olmaması da önemlidir.

KAYNAKLAR

- [1] Bayrak Ö., Temizyürek Ç., Barut M., Türkyılmaz Ö., (2007), “Ortam tahminine dayalı yeni bir mobil konumlama algoritması”, 15. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı, 1-4, Eskişehir, Türkiye, 11-13 Haziran.
- [2] Barut M., Bayrak Ö., Temizyürek Ç., Türkyılmaz O., (2006), “Hücresel ağlarda konum belirleme için RSS tabanlı çözümler”, 4. Elektrik-Elektronik Otomasyon ve Aydınlatma Fuarı, 1-5, Bursa, Türkiye, 6-10 Aralık.
- [3] Kök İ.Ş., (2009), “Bina içi Konumlandırma Sistemi”, Yüksek Lisans Tezi, Türkiye Odalar ve Borsalar Birliği Üniversitesi.
- [4] Yücel H., Yazıcı A., Edizkan R., (2014), “İç ortam konumlandırma sistemleri üzerine derleme”, 22. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı, 1-4, Trabzon, Türkiye, 23-25 Nisan.
- [5] Chan Y., Tsui W., Ching P., (2004), “Time-of-arrival based localization under NLOS conditions”, Journal of IEEE Transactions on Vehicular Technology, 55 (1), 17-24.
- [6] Gezici S., Poor H. V., (2009), “Position estimation via Ultra-Wide-Band signals”, Journal of Proceedings of the IEEE, 97 (2), 386-403.
- [7] Çakır O., Kaya İ., (2013), “Verici konumu tespitinde alıcı dağılımının konumlandırma hatası üzerindeki etkisinin incelenmesi”, 21. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı, 1-4, Girne, KKTC, 24-26 Nisan.
- [8] Web 1, (2014), <http://howdydesmond.blogspot.com.tr/2009/05/week-4-journal-practical-session.html>, (Erişim Tarihi: 24/05/2014).
- [9] Smith J., Abel J., (1987), “The spherical interpolation method of source localization”, Journal of IEEE Oceanic Engineering, 12(1), 246-252.
- [10] Urruela A., Sala J., Riba J., (2006), “Average performance analysis of circular and hyperbolic geo location”, Journal of IEEE Transactions on Vehicular Technology, 55 (1), 52-66.
- [11] Kaplan L. M., (2006), “Global node selection for localization in a distributed sensor network”, Journal of IEEE Transactions on Aerospace and Electronic Systems, 42 (1), 113-135.
- [12] Giorgetti G., Cidronali A., Manes G., (2009), “Single-anchor indoor localization using as witched-beam antenna”, Journal of IEEE Communications Letters, 13 (1), 58-60.

- [13] Zeng W. J., Li X.L., (2010), "High-Resolution multiple wideband and nonstationary source localization with unknown number of sources", Journal of IEEE Transactions on Signal Processing, 58 (6), 3125-3136.
- [14] Stella M., Russo M., Begušić D., (2013), "GSM-Based approach for indoor localization", Journal of World Academy of Science Engineering and Technology, 7 (4), 158-162.
- [15] Otsason V., (2005), "Accurate Indoor Localization Using Wide Gsm Fingerprinitng, Yüksek Lisans Tezi, Tartu Üniversitesi.
- [16] Özbayoğlu A.M., Kök İ. Ş, (2011), "Sinyal gücüne bağlı bina içi konum tespiti modelleri karşılaştırılması", Elektrik-Elektronik Bilgisayar Sempozyumu, 99-104, Elazığ, Türkiye, 5-7 Ekim.
- [17] Otsason V., Varshavsky A., LaMarca A., Lara E., (2005), "Accurate GSM indoor localization", 7th International Conference UbiComp, 141-158, Tokyo, Japonya, 11-14 Eylül.
- [18] Varshavskya, A., Lara E., Hightowerc J., LaMarcac A., Otsason V., (2007), "GSM indoor localization", Journal of Pervasive and Mobile Computing, 3 (6), 698-720.
- [19] Martin E., Vinyals O., FriedLand G., Bajcsy R., (2010), "Precise indoor localization using smart phones", Proceedings of the İnternational Conference on Multimedia, 787-790, Newyork, ABD, 25-29 Ekim.
- [20] Buyruk H., Keskin A. K., Şendil Ş., Çelebi H.,Partal H.P. İleri Ö., Zeydan E., Ergüt S., (2013), "RF parmakizi tabanlı GSM bina içi konumlandırma", 21. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı , 1-4, Girne, KKTC.
- [21] Miloš N. B., Aleksandar M. N., (2009), "Positioning in WLAN environment by use of artificial neural networks and space partitioning", Journal of Annals Telecommunications, 64(9), 665-676.
- [22] Web 2, (2014), <http://www.alparslan.edu.tr/bilgisistemleri/RFIDNedir.html>, (Erişim Tarihi: 20/05/2014).
- [23] Javed M. H. , Neskovi A., Magil E., (2005), "New neural network based mobile position estimation in a metropolitan area", 15th ICANN International Conference, 935 – 941, Warsaw, Polanya, 11-15 Eylül.
- [24] Salcic Z., Chan E., (2000), "Mobile station positioning using GSM cellular phone and artificial neural networks", Journal of Wireless Personal Communications, 14 (3), 235-254.
- [25] Lee H. J., Lee M. C., (2006), Localization of mobile robot based on radio frequency identification devices, IEEE SICE-ICASE International Joint Conference, 5934-5939, Busan, Güney Kore, 18-21 Ekim.

- [26] Nanli B. G., (2011), "Performance-based evaluation of RFID-based indoor location sensing solutions for the built environment", *Journal of Advanced Engineering Informatics*, 25(3), 535–546.
- [27] Pradhan A., Ergen E., Akinci B., (2009), "Technological assessment of radio frequency identification technology for indoor localization", *Journal of Comp. Civil Eng.* 23(4), 230–238.
- [28] Silva R., Goncalves P. A., (2009), "Enhancing the efficiency of active RFID-based Indoor location systems," *IEEE Wireless Communications and Networking Conference*, 1-6, Budapeşte, Macaristan, 5-8 Nisan.
- [29] Bouet M., Aldri L. S., (2008), "RFID tags: positioning principles and localization techniques", *1st IFIP Wireless Days*, 1-5, Dubai, Birleşik Arap Emirlikleri, 24-27 Kasım.
- [30] Stelzer A., Pourvoyeur K., Fischer A., (2004), "Concept and application of LPM a novel 3-D local position measurement system", *Journal of IEEE Transaction Microwave Theory Techniques*, 52(12), 2664-2669.
- [31] Toplan E., Ersoy C., (2012), "Yaşlı takibi amaçlı RFID tabanlı bina içi konum belirleme", *20. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı*, İstanbul, Türkiye, 18-20 Nisan.
- [33] Bekkali A., Sanson H., Matsumoto M., (2007), "RFID indoor positioning based on probabilistic RFID map and kalman filtering", *3.th IEEE Wireless and Mobile Computing-Networking and Communications*, 1-21, White Plains, New York, ABD, 8-10 Aralık.
- [33] Bouet M., Pujolle G., (2008), "A range-free 3-D localization method for RFID tags based on virtual landmarks", *19th IEEE Personal Indoor and Mobile Radio Communications*, 1–5, Cannes, Fransa, 15-18 Eylül.
- [34] Web 3, (2014), <http://mysystem.org/elektronik/Bluetooth.htm>, (Erişim Tarihi: 14/05/2014).
- [35] Ardıl E., (2009), "Esnek Hesaplama Yaklaşımı İle Yazılım Hata Kestirimi", *Yüksek Lisans Tezi*, Trakya Üniversitesi.
- [36] Web 4, (2014), <http://bmb.cu.edu.tr/uorhan/DersNotu/Ders10.pdf>, (Erişim Tarihi: 14/05/2014).
- [37] Web 5, (2014), <http://bmb.cu.edu.tr/uorhan/DersNotu/Ders02.pdf>, (Erişim Tarihi: 14/05/2014).
- [38] Web 6, (2014), <http://bmb.cu.edu.tr/uorhan/DersNotu/Ders03.pdf>, (Erişim Tarihi: 14/05/2014).
- [39] Web 7, (2014), <http://bmb.cu.edu.tr/uorhan/DersNotu/Ders06.pdf>, (Erişim Tarihi: 14/05/2014).

- [40] Web 8, (2014), <http://bmb.cu.edu.tr/uorhan/DersNotu/Ders09.pdf>, (Eriřim Tarihi: 14/05/2014).

ÖZGEÇMİŞ

Ahmet Bacak 1987 yılında Isparta’da doğdu. İlköğretim ve lise eğitimini Isparta’da tamamladı. 2005 yılında başladığı İstanbul Teknik Üniversitesi (İTÜ), Elektrik ve Elektronik Fakültesi, Elektronik Mühendisliği Bölümü’nü 2010 yılında başarıyla tamamladı. 2011 yılında yüksek lisans eğitimine GYTE Bilgisayar Mühendisliği Anabilim Dalında başladı. 2011 yılından bu yana TÜBİTAK BİLGEM Siber Güvenlik Enstitüsünde araştırmacı olarak çalışmaktadır.

EKLER

Ek A: Tez Çalışması Kapsamında Yapılan Yayınlar

Bacak A., Çelebi H., (2014), "Alınan sinyal gücü RF parmakizi tabanlı binaıçi konumlandırma sistemlerinde pratik faktörler", 22. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı , 1 - 4, Trabzon, Türkiye, 23-25 Nisan.