



SIVAS CUMHURİYET ÜNİVERSİTESİ
Sosyal Bilimler Enstitüsü
Yönetim Bilişim Sistemleri Ana Bilim Dalı

MAKİNE ÖĞRENMESİ YAKLAŞIMI İLE İÇ MEKÂN KONUM TESPİT SİSTEMİNİN TASARIMI

Yüksek Lisans Tezi

Emre YÜKSEK

Sivas
Ağustos 2020

SİVAS CUMHURİYET ÜNİVERSİTESİ
Sosyal Bilimler Enstitüsü
Yönetim Bilişim Sistemleri Ana Bilim Dalı

**MAKİNE ÖĞRENMESİ YAKLAŞIMI İLE İÇ MEKÂN KONUM
TESPİT SİSTEMİNİN TASARIMI**

Yüksek Lisans Tezi

Emre YÜKSEK

Tez Danışmanı
Doç. Dr. Ahmet Gürkan YÜKSEK

Sivas
Ağustos 2020

KABUL VE ONAY

Üniversite: : Sivas Cumhuriyet Üniversitesi
Enstitü : Sosyal Bilimler Enstitüsü
Ana Bilim Dalı : Yönetim Bilişim Sistemleri Ana Bilim Dalı
Tezin Başlığı : Makine Öğrenmesi Yaklaşımı ile İç Mekân Konum Tespit Sisteminin Tasarımı
Savunma Tarihi : 24.08.2020
Danışmanı : Doç. Dr. A. Gürkan YÜKSEK
Öğrenci ORCID No : 0000-0002-1885-5539

Unvanı - Adı Soyadı

İmza

Jüri Başkanı : Prof. Dr. Oğuz KAYNAR

ORCID No : 0000-0003-2387-4053

Üye : Doç. Dr. A. Gürkan YÜKSEK

ORCID No : 0000-0001-7709-6360

Üye : Doç. Dr. Metin ZONTUL

ORCID No : 0000-0002-7557-2981

Oy Birliği

Oy Çokluğu

Emre YÜKSEK tarafından hazırlanan Makine Öğrenmesi Yaklaşımı ile İç Mekân Konum Tespit Sisteminin Tasarımı başlıklı tez, kabul edilmiştir.

.../.../.....,

Prof. Dr. Ahmet ŞENGÖNÜL
Enstitü Müdürü

ETİK İLKELERE UYGUNLUK BEYANI

Sivas Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü bünyesinde hazırladığım bu Yüksek Lisans tezinin bizzat tarafımdan ve kendi sözcüklerimle yazılmış orijinal bir çalışma olduğunu ve bu tezde;

- 1- Çeşitli yazarların çalışmalarından faydalandığımda bu çalışmaların ilgili bölümlerini doğru ve net biçimde göstererek yazarlara açık biçimde atıfta bulunduğumu;
- 2- Yazdığım metinlerin tamamı ya da sadece bir kısmı, daha önce herhangi bir yerde yayımlanmışsa bunu da açıkça ifade ederek gösterdiğimi;
- 3- Başkalarına ait alıntılanan tüm verileri (tablo, grafik, şekil vb. de dâhil olmak üzere) atıflarla belirttiğimi;
- 4- Başka yazarların kendi kelimeleriyle alıntıladığım metinlerini, tırnak içerisinde veya farklı dizerek verdiğim yine başka yazarlara ait olup fakat kendi sözcüklerimle ifade ettiğim hususları da istisnasız olarak kaynak göstererek belirttiğimi,

beyan ve bu etik ilkeleri ihlal etmiş olmam halinde bütün sonuçlarına katlanacağımı kabul ederim.

24/08/2020

Emre YÜKSEK

TEŐEKKÜR

Tez alıŐmam boyunca bilgi ve deneyimlerinden daima yararlandıđım, danıŐmanım saygıdeđer hocam Do. Dr. Ahmet Gürkán YÜKSEK 'e her anlamda katkılarını ve desteđini esirgemeyen tez boyunca beni yönlendiren sabır ve anlayıŐı, bana inanıp güvendiđi ve her konuda desteklerini esirgemeyip yanımda olduđu için sonsuz teŐekkürlerimi sunarım.

Bana inanan, güvenen ve her zaman yanımda olup sabır gösteren aileme de beni destekledikleri için ok teŐekkür ederim.



İÇİNDEKİLER

İÇİNDEKİLER	İ
KISALTMALAR	V
TABLO LİSTESİ	vii
ŞEKİL LİSTESİ.....	ix
ÖZET.....	XV
ABSTRACT	XVII
GİRİŞ	1
BİRİNCİ BÖLÜM.....	15
1.İÇ MEKÂN KONUM ALGILAMA.....	15
1.1. İç Mekân Konumlandırma Yöntemleri	16
1.1.1. Gelen Sinyal Gücü Seviyesi Yöntemi.....	16
1.1.2. Parmak İzi Yöntemi	17
1.1.3. Geliş Açısı Yöntemi.....	18
1.1.4. Geliş Zamanı Yöntemi	19
1.1.5. Geliş Zamanı Farkı Yöntemi.....	21
1.1.6. Trilaterasyon	22
1.1.7. Üçgenleştirme	24
1.1.8. İç Mekân Konumlandırma Yöntemlerinin Kıyaslanması	25
1.2. İç Mekân Konumlandırma Standartları ve Teknolojileri	26
1.2.1. Bluetooth.....	27
1.2.2. RFID.....	28
1.2.3. Ultrasonic/Ultrasound	29

1.2.4. Kızılötesi	30
1.2.5. WiFi.....	31
1.2.6. ZigBee	31
1.2.7. İç Mekân Konumlandırma Teknolojilerinin Kıyaslanması.....	32
İKİNCİ BÖLÜM	35
2.KURAMSAL TEMELLER.....	35
2.1. Nesnelerin İnterneti	36
2.2. Makine Öğrenmesi	39
2.2.1. Regresyon Analizi	44
2.2.1.1. Doğrusal Lineer Regresyon Analizi.....	46
2.2.1.1.1. Basit Lineer Regresyon Analizi	46
2.2.1.1.2. Çoklu Lineer Regresyon Analizi.....	49
2.3. Bulanık Mantık.....	52
2.3.1. Klasik Küme ve Bulanık Küme Kavramları	53
2.3.2. Bulanık Küme Yaklaşımı	55
2.3.3. Bulanık Sistemler	57
2.3.3.1. Mamdani Bulanık Modeli	59
2.3.3.2. Takagi-Sugeno Bulanık Modeli	61
2.4. Yapay Sinir Ağları	64
2.4.1. Biyolojik Sinir Sistemi	64
2.4.2. Yapay Sinir Ağı.....	66
2.4.2.1. Yapay Sinir Ağları Modelleri.....	69
2.4.2.1.1. İleri Beslemeli Yapay Sinir Ağları.....	70
2.4.2.1.2. Geri Beslemeli Yapay Sinir Ağları	71
2.4.2.2. Yapay Sinir Ağlarında Öğrenme.....	72

2.4.2.3. Yapay Sinir Ağları Öğrenme Algoritması	72
2.5. Sinirsel Bulanık Mantık	76
2.5.1. Sinirsel Bulanık Mantık Ağ Yapıları	76
2.5.1.1. ANFIS (Adaptive Network Based Fuzzy Inference System – Adaptif Ağ Tabanlı Bulanık Sonuç Çıkarım Sistemi).....	78
2.6. K-En Yakın Komşu Algoritması (k-Nearest Neighbours, KNN)	83
ÜÇÜNCÜ BÖLÜM	85
3.MODELİN TASARIMI VE DENEYSEL SONUÇLAR.....	85
3.1. Çalışma Sahası ve Çalışma Ekipmanlarının Hazırlanması	87
3.2. Veri Setinin Hazırlanması	89
3.3. ANFIS Modelinin Kurulması ve Eğitilmesi	92
3.4. ANFIS Modelinin Test Edilmesi ve Sonuçların Alınması.....	95
4.5. YSA Modelinin Kurulması ve Eğitilmesi	113
SONUÇ.....	123
KAYNAKÇA	125
ÖZ GEÇMİŞ.....	141

KISALTMALAR

μs	Mikrosaniye / Microsecond
AOA	Geliş Açısı / Angle of Arrival
BLE	Düşük Enerjili Bluetooth / Bluetooth Low Energy
dBm	Desibel MiliWatt / Decibel-MiliWatts
GPS	Küresel Konumlandırma Sistemi / Global Positioning System
IR	Kızılötesi / Infrared
LOS	Görüş Açısı / Line of Sight
RFID	Radyo Frekansı ile Tanımlama / Radio-Frequency Identification
RSS	Gelen İşaret Gücü / Received Signal Strength
RSSI	Alınan Sinyal Gücü Göstergesi / Received Signal Strength Indicator
TDOA	Geliş Zamanı Farkı / Time Difference of Arrival
TOA	Geliş Zamanı / Time of Arrival
WiFi	Kablosuz Bağlantı Alanı / Wireless Fidelity



TABLO LİSTESİ

Tablo 1.1. Farklı Konum Algılama Yöntemlerinin Kıyaslanması	26
Tablo 1.2. Farklı Konum Algılama Teknolojilerinin Kıyaslanması.....	33
Tablo 3.1. Çalışma Sahasındaki Bölgelerdeki Vericilerden Alınan RSSI (dBm) Veri Serisi Örneği	90
Tablo 3.2. Bazı Bölgelerdeki Ortalama RSSI (dBm) Değerleri.....	91
Tablo 3.3. Veri Setini ANFIS Modelinin Eğitimi İçin Bölümlere Ayıran MATLAB Kodu.....	94
Tablo 3.4. ANFIS Modelinin Özelliklerinin Belirlendiği ve Eğitimin Yapılmasını Sağlayan MATLAB Kodu	94
Tablo 3.5. Farklı Üyelik Fonksiyonları ile Eğitilen ANFIS Modelinin Sonuç Kontrol Değerleri.....	95
Tablo 3.6. Farklı Üyelik Fonksiyonları ile Eğitilen ANFIS Modelinin İkinci Test Veri Seti İçin Sonuç Kontrol Değerleri.....	107
Tablo 3.7. Farklı Algoritmalar ile Eğitilen YSA Modelinin İkinci Test Veri Seti İçin Sonuç Kontrol Değerleri	121



ŞEKİL LİSTESİ

Şekil 1.1. RSSI Yöntemi.....	17
Şekil 1.2. Parmak İzi Yöntemi.....	18
Şekil 1.3. Geliş Açısı Yöntemi	19
Şekil 1.4. Geliş Zamanı Yöntemi.....	20
Şekil 1.5. Geliş Zamanı Farkı Yöntemi	21
Şekil 1.6. Trilaterasyon Yöntemi	23
Şekil 1.7. Üçgenleştirme Yöntemi	24
Şekil 1.8. İç Mekân Konumlandırma Teknolojileri	27
Şekil 1.9. Bluetooth Sinyalinin Dalga Boyu ve Frekans Aralığı	28
Şekil 1.10. RFID Etiketi	28
Şekil 1.11. RFID Dalga Boyu ve Frekans Aralığı	29
Şekil 1.12. Ultrasonic Ses Dalgalarının Dalga Boyu ve Frekans Aralığı	30
Şekil 1.13. Kızılötesi Dalgaların Dalga Boyu ve Frekans Aralığı.....	31
Şekil 1.14. Wifi Sinyallerinin Dalga Boyu ve Frekans Aralığı	31
Şekil 1.15. ZigBee Sinyallerinin Dalga Boyu ve Frekans Aralığı.....	32
Şekil 2.1. Nesnelerin İnterneti Ekosistemi.....	37
Şekil 2.2. Beş Katmanlı Nesnelerin İnterneti Mimarisi	38
Şekil 2.3. Makine Öğrenmesi Türleri	40
Şekil 2.4. Denetimli Öğrenme	41
Şekil 2.5. Sınıflandırma Yöntemi	42
Şekil 2.6. Denetimsiz Öğrenme	43
Şekil 2.7. Kümeleme Yöntemi.....	43
Şekil 2.8. Doğrusal Regresyon Analizi.....	45

Şekil 2.9. Doğrusal Olmayan Regresyon Analizi	45
Şekil 2.10. En Küçük Kareler Yöntemi	47
Şekil 2.11. Çoklu Lineer Regresyon Analizi	49
Şekil 2.12. Çoklu Lineer Regresyon Analizi	50
Şekil 2.13. Klasik Küme Yaklaşımı.....	54
Şekil 2.14. Bulanık Küme Yaklaşımı.....	54
Şekil 2.15. Klasik Küme ve Bulanık Küme Sınırları.....	54
Şekil 2.16. Bulanık Küme Üyelik Fonksiyonu ve Üyelik Değerleri	55
Şekil 2.17. Üçgen Üyelik Fonksiyonu	56
Şekil 2.18. Yamuk Üyelik Fonksiyonu.....	56
Şekil 2.19. Normal Dağılım Üyelik Fonksiyonu	56
Şekil 2.20. Çan Üyelik Fonksiyonu	56
Şekil 2.21. Bulanık Model Sistemi	58
Şekil 2.22. Mamdani Bulanık Mantık Modeli	61
Şekil 2.23. Takagi-Sugeno Bulanık Mantık Modeli	63
Şekil 2.24. Biyolojik Sinir Sistemi Sinyal İletimi.....	65
Şekil 2.25. Biyolojik Sinir Hücresi ve Bileşenleri.....	65
Şekil 2.26. Temel Yapay Sinir Ağı Hücre Yapısı.....	67
Şekil 2.27. Eşik ve Doğrusal Aktivasyon Fonksiyonu.....	68
Şekil 2.28. Logaritma Sigmoid ve Tanjant Sigmoid Aktivasyon Fonksiyonu	69
Şekil 2.29. İleri Beslemeli Yapay Sinir Ağı.....	70
Şekil 2.30. Geri Beslemeli Yapay Sinir Ağı.....	71
Şekil 2.31. Basit Perceptron Modeli	73
Şekil 2.32. Sinirsel Bulanık Mantık Sisteminin Birinci Yapısı	77
Şekil 2.33. Sinirsel Bulanık Mantık Sisteminin İkinci Yapısı	77

Şekil 2.34. Adaptif Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi.....	79
Şekil 2.35. Birinci Dereceden İki Girişli ve İki Kurallı Takegi-Sugeno Bulanık Modeli	80
Şekil 2.36. KNN Algoritması Çalışma Şekli	83
Şekil 3.1 Modellerin Genel Geliştirilme Süreci.....	85
Şekil 3.2. Çalışma Sahası Haritası	87
Şekil 3.3. Çalışma Sahasına Bluetooth Vericilerin Yerleşim Düzeni.....	88
Şekil 3.4. Bölgelere Ayrılmış Çalışma Sahası.....	89
Şekil 3.5. Kurulan ANFIS Modeli	92
Şekil 3.6. Kurulan ANFIS Modeli Yapısı.....	93
Şekil 3.7. ANFIS Modellerinin Ürettiği Sonuçlar Örneği	96
Şekil 3.8. ANFIS Modelinin dsigmf Üyelik Fonksiyonuna Ait Sonuç Grafikleri	97
Şekil 3.9. dsigmf Üyelik Fonksiyonu Eğitim, Doğrulama ve Test Veri Setleri Üzerindeki x Değerlerine Ait Regresyon Grafikleri	98
Şekil 3.10. dsigmf Üyelik Fonksiyonu Eğitim, Doğrulama ve Test Veri Setleri Üzerindeki y Değerlerine Ait Regresyon Grafikleri	99
Şekil 3.11. ANFIS Modelinin gaussmf Üyelik Fonksiyonuna Ait Sonuç Grafikleri	100
Şekil 3.12. gaussmf Üyelik Fonksiyonu Eğitim, Doğrulama ve Test Veri Setleri Üzerindeki x Değerlerine Ait Regresyon Grafikleri	101
Şekil 3.13. gaussmf Üyelik Fonksiyonu Eğitim, Doğrulama ve Test Veri Setleri Üzerindeki y Değerlerine Ait Regresyon Grafikleri	102
Şekil 3.14. ANFIS Modelleri trimf Üyelik Fonksiyonuna Ait Sonuç Grafikleri	104
Şekil 3.15. trimf Üyelik Fonksiyonu Eğitim, Doğrulama ve Test Veri Setleri Üzerindeki x Değerlerine Ait Regresyon Grafikleri	105

Şekil 3.16. trimf Üyelik Fonksiyonu Eğitim, Doğrulama ve Test Veri Setleri Üzerindeki y Değerlerine Ait Regresyon Grafikleri	106
Şekil 3.17. ANFIS Modellerinin İkinci Test Setiyle Ürettiği Sonuçlar Örneği.....	108
Şekil 3.18. dsigmf Üyelik Fonksiyonu ile Eğitilen ANFIS Modellerinin İkinci Test Veri Seti İçin Sonuç Grafiği.....	108
Şekil 3.19. dsigmf Üyelik Fonksiyonu ile Eğitilen ANFIS Modelinin İkinci Test Veri Seti Üzerindeki x ve y Değerlerine Ait Regresyon Grafikleri	109
Şekil 3.20. gaussmf Üyelik Fonksiyonu ile Eğitilen ANFIS Modellerinin İkinci Test Veri Seti İçin Sonuç Grafiği.....	110
Şekil 3.21. gaussmf Üyelik Fonksiyonu ile Eğitilen ANFIS Modelinin İkinci Test Veri Seti Üzerindeki x ve y Değerlerine Ait Regresyon Grafikleri	111
Şekil 3.22. trimf Üyelik Fonksiyonu ile Eğitilen ANFIS Modellerinin İkinci Test Veri Seti İçin Sonuç Grafiği	112
Şekil 3.23. trimf Üyelik Fonksiyonu ile Eğitilen ANFIS Modelinin İkinci Test Veri Seti Üzerindeki x ve y Değerlerine Ait Regresyon Grafikleri	113
Şekil 3.24. Kurulan YSA Modeli.....	114
Şekil 3.25. Kurulan YSA Modelinin Yapısı	114
Şekil 3.26. Levenberg-Marquardt Algoritması ile Eğitilen YSA Modelinin Sonuç Kontrol Değerleri	115
Şekil 3.27. Levenberg-Marquardt Algoritması ile Eğitilen YSA Modelinin Eğitim, Doğrulama ve Test Veri Setleri Üzerindeki x Değerlerine Ait Regresyon Grafikleri	116
Şekil 3.28. Levenberg-Marquardt Algoritması ile Eğitilen YSA Modelinin Eğitim, Doğrulama ve Test Veri Setleri Üzerindeki y Değerlerine Ait Regresyon Grafikleri	117
Şekil 3.29. Bayesian Regularization Algoritması ile Eğitilen YSA Modelinin Sonuç Kontrol Değerleri	118

Şekil 3.30. Bayesian Regularization Algoritması ile Eğitilen YSA Modelinin Eğitim ve Test Veri Setleri Üzerindeki x Değerlerine Ait Regresyon Grafikleri..... 119

Şekil 3.31. Bayesian Regularization Algoritması ile Eğitilen YSA Modelinin Eğitim ve Test Veri Setleri Üzerindeki y Değerlerine Ait Regresyon Grafikleri..... 120





ÖZET

Günümüzde dış mekân konumlandırma sistemleri hastaneler, havaalanları, fabrikalar ve alışveriş merkezleri gibi birçok iç mekânda da kullanılmaktadır. Ancak GPS gibi dış mekânda oldukça başarılı olabilen konumlandırma sistemleri, uydu görüş açısının sürekli sağlanamaması veya düşük çekim kalitesi sebebiyle iç mekânlarda aynı şekilde başarı sağlamamaktadır. Bu bakımdan iç mekânda en az masraf ile en hassas konumlandırmanın sağlanabilmesi için birçok yöntem geliştirilmektedir. Bu yöntemlerden birisi olan parmak izi ile konumlandırma, kullanımı yaygın mobil cihazlar gibi donanımlar ile çevrede bulunan sinyalleri kullanarak başarılı konumlandırma yapabilmesi sayesinde diğer iç mekân konumlandırma yöntemlerinden ayrılmaktadır.

Bu tez çalışmasında nesnelerin interneti çerçevesinde makine öğrenmesi yaklaşımı kullanarak daha başarılı bir iç mekân konumlandırma sisteminin geliştirilmesi amaçlanmıştır. Çalışmanın ilk aşamasında nesnelerin interneti kullanılarak iç mekândan toplanan veriler ile referans bir parmak izi veri tabanı oluşturulmuştur. İkinci aşamada ise makine öğrenmesi modelleri kurularak, ilk aşamada oluşturulan parmak izi veri tabanı ile eğitilmiş ve anlık sinyal değerleri kullanılarak konum tespiti yapılmaya çalışılmıştır.

Anahtar Kelimeler: İç Mekân Konumlandırma, Nesnelerin İnterneti, Makine Öğrenmesi



ABSTRACT

Today, outdoor positioning systems are also used in many interior spaces such as hospitals, airports, factories and shopping malls. However, positioning systems, such as GPS, which can be very successful outdoors, do not achieve similar success indoors due to the poor satellite viewing angle or poor shooting quality. In this regard, many methods are developed to provide the most precise positioning in the interior with the least cost. One of these methods, fingerprint positioning, is distinguished from other indoor positioning methods thanks to its ability to perform successful positioning using equipment such as mobile devices that are widely used, and by using the signals in the environment.

In this thesis, it is aimed to develop a more successful indoor positioning system by using machine learning approach within the framework of the Internet of Things. In the first stage of the study, a reference fingerprint database was created with the data collected from the interior using the internet of things. In the second stage, machine learning models were established, trained with the fingerprint database created in the first stage, and location determination was attempted using instant signal values.

Keywords : Indoor Localization, Internet of Things, Machine Learning



GİRİŞ

Son yılların Bilgi Teknolojileri (BT) alanındaki trendlerin başında akıllı olarak adlandırılan cihazların geniş ve yaygın olarak farklı disiplinlerde kullanımı gelmektedir. En genel tarif olarak akıllı cihazlar, kullanıcılar tarafından gönderilen basit komutları anlayan ve günlük etkinliklerde yardımcı olabilen, kullanıcılar ve birbirleri ile etkileşim yeteneğine sahip olan elektronik cihazlardır (akıllı telefonlar, tabletler, akıllı saatler, akıllı gözlükler ve diğer kişisel elektronikler). Aslında akıllı cihazların güçlü yönü uzaktan paylaşmak ve etkileşim kurmak için bir ağa bağlanma yetenekleriyle tanımlanmaktadır. Özellikle bulut bilişimin sağladığı olanakları ile akıllı cihazların yetenekleri birleştiren yenilikçi teknolojilerin güncelliği yeni ürünlerin geliştirilmesi ve kullanıcılara sunulması için geniş imkânlar sunmaktadır. Kısaca bahsi geçen bu birlikteliğe örnek olarak verilebilecek konum bilgilerinin algılanması, bu bilgiler üzerinden destekler sunarak kişilerin veya nesnelerin yönetilmesi yaygın kullanım alanlarına sahip bir teknolojidir. Bilindiği üzere küresel konumlandırma sistemi (Global Positioning Systems - GPS) temel konumlandırma teknolojilerinin başında gelmektedir. GPS düzenli olarak kodlanmış bilgi gönderen bir uydu ağıdır ve uydularla nesnelere arasındaki mesafeyi ölçerek bu nesnelerin dünya üzerindeki kesin konumlarını (hata payı ile birlikte) gerçek zamanlı olarak tespit etmeyi olanaklı hale getirmektedir. Bununla birlikte, modern binaların içindeki uydu sinyallerinin alınmasındaki önemli kayıp nedeniyle, GPS iç mekânlarda kullanıldığında makul bir konumlandırma sonucu elde etmek zordur. Dış mekânlarda yüksek doğrulukta konum tespitine olanak sağlıyorken, uydular ile direk görüş çizgisinin (LOS) sağlanamadığı durumlarda aynı başarıyı sunamamaktadır. GPS uyduları tarafından yayılan sinyaller engeller ile karşılaştığında şiddetlerinde zayıflama olan ortamlarda başarılı olamamaktadır. Bu bakımdan iç mekân konum algılama gereksinimi artarak farklı bir bağlamda araştırma odağı haline gelmiştir.

İç mekân (kapalı ortam) konumlandırma, son yılların yazılım ve donanım sistemlerinin sağladığı yenilik ve gelişmiş özellikleri üzerinden kapalı ortamların

konum bilgilerini algılayarak çalışacak uygulamalar için bağlam farkındalığı sağlandığından dolayı önemi giderek artan bir teknolojidir. Bununla birlikte mobil cihaz kullanıcılarının ve bağlantılı bilgi teknolojilerinin son yıllardaki hızlı artışı da iç mekân konumlandırmayı önemli kılmaktadır (Dziubany vd. 2018). Bir strateji analitiğinde raporlanan çalışmayla (Belloni 2010), insanların zamanlarının %80-90'ını kapalı ortamlarda geçirdikleri, hücresel aramaların %70'inin ve hücresel veri iletişiminin %80'inin kapalı ortamlardan gerçekleştirildiği saptanmış ve iç mekân konumlandırma sisteminin önemi ve ihtiyacından bahsedilmiştir. Yapılan diğer bir araştırmanın (ResearchAndMarkets 2018) sonucuna göre ise konum bazlı bilgi servisleri 2018 yılının sonlarında dünya genelinde yaklaşık olarak 1,5 milyardan fazla mobil kullanıcı seviyelerine çıkmış ve toplam gelirleri 3,494 milyar dolara ulaşmıştır ve 2027 yılında ise 24,6 milyar dolar gelir seviyesine ulaşması beklenmektedir. Bu doğrultuda iç mekân konumlandırma sistemleri ile bu sistemlerden faydalanan teknolojiler, uygulamalar ve yapılan çalışmaların sayısı her geçen gün artmaktadır. Ancak mevcut konumlandırma sistemleri güvenlik, doğruluk, işlevsellik ve kullanılabilirlik konusunda endüstriyel gereklilikleri tam olarak karşılayamamaktadır (Bai 2016). Bu sebeple gerek akademik düzeyde yapılan çalışmalarda gerekse de endüstrideki birçok araştırma grupları tarafından yapılan çalışmalarda iç mekân konumlandırma sistemlerinin bu handikaplarının giderilmesine uğraşılmaktadır. Çeşitli platform ve mimarilere sahip yenilikçi ve yaratıcı iç mekân konumlandırma sistemlerinin geliştirilmesi ve bunların uygulamalarda yüksek performanslarda çıktılar verecek şekilde tasarlanması için araştırmalara yoğunlaşmaktadır (Liu vd. 2007). Fakat bütün bu çabalara rağmen mevcut iç mekân konumlandırma sistemleri hala sınırlıdır (Ye 2012).

İç mekân konumlandırma, radyo sinyalleri, kızılötesi sinyaller, ses dalgaları ya da kablosuz sensör veya cihazlar tarafından elde edilen verileri kullanarak kapalı bir mekân içerisindeki kişi veya nesnelerin konumlarını tespit etmeye yardımcı olan sistemler olarak tanımlanmaktadır (Dempsey 2003; Zeimpekis vd. 2002). İç mekân konumlandırma sistemleri (kapalı ortam konumlandırma sistemleri), binalarda iç mekân navigasyonu, nesnelere veya etkinlikleri insanlara hatırlatmaya yönelik kişisel asistan, lojistikte mal hareketlerinin gerçek zamanlı olarak izlenmesine ve

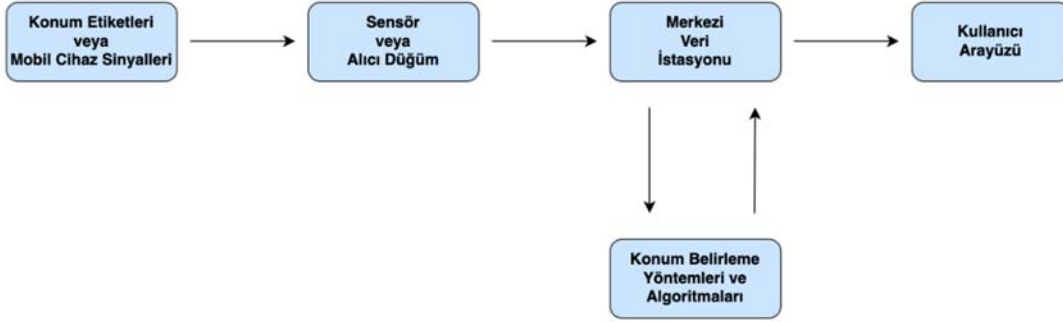
otomasyonuna olanak sağlayarak insan hatası ve ihmalinin azaltılmasına, akıllı kütüphane veya herhangi bir nesnenin kolayca bulunabileceği akıllı çalışma alanı gibi birçok potansiyel gerçek hayat uygulamaları için imkân sunmaktadır (Dwiyasa 2018). İç mekân konumlandırma ile alışveriş merkezlerinde müşterilere konuma dayalı reklamlar gösterilebilir ve kişisel dijital asistanlar yardımıyla müzeler ve tarihi yerlerdeki turlar için kullanılabilir (Zhang 2012). Akıllı ev ve ebeveynler için çocuk takibi gibi birçok farklı uygulama da iç mekân konumlandırmanın sayesinde insan hayatını kolaylaştırmaktadır. İç mekân konumlandırma aynı zamanda daha fazla iş fırsatı sağlamak için tüketiciler ve şirketler arasında etkileşim de sağlamaktadır (Yang vd. 2010).



Şekil 1.1. Dış Mekan ve İç Mekan Konumlandırma

Kaynak: Mautz Rainer (2012). Indoor Positioning Technologies.

Bir iç mekân konum algılama sistemi şekil 1.2’de gösterilen birkaç adımdan oluşmaktadır. İlk olarak etiketler veya mobil cihazlar sinyalleri sensörlere veya alıcı düğümlere iletir, ardından sensörler veya alıcı düğümlerde toplanan veriler merkezi bir veri istasyonuna iletilir, bu veri istasyonu konum belirleme yöntemleri ve algoritmalarını kullanarak cihazların veya etiketlerin konumlarını hesaplar ve son olarak da hesaplanan konum (x,y) koordinatları (2D – Two Dimension) ile birlikte kullanıcı arayüzünde bulunan bir haritada gösterilir (Gao 2018).



Şekil 1.2. İç Mekân Konumlandırma Yöntemi Çalışma Adımları

İç mekân konumlandırma alanında kablosuz iletişim teknolojilerinden olan Bluetooth, WiFi, RFID, Ultra-Wideband, Ultrasound ve ZigBee gibi birçok farklı teknolojiler kullanılmaktadır ve son yıllarda bu teknolojiler kullanılarak iç mekân konumlandırma alanında birçok farklı çalışmalar yapılmıştır (Deak vd. 2012; Gu vd. 2009; Liu vd. 2007).

İç mekân konumlandırma yapabilmek için çeşitli teknolojilerin geliştirilmesinin yanında, son yirmi yılda iç mekân konumlandırma alanında çeşitli yöntemler ve metotlar da kapsamlı şekilde araştırılmış ve bir dizi yaklaşımlar geliştirilmiştir (Han 2016). Gelen Sinyal Gücü Seviyesi (Received Signal Strength Indicator (RSSI)) alıcıya ulaşan sinyal seviyesine göre (Sumitra vd. 2018), Parmak İzi (Fingerprinting) önceden toplanmış sinyal bilgileri ile (Doiphode vd. 2016), Geliş Açısı (Angle of Arrival, AoA) alıcıya ulaşan sinyallerin varış açısını kullanarak (Liu 2018), Geliş Zamanı (Time of Arrival, ToA) sinyal yayılım zamanını kullanarak (Al-Ammar vd. 2014), Geliş Zamanı Farkı (Time Difference of Arrival, TDoA) yayılan sinyallerin geliş zamanı arasındaki farkı kullanarak (Nuaimi, Kamel 2011), Trilaterasyon (Trilateration) üç veya daha fazla referans düğümü ile arasındaki mesafeyi kullanarak (Dädeby, Hesselgren 2017), Multilaterasyon (Multilateration) bilinen bir zaman ve konumdan sinyal gönderimi yapan vericilerle arasındaki mesafe farkını kullanarak (Dias 2016) ve Üçgenleştirme (Triangulation) üç farklı referans noktasından alınan sinyalin radyal mesafesini kullanarak (Oguntala vd. 2018) konum tespiti yapmaktadır.

Son yıllarda mobil cihazların artışı ve sosyal medyanın artan popülaritesi konum bazlı servislerde yoğun taleplerin oluşmasına neden olmuştur (Han 2016). Literatüre bakıldığı zaman son dönemlerde güvenilir ve hassas iç mekân konumlandırma sağlamak için büyük çaba sarf edilmiş ve çok sayıda araştırma yapıldığı görülmektedir.

Gonzalez ve Garcia, kullanıcının iç mekândaki konumunu izlemek için Bluetooth referans düğümlerini kullanan bir Bluetooth Konum Ağı (Bluetooth Location Network, BLN) sistemini geliştirmiştir. Bluetooth özellikli kullanıcı cihazı, Bluetooth referans düğümleriyle iletişim kurarak kullanıcı konum bilgisini bir ana düğüme iletir. Ana düğüm servis sunucularına bağlanır. BLN sistemi tipik hücresele ağlardan esinlenilmiştir ve oda düzeyinde bir hassasiyete sahiptir ve yakınlığa dayalı servisler için daha uygundur. Sistem, gerçek zamanlı olmayan, yaklaşık 11 saniyelik bir yanıt süresine sahiptir (Gonzalez, Garcia 2002).

Diaz ve çalışma arkadaşları, kullanıcı ile sabit Bluetooth alıcıları arasındaki mesafeyi hesaplamak için kullanıcı cihazlarından RSSI değerlerini kullanan Bluepass adlı Bluetooth tabanlı bir iç mekân konumlandırma sistemini geliştirmiştir. Bluepass sistemi merkezi bir sunucu, yerel bir sunucu, bir Bluetooth algılama cihazı ve kullanıcı cihaz için bir uygulamadan oluşmaktadır. Kullanıcı, sistemi kullanabilmek için mutlaka cihaza uygulamayı yüklemiş olmalı ve uygulamaya giriş yapmalıdır. Yerel sunucu tek bir haritayı göstermek için, merkezi sunucu ise farklı haritaları birbirine bağlamayı amaçlar. 2.33 m ortalama hata karesi (Mean Square Error, MSE) elde edilmektedir (Diaz vd. 2010).

Zafari ve çalışma arkadaşları, iç mekân konumlandırma sistemi için iBeacons kullanmıştır. RSSI değerleri, bir kullanıcı cihazındaki farklı iBeacons'tan toplanır ve bu değerleri farklı konumlandırma algoritmaları çalıştıran bir sunucuya iletir. Sunucu tarafında, Parçacık Filtresi (Particle Filter, PF) ve Kalman Filtresi - Parçacık Filtresi (Kalman Filter-Particle Filter, KF - PF) ve Parçacık Filtresi - Genişletilmiş Kalman Filtresi (Particle Filter-Extended Kalman Filter, PF - GKF) gibi yaklaşımlar, sistemin konumlandırma doğruluğunu artırmak için kullanılmaktadır. Deneysel sonuçlar, ortalama olarak, PF, KF - PF ve PF - GKF'nin sırasıyla 1,441 m, 1,03 m ve 0,95 m hassasiyet elde ettiğini göstermektedir. Sistem enerji açısından verimli ve başarılı

konumlandırma yapmasına rağmen, önemli bir gecikmeye neden olmakta ve iBeacons'in geliştirme ve yerleştirme süreci ek maliyete neden olmaktadır (Faheem 2016).

Kriz ve çalışma arkadaşları, ortalama konumlandırma doğruluğunu artırmak için BLE özellikli iBeacon ile WiFi tabanlı konumlandırma sistemini birleştirerek hibrit bir sistem geliştirmiştir. Başlangıçta, RSSI parmak izleri farklı referans düğümlerinden toplanır ve bir veri tabanında saklanır. Sistem çevrimiçi aşamada, kullanıcının Android cihazındaki uygulama RSSI değerlerini farklı sensörlerden alır ve ardından çevrimdışı değerleri kullanarak kullanıcının konumunu tahmin etmektedir. iBeacons ile WiFi teknolojilerinin birlikte kullanılması konumlandırma doğruluğunda %23 iyileşme sağlamakta ve median doğruluğu da 0,77 m olmaktadır. Sistem gerçek zamanlı olarak çalışmaz ve doğru bir tahmin elde etmek için çoklu RSSI değerlerine bağımlıdır (Kriz, Kozel 2016).

Kotanen ve çalışma arkadaşları, bir Bluetooth Bölgesel Konumlandırma Uygulamasının (Bluetooth Local Positioning Application, BLPA) tasarımını ve uygulamasını geliştirmiştir. Sistem ilk önce basit bir yayılım modeline göre alınan sinyal gücü seviyelerini mesafe tahminlerine dönüştürmekte ve daha sonra mesafe tahminlerine göre üç boyutlu konum tespitini yapmak için Genişletilmiş Kalman Filtresini (EKF) kullanmaktadır. BLPA'nın doğruluk oranı 3,76 m olmaktadır (Kotanen vd. 2003).

Aalto ve çalışma arkadaşları, Bluetooth özellikli cep telefonları arasında konum tabanlı bilgilerin aktarılmasını sağlamak için Gerçek Zamanlı Gezinme Yardımı (Real-Time Navigational Assistance, URNA) sistemini geliştirmiştir. Sistem Hücre Kaynağı (Cell of Origin, CoO) yöntemini kullanarak, bir koridorda yapılan testler sırasında konumlandırma doğruluğu 10 m ila 20 m olarak belirtilmiştir. URNA, cep telefonlarına konum farkındalığı sağlayan mobil reklamcılık için tasarlanmıştır (Aalto vd. 2004).

Zonith, konuşlandırılmış Bluetooth işaretçilerinden (her biri bir veya daha fazla odayı kapsayan) ve izlenecek kişilerin giydiği Bluetooth cihazlarından oluşan bir iç mekan konumlandırma modülüdür. Grafik bir arayüzde, kullanıcıların yerlerini

görüntülemek mümkündür. Zonith, işçi koruma uygulamaları ve otomatik alarm gönderimi için yeterli oda düzeyinde hassasiyet sağlamaktadır (Zonith 2000).

Wang ve çalışma arkadaşları, üzerinde RFID etiketleri bulunan farklı nesnelerin konumunu bulabilmek için üzerinde RFID bulunan bir robot kullanan RF-Compass sistemini geliştirmiştir. RF-Compass, hedefin konumunu tespit edebilmek için yeni bir uzay bölümlenme optimizasyon algoritması kullanmaktadır. Robot üzerindeki RFID etiketlerinin sayısı, alan bölümlerinin sayısını yansıtmaktadır. Bu nedenle RFID etiketlerinin sayısındaki artış, hedef nesneyi küçük bir bölgeyle sınırlandırarak konumlandırma doğruluğunu artırır. Ayrıca, robot üzerindeki artan RFID sayısı, cihaz oryantasyonunun hesaplanmasında da yardımcı olur. RF-Compass, ortalama 2,76 cm konumlandırma doğruluğuna sahiptir (Wang vd. 2013).

Shirehjini ve çalışma arkadaşları, mobil cihazın yerini ve yönünü hesaplamak için bir halının içerisine RFID etiketleri yerleştirmiş ve mobil cihazdaki okuyuculara dayanan RFID tabanlı bir iç mekân konumlandırma sistemi geliştirmiştir. Geliştirilmiş sistem kısa mesafe pasif RFID ve sensör verilerinin yorumlanmasına yardımcı olan diğer çevre birimlerini kullanır. Mobil cihazdaki okuyucular halıdaki RFID etiketlerinden gelen bilgileri okur ve ardından konumunu hesaplamak için bilgileri kullanmaktadır. Geliştirilen sistem ortalama 6,5 cm konumlandırma doğruluğuna ulaşmaktadır (Shirehjini vd. 2012).

Seco ve çalışma arkadaşları, 1600 m²'lik 55 odayı kapsayan 71 aktif RFID etiketi kullanarak geliştirdikleri sistemde ortalama 1,5 m konumlandırma doğruluğunu elde etmişlerdir. Sistem iç mekânda yayılan RSSI sinyallerinin mekânsal bağımlılığını tanımlamak için Gauss işlemlerini kullanmaktadır (Seco vd. 2010).

Wang ve çalışma arkadaşları, iç mekânlarda konumlandırma yapmak için aktif RFID etiketleri kullanan bir sistem geliştirmiştir. Sabit referans noktaları olan RFID etiketleri ortamda dağınık halde bulunmaktadır ve mobil kullanıcı aygıtı bir RFID okuyucusuna sahiptir. Sistem iki aşamalı bir çalışma prensibine sahiptir. İlk aşamada boşluklardaki sinyalin gücü analiz edilmektedir. İkinci aşamada ise kullanıcının hareketi sinyal gücü kullanılarak analiz edilmektedir. Sistemin doğruluğunu artırmak için etiket sayısının artırılması ek maliyete yol açmaktadır (Ching vd. 2009).

Hightower ve çalışma arkadaşları, RFID etiketleri kullanarak konum algılama yapan olan SpotON sistemini geliştirmiştir. Geliştirilen sistem iç mekân ortamında farklı varlıkların yerini bulmak için RSSI bilgisini kullanmaktadır. Sistemde RFID etiketleri, etiketlenmiş kullanıcıların veya varlıkların birbirlerine göre göreceli konumlarını iletmektedir ve sistem ancak bir oda ortamında çalışabilmektedir. SpotON sisteminde RFID etiketlerinin mutlak konumunun bilinmesi zorunluluğu vardır (Hightower vd. 2001).

Sonitor, oda düzeyinde hassasiyette hastanelerde hasta ve ekipman takibi amacıyla geliştirilmiş ve piyasada satılan bir ultrasound konumlandırma sistemidir. Kullanıcı tarafından giyilen ve hareketle aktifleşen etiketler, sinyali işleyen ve ilgili bilgiyi LAN veya WLAN vasıtasıyla merkezi bir sunucuya aktaran duvara monte edilmiş alıcılara benzersiz tanımlama kodlarıyla ultrasound sinyaller iletir. Sistemde maksimum aralık 18 m olarak belirlenmiştir (Sonitor 1997).

Ward ve çalışma arkadaşları, ultrasound sinyaller kullanarak BAT iç mekân konumlandırma sistemini geliştirmiştir. Havadaki ses dalgalarının düşük hızı nedeniyle (330 m/s), konumlandırma sisteminin doğruluğu diğer teknolojilere kıyasla önemli ölçüde iyileşir. Bir BAT sisteminde, konumu tespit edilecek cihazlara özel vericiler sağlanır. Pozisyonları sabit ve bilinen alıcılar iletilen sinyali alır ve kullanıcının konum tahmininde kullanır. BAT sisteminde vericilerin ve alıcıların senkronize edilmesi gerekliliği vardır. BAT sistemi konum tespitini üç boyutlu olarak 3 cm kadar bir hassasiyette yapmaktadır. Ancak BAT sisteminde ultrasound sinyallerinin kullanımı nedeniyle sensörlerin yerleştirilmesinde hassasiyet gösterilmesi gerekmektedir. Ayrıca sistem pahalı olan birçok özel bağlantı noktası gerektirmektedir (Ward vd. 1997).

Cricket sistemi, iç mekân konumlandırma yapmak için RF sinyalleri ve ultrasound sinyallerin bir kombinasyonunu kullanmaktadır. Radyo sinyalini yalnızca alıcıları senkronize etmek için kullanmaktadır. Cricket sistemi, alıcı ile verici arasında herhangi bir senkronizasyon gerektirmez. Sistem konumlandırmayı 10 cm hassasiyetle yapar ancak özel donanım gerektirir ve ultrasound teknolojinin kullanımı nedeniyle sınırlıdır (Priyantha vd. 2000).

Want ve çalışma arkadaşları tarafından geliştirilen Active Badge sistemi, kızılötesi iç mekân konumlandırma sistemlerin içerisinde ilklerden ve en çok tanınanlardan bir sistemdir. Sistem insanları oda düzeyinde konumlandırmak için tasarlanmıştır. Bina personeli, 0,07 Hz bandında benzersiz kodlarla kısa kızılötesi sinyaller yayan Active Badges takmaktadır. Sinyaller, binanın içine yerleştirilmiş sabit kızılötesi alıcıları tarafından bir ağda toplanır. Active Badges sistemi Hücre Kaynağı (CoO) yöntemini kullanmakta ve konumlandırma doğruluğu 6 m olmaktadır. Active Badges sisteminin en büyük dezavantajı 15 saniye olan konum güncelleme hızının gerçek zamanlı uygulamalar için uygun olmamasıdır (Want vd. 1992).

Atsuumi ve çalışma arkadaşları tarafından kızılötesi ışınların özel bir uygulaması geliştirilmiştir. Sistem, açısal bilgi sağlayarak konumlandırma sistemlerinin entegrasyonunun sensör kaymasını azaltmak için tasarlanmıştır. İsabet açısı, polarize kızılötesi ışığın kullanılmasıyla tek bir kızılötesi etikete göre tahmin edilir. Kızılötesi etiket, bir kızılötesi ışık kaynağından ve sadece tek bir düzlem boyunca salınan ışığı geçiren bir optik polarize filtreden oluşur. Alıcı, bir fotoğraf dedektöründen ve yatay açığa bağlı olarak sinyal yoğunluğunun azalmasına neden olan dönen bir polarizörden oluşur. Değişen zaman sinyalinin fazı polarizasyon düzleminin açısına çevrilir. Bu açı bilgileri kullanılarak konum tespiti yapılmaktadır (Atsuumi, Sano 2010).

Hauschildt ve çalışma arkadaşları, insan derisinin termal radyasyonunu tespit etmek için pasif termal kızılötesi sensörlerine dayanan bir konumlandırma sistemi geliştirmiştir. Termal kızılötesi yaklaşımları, kızılötesi kameralara kıyasla daha düşük çözünürlükte bir dizi termokupl (ısı çifti) kullanır. Radyasyon kaynağına göre açılar ölçüldüğü odanın köşelerine çoklu sensörler yerleştirilmiştir. Konum daha sonra geliş açısı prensibi ile kabaca tahmin edilmektedir. Birden fazla ısı çifti dizisinden üçgenleştirme yöntemi ile insanların pozisyonları belirlenmektedir (Hauschildt, Kirchhof 2010).

Luo ve çalışma arkadaşları, kullanıcının yerini bulmak için WiFi erişim noktalarından alınan RSSI değerlerini kullanmaya dayanan Pallas sistemini geliştirmiştir. Pallas sistemi ilk olarak WiFi erişim noktalarından alınan RSSI bilgileri ile kat planını oluşturur. Ardından kullanıcının WiFi erişim noktalarındaki RSSI

bilgilerini kullanarak kullanıcının oluşturulan kat planında konumlandırılmasını yapmaktadır (Luo vd. 2017).

Kotaru ve çalışma arkadaşları, kullanıcı konumunu elde etmek için kullanılan geliş açısı ve uçuş süresi yöntemleriyle doğru bir tahmini elde etmek için kanal durum bilgisi (Channel State Information, CSI) ve RSSI bilgilerini kullanan SpotFi sistemini geliştirmiştir. SpotFi, pahalı donanım bileşenlerine gerek kalmadan standart WiFi kartı kullanarak ortalama 40 cm doğruluk payıyla konumlandırma sağlar (Kotaru vd. 2015).

Carrera ve çalışma arkadaşları, WiFi parmak izleri ile manyetik alan ölçümleriyle kombine ederek oda düzeyinde konum tespiti yapmak için ayırt edici öğrenme (discriminative learning) temelli bir sistem geliştirmiştir. Manyetik alan ölçümleriyle haritası çıkarılan odada parmak izi yöntemiyle kullanıcının konumu tespit edilmektedir. Sistem 1,44 m doğruluk payıyla konumlandırma yapmaktadır (Carrera vd. 2018).

Biehl ve çalışma arkadaşları, oda düzeyinde konumlandırma yapmak için geliştirdikleri özel bir yazılımla WiFi temelli olan LoCo sistemini geliştirmiştir. Sistemde bir sınıflandırıcı ilk önce çevrimdışı aşamada WiFi erişim noktalarından gelen RSSI değerleri ile boosting öğrenme yöntemi kullanılarak eğitilir. Çevrimiçi aşamada ise kullanıcı cihazından toplanan RSSI değerleri kullanıcının muhtemel yerini tahmin etmek için kullanılır (Biehl vd. 2014).

Ou ve çalışma arkadaşları, geliştirdikleri sistemde geleneksel üçgenleştirme yöntemine ek olarak özel yakınlık öğrenme ve konumlandırma ile daha hızlı bir hesaplama tekniğini kullanmış ve konumlandırma süresini azaltmaya çalışmıştır. Sistem ZigBee modüllerinden alınan RSSI bilgilerini kullanarak konum tespitini ortalama 0,42 m hata payı yapmaktadır (Ou vd. 2017).

Uradzinski ve çalışma arkadaşları, konum tespiti yapmak için parmak izi yöntemini kullanarak bir sistem geliştirmiştir. Sistemden alınan parmak izlerini en yakın komşu (the nearest algorithm), ağırlıklı en yakın komşu (weighted nearest algorithm) ve bayes (bayesian algorithm) algoritmalarını kullanarak konum tespiti yapmış ve algoritmaların performanslarını kıyaslamıştır. Sistem ağırlıklı en yakın

komşu algoritması ile 0.51 m hata payı ile konum tespitinde en iyi sonucu vermiştir (Uradzinski vd. 2017).

Makine öğrenmesi (Machine Learning, ML), yazılım uygulamalarının açıkça programlanmadan sonuçları tahmin etmede daha doğru olabilmesini sağlayan bir yapay zeka alanıdır (SearchEnterpriseAI 2017). Sayısı her geçen gün artan akıllı cihazların çoğunda mevcut sensörler ile büyük miktarda toplanan veri makine öğrenmesi ile konumlandırma sistemlerine yardımcı olmak için kullanılabilir (Jain 2019). Makine öğrenmesi modelleri, büyük veri kümeleri arasında gezinmek ve iç mekân konumlandırma için önemli bilgi gruplarını bulmak için mükemmel bir çözümdür ve iç mekân konumunu bulmak için doğru modeller oluşturur (Mascharka, Manley 2016). Makine öğrenmesi, denetimli öğrenme ve denetimsiz öğrenme olmak üzere iki kategoriye ayrılır. Denetimli öğrenme sonuçları bilinen bir girdi veri kümesini alır ve yeni verilere yanıt vermek için bir model oluştururken, denetimsiz öğrenme sonuçları bilinmeyen bir girdi veri kümesinden model oluşturarak yeni verilere yanıt verir (MathWorks 2018). Makine öğrenmesinin iç mekân konumlandırmada doğru ve güçlü sonuçlar elde etme, maliyet düşürme ve enerji tasarrufu sağlama konusunda sağladığı avantajlar bulunmaktadır (Ahmadi, Bouallegue 2017). Son yıllarda literatürde makine öğrenmesi ile iç mekân konumlandırma alanında yapılmış çalışmaların sayısının arttığı görülmektedir.

Malavalli ve çalışma arkadaşları, RSSI bilgilerini parmak izi yöntemi ve makine öğrenmesi ile kullanarak WiFi tabanlı bir iç mekân konumlandırma sistemi geliştirmiştir. Sistem Bayes modeli ile tahminde bulunmakta ve iki farklı mekânda testler gerçekleştirilmiştir. İlk testte 14 referans noktası bulunan bir koridorda makine öğrenmesi modelinin doğruluk skoru (f-score) 0.893 olurken 6 odalı bir evde gerçekleştirilen ikinci testte doğruluk skoru 0.994 olmuştur (Malavalli vd. 2017).

Mascharka ve çalışma arkadaşları, gömülü sensörlerden gelen verilerle makine öğrenmesi algoritmalarını test ederek iç mekân konumlandırmada en iyi algoritmayı bulmayı hedeflemiştir. Gerçek ortamdan elde ettikleri 3110 verilik veri kümesini 20 makine öğrenmesi algoritmasıyla test etmişler ve en iyi sonucu ortalama 0.76 m'lik hata payı ile K* algoritmasının verdiğini tespit etmişlerdir (Mascharka, Manley 2016).

Salamah ve çalışma arkadaşları, yaptıkları çalışmada makine öğrenmesi yaklaşımını kullanan WiFi tabanlı iç mekân konumlandırma sistemlerinin hesaplama zamanını düşürmek ve performansını artırmayı amaçlamıştır. Android tabanlı mobil cihaz kullanarak oluşturdukları deneysel ortamda sistemi hem statik hem de dinamik olarak test etmişlerdir. Önerdikleri sistemin performansını k-En Yakın Komşu (k-Nearest Neighbor), Karar Ağacı (Decision Tree), Rasgele Orman (Random Forest) ve Destek Vektör Makinesi (Support Vector Machine) algoritmaları ile test etmişlerdir. Sistemin konumlandırma başarısı statik modda Rasgele Orman ile %70 ve dinamik modda da k-En Yakın Komşu ile %33 artış göstermiştir (Salamah vd. 2016).

Hsieh ve çalışma arkadaşları, geliştirdikleri makine öğrenmesi yaklaşımını sistemde Bluetooth teknolojisini ve Android tabanlı akıllı cihaz kullanmıştır. Bluetooth vericilerinden gelen sinyallerin RSSI bilgisine Kalman Filtresi Algoritmasını uygulayarak iç mekân konumlandırma da daha başarılı bir sonuç elde etmeye çalışmışlardır. Geliştirdikleri sistemi k-En Yakın Komşu, Destek Vektör Makineleri ve Rasgele Orman algoritmalarıyla test etmiş ve en başarılı sonucu k-En Yakın Komşu algoritması ile eğitilen model vermiştir (Hsieh vd. 2019).

AlHajri ve çalışma arkadaşları, iç mekân konumlandırmada yüksek doğrulukta konum tespiti yapabilmek için iki aşamalı makine öğrenimi yaklaşımına dayanan bir sistem geliştirmişlerdir. İlk aşamada ortam türünü tanımak için k-En Yakın Komşu algoritması kullanılmış, ikinci aşamada ise tanımlanan ortam türüne göre radyo frekans özelliklerinin en uygun kombinasyonu belirlenmiştir. Yapılan çalışmada ölçülen sinyallerden elde edilen gerçek veriler kullanılmış ve konum tespitindeki doğruluk oranı %50 ila %70 arasında artış göstermiştir (AlHajri vd. 2019).

Teran ve çalışma arkadaşları, IoT çerçevesinde WiFi ve Bluetooth teknolojilerinin ortak kullanıldığı bir iç mekân konumlandırma sistemi geliştirmiştir. Sistemde makine öğrenmesi yaklaşımıyla birlikte sinyal/gürültü oranı (Signal-to-Noise Ratio, SNR), RSSI bilgisi ile parmak izi yöntemi kullanılarak konum tespiti yapılmaktadır. Sistemde 4 adet Bluetooth vericisi ile 5 adet WiFi erişim noktası kullanılmış ve konum tespitindeki doğruluk oranı k-En Yakın Komşu algoritması ile %75 oranında artış göstermiştir (Terán vd. 2018).

Bu çalışmada makine öğrenmesi yaklaşımı ve nesnelerin interneti kullanılarak çevresel durumu sınırlı miktardaki eğitim verisinden öğrenebilen ve mevcut iç mekân konumlandırma sistemlerinden daha iyi doğruluk sağlayan, daha az maliyetli ve daha kısa eğitim süresi olan bir iç mekân konumlandırma sisteminin geliştirilmesi amaçlanmıştır. Gerçek ortamda kurulan sistemdeki Bluetooth vericilerinden alınan sinyallerin RSSI bilgileri ile makine öğrenmesi algoritmaları kullanarak bir model geliştirilmiştir. Geliştirilen modelin başarısı farklı ortamlarda test edilmiştir.

Bu tezde geliştirilen ve iç mekân konumlandırmayı daha başarılı hale getirilebilmeyi amaçlayan makine öğrenmesi modellerinin daha iyi anlaşılabilmesi için, kullanılan iç mekân konumlandırma yöntemleri ve teknolojileri ile makine öğrenmesi yöntemleri ve tekniklerinin ifade edilmesi gerekmektedir. Bölüm 2, iç mekân konumlandırma yöntemleri ve teknolojilerinin incelenmesinden oluşmaktadır. Bölüm 3'te kullanılan nesnelerin interneti kavramı ile makine öğrenmesi yöntemleri ve tekniklerinin detaylı bilgileri paylaşılmıştır. Bölüm 4'te makine öğrenmesi modellerinin kurulması, deneysel çalışmalar ve deneysel çalışmalardan alınan sonuçlara yer verilmiştir. Geliştirilen makine öğrenmesi modellerinin başarımlarını sonuç kısmında yorumlanmıştır.



BİRİNCİ BÖLÜM

1.İÇ MEKÂN KONUM ALGILAMA

Yirminci yüzyılın başından beri hızlı bir ilerleme sergileyen teknolojik gelişimler, toplumsal dinamikler üzerinde önemli değişimlerin oluşmasına zemin hazırlamıştır. İnsanlar vakitlerinin büyük çoğunluğunu iç mekân ortamlarda geçirme alışkanlığı edinmiş olmaları, mobil cihazların/uygulamaların kullanımının yoğun bir şekilde artmış olması ve sosyal ağların artan popülaritesi gibi sayabileceğimiz alışkanlıklar toplum hayatını şekillendirici dinamikler arasına girmiştir. Saydığımız bu unsurlarda konum tabanlı servislere ve uygulamalara olan talebi tetiklemiş, bu tür uygulamaların artmasını ve önemli bir araştırma alanı olmasını sağlamıştır. GPS temelli sistemler dış mekân konum belirlemede oldukça etkili bir yöntem olsa da iç mekân konum belirlemede aynı başarıyı gösterememektedir (Svalastog 2007). Bu durum iç mekân konum tespiti problemlerinin çözümü için yapılan araştırma ve çalışmaların artmasını, yeni boyutlar kazanmasını ve güncel yoğun çalışılan bir alan olmasını beraberinde getirmiştir. Özetle; iç mekân konumlandırma sistemleri, radyo sinyalleri, kızılötesi sinyaller, ses dalgaları, kablosuz sensör veya cihazlar tarafından elde edilen verileri kullanarak kapalı bir mekân içerisindeki kişilerin veya nesnelerin konumlarını tespit etmeye yardımcı olan sistemlerdir.

İç mekân konumlandırma sistemleri günlük hayatın birçok aşamasında yaşama kolaylıklar sağlamaktadır; havalimanları, tren istasyonları, alışveriş merkezleri vb. gibi birçok kapalı mekânda rota oluşturma ve yön tarifi ile insanların hayatlarını kolaylaştırabilmektedir (Sonitor 1997; Zonith 2000). “Endüstri 4.0” (Xu vd. 2018) kavramı altında önem kazanan insansız üretime geçmeye başlayan fabrikalarda, robotların fabrika içinde parça ve malzeme taşımalarını konumlandırma sistemleri sayesinde yaptıkları da görülmektedir. Ticaret ve reklam sektöründe, alışveriş merkezlerinde aranan herhangi bir konumun kolayca bulunması ve tüketiciye bulunduğu konumda bulunan mağazaların kampanya ve fırsatlarından haberdar edilmesi de yine konumlandırma sistemleri sayesinde gerçekleştirilebilmektedir. Müzeler ve tarihi yerlerde düzenlenen turlarda kişinin bulunduğu konumdaki eserler

hakkında bilgilerin verilmesi iç mekân konumlandırma sistemleri ile mümkün olabilmektedir.

İç mekânda konum tespiti yapabilmek için birçok teknoloji ve bu teknolojilerin kullanıldığı yöntem ve metotlar bulunmaktadır. İç mekân konumlandırmada Bluetooth, WiFi, RFID, Ultra-Wideband, Ultrasound ve ZigBee gibi birçok farklı teknolojiler ve bu teknolojilerle Gelen Sinyal Gücü Seviyesi, Parmak İzi, Geliş Açısı ve Geliş Zamanı gibi birçok farklı yöntem kullanılmaktadır.

1.1. İç Mekân Konumlandırma Yöntemleri

Bir kaynağa yerleştirilmiş sensör (algılayıcı) cihazlardan alınan verilerin belirli metot ve algoritmalar kullanılarak iç mekândaki bir nesnenin bulunduğu konumun belirlenmesi konum algılama yöntemlerinin esasını teşkil etmektedir. Ancak iç mekânlar konum tespitinde kullanılan sensör cihazlar için, sensörlerin yerleştirildiği ortamın sinyal iletimine uygunluğu, sensörlerin birbirleri ile sağlıklı bilgi alışverişinde bulunabilmesi için aralarındaki mesafe ve ortamdaki başka cihazlardan yayılan sinyallerin oluşturduğu gürültü gibi birçok farklı zorluklar bulunmaktadır (Mautz 2012). Bununla birlikte iç mekân alanlar sinyallerin yayılımı zor olan ortamlardır. Seyrek görüş açısı, sinyallerin iç mekânda soğurulması, yansıması ve saçılması gibi etkenlere maruz kalması gibi pek çok problemle karşılaşılmaktadır. Bu problemleri çözebilmek için birçok teknik ve metot geliştirilmiştir.

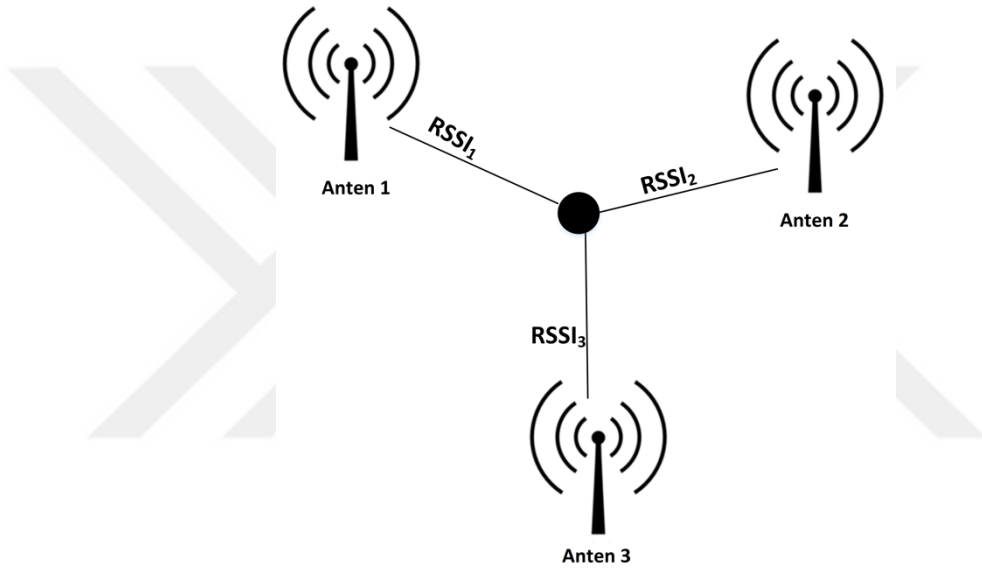
1.1.1. Gelen Sinyal Gücü Seviyesi Yöntemi

Gelen sinyal gücü yöntemi (Received Signal Strength Indicator, RSSI), iç mekân konum tespiti için en sık kullanılan yöntemlerden birisidir. RSS, vericiden alıcıya ulaşan sinyalin desibel-miliwatt (dBm) veya miliwatt (mW) cinsinden ölçülen değeridir. RSS değeri bir alıcı ile verici arasındaki mesafeyi ölçmek için kullanılır. RSS değeri ne kadar büyük olursa alıcı ile verici arasındaki mesafe o kadar azdır. Bir alıcı ile verici arasındaki mesafe ne kadar yakın ise sinyal o kadar güçlü olur, çünkü yayılan sinyal mesafe arttıkça zayıflar, sinyal gücü ile mesafe orantılıdır (Hara vd. 2005). Gelen sinyal gücü yönteminin en büyük avantajı kullanımının basit olması ve ekstra herhangi bir donanıma ihtiyaç duymamasıdır. Bu yöntemin en büyük

dezavantajı sinyal dağılımının harici parametrelerden etkilenmesi ve sinyallerin ideal dairesel yayılımdan ziyade düzensiz yayılım göstermesidir (Hara vd. 2005).

RSSI yöntemi ile konum tespiti eşitlik 1.1 ile yapılmaktadır. Şekil 1.1’de RSS temelli konum algılama sistemi gösterilmiştir.

$$d = d_0 \times 10^{\left(\frac{P_0 - P_d}{10n}\right)} \Leftrightarrow P(d) = P_0 - 10n \log_{10}\left(\frac{d}{d_0}\right) \quad \text{Eşitlik 1.1}$$



Şekil 1.1. RSSI Yöntemi

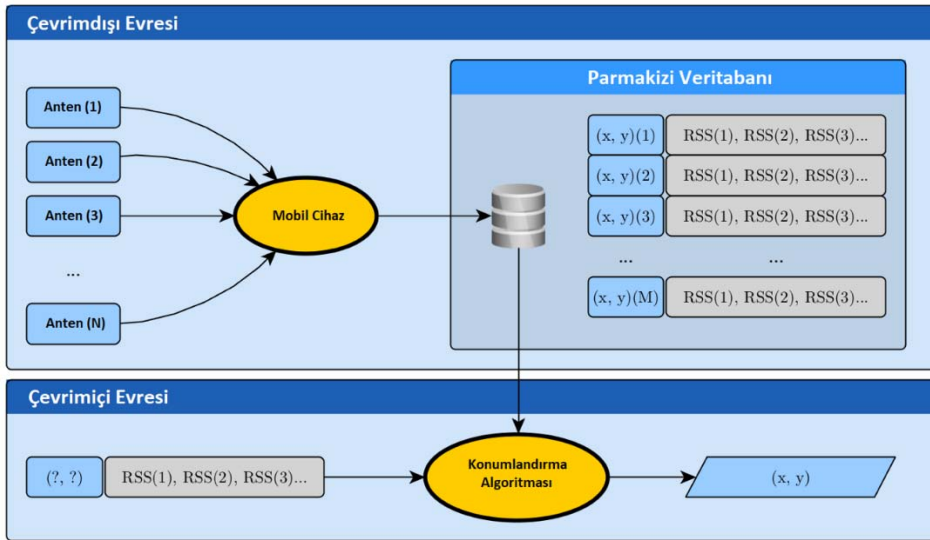
Kaynak: Zafari Faheem, Gkelias Athanasios ve Leung Kin (2017). A Survey of Indoor Localization Systems and Technologies.

Eşitlik 1.1’deki n değeri yol kaybı değeri (çevre şartlarına göre değişkenlik gösterir, örneğin iç mekân için 4 ve dış mekân için 2), P_0 değeri d_0 mesafesindeki sinyal gücü ve $P(d)$ ise konumu tespit edilecek nesnenin bulunduğu d konumundaki ölçülen sinyal gücünü temsil etmektedir.

1.1.2. Parmak İzi Yöntemi

Parmak izi (Fingerprinting) yöntemi, önceden toplanmış sinyal verileri ile bir nesne veya kişinin konumunun tespit edilmesi yöntemidir. Parmak izi yöntemi çevrimdışı (eğitim) ve çevrimiçi (test, konum tespiti) olmak üzere iki adımdan

oluşmaktadır. Çevrimdışı aşamasında vericilerden gelen sinyaller RSSI bilgileriyle toplanır ve vektörlerde kaydedilir (Chuenurajit vd. 2013). Her RSSI vektörü bilinen bir konumun parmak izini temsil eder ve çevrimiçi aşamasında kullanılmak üzere veri tabanında saklanır (Oguntala vd. 2018). Çevrimiçi aşamada hedef kişi veya nesne bulunduğu konumdaki RSSI bilgisini sunucuya gönderir. Sunucudaki konum algılama algoritması bazı benzerlik ölçümleri kullanarak hedefin RSSI vektörünü veri tabanında bulunan vektörlerle karşılaştırarak hedefin konumunu tahmin eder. Veri tabanı, sunucudan gönderilen vektörün en iyi korelasyonu ile konumu döndürür (Oguntala vd. 2018). Şekil 1.2’de parmak izi yöntemi detaylı şekilde gösterilmiştir.



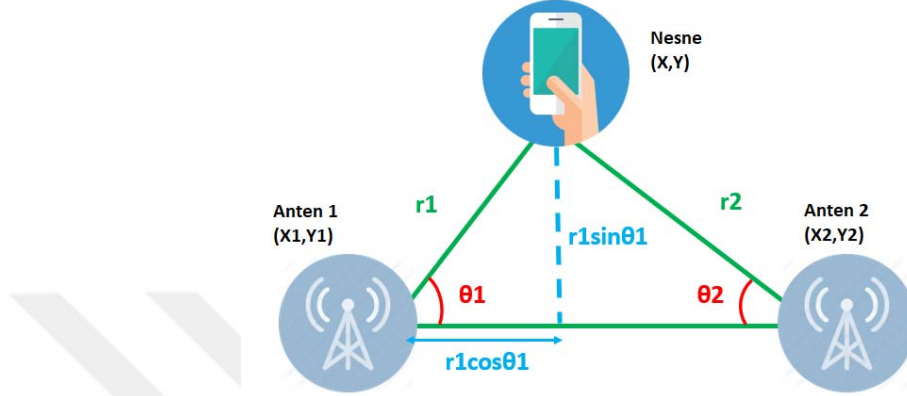
Şekil 1.2. Parmak İzi Yöntemi

Kaynak: Vandenabeele Thomas (2017). *Study of Wi-Fi Fingerprint-Based Indoor Positioning on a smartphone.*

1.1.3. Geliş Açısı Yöntemi

Geliş açısı (Angle of Arrival, AoA) yöntemi konumu tespit edilecek nesne veya kişiye ulaşan sinyallerin varış açısını belirleyerek konum tespit etme yöntemidir. Geliş açısı yönteminde hedefin konumunu, her biri bir vericiden hedefe doğru gönderilen sinyallerin hedefle yaptığı açı yönü çizgisi çiftlerinin kesişimi ile belirlenir (Liu vd. 2007). Geliş açısı yöntemi hedef nesne veya kişinin konumunu, konumu bilinen iki referans noktası ve bu referans noktalarından gönderilen sinyallerin hedef ile yaptığı

açıları kullanarak tespit eder. Yönü bilinen antenler veya anten dizileri geliş açısı yönteminin olmazsa olmazıdır. Şekil 1.3’de geliş açısı yönteminin çalışma prensibi gösterilmiştir. Geliş açısı yönteminde hata sayısı anten sayısı arttıkça azalmaktadır.



Şekil 1.3. Geliş Açısı Yöntemi

Kaynak: Ching-Chieh Chiu (2017). Indoor Positioning System with BLE and Wi-Fi technology—Data Analysis and Accuracy Improvement. <https://dspace.cvut.cz/handle/10467/70519> (Erişim Tarihi: 13.06.2019)

Geliş açısı yöntemi ile nesnenin konumu eşitlik 1.2 ve eşitlik 1.3 kullanılarak hesaplanır. Formüllerde (x_1,y_1) Anten1’in konumu, (x_2,y_2) Anten2’nin konumunu ve (x,y) ise nesnenin konumunu göstermektedir. Anten1’in nesne ile yaptığı açı θ_1 ve Anten2’nin nesne ile yaptığı açı ise θ_2 ile gösterilmiştir.

$$x = r_1 \cos \theta_1 = r_2 \cos \theta_2 \quad \text{Eşitlik 1.2}$$

$$y = r_1 \sin \theta_1 = r_2 \sin \theta_2 \quad \text{Eşitlik 1.3}$$


1.1.4. Geliş Zamanı Yöntemi

Geliş zamanı (Time of Arrival, ToA) yönteminde verici ve alıcı arasındaki mesafeyi hesaplamak için sinyal yayılım zamanını kullanılır. Geliş zamanı yönteminde vericiden alıcıya iletilen sinyalin vericiden çıktığı zaman ile alıcıya ulaştığı zamanın farkıyla hareket süresi hesaplanır (Fagan, Meier 2011). Geliş zamanı

yöntemi sinyal hareket süresinin ışık hızıyla çarpılmasıyla elde edilen Öklid mesafesi ile ilişkilendirilebilir (Oguntala vd. 2018). Bununla birlikte Öklid mesafesi kestirimi sinyalin ortamda yayılma hızına bağlıdır ve ortamın yapısal özelliklerinin doğru bir şekilde anlaşılmasını gerektirmektedir (Mautz 2009). Geliş zamanı yönteminin efektif kullanılabilmesi için referans noktalarının birbirleriyle senkronize olması ve gönderilen sinyallere zaman damgasının da eklenmesi gerekmektedir (Wymeersch vd. 2009). Konumu bilinen referans noktalarından zaman farkı alınarak eşitlik 1.4’de gösterildiği gibi her bir referans noktası ile nesne arasındaki mesafe hesaplanır. Eşitlikteki t_0 değeri vericiden nesneye giden sinyalin başladığı zamanı, t_i değeri vericiden gelen sinyalin nesneye ulaştığı zamanı temsil eder. C sabiti ise 3×10^8 m/s’dir.

$$r_i = (t_i - t_0) \times c \quad \text{Eşitlik 1.4}$$

Şekil 1.4’de üç farklı verici ile alıcı arasındaki mesafenin geliş zamanı yöntemi ile bulunması gösterilmiştir.




Şekil 1.4. Geliş Zamanı Yöntemi

Kaynak: Ching-Chieh Chiu (2017). Indoor Positioning System with BLE and Wi-Fi technology—Data Analysis and Accuracy Improvement. <https://dspace.cvut.cz/handle/10467/70519> (Erişim Tarihi: 13.06.2019)

1.1.5. Geliş Zamanı Farkı Yöntemi

Geliş zamanı farkı (Time Difference of Arrival, TDoA) yöntemi ile konum tespiti vericilerden yayılan sinyallerin geliş zamanları arasındaki fark kullanılarak yapılmaktadır. Geliş zamanı farkı yöntemi, farklı vericilerden gönderilen sinyallerin hedef kişi veya nesneye ulaştığı zamanların farkına dayanmaktadır (Ahson, Ilyas 2010). Vericilerden gönderilen sinyallerin geliş zamanı farkları hiperbollere dönüştürülür ve bu hiperbollerin kesişimi hedef nesnenin konumunu belirtir (Gentner, Jost 2013). Geliş zamanı farkı yönteminde vericilerin birbirleri ile senkronize çalışması gerekir. Şekil 1.5’de üç farklı vericinin alıcı ile arasındaki mesafenin geliş zamanı farkı yöntemi ile bulunması gösterilmiştir.



Şekil 1.5. Geliş Zamanı Farkı Yöntemi

Kaynak: Ching-Chieh Chiu (2017). Indoor Positioning System with BLE and Wi-Fi technology—Data Analysis and Accuracy Improvement. <https://dspace.cvut.cz/handle/10467/70519> (Erişim Tarihi: 13.06.2019)

Şekil 1.5’de gösterilen nesne (x,y) ile anten1 (x_1,y_1) , anten2 (x_2,y_2) ve anten3 (x_3,y_3) arasındaki mesafeler, sırasıyla eşitlik 1.5, eşitlik 1.6 ve eşitlik 1.7 kullanılarak hesaplanır. Nesne ile antenler arasındaki mesafeler sırasıyla r_1 , r_2 ve r_3 olarak gösterilmiştir.

$$r_1 = \sqrt{(x - x_1)^2 + (y - y_1)^2} \quad \text{Eşitlik 1.5}$$

$$r_2 = \sqrt{(x - x_2)^2 + (y - y_2)^2} \quad \text{Eşitlik 1.6}$$

$$r_3 = \sqrt{(x - x_3)^2 + (y - y_3)^2} \quad \text{Eşitlik 1.7}$$


Anten1 ve anten2 ile oluşan hiperbol eşitlik 1.8 kullanılarak hesaplanır. Yine anten1 ve anten3 ile oluşan hiperbol ise eşitlik 1.9 kullanılarak hesaplanır. Eşitlik 1.8 ve eşitlik 1.9 ile hesaplanan hiperbolik eğrilerin kesişim noktası nesnenin yerini vermektedir.

$$r_1 - r_2 = \sqrt{(x - x_1)^2 + (y - y_1)^2} - \sqrt{(x - x_2)^2 + (y - y_2)^2} \quad \text{Eşitlik 1.8}$$

$$r_3 - r_1 = \sqrt{(x - x_3)^2 + (y - y_3)^2} - \sqrt{(x - x_1)^2 + (y - y_1)^2} \quad \text{Eşitlik 1.9}$$

1.1.6. Trilaterasyon

Trilaterasyon (Trilateration) yöntemi bir nesnenin konumunu bilinen konumlara yerleştirilmiş referans noktalarına olan uzaklığını kullanarak tespit etmektedir. Trilaterasyon yöntemi referans noktalarını merkez kabul eden ve yarıçapı da hedef nesneye uzaklığı olan dairelerin kesişimi ile konum tespiti yapmaktadır (Svalastog 2007). Trilaterasyon yönteminin çalışma prensibi şekil 1.6'da görülmektedir. Şekil 1.6'da $A_0 (0, 0, 0)$, $A_1 (x_1, 0, 0)$ ve $A_2 (x_2, y_2, 0)$ noktaları referans noktalarını temsil etmektedir.



Şekil 1.6. Trilaterasyon Yöntemi

Kaynak: Dädeby Sebastian ve Hesselgren Joakim (2017). *A system for indoor positioning using ultra-wideband technology.* <https://hdl.handle.net/20.500.12380/249898> (Erişim Tarihi: 12.06.2019)

Nesnenin konumu referans noktalarının nesneye olan uzaklıkları kullanılarak sırasıyla eşitlik 1.10, eşitlik 1.11 ve eşitlik 1.12 kullanılarak hesaplanır.

$$x = \frac{r_0^2 - r_1^2 + x_1^2}{2x_1} \quad \text{Eşitlik 1.10}$$


$$y = \frac{r_0^2 - r_2^2 + x_2^2 + y_2^2}{2y_2} - \frac{x_2}{y_2}x \quad \text{Eşitlik 1.11}$$

$$z = \pm \sqrt{r_0^2 - x^2 - y^2} \quad \text{Eşitlik 1.12}$$

Eşitliklerdeki r_0 değeri ilk referans noktası ile nesne arasındaki mesafeyi, r_1 değeri ikinci referans noktası ile nesnenin arasındaki mesafeyi ve r_2 değeri üçüncü referans noktası ile nesnenin arasındaki mesafeyi göstermektedir. Eşitliklerdeki x , y ve z koordinatları ise konumu tespit edilecek nesnenin koordinatlarıdır. Trilaterasyon yöntemi N boyutlu bir noktanın konumunu bulabilmek için $N+1$ adet referans noktasına ihtiyaç duymaktadır.

1.1.7. Üçgenleştirme

Üçgenleştirme (Triangulation), bir nesnenin konumunu konumu bilinen referans noktalarına olan uzaklığı ve referans noktalarına yaptığı açıyı kullanarak tespit etmektedir. Üçgenleştirme yöntemi hedef nesnenin konumlandırılmasında üçgenin geometrik özelliğinden faydalanmaktadır (Oguntala vd. 2018). Üçgenleştirme yönteminde referans noktalarının hedef nesneye olan uzaklıklarını yarıçap olarak kabul eden çemberlerin kesişimi hedef nesnenin konumunu vermektedir. Üçgenleştirme yöntemi ile trilaterasyon yöntemi birbirine benzemekle birlikte aralarındaki tek fark üçgenleştirme yönteminde referans noktalarının hedefe olan uzaklığın yanı sıra hedef ve referans noktaları arasındaki açıyı da kullanmasıdır. Şekil 1.7’de çalışma prensibi gösterilen üçgenleştirme yönteminde (x_1, y_1) , (x_2, y_2) ve (x_3, y_3) noktaları referans noktalarını göstermekte ve referans noktalarının hedefe olan uzaklıkları ise b, c ve d ile ifade edilmektedir.



Şekil 1.7. Üçgenleştirme Yöntemi

Kaynak: Ching-Chieh Chiu (2017). Indoor Positioning System with BLE and Wi-Fi technology—Data Analysis and Accuracy Improvement. <https://dspace.cvut.cz/handle/10467/70519> (Erişim Tarihi: 13.06.2019)

Üçgenleştirme yönteminde referans noktalarının hedef nesneye olan uzaklıkları eşitlik 1.13, eşitlik 1.14 ve eşitlik 1.15 kullanılarak hesaplanır.

$$b^2 = x^2 + y^2 \Rightarrow x = \frac{b^2 + a^2 - c^2}{2a} \quad \text{Eşitlik 1.13}$$

$$c^2 = y^2 + (a - x)^2 \Rightarrow y \Rightarrow \pm \sqrt{b^2 - \left\{ \frac{b^2 + a^2 - c^2}{2a} \right\}^2} \quad \text{Eşitlik 1.14}$$

$$d = \sqrt{(X_3 - X')^2 + (Y_3 - Y')^2} \quad \text{Eşitlik 1.15}$$

1.1.8. İç Mekân Konumlandırma Yöntemlerinin Kıyaslanması

İç mekân konum algılama birçok farklı yöntem kullanılarak yapılmaktadır. İç mekânda konum algılamak için Gelen Sinyal Gücü Seviyesi, Parmak İzi, Geliş Açısı, Geliş Zamanı, Geliş Zamanı Farkı, Trilaterasyon ve Üçgenleştirme yöntemleri kullanılmaktadır. Gelen Sinyal Gücü Seviyesi alıcıya ulaşan sinyal seviyesine göre (Sumitra vd. 2018), Parmak İzi önceden toplanmış sinyal bilgileri ile (Doiphode vd. 2016), Geliş Açısı alıcıya ulaşan sinyallerin varış açısını kullanarak (Liu 2018), Geliş Zamanı sinyal yayılım zamanını kullanarak (Al-Ammar vd. 2014), Geliş Zamanı Farkı yayılan sinyallerin geliş zamanları arasındaki farkı kullanarak (Nuaimi, Kamel 2011), Trilaterasyon üç veya daha fazla referans düğümü ile arasındaki mesafeyi kullanarak (Dädeby, Hesselgren 2017) ve Üçgenleştirme üç farklı referans noktasından alınan sinyalin radyal mesafesini kullanarak (Oguntala vd. 2018) konum tespiti yapmaktadır.

İç mekân konumlandırmada kullanılan her bir yöntemin avantajı ve dezavantajı bulunmaktadır. Gelen Sinyal Gücü Seviyesi yöntemi uygulama basitliği, düşük maliyetli olması ve birçok farklı teknoloji ile kullanılabilir olması yönünden avantaj sağlarken; gürültüye karşı hassas olması ve çevresel koşullara bağımlı olması yönünden dezavantaj oluşturmaktadır. Geliş Açısı yöntemi yüksek konumlandırma doğruluğu, açı oluşturma bilgisi ve daha az sayıda referans noktası kullanması yönünden avantaj sağlarken; yüksek boyutlu ve maliyetli donanım ihtiyacı, karmaşık algoritmalarla çalışması ve uzun mesafelerde başarısız sonuçlar vermesi yönünden dezavantaj oluşturmaktadır. Geliş Zamanı yöntemi uygulanmasının basit ve ucuz olması ve yüksek konumlandırma doğruluğu yönünden avantaj sağlarken; bazı

zamanlarda senkronizasyon gerektirmesi yönünden dezavantaj oluşturmaktadır. Geliş Zamanı Farkı yöntemi ise yüksek konumlandırma doğruluğu, çok düğümlü desteği sunması ve yüksek konum güncelleme oranı sağlaması yönünden avantaj sağlarken; efektif olarak çalışması için birden fazla düğüm gerekliliği, karmaşık algoritmalarla çalışması ve senkronizasyon ihtiyacının olması yönünden dezavantaj oluşturmaktadır (Zandian 2019).

İç mekân konum algılama yöntemlerinden en sık kullanılan Geliş Zamanı yöntemi, Geliş Zamanı Farkı yöntemi, Geliş Açısı yöntemi ve Sinyal Kalite Bilgisi (RSSI) yöntemlerinin karşılaştırılması Tablo 1.1’de gösterilmiştir.

Tablo 1.1. Farklı Konum Algılama Yöntemlerinin Kıyaslanması

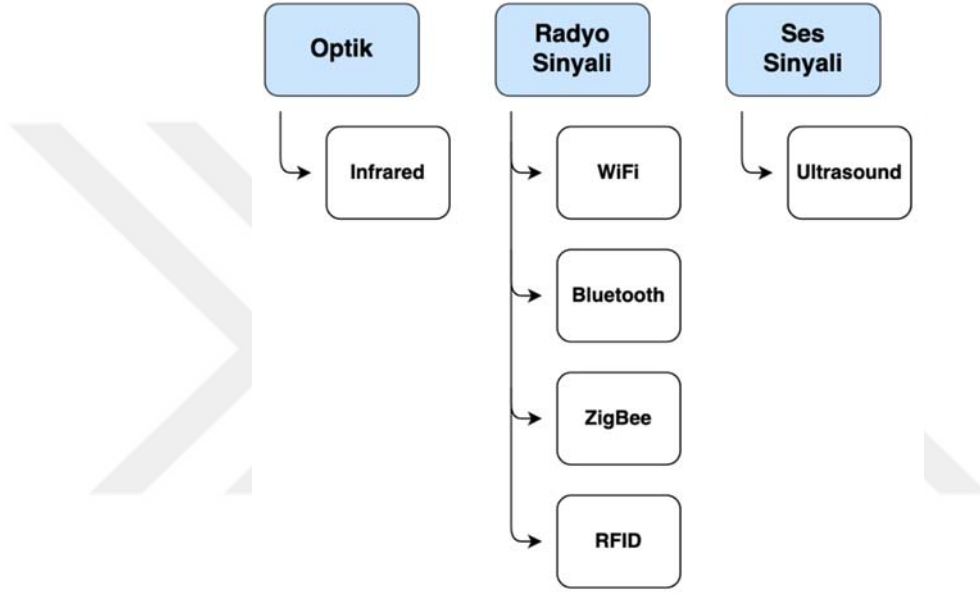
Konumlandırma Yöntemleri	Konumlandırma Temeli	Kısıtı
Geliş Zamanı Yöntemi	Gönderilen sinyalin zamanı	Zaman senkronizasyonu gereksinimi
Geliş Zamanı Farkı Yöntemi	Gönderilen sinyalin zamanı	Zaman senkronizasyonu gereksinimi
Geliş Açısı Yöntemi	Alınan sinyalin açısı	Yüksek hassasiyetli direkt anten gereksinimi
Sinyal Kalite Bilgisi	Sinyal gücü	Sinyal alımı için zaman ihtiyacı

Kaynak: Ching-Chieh Chiu (2017). Indoor Positioning System with BLE and Wi-Fi technology—Data Analysis and Accuracy Improvement. <https://dspace.cvut.cz/handle/10467/70519> (Erişim Tarihi: 13.06.2019)

1.2. İç Mekân Konumlandırma Standartları ve Teknolojileri

GPS temelli sistemler dış mekân konum belirlemede oldukça etkili olmasına rağmen, iç mekânlarda konum belirlemede aynı başarıyı gösterememektedir (Svalastog 2007). Bu durum iç mekân konumlandırma alanında farklı standartlar ve teknolojilerin geliştirilmesini ve birçok farklı teknolojiler kullanılmasını zorunlu

kılmıştır. İç mekân konumlandırma alanında kullanılan teknolojiler kullandıkları altyapı ve barındırdıkları özellikler bakımından optik, radyo sinyallerini kullananlar, ve ses dalgalarını kullananlar olarak gruplandırılabilir (Zandian 2019). İç mekân konumlandırmada Kızılötesi (Infrared), WiFi, Bluetooth, ZigBee ve Ultrasound gibi birçok teknoloji kullanılmaktadır. Şekil 1.8’de iç mekân konumlandırmada en çok kullanılan teknolojilerin gruplandırılması gösterilmiştir.




Şekil 1.8. İç Mekân Konumlandırma Teknolojileri

Kaynak: Zandian Reza (2019). Ultra-wideband Based Indoor Localization of Mobile Nodes in ToA and TDoA Configurations. <https://pub.uni-bielefeld.de/record/2934897> (Erişim Tarihi: 04.08.2019)

1.2.1. Bluetooth

Bluetooth, IEEE 802.11.5 standardına dayanan farklı sabit veya hareketli cihazlar arasında kablosuz ve kısa mesafeli, ses ve veri aktarılması için geliştirilmiş bir teknolojidir. Bluetooth teknolojisinin en yeni sürümü olarak bilinen Bluetooth Low Energy (BLE) eski sürümlere oranla daha yüksek enerji verimliliğine sahip 24 Mbps veri hızı ve 70-100 metre kapsama alanı sunması ile iç mekânda konum tespiti için oldukça uygun bir teknolojidir. Ayrıca çeşitliliği, düşük maliyeti ve enerji verimliliği ile BLE teknolojisinin avantajlarındandır. BLE teknolojisinin altyapısı genellikle 1 tip

cihazdan oluşur; BLE Beacon. Beacon'ların görevi periyodik olarak varlıklarını duyurmaktır. BLE Beaconlar periyodik olarak tüm BLE destekleyen cihazların alabileceği bir sinyal yaymaktadır. Bu sinyalin içeriğinde ise kimlik bilgisi (ID) ve sinyal kalite bilgisi (RSSI) bulunmaktadır. Şekil 1.9'da Bluetooth sinyalinin dalga boyu ve frekans değerleri gösterilmiştir.




Şekil 1.9. Bluetooth Sinyalinin Dalga Boyu ve Frekans Aralığı

Kaynak: Mautz Rainer (2012). Indoor Positioning Technologies. doi:10.3929/ethz-a-007313554

1.2.2. RFID


RFID (Radio Frequency Identification), üzerinde mikroişlemci ile donanmış etiket taşıyan bir nesnenin, bu etikette taşıdığı kimlik yapısı ile hareketlerinin izlenebilmesine imkân veren radyo frekansları ile çalışan bir teknolojidir (RFID Türkiye 2007).



Şekil 1.10. RFID Etiketi

RFID etiketleri temel olarak iki kategoriye ayrılmaktadır. Bunlar pasif ve aktif etiketlerdir. Pasif RFID etiketlerin kendilerine ait güç kaynakları yoktur ve enerji ihtiyacını RFID okuyucudan gelen enerji dalgaları ile karşılamaktadır. Aktif etiketlerin ise kendilerine ait güç kaynakları mevcuttur ve sinyal yayını yapabilmektedir. RFID okuyucu ise antenleri ile etiketlerin çiplerindeki kayıtlı bilgilerin okunup sisteme aktarılması görevini görmektedir. Şekil 1.11'deki gibi dalga boyu ve frekans

değerlerine sahip olan RFID sistemler katı cisim ve maddelerden büyük oranda geçebildikleri doğrudan görüş açısı olmayan ortamlarda da kullanılabilir.




Şekil 1.11. RFID Dalga Boyu ve Frekans Aralığı

Kaynak: Mautz Rainer (2012). Indoor Positioning Technologies. doi:10.3929/ethz-a-007313554

1.2.3. Ultrasonic/Ultrasound

Ultrasonic/Ultrasound konumlandırma sisteminin konsepti, deniz tabanındaki balinaların birbirleriyle iletişim kurmak veya yarasaların mağaralarda yönlerini bulmak için ultrasonic ses dalgalarını kullanmasına dayanmaktadır (Ching-Chieh 2017). Ultrasound tabanlı konum algılama teknolojisi, esas olarak ultrasonic ses sinyallerinin (> 20KHz) uçuş süresi (Time of Flight) ölçümlerine ve bir verici ile bir alıcı düğüm arasındaki mesafeyi hesaplamak için ses hızını kullanmasına dayanmaktadır. Ultrasound teknolojisi santimetre düzeyinde hassasiyetle iç mekân konum algılama doğruluğu sağlar ve aynı zamanda yüksek enerji verimliliği ve iç mekândaki odalar arasında sıfır sızıntıyla birden fazla mobil düğümü takip edebilme yeteneğine sahiptir (Hazas, Hopper 2006). Genellikle ultrasonic ses sinyali iletimi, gerekli senkronizasyonu sağlamak için bir RF (Radyo Frekans) sinyalleriyle birlikte yapılmaktadır. Bununla birlikte, RF sinyallerinin aksine, nem ve sıcaklık değiştiğinde ses hızı önemli ölçüde değişmektedir. Bu nedenle sıcaklık sensörleri bu değişiklikleri hesaba katmak için ultrasound sistemleriyle birlikte kullanılmaktadır (Zafari vd. 2017). Şekil 1.12’de ultrasonic ses dalgalarının dalga boyu ve frekans aralığı gösterilmektedir.




Şekil 1.12. Ultrasonic Ses Dalgalarının Dalga Boyu ve Frekans Aralığı

Kaynak: Mautz Rainer (2012). Indoor Positioning Technologies. doi:10.3929/ethz-a-007313554

1.2.4. Kızılötesi

Kızılötesi (Infrared, IR), görünür ışığa nazaran daha uzun dalga boylarına sahip elektromanyetik radyasyondur (EMR) ve ışık olarak adlandırılmasına rağmen görünmezdir. Görünür spektrumun nominal kırmızı kenarından 700 nm'de (frekans 430 THz), 10 mm'ye (300 GHz) kadar uzanır. Oda sıcaklığına yakın nesnelere tarafından yayılan termal radyasyonun çoğu kızılötesidir. Tüm EMR gibi, IR de parlak enerji taşır ve hem dalga gibi hem de kuantum partikülü foton gibi davranır. Kızılötesi (IR) konum algılama teknolojisi, televizyon ve mobil cihazlarda da bulunan kızılötesi sensörlerin konum algılamada kullanılmasına dayanmaktadır (Ching-Chieh 2017). Ayrıca, kızılötesi radyasyon aynı zamanda iç mekan konumlandırma yöntemlerinde kullanılan ilk kablosuz sensör teknolojisidir (Casas vd. 2007). Kızılötesi konum algılama sistemlerinin hassas konum tespiti yapabilmesi için alıcı ile verici arasında doğrudan bir görüş olması ve aynı ortamda olması gerekmektedir. Kızılötesi konum algılama sistemleri iç mekânlarda oldukça başarılı konum tespiti yapabilmektedir. Ayrıca kızılötesi vericilerinin küçük ve taşınabilir, sistem tasarımı, montajı ve bakımının kolay olması kızılötesi konum algılama sistemlerine önemli avantajlar sağlamaktadır. Ancak güvenlik ve gizlilik kızılötesi konum algılama sistemleri için önemli dezavantajlar oluşturmaktadır. Şekil 1.13'de gösterilen kızılötesi dalgaların dalga boyu ve frekansları ile dış kaynaklardan gelen parazitlerle girişime neden olduğundan dolayı istikrarsız bir yapı sergilediği durumlar olabilmektedir. Bu parazitleri engelleyecek filtrelerin tasarlanması ise sistemin maliyetini artmasına sebep olmaktadır.




Şekil 1.13. Kızılötesi Dalgaların Dalga Boyu ve Frekans Aralığı

Kaynak: Mautz Rainer (2012). Indoor Positioning Technologies. doi:10.3929/ethz-a-007313554

1.2.5. WiFi

IEEE 802.11 standardı ya da bilinen adıyla WiFi temel olarak ağ oluşturmak ve kamusal, özel ve ticari ortamdaki farklı cihazlara internet erişimi sağlamak için kullanılan bir teknolojidir. WiFi teknolojisi 1 km'ye kadar yükseltilebilen sinyal sunma kapasitesine sahiptir (Liu vd. 2007). Günümüzde akıllı telefonların, dizüstü bilgisayarların ve diğer taşınabilir cihazların WiFi erişimi desteği sunması WiFi teknolojisini iç mekân konum algılama konusunda oldukça cazip kılmaktadır (Zafari vd. 2017). Mevcut WiFi erişim noktaları, sinyal toplama bakımından referans olarak da kullanılabilirliğinden ek altyapı ihtiyacı olmaması WiFi teknolojisini iç mekân konum algılamada cazip kılan özelliklerinden başında gelmektedir. Bu özelliğinden dolayı günümüzde WiFi teknolojisi kullanılarak iç mekân konum algılama hakkında yapılan çalışma ve araştırma sayısında artış gözlenmektedir. WiFi sinyallerinin dalga boyları ve frekans aralığı şekil 1.14'de gösterilmektedir.




Şekil 1.14. Wifi Sinyallerinin Dalga Boyu ve Frekans Aralığı

Kaynak: Mautz Rainer (2012). Indoor Positioning Technologies. doi:10.3929/ethz-a-007313554

1.2.6. ZigBee

ZigBee, IEEE 802.15.4 altyapısında ve standart sarmal ağlar (Mesh Network Dizilişi) ile uygulama profilleri kullanılarak kurulan kısa mesafe kablosuz ağ standardı olarak tanımlanmaktadır. Güvenirliği, düşük maliyeti ve enerji tasarrufu gibi avantajları göz önüne alındığında ZigBee, PC girdi aygıtları gibi sensör ve yönetim

ürünlerinin kablosuz bağlantıları için kullanılabilir. ZigBee, kablosuz iletişim kanallarının otomatik olarak aranmasına ve çok sayıda kablosuz ağın bir arada var olmasına imkân tanımaktadır. ZigBee IEEE 802.15.4 standardının özelliğini kullanarak güvenilir, düşük güçlü izleme ve kontrol ürünlerinin telsiz iletişimini sağlamaktadır (Baronti vd. 2007). IEEE 802.15.4 ve 802.15 standartlarının bir parçasını ve kişisel yerel ağ (Personal Area Network) teknolojisini desteklemektedir. Protokolün amacı düşük maliyetli, uzun süreli pil kullanan sensörlerin kullanılmasını desteklemektir (İTÜ 2013). Şekil 1.15'te ZigBee sinyallerinin dalga boyu ve frekansları gösterilmiştir.



Şekil 1.15. ZigBee Sinyallerinin Dalga Boyu ve Frekans Aralığı

Kaynak: Mautz Rainer (2012). Indoor Positioning Technologies. doi:10.3929/ethz-a-007313554

1.2.7. İç Mekân Konumlandırma Teknolojilerinin Kıyaslanması

İç mekân konumlandırmada birçok farklı standart ve teknolojiler kullanılmaktadır. Kullanılan standartlar ve teknolojiler altyapıları ve barındırdıkları özellikler ile birbirlerinden ayrılmaktadır. Optik temelli Kızılötesi, radyo sinyalleri temelli WiFi, Bluetooth, ZigBee ve RFID ve ses dalgaları temelli Ultrasound en sık kullanılan iç mekân konumlandırmada teknolojilerdir. Her bir teknolojinin avantaj ve dezavantajları bulunmaktadır. Optik tabanlı teknolojiler santimetre seviyesinde konum tespiti yapabilmeleri, radyo sinyallerinin oluşturduğu gürültüye karşı düşük hassasiyet sunması ve düşük maliyetiyle avantaj sağlarken; verici ile alıcının doğrudan görüş açısına sahip olma zorunluluğu ve diğer ışık kaynaklarına karşı aşırı duyarlı olması açısından dezavantaj oluşturur (Zandian 2019). Ses tabanlı teknolojiler uygulama basitliği, santimetre seviyesinde konum tespiti yapabilmeleri, düşük maliyetli olması ve radyo sinyallerinin oluşturduğu gürültüye karşı düşük hassasiyet sunması ile avantaj sağlarken; sesli ortamlarda efektif çalışmaması ve ses dalgalarını soğuracak çevresel koşulların bulunduğu ortamlarda başarısız olmasıyla dezavantaj oluşturur (Zandian

2019). Radyo sinyalleri temelli teknolojiler sundukları özellikler ile en çok kullanılan teknolojilerdir. Radyo sinyalleri temelli teknolojiler görüş hattı olmayan ortamlarda da çalışabilmesi, geniş kapsama alanı sunması, iyi doğruluk oranı sağlaması ve sinyallerin çok yönlü kullanılabilirliği ile avantaj sağlarken; diğer cihazlardan yayılan sinyaller ile oluşan sinyal gürültüsünden etkilenmesi, altyapı gerekliliği ve uygulanmasının karmaşıklığı dezavantaj oluşturmaktadır (Zandian 2019).

İç mekân konum algılama sistemleri olarak sık kullanılan RFID, ZigBee, Wi-Fi ve Bluetooth teknolojilerinin kıyaslanması tablo 1.2’de gösterilmiştir.

Tablo 1.2. Farklı Konum Algılama Teknolojilerinin Kıyaslanması

	RFID	ZigBee	Wi-Fi	Bluetooth
Transfer Hızı	106 kbps	250 kbps	300 Mbps	1 Mbps
İletim Mesafesi (m)	1.5	50 - 300	100 - 300	1 - 50
Güç Tüketimi (mA)	0	5	10 - 50	<15
Hata Payı	<2m	<5m	<4m	<2m
Başarı Oranı	Düşük	Orta	Orta	Orta
Maliyet	Orta	Orta	Yüksek	Düşük
Avantajı	Geniş uygulanabilirlik	Düşük güç tüketimi, düşük maliyet, programlanabilirlik	Yüksek hız, yüksek popülarite, yüksek entegrasyon	Düşük güç tüketimi, düşük maliyet, çapraz platform

Kaynak: Ching-Chieh Chiu (2017). Indoor Positioning System with BLE and Wi-Fi technology—Data Analysis and Accuracy Improvement. <https://dspace.cvut.cz/handle/10467/70519> (Erişim Tarihi: 13.06.2019)



İKİNCİ BÖLÜM

2.KURAMSAL TEMELLER

İç mekân konumlandırma sistemi olarak kurgulanan bu çalışmanın sonuçlarını ve başarısının daha iyi anlaşılabilmesi için temel aldığı bileşenler olan Nesnelerin İnterneti (Internet of Things), Makine Öğrenmesi (Machine Learning), Bulanık Mantık (Fuzzy Logic), Yapay Sinir Ağları (Neural Network), ANFIS (Adaptive Network Based Fuzzy Inference System, Adaptif Ağ Tabanlı Bulanık Sonuç Çıkarım Sistemi) ve k-En Yakın Komşu (k-Nearest Neighbours) yaklaşımlarının da anlaşılması gerekmektedir.

Makine öğrenmesi, bilgisayarların algılayıcı veya veritabanları gibi veri türlerine dayalı öğrenimini olanaklı kılan algoritmaların tasarım ve geliştirme süreçlerini konu edinen bir bilim dalıdır (Samuel 1959). Makine öğrenmesi, bilgisayarların açıkça programlanmaksızın verilen görevleri nasıl gerçekleştirebileceklerini keşfetmeyi amaçlamaktadır. Makine öğrenmesi, 'eğitim verisi' olarak bilinen örnek verileri kullanarak oluşturduğu matematiksel modeli kullanarak tahmin ve kararları oluşturmaktadır.

Bulanık mantık, insan gibi düşünmeyi esas alan ve bu düşünce sistemini matematiksel fonksiyonlara çevirerek işlem yapan bir bilim dalıdır (Zadeh 2008). Bulanık mantık, klasik küme teorisinin yerine bulanık küme teorisine dayanmaktadır. Bulanık küme teorisi, bir elemanın bir kümeye üyeliği hakkında kesin ifadeler yerine 0 ila 1 aralığında üyelik değerlerine sahip olduğu bir yaklaşımdır.

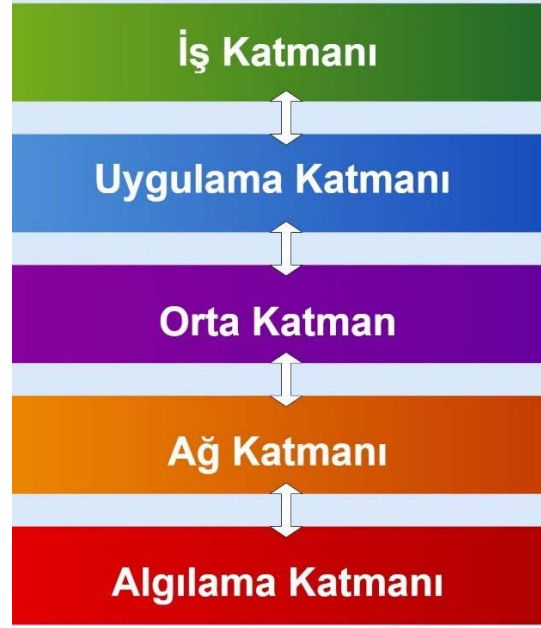
Yapay sinir ağları, insan beyninin bilgi işleme yeteneğinden esinlenerek geliştirilen bir bilgi işleme teknolojisidir (Chen 2019). Yapay sinir ağları ile biyolojik sinir sisteminin taklit edilmesine çalışılmaktadır. Biyolojik sinir ağında sinir hücreleri bulunmaktadır ve bu sinir hücrelerine birbirlerine bağlanarak ağı oluşturmaktadır. Oluşturulan ağ sayesinde öğrenme ve veriler arasındaki ilişkileri ortaya çıkarmak amaçlanmaktadır.

ANFIS, yapay sinir ağlarının öğrenme ve paralel hesaplama yetenekleri ile bulanık mantığın çıkarım özelliğini birleştirmeyi hedefleyen hibrit bir yaklaşımdır. Bu yaklaşım, bulanık mantığın uzman tecrübesi ve görüşlerini sisteme aktarırken, mimarisinin sağladığı avantajları sayesinde doğrusal ve doğrusal olmayan ilişkileri modelleyebilen yapay sinir ağlarının öğrenme yeteneğini kullanarak veriden hareketle farklı formlarda bulunan yapıları başarıyla modelleyebilme özelliğine sahiptir (Cybenko 1989; Hornik vd. 1989; Hornik 1991).

2.1. Nesnelerin İnterneti

Nesnelerin İnterneti, birbirleriyle ilişkili bilgi işlem cihazları, mekanik ve dijital makineler, nesneler, hayvanlar veya benzersiz tanımlayıcılar ile sağlanan, insanlara ve insandan ağa gerek duymadan bir ağ üzerinden veri aktarabilen sistemleri ifade etmektedir (Proente 2019). Cambridge Üniversitesi'ndeki akademisyenlerin, 1991 yılında kahve makinesini takip etmek için kurduğu bir kameralı sistem, nesnelerin internetinin başlangıcı olarak kabul edilmektedir.

Gelişen teknoloji ile beraber geliştirilen cihazlar sayesinde nesnelerin interneti daha etkin kullanılmaya başlanmıştır. Özellikle akıllı cihazların insan hayatına girişi ile nesnelerin internetinin kullanım hızı artmıştır. Nesnelerin interneti, insan hayatına büyük kolaylıklar sağlamaktadır. Günümüzde nesnelerin interneti, tıp alanında cihazlardan gelen verilerin takibinde, hava, su ve toprak gibi çevresel kirlilik kontrolünde, sanayide üretim cihazlarının takibinde, ev içerisinde ışık, açık cihaz ve kapı kilidi kontrolünde ve alışveriş sektörü gibi birçok alanda yaygın olarak kullanılmaktadır. Örneğin, bir akıllı ev sisteminde evin sıcaklığının ayarlanması, odaların aydınlatması ve klima derecesinin ayarlanması gibi birçok işlem nesnelerin interneti sayesinde akıllı cihazlar kullanılarak yapılmaktadır. Ayrıca nesnelerin interneti, giyilebilir cihazlarda da kullanılarak gerçek zamanlı veri akışı sağlayabilmektedir. Şekil 2.1'de nesnelerin interneti ekosistemi gösterilmiştir.



Şekil 2.2. Beş Katmanlı Nesnelerin İnterneti Mimarisi

- **Algılama Katmanı:** Nesne ile ilgili bilgilerin alındığı katmandır. Bu bilgiler sensör, RFID, NFC veya kamera gibi donanımlar kullanılarak alınır. Genellikle bu katman düşük özellikli mikro denetleyici barındırmaktadır.
- **Ağ Katmanı :** Algılayıcılardan toplanan verilerin, Bluetooth, WiFi, kızılötesi ve RFID gibi teknolojilerin kullanılmasıyla merkezi işlem birimlerine güvenli bir şekilde iletildiği katmandır (Arslan, Kirbaş 2016).
- **Orta Katman:** Oluşturulan bir nesnelerin interneti sisteminde yer alan cihazların, birbirleriyle iletişim kurmaları için kullanılan ve farklı tiplerdeki servislerden oluşan katmandır. Bu katmanın algılayıcı cihazdan gelen verilerin depolanması ve servislerin yönetilmesi olmak üzere iki temel görevi bulunmaktadır (Arslan, Kirbaş 2016).
- **Uygulama Katmanı:** Orta katmandaki işlenen bilgiye dayanarak dahili uygulamaların yönetilmesinden sorumlu olan katmandır.

- **İş Katmanı:** Bu katman, tüm nesnelere interneti uygulamaları ile servis yönetimini kapsamaktadır. Alt katmanlardan gelen verilerin analiz edilerek bir sonuç verisinin üretildiği katmandır.

Nesnelerin interneti, konum olarak uzakta olan nesnelere erişim, birbirine bağlı cihazlar arası bilgi alışverişi sağlanması, düşük maliyetli çözümler üretebilmeyi kolaylaştırması ve insan müdahalesi olmadan iş yapabilmeyi sağlanması gibi birçok fayda sunmaktadır.

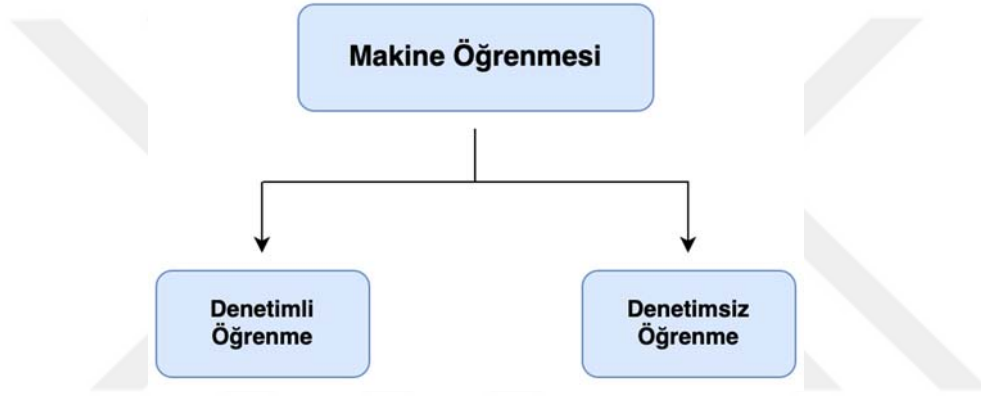
2.2. Makine Öğrenmesi

Makine öğrenmesi, bilgisayarlara açıkça programlanmadan öğrenme olanağı sağlayan bir çalışma alanıdır (Samuel 1959). Makine öğrenmesi, verilerden bilgi çıkarmakla ilgili ve istatistik, yapay zekâ ve bilgisayar bilimlerinin kesişimindeki bir araştırma alanı olmakla birlikte tahmine dayalı analitik ve istatistiksel öğrenme olarak da tanımlanabilmektedir (Müller, Guido 2016). Makine öğrenmesi bilgisayarların veya makinelerin, belirli bir görevi yerine getirmek için açıkça programlanmak yerine veri odaklı kararlar almalarını sağlar ve bu programlar veya algoritmalar, zaman içinde yeni verilere maruz kaldıkça öğrenmek ve gelişmek üzerine tasarlanmıştır (Edureka 2018).

Makine öğrenmesi yöntemlerinin uygulanması son yıllarda günlük yaşamın her alanında giderek yaygınlaşmaktadır (Müller, Guido 2016). İnternet sitelerindeki kişiye özel önerilerden, fotoğraflardaki kişileri tanımaya, DNA dizilerini analiz etmeden, hastalıklarda kişiselleştirilmiş tedavilerin uygulanmasına kadar birçok farklı alan ve disiplinde makine öğrenmesi kullanılmaktadır (Müller, Guido 2016). Aynı zamanda birçok modern web sitesi, uygulama ve cihazların özünde makine öğrenmesi algoritmalarının bulunduğu görülmektedir. Google, Amazon ve Facebook gibi büyük şirketler birçok farklı makine öğrenmesi modelini sistemlerine entegre etmişlerdir. Ticari uygulamaların dışında veri odaklı araştırma ve çalışmalarda makine öğrenmesi kullanımı giderek artmaktadır.

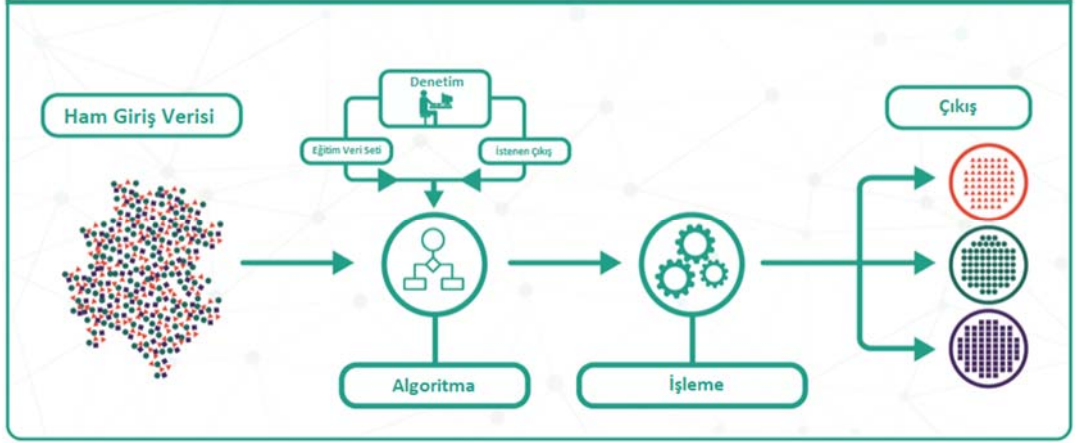
Makine öğrenmesinin genel çalışma prensibi birkaç adımdan oluşmaktadır. İlk adımda makine öğrenmesi algoritması bir model oluşturmak için eğitim veri seti

kullanılarak eğitilir. İkinci adımda makine öğrenmesi algoritması, eğitim veri setinde bulunmayan yeni bir veri ile karşılaştığında oluşturduğu model temelinde bir tahmin yapar. Ardından yaptığı tahminin doğruluk değeri değerlendirilir. Eğer doğruluk değeri kabul edilebilir seviyede ise model uygulanmaya alınır. Ancak doğruluk değeri kabul edilebilir seviyede değilse, makine öğrenmesi algoritması artırılmış bir veri seti ile modeli yeniden eğitir. Makine öğrenmesi Denetimli Öğrenme (Supervised Learning) ve Denetimsiz Öğrenme (Unsupervised Learning) olmak üzere iki farklı türden oluşmaktadır.



Şekil 2.3. Makine Öğrenmesi Türleri


Denetimli Öğrenme, eğitim verilerinden bir anlam çıkarmaya çalışan bir makine öğrenmesi türüdür (Chugh 2017). Denetimli öğrenmede, modelin eğitimi için eğitim veri setindeki hem girdi hem de istenen çıktı veriler sağlanarak model oluşturulur. Eğitim setindeki girdi ve çıktı verileri, oluşturulan modelin öğrenme temelini sağlamak amacıyla önceden etiketlenmiştir. Şekil 2.4’de denetimli öğrenmenin çalışma prensibi gösterilmiştir.



Şekil 2.4. Denetimli Öğrenme

Kaynak: Loon Ronald van (2018). Big Data Made Simple. *Big Data Made Simple*. <https://bigdata-madesimple.com/machine-learning-explained-understanding-supervised-unsupervised-and-reinforcement-learning/> (Erişim Tarihi: 28.11.2019)

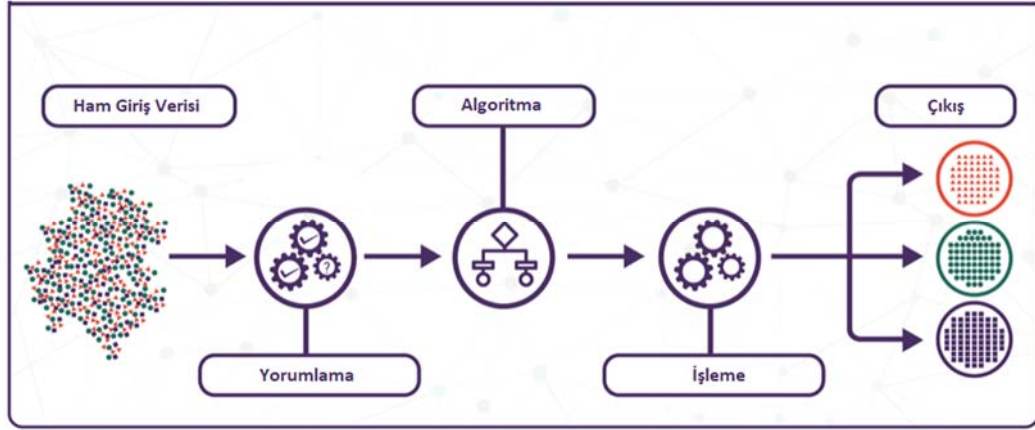
Denetimli öğrenme de Regresyon (Regression) ve Sınıflandırma (Classification) olmak üzere kendi içinde ikiye ayrılır. Regresyon iki veya daha fazla değişkenin arasındaki ilişkiyi bulmayı amaçlayan güçlü bir istatistiksel yöntemdir. Sınıflandırma ise ilk defa karşılaşılan bir verinin eğitim seti kullanılarak sınıflandırması yöntemidir. Şekil 2.5’de bir denetimli öğrenme modeli olan sınıflandırma yönteminin çalışma prensibi gösterilmiştir.



Şekil 2.5. Sınıflandırma Yöntemi

Kaynak: Wittek Peter (2014). Quantum Machine Learning: What Quantum Computing Means to Data Mining. Academic Press.


Denetimsiz öğrenme, denetimli öğrenmenin aksine eğitim verisinde çıktı verileri olmadan sadece girdi verilerini kullanarak anlam çıkarmaya çalışan bir makine öğrenmesi türüdür (Chugh 2017). Denetimsiz öğrenmede, modelin eğitimi için eğitim veri setindeki hem girdi hem de istenen çıktı veriler sağlanarak model oluşturulur. Ancak denetimli öğrenmenin aksine eğitim setindeki girdi ve çıktı verileri önceden etiketlenmemiştir. Şekil 2.6'da denetimsiz öğrenmenin çalışma prensibi gösterilmiştir.



Şekil 2.6. Denetimsiz Öğrenme

Kaynak: Loon Ronald van (2018). Big Data Made Simple. *Big Data Made Simple*. <https://bigdata-madesimple.com/machine-learning-explained-understanding-supervised-unsupervised-and-reinforcement-learning/> (Erişim Tarihi: 28.11.2019)

En yaygın denetimsiz öğrenme yöntemi verilerdeki gizli kalıpları veya gruplamaları bulmak için kullanılan Kümeleme (Clustering) yöntemidir. Kümeleme yönteminde modele bir veri seti verildiğinde, içinde kümeler oluşturularak veri setindeki kalıpları ve veriler arasındaki ilişkileri bulur. Şekil 2.7’de bir denetimsiz öğrenme modeli olan kümeleme yönteminin çalışma prensibi gösterilmiştir.



Şekil 2.7 Kümeleme Yöntemi

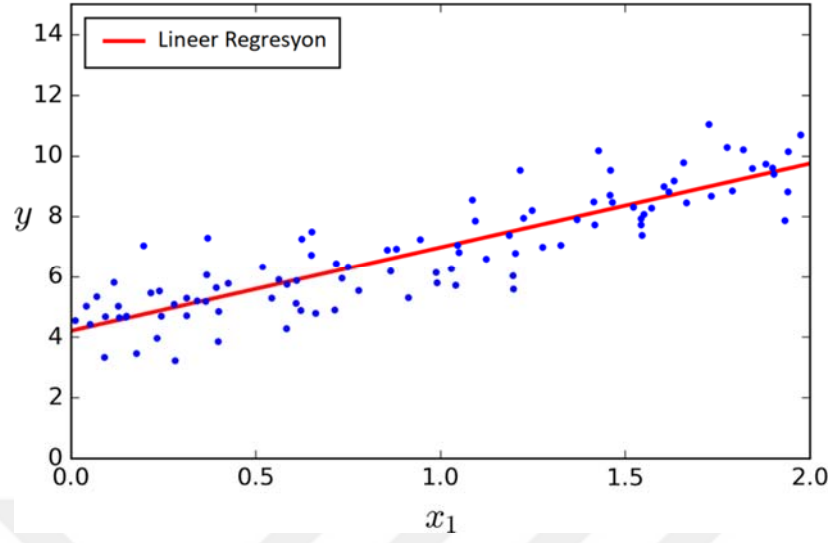
Kaynak: Wittek Peter (2014). Quantum Machine Learning: What Quantum Computing Means to Data Mining. Academic Press.

Makine öğrenmesi, büyük miktarda veriyi yönetmeyi kolaylaştırması ve insanlar tarafından bu büyük miktardaki verinin yönetilmesinin mümkün olmayabileceği durumları anlamaya yardımcı olabilmesi, sistemin insan müdahalesi veya talimatlarına ihtiyacı olmaksızın yürütüp karar alabilmesi, sistemdeki hataları sürekli kontrol ederek bu hataları düzeltebilmesi ve birçok farklı alanda kullanımın olması gibi birçok avantajlar barındırmaktadır (Stark 2018).

2.2.1. Regresyon Analizi

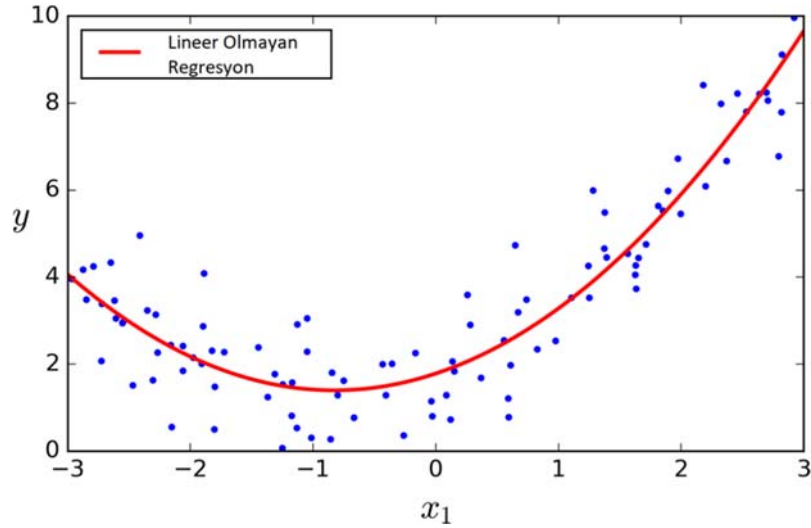
Regresyon analizi, iki veya daha fazla değişkenin arasındaki ilişkiyi incelemek için kullanılmakta olan istatistiksel bir yöntemdir (Chegg 2018). Regresyon analizi, ilgi konusu üzerinde hangi değişkenlerin etkili olduğunu belirleme açısından oldukça güvenilir bir yöntem olmakla birlikte hangi faktörlerin önemli olduğunu, hangi faktörlerin göz ardı edilebileceğini ve bu faktörlerin birbirlerini nasıl etkilediğini belirleme açısından oldukça faydalıdır (SurveyGizmo 2018). Regresyon analizi bağımsız değişken ve bağımlı değişkenin arasındaki anlamlı ilişkiyi göstermede ve birden fazla bağımsız değişkenin, bağımlı değişken üzerindeki etkisinin gücünü göstermede araştırmacılar ve veri analistlerine tahmine dayalı model oluşturma hususunda da yardımcı olmaktadır (Ray 2015). Regresyon analizinde kullanılan bağımlı değişken, anlamlandırılmaya veya tahmin edilmeye çalışılan ana faktördür. Bağımsız değişken ise bağımlı değişkenleri etkileyen girdi faktörlerdir. Regresyon analizi verileri modellemek ve analiz etmek için oldukça etkili bir yöntemdir.

Regresyon analizi, çalışma mantığı olarak çok değişkenli durumlarda bağımlı değişkene etki eden diğer değişkenleri sabit kabul ederek hesaplama yapmaktadır. Bu değişkenlerin bağımlı değişkeni nasıl etkilediği ise bir katsayı ile belirlenmekte ve bu katsayıya değişkenin regresyon katsayısı denilmektedir. Regresyon katsayısı değişkenler arasındaki bağılılığı göstermektedir. Şekil 2.8 ve şekil 2.9'da çalışma prensibi gösterilen regresyon analizinin amacı bir veri kümesinde veriler arasındaki farkın en az olduğu bir çizgi veya eğri bulmaktır.



Şekil 2.8. Doğrusal Regresyon Analizi

Kaynak: Géron Aurélien (2017). *Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent*. O'Reilly Media. <https://www.oreilly.com/library/view/hands-on-machine-learning/9781491962282/ch04.html> (Erişim Tarihi: 31.10.2019)



Şekil 2.9. Doğrusal Olmayan Regresyon Analizi

Kaynak: Géron Aurélien (2017). *Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent*. O'Reilly Media. <https://www.oreilly.com/library/view/hands-on-machine-learning/9781491962282/ch04.html> (Erişim Tarihi: 31.10.2019)

Regresyon analizi, bağımsız değişken sayısı, bağımlı değişkenlerin türü ve regresyon çizgisinin türüne göre çeşitlilik göstermektedir.

2.2.1.1. Doğrusal Lineer Regresyon Analizi

Doğrusal regresyon analizinin (Linear Regression Analysis), basit lineer regresyon analizi (simple linear regression analysis) ve çoklu lineer regresyon analizi (multiple linear regression analysis) olmak üzere iki çeşidi bulunmaktadır. Basit lineer regresyon analizi, bir bağımlı değişken ve bir bağımsız değişken arasındaki lineer ilişkiyi bulmaya çalışırken, çoklu lineer regresyon analizi bir bağımlı değişken ve birden çok bağımsız değişken arasındaki lineer ilişkiyi bulmayı çalışmaktadır.

2.2.1.1.1. Basit Lineer Regresyon Analizi

Basit lineer regresyon analizi, bir değişken ve bir sonuç arasındaki ilişkiyi modellemek için sık kullanılan bir istatistiksel bir yöntemdir (Murphy 2012). Basit lineer regresyon analizinde, bağımlı değişken sürekli iken bağımsız değişken sürekli veya ayrık olmaktadır. Regresyon çizgisi ise doğrusaldır. Basit lineer regresyon analizinde temel fikir verilere en uygun doğrusal çizgiyi elde edebilmektir (Swaminathan 2019). En iyi uyum çizgisi, toplam tahmin hatasının mümkün olduğu kadar en az olduğu çizgidir. Toplam tahmin hatası ise veriler ile regresyon çizgisinin arasındaki mesafelerin toplanması ile elde edilmektedir.


Gözlemlenen veri kümesini doğrusal bir modele geçirmeye çalışmadan önce veri kümesindeki bağımlı ve bağımsız değişkenler arasında bir ilişkinin olup olmadığı değerlendirilmeli ve bu değerlendirme sonucunda bağımlı ve bağımsız değişkenlerin arasında bir ilişki olmaması sonucunda verilerin doğrusal bir regresyon çizgisine yerleştirilmesi yarar sağlamayacaktır (Yale Courses 2019). İki değişken arasındaki ilişkinin sayısal ölçüsü, -1 ile 1 arasındaki bir değer alan korelasyon katsayısı ile ölçülür.

Basit lineer regresyon analizi, bağımlı değişken ile bağımsız değişken arasındaki doğrusal çizgiyi eşitlik 2.1'i kullanarak tespit etmektedir. Eşitlik 2.1'de y bağımlı değişkeni, x bağımsız değişkeni, β_1 değeri doğrusal regresyon çizgisinin

eđimini, β_0 deęeri kesiřimi (regresyon izgisinin y-eksenini kestięi yer) ve ϵ deęeri ise rasgele hata deęerini ifade etmektedir.

$$y = \beta_0 + \beta_1 x + \epsilon \quad \text{Eřitlik 2.1}$$

Basit lineer regresyon analizinde bir veri kumesine doęrusal bir regresyon izgisi yerleřtirmek iin en sık kullanılan yontem en kk kareler (least squares) yontemidir. En kk kareler yontemi veri noktaları arasındaki iliřkinin gorsel olarak gosterilmesini saęlayan ve veri kumesi iin en uygun regresyon izgisinin gosterilmesini saęlayan bir matematiksel regresyon analizi yontemidir (Kenton 2018). Bu yontem her veri noktasından izgiye dikey sapmaların karelerinin toplamını en aza indirerek veri kumesi iin en uygun regresyon izgisini hesaplamaktadır. Sapmaların ilk once kareleri alınıp ardından toplandıęından pozitif ve negatif deęerler arasında iptal yapılmaz. řekil 2.10'da en kk kareler yonteminin alıřma prensibi gosterilmiřtir.



řekil 2.10. En Kk Kareler Yontemi

Kaynak: Ehdp (2019). 5 Kasım 2019 tarihinde <https://www.ehdp.com/methods/least-squares-regression-1.htm> (Eriřim Tarihi: 05.11.2019)

En kk kareler yontemi dord adımdan oluřmaktadır. İlk adımda iki boyutlu uzayda bulunan veri kumesindeki verilerin x-ekseni ve y-eksenindeki deęerlerinin ortalaması eřitlik 2.2 ve eřitlik 2.3 kullanılarak alınır. İkinci adımda veri kumesine en

uygun regresyon çizgisine ait olan eğim eşitlik 2.4 kullanılarak hesaplanır. Üçüncü adımda regresyon çizgisinin y-ekseni ile kesiştiği nokta eşitlik 2.5 kullanılarak hesaplanır. Son adımda ise ikinci adımda hesaplanan eğim ile üçüncü adımda hesaplanan y-ekseni kesişim noktası kullanılarak regresyon çizgisinin denklemi eşitlik 2.1 kullanılarak hesaplanır.

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad \text{Eşitlik 2.2}$$

$$\bar{y} = \frac{\sum_{i=1}^n y_i}{n} \quad \text{Eşitlik 2.3}$$

$$m = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad \text{Eşitlik 2.4}$$

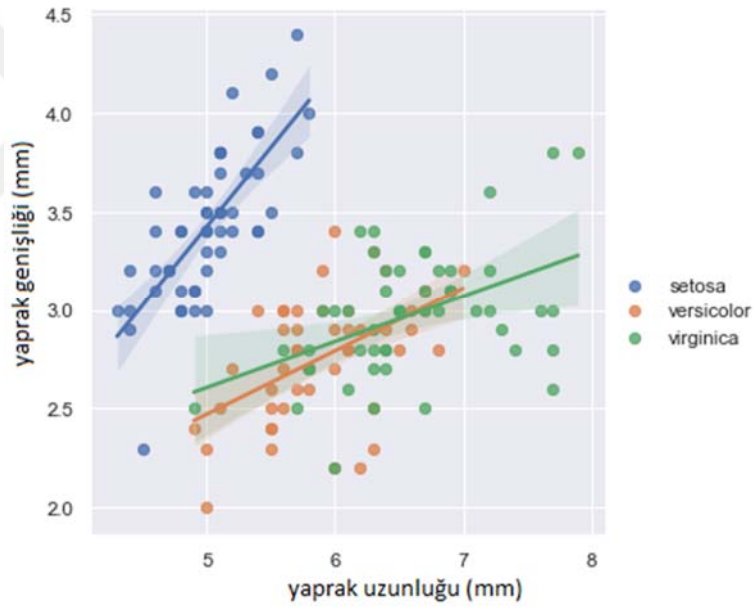
$$b = \bar{y} - m\bar{x} \quad \text{Eşitlik 2.5}$$

Eşitlik 2.2'deki \bar{x} değeri veri kümesindeki verilerin x-ekseni değerlerinin ortalamalarını, eşitlik 2.3'deki \bar{y} değeri veri kümesindeki verilerin y-ekseni değerlerinin ortalamalarını, eşitlik 2.4'deki m değeri regresyon çizgisinin eğimini ve eşitlik 2.5'deki b değeri regresyon çizgisinin y-eksenini kestiği noktayı temsil etmektedir. Eşitlik 2.5'de hesaplanan b değeri, eşitlik 2.1'deki a değeri yerine ve eşitlik 2.4'de hesaplanan m değeri de eşitlik 2.1'deki b yerine yazılarak veri kümesine en uygun regresyon çizgisi bulunmuş olmaktadır.

Basit lineer regresyon analizinin anlaşılması ve kullanımının oldukça kolay olması avantaj oluşturmaktadır. Ayrıca çoğu durumda çalışması ve verilere tam olarak uymasa bile iki değişken arasındaki ilişkinin niteliğini bulmak için kullanılmaktadır. Ancak basit lineer regresyon analizi sadece doğrusal olan bağımlı ve bağımsız değişkenler arasındaki ilişkiyi modellemektedir ve verilerdeki aykırı değerlere karşı oldukça hassastır.


2.2.1.1.2. Çoklu Lineer Regresyon Analizi

Çoklu lineer regresyon analizi, iki veya daha fazla sayıdaki bağımsız değişken ve bir bağımlı değişkenin arasındaki lineer ilişkiyi modellemek için kullanılan ve basit lineer regresyon analizinin uzantısı olan istatistiksel bir yöntemdir (Marill 2004). Çoklu lineer regresyon analizinde bağımlı değişken sürekli iken bağımsız değişkenler ise sürekli veya ayrık olmaktadır. Çoklu lineer regresyon analizi, basit lineer regresyon analizinin tersine veri kümesinde sonucun birden fazla değişkenle ilişkili olduğu durumlarda kullanılmaktadır. Veri kümesindeki veriler bir veya daha fazla derinlikli olabilmektedir. Şekil 2.11’de iki bağımsız değişkenli ve şekil 2.12’de ise üç bağımsız değişkenli çoklu lineer regresyon analizi gösterilmektedir.



Şekil 2.11. Çoklu Lineer Regresyon Analizi

Kaynak: Hackernoon (2019). <https://hackernoon.com/types-of-linear-regression-w4o227s5> (Erişim Tarihi: 05.11.2019)



Şekil 2.12. Çoklu Lineer Regresyon Analizi

Kaynak: Hatipoğlu Ekrem (2018). Machine Learning-Prediction Algorithms-Multiple Linear Regression. *Medium*. 12 Kasım 2019 tarihinde <https://medium.com/@ekrem.hatipoglu/machine-learning-prediction-algorithms-multiple-linear-regression-part-3-c25a5a4205b6> (Erişim Tarihi: 12.11.2019)

Çoklu lineer regresyon analizi, bağımlı değişken ve bağımsız değişkenler arasındaki doğrusal çizgiyi eşitlik 2.6'yı kullanarak tespit etmektedir. Eşitlik 2.6'da y bağımlı değişkeni, x değerleri (x_1, x_2, \dots, x_n) bağımsız değişkenleri, β değerleri $(\beta_1, \beta_2, \dots, \beta_n)$ her bir değişken için eğim katsayısını, β_0 değeri kesişimi ve ϵ değeri ise rasgele hata değerini ifade etmektedir.

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \epsilon \quad \text{Eşitlik 2.6}$$

Çoklu lineer regresyon analizinde bir veri kümesini regresyon çizgisine yerleştirmek için en sık kullanılan yöntem, en küçük kareler yöntemidir. Ancak yöntem basit lineer regresyon analizindeki kullanımından farklı olarak matris şeklinde kullanılmaktadır. Veri kümesindeki her bir verinin n derinlikte olduğu çoklu lineer regresyon modeli eşitlik 2.7 kullanılarak modellenmektedir.

$$y_1 = \beta_0 + \beta_1 x_{11} + \beta_2 x_{12} \dots + \beta_k x_{1k} + \epsilon_1$$

$$y_2 = \beta_0 + \beta_1 x_{21} + \beta_2 x_{22} \dots + \beta_k x_{2k} + \epsilon_2$$

...

Eşitlik 2.7

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} \dots + \beta_k x_{ik} + \epsilon_i$$

...

$$y_n = \beta_0 + \beta_1 x_{n1} + \beta_2 x_{n2} \dots + \beta_k x_{nk} + \epsilon_n$$

Eşitlik 2.7 kullanılarak modellenen n derinlikli çoklu regresyon modelinin genel formülü ise eşitlik 2.8'de gösterilmiştir.

$$y = X\beta + \epsilon$$

Eşitlik 2.8

Eşitlik 2.8'deki y, X, β ve ϵ değerlerinin matris formülleri ise sırasıyla eşitlik 2.9, eşitlik 2.10, eşitlik 2.11 ve eşitlik 2.12'de gösterilmiştir. X matrisine tasarım matrisi denilmektedir. X matrisi gözlemlerin elde edildiği bağımsız değişkenlerin düzeyleri hakkında bilgi içermektedir. β matrisi ise eğitim katsayılarını içermektedir.

$$y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}$$

Eşitlik 2.9

$$X = \begin{bmatrix} 1 & x_{11} & x_{12} & \dots & x_{1n} \\ 1 & x_{21} & x_{22} & \dots & x_{2n} \\ 1 & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{nn} \end{bmatrix}$$

Eşitlik 2.10

$$\beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_n \end{bmatrix}$$

Eşitlik 2.11

$$\epsilon = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix} \quad \text{Eşitlik 2.12}$$

Çoklu lineer regresyon modelinin tespiti eşitlik 2.13 ve eşitlik 2.14 kullanılarak yapılmaktadır. Eşitlik 2.14 kullanılarak hesaplanan \hat{y} değeri çoklu regresyon modelini vermektedir.

$$\hat{\beta} = (X'X)^{-1} X'y \quad \text{Eşitlik 2.13}$$

$$\hat{y} = X \hat{\beta} \quad \text{Eşitlik 2.14}$$

Çoklu lineer regresyon analizinin iki veya daha fazla bağımsız değişkenin bağımlı değişken üzerinde etkisini belirleme imkânı sunabilmesi ve veri kümesindeki verileri verimli kullanabilme yeteneğinin olması avantaj oluşturmaktadır. Ancak veri kümesindeki aykırı değerlere, eksik veriye ve yanlış korelasyon değerlerine karşı oldukça hassastır.

2.3. Bulanık Mantık


Klasik mantık her önermenin ya doğru olduğu ya da yanlış olduğu varsayımını referans alarak hareket etmektedir. Ancak bazı önermelerin doğruluk değerleri ölçümlerin temel sınırlamaları sebebiyle belirsiz olmasından dolayı bulanık mantık konusu, 1965 yılında Zadeh tarafından ortaya atılmıştır (Zadeh 1965: 3). Zadeh bulanık mantık önermesiyle birlikte, klasik mantıktaki iki önermenin arasına belirsizlik adı verilen üçüncü bir önerme fikrini ortaya koymuştur. Bu fikri ile Zadeh, klasik iki değerli mantığın doğruluk değerlerini daha esnek hale getirmeyi amaçlamıştır. Bulanık mantık, temelde çok değişkenli mantık, olasılık teorisi, genetik algoritmalar ve yapay sinir ağları yaklaşımları üzerine oluşturulmuş ve olayların gerçekleşme olasılıklarından ziyade daha çok gerçekleşme dereceleri ile ilgilenen kavramı ortaya atmaktadır (Goguen 1973).

Bulanık mantık, birden çok değer, aynı değişken üzerinden işlenmesine izin veren değişken işleme yaklaşımıdır ve bir sonuç dizisi elde etmeyi mümkün kılan


kesin olmayan veri spektrumu ile sorunları çözmeye çalışır (Scott 2019). Bulanık mantık, girdi verildiğinde eldeki tüm mevcut bilgileri dikkate alarak mümkün olabilecek en iyi kararı vererek sorunları çözmek için tasarlanmıştır. Bulanık mantık işlemleri, bir problemin tanımlanması ve analizi, değişken kümelerin ve mantık ilişkilerinin geliştirilmeden bulunan bilgilerin bulanık kümelere dönüştürülmesi ve ardından da modelin yorumlanması sürecidir. Bulanık mantık algoritması her türlü problem için uygun değildir. Bulanık mantık, bir veya birden fazla denetim değişkeninin bulunduğu durumlarda ve sisteme ait bir matematiksel modelin olmadığı ya da olsa da bu modelin kodlanmasının zor olduğu durumlar ile gerçek zamanlı işlemler için ayrıntılı hesaplamaların çok karmaşık olduğu durumlarda uygulanmaktadır (Anderson 1995).

2.3.1. Klasik Küme ve Bulanık Küme Kavramları

Klasik mantıkta bir kümeyi oluşturan elemanlar hakkındaki tanımlayıcı yargılar keskin özelliklidir. Yani bir eleman bir kümenin ya elemanıdır ya da elemanı değildir. Bu tür kümeler keskin (crisp) küme olarak adlandırılır. Ancak bulanık mantık yaklaşımında elemanı ya da elemanı değildir şeklinde keskin bir ayrım söz konusu değildir. Bir örnek olarak sıcaklık değerleri sınıflandırılmasını ele alalım. 0-20 dereceler arası soğuk olarak, 20 derece ve üstü sıcaklık değerleri ise sıcak olarak kabul edilsin. Klasik mantığa göre 20 derecelik sıcaklık 'sıcak' olarak değerlendirilirken 19,5 derecelik sıcaklık ise 'soğuk' olarak değerlendirilmektedir. Ancak bulanık mantık kümesinin elemanları, bu kümenin elemanlarına $[0,1]$ kapalı aralığında reel değerler atayan üyelik fonksiyonlarının kullanılmasıyla tanımlanmaktadır. Elemanların sahip oldukları değerler üyelik derecesi olarak adlandırılmaktadır. Aynı zamanda bu değerler sayesinde bir elemanın herhangi bir bulanık kümenin özelliklerini ne kadar taşıdıkları ifade edilebilmektedir. Şekil 2.13'de klasik küme yaklaşımı ve şekil 2.14'de ise bulanık küme yaklaşımı gösterilmiştir.




Şekil 2.13. Klasik Küme Yaklaşımı



Şekil 2.14. Bulanık Küme Yaklaşımı

Klasik bir küme $A = \{ x \in U \mid P(x) \}$ bağıntısı kullanılarak ifade edilmektedir. Bu bağıntıda A klasik kümeyi, P kümenin özelliğini ve U ise bu kümenin ait olduğu uzayı ifade etmektedir. Kümenin fonksiyonu ise $\mu_A(x) : U \rightarrow \{0,1\}$, eğer x bu kümeye ait bir eleman ise '1' olarak değilse '0' olarak tanımlanmaktadır. Bulanık küme teorisinde ise üyelik fonksiyonu olarak da bilinen $\mu_A(x) : U \rightarrow [0,1]$ fonksiyonu daha genelleşmiş bir yapıyı temsil etmektedir. Şekil 2.15'de klasik küme ve bulanık küme venn şeması kullanılarak gösterilmiştir.

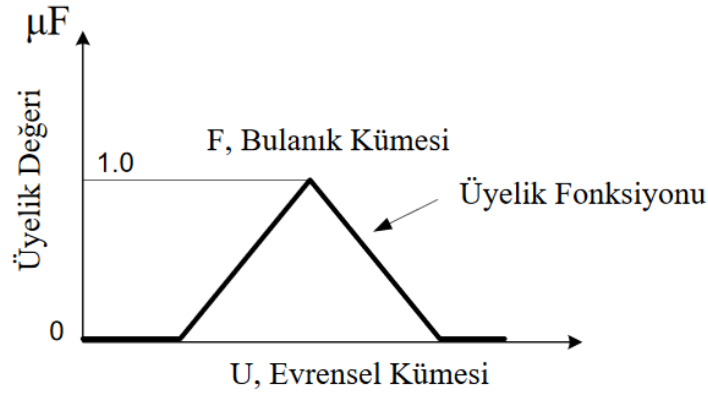


Şekil 2.15. Klasik Küme ve Bulanık Küme Sınırları

Şekil 2.15'de gösterilen 'a' elemanı hem klasik kümenin hem de bulanık kümenin kesin elemanıdır ve bu elemanın üyelik derecesi ise 1 olarak, 'c' elemanı ise hem klasik kümenin hem de bulanık kümenin kesin elemanı değildir ve bu elemanın üyelik derecesi ise 0 olarak ve 'b' elemanı ise klasik kümenin kesin elemanı değildir ancak bulanık kümenin belirli derecede elemanıdır ve bu elemanın üyelik derecesi ise klasik kümede 0 bulanık kümede ise $[0,1]$ aralığında bir değerle ifade edilir.

2.3.2. Bulanık Küme Yaklaşımı


Bulanık küme yaklaşımında, klasik küme yaklaşımından farklı olarak şekil 2.14'de görüldüğü üzere 0-10 derece arasındaki sıcaklık değerlerinin soğuk küme grubuna üyelik değerleri 1 ve sıcak küme grubuna üyelik değerleri 0 olup kesin soğuk olarak değerlendirilirken, 25-40 derece arasındaki sıcaklık değerlerinin ise soğuk küme grubuna üyelik değerleri 0 ve sıcak küme grubuna üyelik değerleri 1 olup kesin sıcak olarak değerlendirilmektedir. 15-25 derece arasındaki sıcaklık değerleri ise soğuk ve sıcak bulanık kümelerinde üyelik değerlerine sahiptir. X evrensel kümesinde tanımlanan bulanık A kümesinin üyelik fonksiyonu $\mu_F = X \rightarrow [0,1]$ şeklinde tanımlanmaktadır ve μ_F fonksiyonu $[0,1]$ aralığında bir gerçek değer üretmektedir.



Şekil 2.16. Bulanık Küme Üyelik Fonksiyonu ve Üyelik Değerleri

Bulanık mantıktaki belirsizlik durumları, bu durumu temsil eden küme elemanlarına üyelik fonksiyonları verilerek tanımlanmaktadır. En büyük önem derecesine sahip öğeler 1 değerini, en az önem derecesine sahip öğeler 0 değerini ve diğer öğeler ise önem derecesine göre $[0,1]$ aralığında değerler almaktadır. Bu şekilde her bir öğe için $[0,1]$ aralığındaki değerlere üyelik derecesi ve bu değerleri üreten fonksiyonlara ise üyelik fonksiyonları denilmektedir. Bulanık modeller oluşturulurken değişik yapılardaki üyelik fonksiyonları seçilebilir. Çok farklı yapıda ve çok sayıda üyelik fonksiyonu bulunmasına rağmen, literatürde en çok kullanılan üyelik fonksiyonları üçgen (triangular), yamuk (trapezoidal), normal dağılım (gaussian) ve çan şekilli (bell-shaped) üyelik fonksiyonlarıdır. Şekil 2.17'de gösterilen üçgen ve

şekil 2.18’de gösterilen yamuk üyelik fonksiyonları bir vektör fonksiyonu olup üçgen üyelik fonksiyonu 3 ve yamuk üyelik fonksiyonu 4 sayısal parametre bağılyken şekil 2.19’da gösterilen normal dağılım üyelik fonksiyonu 2 ve şekil 2.20’de çan şekilli üyelik fonksiyonu 3 parametreye bağılıdır (Sarı, Arslan 2007).




$$U(x; a, b, c) = \begin{cases} 0 & x < a \\ (x-a)/(b-a) & a \leq x \leq b \\ (c-x)/(c-b) & b \leq x \leq c \\ 0 & x > c \end{cases}$$

$$Y(x; a, b, c, d) = \begin{cases} 0 & x < a \\ (x-a)/(b-a) & a \leq x < b \\ 1 & b \leq x \leq c \\ (d-x)/(d-c) & c < x \leq d \\ 0 & x > d \end{cases}$$


Şekil 2.17. Üçgen Üyelik Fonksiyonu

Şekil 2.18. Yamuk Üyelik Fonksiyonu



$$G(x; a, b) = e^{-\left(\frac{x-a}{b}\right)^2}$$

Şekil 2.19. Normal Dağılım Üyelik Fonksiyonu



$$B(x; a, b, c) = \frac{1}{1 + \left|\frac{x-c}{a}\right|^{2b}}$$

Şekil 2.20. Çan Üyelik Fonksiyonu

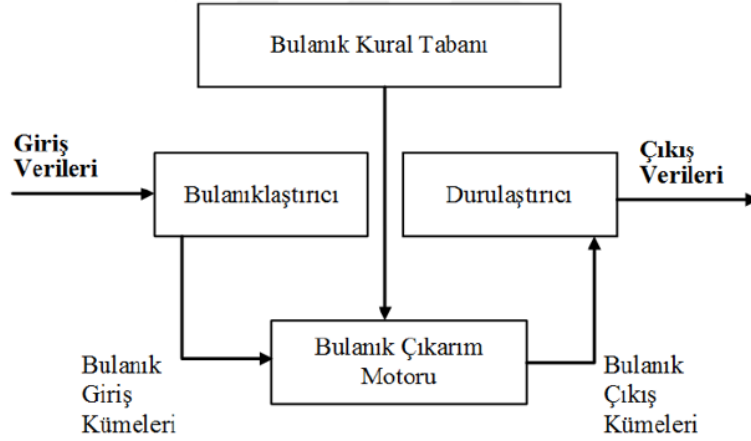
2.3.3. Bulanık Sistemler

Bulanık sistemler, mevcut verilerdeki girdi değişkenlerini bulanık küme ilkeleri çerçevesinde kullanarak çıktı değişkenlerinin elde edildiği sistemlerdir. Uzman kişilerin deneyimleri ve sözel verilerin bulanık modele katılmasıyla çözüme kavuşturulması, bulanık sistemlerin en büyük avantajını oluşturduğu kısımdır. Bu amaç doğrultusunda bulanık modelin değişkenleri, bulanık alt kümeler olarak ifade edilirler ve çıkarım için klasik küme işlemlerinin genelleştirilmesiyle elde edilen bulanık küme işlemleri kullanılır (Zadeh 1965). Bulanık modeller (bulanık çıkarım sistemi), bulanık “Eğer-İse” kurallarını temel alan sistemlerdir. “Eğer-İse” kuralında, “Eğer” kısmında sonuca sebep olan giriş değişkenleri ve bu değişkenler arasındaki mantıksal ilişkiler, “İse” kısmında ise bu giriş değişkenlerine bağlı olarak ortaya çıkan sonuç değişkenleri yer almaktadır. Bulanık kuralların genel formu aşağıda gösterildiği şekildedir:

$$\begin{array}{l} \text{Kural 1:} \quad \mathbf{Eğer} \quad x = A_1 \text{ ve } y = B_1 \quad \mathbf{İse} \quad z = N_1 \\ \text{Kural 2:} \quad \mathbf{Eğer} \quad x = A_2 \text{ ve } y = B_2 \quad \mathbf{İse} \quad z = N_2 \end{array}$$

Burada x ve y “Eğer” kısmındaki girdi değişkenlerince tanımlanan koşulları ve z ise “İse” kısmındaki çıktı değişkenlerince tanımlanan koşulları temsil etmektedir.

Şekil 2.21.’de gösterilen genel bulanık model sistemi, giriş verileri, bulanıklaştırıcı, bulanık kural tabanı birimi, bulanık çıkarım motoru birimi, durulaştırıcı ve çıkış verilerden oluşmaktadır.



Şekil 2.21. Bulanık Model Sistemi

Kaynak: Yılmaz Mehmet ve Arslan Ersoy (2005). Bulanık Mantığın Jeodezik Problemlerin Çözümünde Kullanılması, 11.

Şekil 2.21’de gösterilen bulanık model sistemini oluşturan bileşenler aşağıda kısaca tanımlanmıştır:

1) **Giriş Verileri:** İncelenecek probleme ait girdi değişkenlerini içeren yapıdır. Girdi değişkenlerine ait tüm bilgileri tutar. Bu bilgilerin türünün sayısal ve/veya sözel olmasından dolayı genel veri tabanı da denilmektedir.

2) **Bulanıklaştırıcı:** Sayısal türdeki girdi verilerine ait değerleri, sözel olarak nitelendirilen bulanık kümelerdeki üyelik değerlerine atayan bir işlemcidir.

3) **Bulanık Kural Tabanı Birimi:** Veri tabanındaki girişleri “Eğer-İse” türündeki kurallar formunda çıkış değerlerine bağlayan kuralların tümünü içeren birimdir. Bu kuralların oluşturulmasında sadece girdi verileri ile çıktı verileri arasındaki tüm ara (bulanık küme) bağlantılar düşünülür. Böylelikle, her bir kural girdi uzayının bir parçasını çıktı uzayına mantıksal olarak bağlar. Bu bağlamaların tümü ise kural tabanını oluşturmaktadır.

4) **Bulanık Çıkarım Motoru Birimi:** Bulanık kural tabanında giriş ve çıkış bulanık kümeleri arasında oluşturulmuş olan parça ilişkilerin

tümünü bir araya getirerek, sistemin bir çıkışlı gibi davranmasını sağlayan işlemler bütünüdür. Bu motor, her bir kuralın çıkarımlarını bir araya getirerek, tüm sistemin girdiler altında nasıl bir çıktı vereceğinin belirlenmesine yarar.

5) Durulaştırıcı: Bulanık işlemler sonucunda üretilen bulanık çıkarım sonuçlarını keskin sayısal çıkış değerlerine dönüştüren mekanizmadır.

6) Çıkış Verileri: Bilgi ve bulanık kural tabanının bulanık çıkarım motoru aracılığıyla etkileşimi sonucunda elde edilen çıktı değerlerinin topluluğunu belirtir.

Bulanık model sisteminin çalışma prensibinde önce bulanıklaştırıcı katmanındaki mevcut verilerden seçilmiş giriş değişkenlerinin üyelik dereceleri belirlenir. Ardından bulanık kural tabanında, giriş ve çıkış değişkenlerini mantıksal olarak birbirlerine bağlayan kurallar oluşturulur ve bu kuralların tümü bulanık çıkarım motorunda bir araya getirilerek girişlerin üyelik derecelerine göre çıktıları üretilir. Son olarak da durulaştırıcı katmanında bulanık çıkarım sonuçları sayısal keskin çıkış değerlerine dönüştürülmektedir.

Bulanık mantık ile modelleme, anlaşılmasının kolay olması, dayandığı matematiksel teoremin basit olması, esnek olması, eksik ya da yetersiz veriler ile işlem yapabilme olanağı sağlaması, uzman kişilerin görüş ve tecrübelerinden faydalanmayı sağlaması ve günlük konuşma dilini kullanması özellikleri sebebiyle oldukça avantajlıdır.

Birçok farklı bulanık modeller bulunmasına karşın, literatürde en sık olarak kullanılan bulanık çıkarım sistemleri Mamdani ve Takagi-Sugeno bulanık çıkarım sistemleridir.

2.3.3.1. Mamdani Bulanık Modeli

Mamdani bulanık modeli, deneyimli bir insan operatörden elde edilen bir dizi dilsel kontrol kurallarını sentezleyerek bir buhar motoru ve kazan kombinasyonunu kontrol etme çabası olarak 1975 yılında Ebrahim Mamdani tarafından önerilmiştir (Mamdani, Assilian 1975). Bu modelde, hem girdi değişkenleri hem de çıktı


değişkenleri üyelik fonksiyonlarıyla ifade edilir (Akyılmaz, Ayan 2010). Mamdani bulanık modeli, insan davranışlarını modellemeye yakın olması ve kolaylıkla oluşturulma gibi özellikleri sebebiyle oldukça yaygın bir kullanıma sahiptir. Aynı zamanda bulanık küme kuramı kullanılarak oluşturulan ilk kontrol sistemlerinin arasındadır.

Mamdani tipi bulanık model beş adımdan oluşmaktadır. İlk adım olan bulanıklaştırma aşamasında, öncül kısımda bulunan bütün bulanık ifadeler kullanılarak girdi değişkenler için $[0,1]$ kapalı aralığında üyelik dereceleri belirlenir. Ardından ikinci adımda bulanık mantık işlemleri kullanılarak kural ağırlıkları belirlenir. Üçüncü adımda bulanık mantık işlemcileri (VE, VEYA) uygulanır. Dördüncü adımda her bir kuralın çıktısını temsil eden bulanık kümeler birleştirilerek sonuçlar elde edilir. Son adımda ise tek bir sayıya dönüştürülen toplam bulanık küme sonuçları durulaştırma işlemiyle durulaştırılır.

Şekil 2.22’de gösterilen x ve y gibi sayısal iki değişkenli ve iki kurallı Mamdani tipi bulanık modelde z çıkış değerinin C_i bulanık küme fonksiyonları kullanılarak nasıl hesaplandığı gösterilmiştir. Bu bulanık modelin hesaplanmasında iki kural kullanılmıştır. Bu kurallar:

Kural 1: **Eğer** $x = A_1$ ve $y = B_1$ **İse** $z = C_1$

Kural 2: **Eğer** $x = A_2$ ve $y = B_2$ **İse** $z = C_2$



Şekil 2.22. Mamdani Bulanık Mantık Modeli

Kaynak: Palancıoğlu H. Mustafa ve Beşdok Erkan (2005). Hareketli objelerin ulaşım ağındaki hareketlerinin bulanık mantık metotları ile modellenmesi (s. 23). 2. Mühendislik Ölçmeleri Sempozyumu.

Bulanıklaştırılan giriş verileri, daha önce belirlenen kurallara tabi tutulur ve bu kurallar uygulanırken, şartlar arasındaki “VE” durumunda giriş üyelik değerlerinin en küçük olanı ve “VEYA” durumunda da yine giriş üyelik değerlerinin en büyük olanı seçilerek çıkış üyelik fonksiyonunda bu sayının altında kalan alan bulunmaktadır. Her bir kurala ait çıkış üyelik fonksiyonları bulunduktan sonra bu alanlar çeşitli berraklaştırma yöntemlerinin yardımıyla kesin çıkış bilgisinin elde edilmesinde kullanılmaktadır (Palancıoğlu, Beşdok 2005).

2.3.3.2. Takagi-Sugeno Bulanık Modeli

Takagi-Sugeno bulanık modeli veya daha çok bilinen adıyla Sugeno bulanık modeli Takagi, Sugeno ve Kang tarafından 1985 yılında tanıtılmış ve ilk kez o tarihte

kullanılmıştır (Sugeno 1985). Sugeno modeli, Mamdani bulanık mantık modelinin bir uyarlamasıdır. Mamdani ve Sugeno bulanık mantık modellerinde, bulanık çıkarım sürecinin ilk iki bölümü olan girişleri bulanıklaştırmak ve bulanık operatörü uygulamak işlemleri birebir aynı olmakla birlikte Sugeno ve Mamdani bulanık mantık modelleri arasındaki temel fark ise Sugeno modelinde çıktı üyelik fonksiyonlarının doğrusal veya sabit olmasıdır (Mathworks 2018). Sugeno bulanık modeli çıktı üyelik fonksiyonları sabit veya doğrusal olduğu zaman farklı adlandırılmaktadır. Bu model, üyelik fonksiyonları sabit olduğunda sıfıncı derece ve 1.dereceden doğru denklemi olduğunda ise birinci derece “Sugeno bulanık model” olarak adlandırılmaktadır. Bir Sugeno tipi bulanık modelinin bulanık kuralı aşağıdaki forma sahiptir;


$$\text{Eğer } x = A \text{ ve } y = B \text{ İse } z = f(x, y) = px + qy + r(c)$$

Bu kuralda A ve B , $z = f(x, y)$ fonksiyonuna bağlı keskin çıkış veren bir fonksiyon olmasına rağmen giriş değişkenlerinin bulanık kümeleridir. Çıkış değeri olan z ise genellikle x ve y değişkenlerine bağlı bir polinomdur. Ancak z çıkış değeri, bulanık kuralın girişi tarafından belirtilmiş bölge dahilinde, bir sistemin çıkışını tanımlayabildiği sürece herhangi bir fonksiyon da olabilir (Haznedar 2017).

Şekil 2.23’de Birinci dereceden Sugeno modelinin bulanık çıkarım mekanizması gösterilmiştir. Sugeno bulanık mantık modelinde hem giriş katsayılarının hem de kural ağırlıklarının uzman kişi tarafından elde edilmesinin zor olması sebebiyle bu sayıların bir optimizasyon algoritmasının yardımıyla bulunması gerekmektedir. Her bir kuralın keskin çıkışının olması nedeniyle, sonuç keskin çıkış değeri ağırlıklı ortalama ile elde edilmektedir. Bu yaklaşımıyla Sugeno bulanık mantık modeli Mamdani modeline kıyasla durulaştırma işlemindeki hesaplama yükünü ve zaman kaybını oldukça azaltan fonksiyonel bir yaklaşımdır. Bu özellikleriyle birlikte Sugeno modeli sistem modelleme ve denetçi tasarımına çok uygun bir çıkarım modelidir. Pratikte bazen ağırlıklı ortalama operatörü yerine, eşitlik 2.15’de gösterilen z operatörü kullanılmaktadır.

$$z = ((w_1 z_1 + w_2 z_2) / (w_1 + w_2)) \quad \text{Eşitlik 2.15}$$

Eşitlik 2.15'deki z operatörünün kullanılmasıyla yapılan basitleştirme işlemi, kuralların tetikleme katsayılarının toplamı "1" e yakınsamadıkça ($\sum_i w_i = 1$), üyelik fonksiyonlarının dilsel anlamlarının kaybolmasına neden olabilmektedir.



Şekil 2.23. Takagi-Sugeno Bulanık Mantık Modeli

Kaynak: Özçalık Hasan Rıza ve Uygur Ali Fazıl (2003). Dinamik Sistemlerin Uyumlu Sinirsel-Bulanık Ağ Yapısına Dayalı Etkin Modellenmesi. *KSÜ Fen ve Mühendislik Dergisi*, 6(1), 36-46.

Sıfırıncı dereceden bir Sugeno modeli komşu üyelik fonksiyonlarının şartları ile yeterince örtüşebildiği sürece kendi giriş değişkenlerine bağlı olarak düzgün bir fonksiyon olurken, Mamdani modelinde ise üyelik fonksiyonlarındaki örtüşmeler ara değerlendirmenin düzgünlüğü üzerinde belirleyici bir etkiye sahip değildir.

Sugeno bulanık mantık modelinin, numerik hesaplamalara uygun olması, doğrusal olmayan sistemlerin kontrol edilebilmesi için doğrusal teknikler sunması, optimizasyon teknikleri ile birlikte iyi çalışabilmesi, çıktı uzayında sürekliliği sağlayabilmesi ve matematiksel analiz için uygun olması gibi birçok avantajları bulunmaktadır. Ancak yüksek dereceli Sugeno modelinin kullanılmasının oldukça kompleks bir yapıya yol açması, girdi ve alt küme sayılarının artmasının neden olduğu eğitilme zorluğu ve insan sezgilerine çok uygun olmayan yapısı gibi dezavantajlar da barındırmaktadır (Yılmaz, Arslan 2005).

2.4. Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin bilgi işleme tekniğinden esinlenilerek geliştirilmiş bir bilgi işleme teknolojisidir (Chen 2019). Yapay sinir ağları, insan beyninin özelliklerinden birisi olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardıma ihtiyaç duymadan gerçekleştirme amacıyla geliştirilmiştir. İnsan beyni oldukça kompleks yapıda ve çok hızlı çalışan bir bilgisayar olarak düşünülebilir. İnsan beynindeki biyolojik sinir ağlarının performansı küçümsenemeyecek kadar yüksektir ve karmaşık olayları işleyebilecek yetenektedir. Yapay sinir ağlarını kullanarak bu yeteneğin makinelere geçirilmesi hedeflenmektedir. Yapay sinir ağları örneklerden elde ettiği bilgi ile kendi deneyimlerini oluşturur ve bu deneyimlerini daha sonraki karşılaştığı durumlar için kullanır. Ayrıca sinir ağı eğitildikten sonra eksik bilgi çalışma yeteneğine sahiptir ve ağa gelen yeni örneklerde eksik bilgi bulunsa bile sonuç üretebilir. Yapay sinir ağlarıyla, basit bir biyolojik sinir sisteminin çalışma şekli taklit edilir. Bu nedenle biyolojik sinir sisteminden kısaca bahsetmekte yarar vardır.


2.4.1. Biyolojik Sinir Sistemi

Biyolojik sinir sisteminde, 10 milyardan fazla sinir hücresi (nöron) yer almaktadır ve her bir sinir hücresi yaklaşık olarak 10.000 sinir hücresi ile bağlantılıdır. Bu sinir hücrelerinde, sinyallerin iletimi karmaşık elektro-kimyasal işlemler zinciriyle oluşan ve sayısı saniyede 1000'e kadar varabilen titreşimler şeklinde olmaktadır. Biyolojik sinir sistemi, merkezinde beynin olduğu bilgiyi alan, değerlendiren ve uygun kararlar veren üç katmanlı yapıdan oluşmaktadır. Alıcı sinirler yapı içerisinde veya dış ortamdaki topladıkları uyarıları elektriksel sinyallere dönüştürerek beyne bilgi iletimi yapmaktadır. Tepki sinyalleri ise beyin tarafından üretilen elektriksel darbeleri yapı dışına çıktı olarak uygun tepkilere dönüştürmektedir. Merkezi sinir sisteminde ise bu veriler şekil 2.24'de gösterildiği şekilde alıcı ile tepki sinirleri arasında ileri veya geri besleme yönünde değerlendirilerek uygun tepkiler oluşturulmaktadır.



Şekil 2.24. Biyolojik Sinir Sistemi Sinyal İletimi

Merkezi sinir sisteminin en temel elemanı sinir hücresidir. Dentritler, öteki sinir hücrelerinden aldıkları bilgileri hücre gövdesine (soma) bir ağaç dallanması biçiminde iletir. Aksonlar ise elektriksel darbe biçimindeki bilgiyi hücre dışına taşıyan yoldur ve aksonların bitimi ince yollara ayrılarak diğer hücreler için dentritleri oluşturmaktadır. Akson ve dentrit arası bağlantı elemanına sinapsis denilmektedir. Şekil 2.25’de biyolojik sinir hücresi ile bileşenleri gösterilmiştir.



Şekil 2.25. Biyolojik Sinir Hücresi ve Bileşenleri

Kaynak: Miller James D. ve Forte Rui Mihuel (2017). Mastering Predictive Analytics with R- Second Edition. https://subscription.packtpub.com/book/big_data_and_business_intelligence/9781787121393/5/ch05lv11sec38/the-biological-neuron (Erişim Tarihi: 19.02.2020)

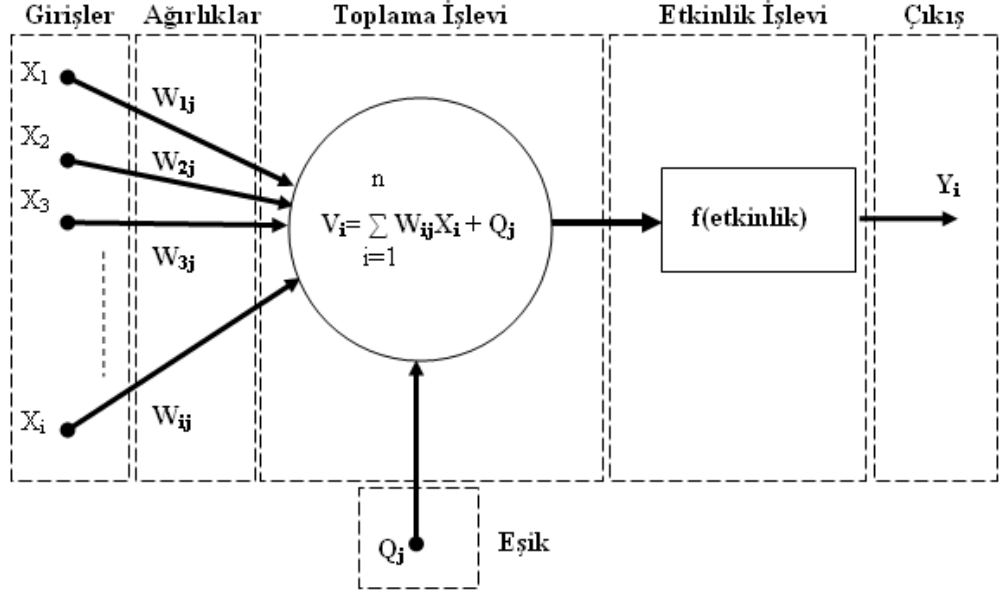
Bu yapının görevi bilgiyi işlemek, değerlendirmek ve merkezi sinir sistemindeki bilgilerle karşılaştırmaktır. Bu işlemlerin sonucunda komutlar, merkezi sinir sisteminde üretilerek motor organlara iletilmektedir. Motor organlar ise eylemi doğrulayan geri beslemeli bağlantılar kullanarak merkezi sinir sistemini denetler ve

yönetir. Hem iç hem de dış geri beslemeli kontroller komutlar ile gerçekleştirilmektedir.

2.4.2. Yapay Sinir Ağı

Bilim insanları, insan beyninin nöro-fiziksel yapısını incelemiş ve matematiksel modelini çıkartmak için yoğun çalışmalarda bulunmuşlardır. Bu çalışmaların sonucunda da günümüz bilgisayarlarının algoritmik işlem gerçekleştirme yöntemlerinden farklı ve yeni bir yöntem olarak yapay sinir ağları ortaya çıkmıştır. Biyolojik sinir ağlarının sinir hücrelerine sahip olması gibi yapay sinir ağları da yapay sinir hücrelerine sahiptir. Sinir ağı, yapay sinir hücrelerinin kendi aralarında bağlantı kurmasıyla oluşur ve genellikle birçok katmandan oluşmaktadır. Ancak yapay sinir ağı, biyolojik sinir sistemine kıyasla daha az kompleks yapıdadır. İnsan beyninin çalışma prensibini taklit eden yapay sinir ağı, veriden öğrenebilme, genelleme yapabilme ve sınırsız sayıda veri ile çalışabilme gibi birçok önemli özelliğe sahiptir.

Şekil 2.26'da gösterilen temel bir yapay sinir ağı hücresi, girişler (input), ağırlıklar (weight), toplama fonksiyonu, aktivasyon fonksiyonu ve çıkışlar (output) olmak üzere 5 ana bileşenden oluşmaktadır. Girişler, yapay sinir hücresine dış ortamdan veya diğer hücrelerden gelen bilgilerdir. Ağırlıklar, bir yapay sinir hücresine gelen bilginin önemini ve hücre üzerinde olan etkisini göstermektedir. Ağırlığın eksi bir değer olması hücre üzerindeki etkisinin negatif olduğunu, artı bir değer olması hücre üzerindeki etkisinin pozitif olduğunu ve sıfır olması ise hücre üzerinde herhangi bir etkisinin olmadığını göstermektedir. Toplama fonksiyonu, bir sinir hücresine gelen net girişi hesaplamaktadır. Bu hesaplamayı yapmak için çeşitli fonksiyonlar kullanılmaktadır. En yaygın olan hesaplama yöntemi ise ağırlıklı toplamı bulma yöntemidir. Bu yöntemde her gelen giriş değeri, kendi ağırlığı ile çarpılarak toplanır ve böylece ağa giren net giriş bulunmuş olmaktadır. Aktivasyon fonksiyonu ise sinir hücresine gelen net girişi işleyerek hücrenin bu girişe karşı üreteceği çıkışı hesaplamaktadır. Çıkışlar, aktivasyon fonksiyonu tarafından üretilen çıkış değerleridir. Üretilen çıkış değeri dış ortama veya başka bir sinir hücresine gönderilebilir.



Şekil 2.26. Temel Yapay Sinir Ağı Hücre Yapısı

Kaynak: Yüksek Ahmet Gürkan (2007). Hava kirliliği tahmininde çoklu regresyon analizi ve yapay sinir ağları yönteminin karşılaştırılması. Cumhuriyet Üniversitesi, Sivas.


Yapay sinir ağlarındaki nöronlar, incelendiği zaman sinapsisler, toplayıcılar ve aktivasyon fonksiyonları olmak üzere üç ana bölümden oluştuğu ve oldukça basit işlemlere sahip işlemci oldukları görülmektedir. Şekil 2.26’da görüldüğü üzere giriş değerlerine sahip sinaptik bağlantılar sahip oldukları ağırlıklarla çarpılır ve bir toplayıcıya uygulanır. Toplayıcıdan üretilen sonuç nöronun aktivasyon fonksiyonundan geçirilir ve en son olarak da çıkışlar hesaplanır. Ağırlıklı toplamın oluşturulması için eşitlik 2.16 ve çıkışların hesaplanması için ise eşitlik 2.17 kullanılmaktadır.

$$s = w_1u_1 + w_2u_2 + w_3u_3 + \dots + w_nu_n - Q = \sum_{i=1}^n w_iu_i - Q \quad \text{Eşitlik 2.16}$$


$$y = f(s) = f\left(\sum_{i=1}^n w_i u_i - Q\right) = f(w \cdot u - Q) \quad \text{Eşitlik 2.17}$$

Nöronun girişindeki giriş değerlerindeki her bir değişim, nöronun çıkışında değişkenlik oluşturmaktadır. Bu değişkenlik, girişin model üzerindeki etkisini belirleyen bağlantı ağırlıklarına (w_i), toplayıcının eşik değerine (Q) ve nöronun aktivasyon fonksiyonunun ($f(s)$) tipine bağlıdır. Şekil 2.26'da görüldüğü üzere yapay sinir sisteminin eşik değeri (Q_j) girişlerden bağımsızdır ve bu durum giriş değerlerinin sıfır olduğu durumda nöron çıkışında $f(0)$ yerine $f(s)$ değerinin üretilmesini sağlayarak nöron çıkışında sıfır değerinin üretilmesini engellemektedir. Eşik değerinin kullanılması, pratikte -1 ya da +1 değerine sahip bir giriş Q ağırlığına sahip bir bağlantı ile toplayıcıya giriş şeklinde alınmasıdır (Efe, Kaynak 2000).

Eşitlik 2.17'deki f fonksiyonu aktivasyonudur ve bu fonksiyon sinir hücresine giren net veriyi işleyerek hücrenin bu girişe karşı üreteceği çıkışı hesaplamaktadır. Aktivasyonu fonksiyonu doğrusal olmayan (nonlinear) bir fonksiyondur. Ayrıca türevinin kolay alınabiliyor olması aktivasyon fonksiyonun belirlenirken göz önünde bulundurulması gereken bir husustur. Doğrusal olmayan aktivasyon fonksiyonlarının çeşitli tipleri bulunmaktadır (Graupe 2007). Şekil 2.27 ve şekil 2.28'de çeşitli aktivasyon fonksiyonu tipleri gösterilmiştir.



Şekil 2.27. Eşik ve Doğrusal Aktivasyon Fonksiyonu



Şekil 2.28. Logaritma Sigmoid ve Tanjant Sigmoid Aktivasyon Fonksiyonu

Yapay sinir ağlarında hangi aktivasyon fonksiyonu seçileceği problemin türüne göre değişiklik göstermektedir (Fausett 1994). Aktivasyon fonksiyonu tarafından üretilen değer hücrenin çıktısıdır ve bu değer dış ortamlara veya diğer sinir hücrelerine giriş olarak gönderilebilir. Ayrıca hücreler ürettikleri çıkışları tekrar kendisine giriş olarak gönderebilir. Bir sinir hücresinin birden fazla girişi olabilmesine karşın yalnızca bir çıkış vardır.


Yapay sinir ağları, matematiksel olarak modellenmesi mümkün olmayan veya oldukça zor olan karmaşık problemlerin kolayca modellenebilmesini sağlaması hem pratiklik sağlaması hem de maliyetinin ucuz olması, zaman olarak elverişli çalışması ve yeniden eğitilebilir olması gibi birçok yönden avantaj oluşturmaktadır. Ancak ağın oluşturulmasında, modelin seçilmesinde ve ağın topolojisinin belirlenmesinde herhangi bir kural setinin bulunmaması, optimum çözümü garanti edememesi, sadece nümerik bilgilerle çalışabildiğinden dolayı problemin nümerik gösterime dönüştürülmesi zorunluluğu oluşturması ve eğitimin gerçekleştirilmesinin bazı durumlarda uzun zaman alması yönünden dezavantaj oluşturmaktadır.

2.4.2.1. Yapay Sinir Ağları Modelleri

Yapay sinir ağları, sinir hücrelerinin birbirleriyle farklı formlarda bağlanmalarıyla oluşmaktadır. Sinir hücrelerinin çıkışları ağırlıklar üzerinden diğer sinir hücrelerine veya kendi girişlerine de bağlanabilmektedir. Ayrıca bağlantılarda gecikme üniteleri de olabilir. Sinir hücrelerinin birbirleri arasındaki bağlantı şekillerine, aktivasyon fonksiyonlarına ve öğrenme kurallarına göre birçok farklı yapay sinir ağı modelleri geliştirilmiştir (Fausett 1994).

2.4.2.1.1. İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli yapay sinir ağları, giriş verilerinin n boyutlu giriş vektörü aracılığıyla giriş katmanına sunulduğu, ağırlık değerleri ile buldukları katmanda hesaplandıkları ve üretilen sonucun komşu katmandaki nöronlara iletilerek nöronlar arası bağlantını kurulduğu bir yapay sinir ağı modelidir. Bu modelde gecikmeler bulunmaz ve işlem sadece girişten çıkışa doğru ileri yönde devam etmektedir. Şekil 2.29'da görüldüğü üzere katmanlar ardışık olarak sıralanmıştır ve bir önceki katmandaki nöronların çıkışları, sonraki katmanın nöronların girişlerine ağırlıklar üzerinden uygulanmaktadır. Üretilen çıkış değerleri ile istenen çıkış değerleri karşılaştırılıp bir hata değeri elde edilir ve ardından ağıdaki tüm ağırlık değerleri güncellenir (Öztemel 2003). Gizli katmanlardaki nöronların doğrusal olmayan davranışlarından dolayı ağ da doğrusal olmayan bir yapıya sahiptir. İleri beslemeli yapay sinir ağındaki giriş ve çıkış katmanlarındaki nöron sayıları ise problemin yapısına göre şekillenmektedir. Fakat gizli katmanların yapısının belirlenmesi kişisel tecrübe veya deneme-yanılma yöntemiyle yapılmaktadır.



Şekil 2.29. İleri Beslemeli Yapay Sinir Ağı

Kaynak: Yüksek Ahmet Gürkan (2007). Hava kirliliği tahmininde çoklu regresyon analizi ve yapay sinir ağları yönteminin karşılaştırılması. Cumhuriyet Üniversitesi, Sivas.

İleri beslemeli yapay sinir ağında, ilk gizli katmana birinci sıradaki nöron üzerinden verilecek olan giriş değeri eşitlik 2.18'de ve bu şekilde temsil edilen

fonksiyonun genelleştirilmiş şekli ise eşitlik 2.19’da gösterilmiştir. Eşitlik 2.19’da gösterilen f aktivasyon fonksiyonu için en önemli parametre türevlenebilir bir fonksiyon olmasıdır.


$$G[1 - 1] = x_1w_{11} + x_2w_{21} + x_3w_{31} + \dots + x_nw_{n1} \quad \text{Eşitlik 2.18}$$

$$s_i^{k+1} = \sum_{j=1}^{n_k} w_{ij}^k o_j^k \quad \text{Eşitlik 2.19}$$

$$o_i^{k+1} = f(s_i^{k+1})$$

2.4.2.1.2. Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli yapay sinir ağları, en az bir nöronun çıkışının kendisine ya da diğer nöronlara giriş olarak sunulduğu sinir ağlarıdır ve geri besleme genellikle modele dahil bir geciktirme elemanı kullanılarak yapılmaktadır. Bu işlem, bir katmandaki nöronlar arasında ya da katmanlar arasındaki nöronlar arasında yapılmaktadır. Bu özelliklerinden dolayı, geri beslemeli yapay sinir ağları doğrusal olmayan davranış göstermektedir. Geri beslemeli yapay sinir ağı modeli şekil 2.30’da gösterilmiştir.



Şekil 2.30. Geri Beslemeli Yapay Sinir Ağı

Kaynak: Yüksek Ahmet Gürkan (2007). Hava kirliliği tahmininde çoklu regresyon analizi ve yapay sinir ağları yönteminin karşılaştırılması. Cumhuriyet Üniversitesi, Sivas.

Ağın t anındaki çıkışı $o(t)$ ise $t+\Delta$ anındaki çıkış ise $o(t+\Delta)$ 'dir ve buradaki Δ sabiti ise gecikme süresidir. İleri beslemeli yapay sinir ağları notasyonu kullanılarak $o(t+\Delta)$ fonksiyonu eşitlik 2.20'de verildiği gibi oluşturulmaktadır.

$$o(t + \Delta) = f[w \cdot o(t)] \quad \text{Eşitlik 2.20}$$

2.4.2.2. Yapay Sinir Ağlarında Öğrenme

İnsan beyni yaşadıkça sürekli gelişir ve tecrübe kazanır. Bu gelişim sürecinde duyu organları vasıtasıyla çevresinden elde ettiği verileri yorumlar ve bir sonuç üretir. Ürettiği sonuçları ise sonraki davranışlarında kullanır. Bu doğrultuda daha önce karşılaştığı olay veya durumlarda nasıl tepki vermesi gerektiğini bilir ancak ilk defa karşılaştığı durum veya olayda bir tepki üretemez. Tıpkı insan beyninde olduğu gibi yapay sinir ağları da çevresinden nöronları aracılığıyla aldığı verileri, yorumlar ve aktivasyon fonksiyonundan geçirerek sonuç üretir. Ürettiği bu sonucu, daha önceki tecrübeyle verilen çıkışla karşılaştırarak hata bulur ve bu hata farklı öğrenme algoritmalarıyla indirgenip gerçekte olması gereken değere yaklaştırılmaya çalışılır. Bu süreçte her çevrimde yapay sinir ağı ağırlıkları güncellenir. Eğer yapay sinir ağı, verilen giriş-çıkış çiftleri ile kabul edilebilir ölçütte sonuçlar üretir ise ağırlık değerleri saklanır. Böylece yapay sinir ağının modellenmesi yapılmış olur.

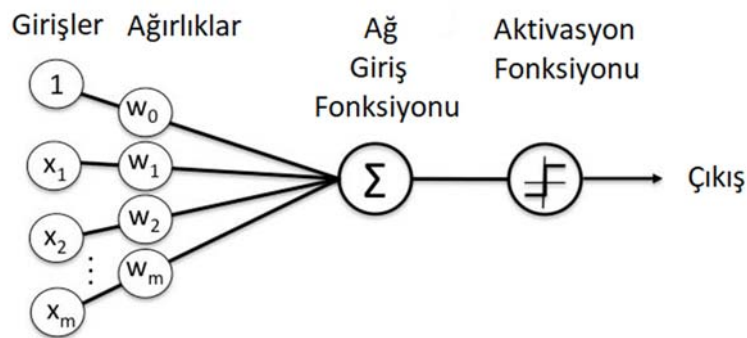
Öğrenme olarak adlandırılan durum, ağırlıkların istenilen sonuç elde edilene kadar güncellenmesiyle geçen zamandır. Yapay sinir ağının öğrenmesi tamamlandıktan sonra ağa daha önce verilmeyen girişler verilir ve ağın yeni verilere ürettiği çıkış incelenir. Eğer ağ, yeni verilen verilere de doğru yaklaşıyorsa sinir ağının öğrenmesi tamamlanmış demektir. Eldeki verilerin büyük bir çoğunluğu sinir ağının eğitilmesi için kullanılırken, kalan diğer kısmı ise sinir ağının başarısını test etmek için kullanılır. Yapay sinir ağlarının eğitilmesi için farklı problem yapılarına farklı öğrenme paradigmaları uygulanmaktadır.

2.4.2.3. Yapay Sinir Ağları Öğrenme Algoritması

Yapay sinir ağları uygulamalarında, modellerin eğitilmesi için birçok farklı öğrenme algoritması kullanılmaktadır ve bu öğrenme algoritmalarının çoğu en eski

öğrenme algoritması olan Hebb Öğrenme Algoritması'nın türevleridir (Fausett 1994). İlk ve en basit öğrenme algoritması olarak bilinen Hebb algoritmasında, eğer sinir ağı içerisinde birbirine bağlı nöronlar aynı anda aktif durumda ise bu anda bu iki nöronun arasındaki ağırlık değerlerinin artması beklenir ve sinapsislerin ağırlıklarının ayarlanması ile öğrenmenin oluşacağı öngörülmektedir. Diğer bir ifadeyle eğer bir sinir hücresi başka bir sinir hücresinden giriş alırsa ve her iki sinir hücresi de aktif durumda yani matematiksel olarak aynı işaretli ise bu sinir hücreleri arasındaki boyut kuvvetlenir (Fine 1999).

Hebb algoritması kendisinden sonra geliştirilen birçok algoritmaya temel oluşturmuştur. Bu algoritmalarından birisi olan Perceptron (Basit Algılayıcı) Modeli, 1957 yılında Frank Rosenblatt tarafından temelinde Hebb algoritmasını alarak fakat daha güçlü olarak geliştirilmiştir. Perceptron modeli tek giriş ve tek çıkış katmanından oluşan tek katmanlı bir işlem birimidir ve bir sinir hücresinin birden fazla giriş alarak bir çıkış üretmesi prensibiyle çalışmaktadır. Çıkış üniteleri bütün giriş ünitelerine bağlıdır ve her bir bağlantının ağırlık değerleri bulunmaktadır. Şekil 2.31'de gösterilen basit bir Perceptron sinir hücresi, algılama, ilişkilendirme ve cevaplandırma üniteleri olmak üzere üç kısımdan oluşmaktadır. Çıkış değerinin hesaplanmasında eşik değer fonksiyonu kullanılmaktadır.



Şekil 2.31. Basit Perceptron Modeli

Kaynak: Simplilearn. (2017). Simplilearn.com. <https://www.simplilearn.com/what-is-perceptron-tutorial> (Erişim Tarihi: 24.02.2020)

Perceptron modeli, eğitilebilen tek bir yapay sinir hücresinden oluşmaktadır ve bu modelde girişler ağa sunulmakta ve her giriş setine karşılık gelen çıkış seti de sinir

ađına gsterilmektedir. Daha sonra sinir ađı ise ğrenme kuralına gre bir ıkıř deđeri hesaplamaktadır. Eđer sinir ađının rettiđi ıkıř olması gereken ıkıř deđerinden farklı ise ađırlıklar ve eřik deđeri yeniden ayarlanır ve nceki iřlemler tekrar edilir.

Perceptron ğrenme modelinde ğrenme sreci eđitim ve test ařamaları olmak zere iki ařamadan oluřmaktadır. Eđitim ařamasında farklı zelliklere sahip iki vektr grubunu birbirinden ayırt edebilmeyi sađlayan ađırlık deđerlerinin elde edilmesi amalanmaktadır. Test ařamasında ise eđitim ařamasında ađırlıkların oluřumuna katkıda bulunmamıř fakat yine de iki gruptan birine dahil olduđu bilinen giriř vektrleri kullanılarak model test edilir.

PERCEPTRON ÖĞRENME KURALI ALGORİTMASI

Adım 1 Başlangıç ağırlıkları ve bias oluşturulur. Basit olarak $w_i = 0$ ($i=1$ 'den n 'ye kadar) $b=0$
Öğrenme oranı parametresi belirlenir ($0 < \alpha \leq 1$). Basit olarak $\alpha = 1$

Adım 2 Eğitimin bitirilmesi için gereken şart sağlanana kadar Adım 3 ile Adım 7 arasındaki işlemler gerçekleştirilir.

Adım 3 Tüm eğitim çiftleri için (giriş, çıkış) Adım 4 ile Adım 6 arasındaki işlemler gerçekleştirilir.

Adım 4 Eğitim gurubundaki girişleri ağa sunulur.

Adım 5 Çıkış ünitesinin, ağa giren veriler için cevabı hesaplanır:

$$y_{in} = b + \sum_i x_i w_i$$
$$y = \begin{cases} 1 & \text{şart } y_{in} > Q \\ 0 & \text{şart } -Q \leq y_{in} \leq Q \\ -1 & \text{şart } y_{in} < -Q \end{cases}$$

Adım 6 Girilen eğitim grubu için ağırlıklar ve bias değeri düzenlenir.

Eğer Hesaplanan değer \neq Beklenen değer ise

$$w_i(\text{yeni}) = w_i(\text{eski}) + \alpha x_i$$
$$b(\text{yeni}) = b(\text{eski}) + \alpha.$$

Aksi takdirde

$$w_i(\text{yeni}) = w_i(\text{eski})$$
$$b(\text{yeni}) = b(\text{eski})$$

(Formülde t beklenen değeri (ağa sunulan giriş, çıkış veri setlerinde çıkış değerini) temsil etmektedir.)

Adım 7 Eğitimin bitirilmesi için gereken şart kontrol edilir. Eğer Adım 3'de hiçbir ağırlık değişimi olmuyor ise eğitim bitirilir, aksi takdirde devam edilir(Fausett 1994).

2.5. Sinirsel Bulanık Mantık

Sinirsel bulanık mantık, yapay sinir ağları ve bulanık mantığın kendine has yeteneklerini birleştirmeyi amaçlayan bir yaklaşımdır. Bölüm 2.4’de incelendiği üzere yapay sinir ağlarının en temel özelliği öğrenebilme yeteneğidir ve bu özelliğinin yanında önemli dezavantajlarından birisi olan öğrenme sonuçlarının çok geniş parametre kümelerinde temsil edilebilmesi nedeniyle sonuçların kelimeler ile ifade edilmesi imkansızdır. Yine bölüm 2.3’de incelendiği üzere bulanık mantığın temeli, doğada bulunan dillerde olduğu gibi insanın düşünüş biçimine oldukça yakın olmasıdır. Fakat bulanık mantık da kuralları kendisi öğrenemez, uzman kişilerin görüşlerine bağlıdır.

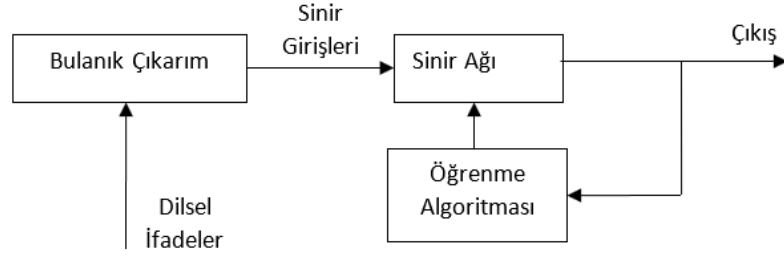
Sinirsel bulanık mantığın anahtar faktörü de burada ortaya çıkmaktadır. Sinirsel bulanık mantık yaklaşımı, yapay sinir ağlarının öğrenme kabiliyeti ve bağlantılı yapıları ile bulanık mantığın insan kapasitesinde karar verebilme ve uzman kişi bilgisini sağlama gibi avantajlarını bir araya getirme fikrini ortaya koymaktadır. Bu yaklaşım sayesinde, yapay sinir ağlarına bulanık mantık gibi karar verebilme ve uzman kişi bilgisi sağlama becerileri kazandırılırken bulanık mantığa ise yapay sinir ağlarının öğrenme ve hesaplama kapasitesi verilebilmektedir.

Bulanık sinir ağlarında, ağın eğitim sürecinin bulanıklaştırılması, sinir ağı çıktılarının bulanık küme ile ifade edilmesi ve yapay sinir hücrelerinin standart toplam ve çarpım işlemleri yerine bulanık küme teorisinde kullanılan birleşim ve kesişim gibi çeşitli işlemlerin kullanılması bulunmaktadır. Bulanık sinir ağları, öğrenme yeteneği, kesin olmayan giriş ve sistem çıktılarının dilsel ifade edilebilirliği, kolay uyarlanabilirlik ve bilgiyi eş zamanlı işleme özelliği açısından avantaj oluşturmaktadır.

2.5.1. Sinirsel Bulanık Mantık Ağ Yapıları

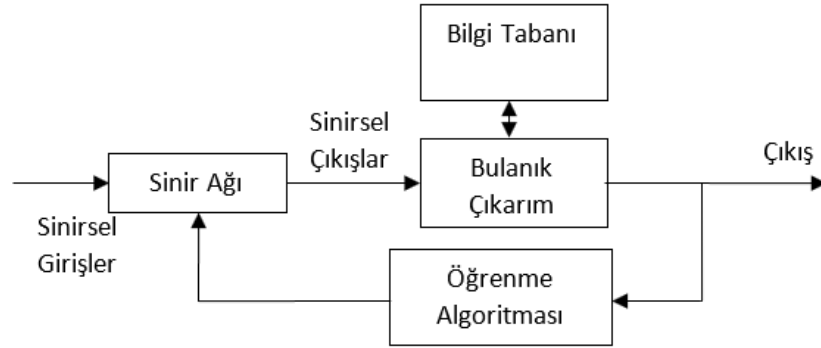
Sinirsel bulanık mantık ağ yapıları iki farklı yapıdan oluşmaktadır. Şekil 2.32’de gösterilen birinci yapıda bulanık çıkarım mekanizmasının dilsel terimlere veya ifadelerle göre oluşturduğu çıkışlar, çok katmanlı sinir ağına giriş vektörü olarak uygulanmaktadır ve sinir ağı eğitilerek istenen çıkışların elde edilmesi

amaçlanmaktadır. Şekil 2.33’de gösterilen ikinci sinirsel bulanık mantık sisteminde ise çok katmanlı sinir ağının çıkışları, bulanık çıkarım mekanizmasının girişlerini oluşturmaktadır.



Şekil 2.32. Sinirsel Bulanık Mantık Sisteminin Birinci Yapısı

Kaynak: Yüksek Ahmet Gürkan (2007). Hava kirliliği tahmininde çoklu regresyon analizi ve yapay sinir ağları yönteminin karşılaştırılması. Cumhuriyet Üniversitesi, Sivas.



Şekil 2.33. Sinirsel Bulanık Mantık Sisteminin İkinci Yapısı

Kaynak: Yüksek Ahmet Gürkan (2007). Hava kirliliği tahmininde çoklu regresyon analizi ve yapay sinir ağları yönteminin karşılaştırılması. Cumhuriyet Üniversitesi, Sivas.

Bulanık mantık yaklaşımında uzman kişi bilgilerinden elde edilen kurallar dilsel ifadeler kullanılarak etiketlense de tasarım, genellikle deneme yanılma yöntemiyle yapıldığından dolayı uzun zaman almaktadır. Ancak sinir ağları kullanılarak bu kurallar oluşturulabilmektedir. Sinirsel bulanık yaklaşımında, sinir

ağları bulanık mantık sistemlerin karar verme sürecinin üyelik fonksiyonlarını uyarlamada kullanılmaktadır.

2.5.1.1. ANFIS (Adaptive Network Based Fuzzy Inference System – Adaptif Ağ Tabanlı Bulanık Sonuç Çıkarım Sistemi)

Adaptif ağ tabanlı bulanık sonuç çıkarım sistemi (ANFIS), Takagi-Sugeno bulanık çıkarım sistemine dayalı bir tür yapay sinir ağı sistemidir ve Jang tarafından 1990'ların başlarında geliştirilmiş olup doğrusal olmayan fonksiyonların modellenmesinde ve kaotik zaman serilerinin tahmininde kullanılmıştır (Jang 1991; Jang 1993). Bu ağ yapısı, her biri tanımlı bir fonksiyonu gerçekleştirme görevini üstlenmiş olan ve farklı katmanlar halinde yerleştirilmiş düğümlerin birbirleri ile birleşiminden oluşmaktadır (Tsoukalas, Uhrig 1997). ANFIS metodolojisi, bulanık mantık ve yapay sinir ağlarından oluşan hibrit bir sistemdir (Buragohain 2009). Bu hibrit yöntem kullanılarak ilk olarak başlangıç değişkenleri ile birlikte giriş değişkenleri, modellenen sistemin giriş ve çıkış verilerinden çıkarılan kurallar yardımıyla türetilir (Buragohain 2009). ANFIS'in en temel amacı ise bulanık mantık sisteminin parametrelerini, giriş ve çıkış veri kümelerini kullanarak bir öğrenme algoritmasının yardımıyla optimize etmektir. Bu optimizasyon ise gerçek çıkış değeri ile hedef çıkış değeri arasındaki hatanın minimum olacağı şekilde yapılmaktadır.

ANFIS, bulanık çıkarım sistemindeki Eğer-İse kuralları ile giriş-çıkış bilgi çiftlerinden oluşmaktadır. Ancak sistemin eğitilmesinde ve denetlenmesinde yapay sinir ağları öğrenme algoritmaları kullanılmaktadır (Jang 1993; Franklin vd. 1998). Eğer x ve y giriş ve z ise çıkış olarak alınacak olursa ANFIS'in temel kural yapısı aşağıdaki şekilde yazılmaktadır:

$$\text{Eğer } x \in A_i \text{ ve } y \in B_i \quad \text{İse } z_i = p_i x + q_i y + r_i$$

Burada A_i ve B_i sırasıyla giriş kısmındaki x ve y değişken uzayını bulanık alt uzaylara ayıran kümelerin etiketi, p_i , q_i ve r_i ise eğitime işlemi boyunca belirlenen tasarım parametreleridir ve z_i ise o kurala ait çıkış değeri olup, giriş değişkenlerinin bir fonksiyonudur. Herhangi bir x , y giriş çifti için sonuç çıkış değeri ise tüm kuralların çıkış değeri olan z_i 'lerin ağırlıklı ortalamasıdır (Özgan vd. 2009). z çıkış değerinin hesaplanması ise eşitlik 2.21 kullanılarak yapılmaktadır.

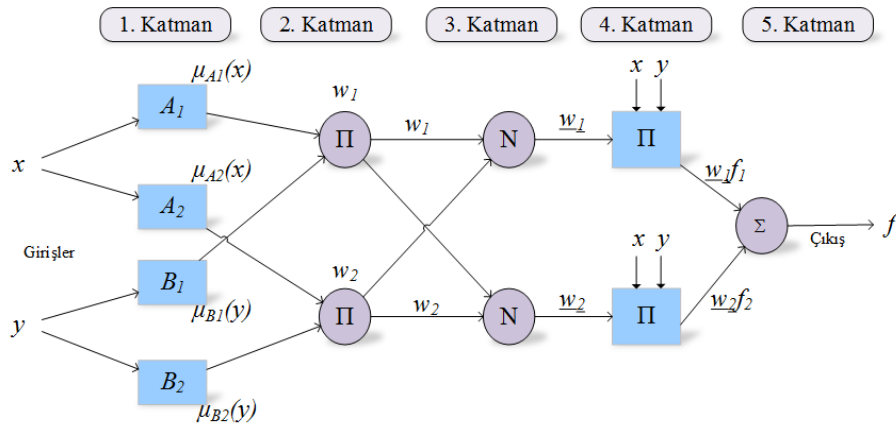
$$z = \sum_{m=1}^k w_m Z_m / \sum_{m=1}^k w_m \quad \text{Eşitlik 2.21}$$

Birinci derece bulanık Takagi-Sugeno modeline dayanan ANFIS modeli aşağıdaki iki kurala bağlı olarak oluşturulmaktadır. Bu kurallarda p_i , q_i ve r_i her bir kural için denklem sabitleridir (Güney, Sarıkaya 2008).

Kural 1 : **Eğer** $x = A_1$ ve $y = B_1$ **İse** $f_1 = (p_1 x + q_1 y + r_1)$

Kural 2 : **Eğer** $x = A_2$ ve $y = B_2$ **İse** $f_2 = (p_2 x + q_2 y + r_2)$


Yukarıdaki kurallar kullanılarak oluşturulan ANFIS mimarisi şekil 2.34'de gösterilmiştir ve 5 katmandan oluşmaktadır. Birinci katmanında giriş verilerine, üyelik fonksiyonları uygulanarak bulanıklaştırma işlemi yapılmaktadır. İkinci katmanında ise bulanık mantık çıkarım sistemine göre kurallar oluşturulmaktadır. Üçüncü katmanında kural katmanından gelen her bir düğüme, ağırlıklı ortalama ile normalizasyon işlemi uygulanmaktadır. Dördüncü katmanında bulanık sonuçlar sayısal değerlere dönüştürülmektedir. Son olarak beşinci katmanında ise tüm düğümlerin çıkış değerleri toplanarak sistemin tek çıkış değeri üretilmektedir.



Şekil 2.34. Adaptif Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi

Kaynak: Haznedar Bülent ve Kalınlı Adem (2016). Training ANFIS using genetic algorithm for dynamic systems identification. *International Journal of Intelligent Systems and Applications in Engineering*, 44-47.

Şekil 2.35’de, şekil 2.34’de mimari yapısı gösterilen birinci dereceden iki girişli ve iki kurallı ANFIS sisteminin Takagi-Sugeno bulanık modeli için akıl yürütme mekanizması gösterilmiştir.



Şekil 2.35. Birinci Dereceden İki Girişli ve İki Kurallı Takagi-Sugeno Bulanık Modeli

Şekil 2.34’de görüldüğü üzere ANFIS 5 katmanlı ve ileri beslemeli bir yapay sinir ağları mimarisine sahiptir. ANFIS çıktısı ile öğrenme verilerini benzetmek için tüm uyarlanabilir parametrelerin ayarlanması, bu mimari için kullanılan öğrenme algoritmasının temel görevidir. Eğitim veri seti sinir ağına tanıtılır ve bir eğitim algoritması kullanılarak sinir ağı eğitilmektedir. Ayrıca model çıktısı ile öğrenme verileri arasındaki hata fonksiyonunun minimum olduğu şartların belirlenmesi hedeflenmektedir (Hímer vd. 2004).

ANFIS mimarisindeki her katmana ait işlemler ve katmanların işleyişi sırasıyla aşağıda belirtilmiştir.

Katman I

Bulanıklaştırma katmanı olarak adlandırılmaktadır. ANFIS modeli, giriş değerlerini bulanık kümelere ayırmada kullanılmaktadır. Bu katmanda bulunan sinir hücreleri adaptif (uyarlanabilir) hücrelerdir ve sinir hücresi sayısı giriş değişkeni sayısına eşittir. Burada, her bir sinir hücresinin çıkışı, giriş değerlerine ve kullanılan üyelik fonksiyonuna bağlı olan üyelik derecelerinden oluşmaktadır. Bu katmandaki sinir hücrelerinin çıkışları O_{li} eşitlik 2.22 ve eşitlik 2.23’de gösterilmiştir (Jang, Sun 1995).

$$O_{1i} = \mu A_i(x) \quad i = 1,2 \quad \text{Eşitlik 2.22}$$

$$O_{1i} = \mu B_{i-2}(x) \quad i = 3,4 \quad \text{Eşitlik 2.23}$$

Eşitliklerdeki A_i ve B_i herhangi bir bulanık küme parametresidir. μA_i ve μB_i bu bulanık küme parametrelerinin üyelik derecelerini temsil etmektedir. Çan eğrisi üyelik fonksiyonu olarak kullanıldığında μA_i , eşitlik 2.24 kullanılarak belirlenmektedir. Eşitlik 2.24'deki a_i , b_i ve c_i sırasıyla, çan eğrisi üyelik fonksiyonunun sigması, eğimi ve merkezini temsil etmektedir.

$$\mu A_i = \frac{1}{1 + \left[\left(\frac{x-c_i}{a_i} \right)^2 \right]^{b_i}} \quad i = 1,2 \quad \text{Eşitlik 2.24}$$

Gaussian üyelik fonksiyonu kullanıldığında μA_i , eşitlik 2.25 kullanılarak belirlenmektedir. Eşitlik 2.25'deki a_i ve c_i sırasıyla, gaussian üyelik fonksiyonunun sigması ve merkezini temsil etmektedir. Bu katmandaki parametreler başlangıç (premise) parametreleri olarak adlandırılmaktadır.

$$\mu A_i = \exp \left[- \left(\frac{x-c_i}{a_i} \right)^2 \right] \quad i = 1,2 \quad \text{Eşitlik 2.25}$$

Katman II

Bu katman kural katmanıdır. Bu katmanda bulunan her bir düğüm, Takagi-Sugeno bulanık mantık çıkarım sistemine göre oluşturulan kuralları ve bu kuralların sayısını ifade etmektedir. Bu katmandaki sinir hücreleri sabittir ve hücre sayısı ile kural sayısı birbirine eşittir. Sinir hücresi girişleri, kuralların giriş kısmındaki değişkenlerinin üyelik fonksiyonlarının değerleridir ve sinir hücresinin çıkışları (O_{2i}), kuralların ağırlık derecelerini (w_i) vermektedir. Her bir kural düğümünün çıkışı (μ_i), birinci katmandan gelen üyelik derecelerinin çarpımı ile eşitlik 2.26 kullanılarak belirlenmektedir.

$$O_{2i} = w_i = \mu A_i(x) \cdot \mu B_i(y) \quad i = 1,2 \quad \text{Eşitlik 2.26}$$

Katman III

Bu katman normalizasyon katmanıdır. Bu katmanda bulunan her bir düğüm, kural katmanından gelen tüm düğümleri giriş değeri olarak kabul etmektedir ve her bir kuralın normalleştirilmiş tetikleme katsayısını hesaplamaktadır. Bu katmanda bulunan sinir hücreleri de sabit hücrelerdir ve girişleri önceki katmandan aldıkları ağırlık değerleridir. Bu katmanda ağırlık değerleri eşitlik 2.27 kullanılarak normalize edilmektedir.

$$O_{3i} = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i = 1,2 \quad \text{Eşitlik 2.27}$$

Katman IV

Bu katman durulaştırma katmanıdır. Durulaştırma katmanında bulunan her bir düğümde verilen bir kuralın ağırlıklandırılmış sonuç değerleri hesaplanmaktadır. Bu katmandaki sinir hücreleri adaptif hücrelerdir ve bu hücrelerin çıkışı eşitlik 2.28 kullanılarak hesaplanmaktadır.

$$O_{4i} = \bar{w}_i \cdot f_i = \bar{w}_i \cdot (p_i x + q_i y + r_i) \quad i = 1,2 \quad \text{Eşitlik 2.28}$$


Katman V

Bu katman toplama katmanıdır. Bu katmanda sadece bir düğüm vardır ve Σ ile etiketlenmiştir. Burada, dördüncü katmandaki her bir düğümün çıkış değerleri toplanarak ANFIS sisteminin gerçek değeri elde edilmektedir. Sistemin gerçek çıkış değeri ise eşitlik 2.29 kullanılarak hesaplanmaktadır.

$$O_{5i} = f = \sum \bar{w}_i \cdot f_i = \frac{\sum w_i f_i}{\sum w_i} \quad i = 1,2 \quad \text{Eşitlik 2.29}$$

2.6. K-En Yakın Komşu Algoritması (k-Nearest Neighbours, KNN)

k-En Yakın Komşu (KNN) algoritması, denetimli öğrenme algoritmasıdır (Harrison 2019). Hem sınıflandırma hem de regresyon problemlerinin çözümünde kullanılmaktadır. KNN algoritması, 1967 yılında T.M. Cover ve P.E. Hart tarafından önerilmiştir. Algoritma, sınıfları belli olan bir veri kümesindeki verilerden yararlanarak sınıflandırma işlemi yapmaktadır. Veri kümesine katılan her bir yeni verinin, mevcut verilere olan uzaklığı hesaplanarak, k sayıdaki en yakın verilere göre sınıf tayini yapılır (Peterson 2009). Algoritma veriler arası uzaklığın hesaplanması için genellikle Öklid Uzaklığı (Euclidian Distance) formülünü kullanmaktadır. Şekil 2.36'da KNN algoritmasının çalışma şekli gösterilmiştir.



Şekil 2.36. KNN Algoritması Çalışma Şekli

Kaynak:<https://medium.com/@k.ulgen90/makine-%C3%B6%C4%9Frenimi-b%C3%B6l%C3%BCm-2-6d6d120a18e1> (Erişim Tarihi: 25.08.2019)

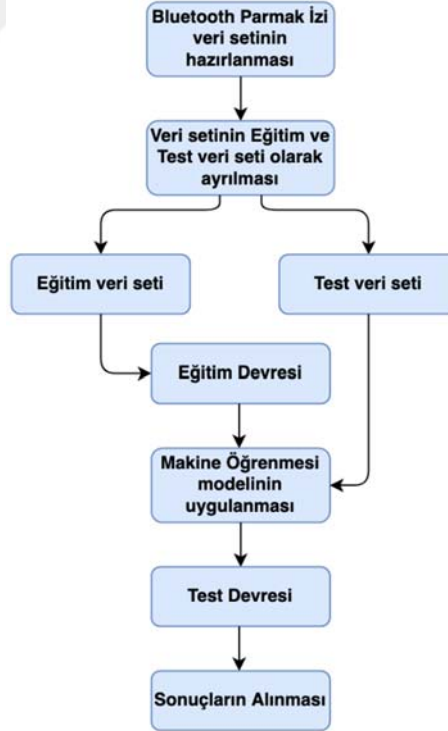
KNN algoritması basit olması, uygulanmasının kolay olması, herhangi bir model oluşturmaya ihtiyaç duymaması ve hem sınıflandırma hem de regresyon problemlerinde kullanılabilmesi açısından avantaj sağlamaktadır. Ancak veri kümesindeki veri sayısının arttıkça hesaplanın yavaşlaması açısından dezavantaj oluşturmaktadır.



ÜÇÜNCÜ BÖLÜM

3.MODELİN TASARIMI VE DENEYSEL SONUÇLAR

Bu tezde Parmak İzi yöntemiyle Bluetooth vericilerden alınan RSSI bilgileri temel olarak iç mekân konumlandırma yapan bir sistemin, makine öğrenmesi kullanılarak daha başarılı bir konumlandırma yapması amaçlanmıştır. Bu tezde geliştirilen model üç kısımdan oluşmaktadır. İlk kısım Parmak İzi yöntemi kullanılarak Bluetooth vericilerin RSSI bilgilerinin okunup veri setinin hazırlanması, ikinci kısımda ANFIS modeli ve YSA modeli kullanılarak makine öğrenmesi modellerinin geliştirilmesi ve üçüncü kısımda ise geliştirilen makine öğrenmesi modellerinin test edilerek başarısının ölçülmesidir. Tezde geliştirilen modellerin genel geliştirilme süreci şekil 3.1’de gösterilmiştir.



Şekil 3.1. Modellerin Genel Geliştirilme Süreci

Sistemin ilk kısmı olan veri setinin hazırlanması için Parmak İzi yöntemi seçilmiştir. Parmak İzi yöntemiyle çalışma sahasındaki Bluetooth vericilerden alınan

RSSI bilgileri kaydedilmiştir. Parmak izi yönteminin kapalı mekânlar için güvenilir bir metot olması (Laitinen, Lohan 2016), bu yöntemin seçilmesinde temel neden olmuştur. Ayrıca Parmak İzi yönteminin seçilmesinde, aşağıdaki nedenler de etkili olmuştur;


- Ücretsiz olması; havada dolaşan kablosuz sinyallerin okunması için herhangi bir lisans ücretinin gerekmemesi
- Esneklik sunması; kullanılmak istenilen duruma göre kolayca ayarlanabilmesi
- Karma sinyal ile kullanılabilmesi; Bluetooth, Wi-Fi veya diğer kablosuz teknolojilerin bir kombinasyonu ile birlikte kullanılabilmesini sağlaması
- Sunucu esnekliği; hem sunucu hem de istemci tarafında veri tipinden bağımsız bir şekilde kullanım sağlaması
- Limitsizlik; istemci tarafında çalışırken aktif cihaz sayısında bir limitinin olmaması
- Uygunluk; kullanılan cihazların tipi veya markası fark etmeksizin çalışabilmesi

Sistemin ikinci kısmında, ilk kısımda hazırlanan veri seti ile makine öğrenmesi kullanılarak iç mekânda konumlandırma yapması ise ANFIS ve YSA ile sağlanmıştır. ANFIS modelinin seçilmesinde aşağıdaki nedenler etkili olmuştur;

- Eğitim aşamasında hızlı yakınsama oranı sağlaması
- Belirsizliğe yüksek derecede toleranslı olması
- Sayısal verilerden sayısal modeller çıkarmada başarılı olması
- Tasarım karmaşıklığını basitleştirmesi
- Uygulanmasının kolay olması
- Yeni kurallar ekleyerek bilgi tabanının kolaylıkla genişletilebilmesi
- Sistemdeki olası bozukluklara karşı sağlamlık sağlaması

3.1. Çalışma Sahası ve Çalışma Ekipmanlarının Hazırlanması


Sivas Cumhuriyet Üniversitesi Bilgisayar Mühendisliği bölümünde bulunan bilgisayar laboratuvarı çalışma sahası olarak ve Raspberry Pi, iOS işletim sistemli mobil cihaz ve macOS işletim sistemli bilgisayar ise çalışma ekipmanları olarak kullanılmıştır. Laboratuvarın uzunluğu yaklaşık 12 m ve eni ise yaklaşık 8 m uzunluğundadır. Şekil 3.2’de çalışma sahasının haritası gösterilmiştir.



Şekil 3.2. Çalışma Sahası Haritası

Çalışma sahasının her bir köşesine vericiler yerleştirilerek çalışma sahasının kurulumu tamamlanmıştır. Şekil 3.3’de ise çalışma sahasına vericilerin yerleşimi gösterilmiştir. Ölçümlerin alınması için kullanılan donanım sistemlerinin teknik yapılarından kaynaklı oluşan farklılıklar ölçüm sonuçları üzerinde etkili bir parametredir ve düzeltilemez bir yapıdadır. Bu farklılık özellikle aynı mesafelerde sistemlerin farklı sonuçlar oluşturması gibi istenmeyen ve kontrol edilemeyen etkiler doğurmaktadır. Bu durum beklendiği gibi Makine öğrenmesi modellerinin eğitimlerini ve ürettikleri sonuçlar üzerinde de etkili olmaktadır. Bununla beraber ölçüm alınan ortamın fiziksel boyutuda (en x boy) ölçülen sinyaller arasında özellikle yakın konumlarda sinyal şiddetinde beklenenden daha ufak değişimler göstermektedir. Bu dezavantajları gidererek modelin eğitilmesinde daha sağlıklı veriler (kontrol edilemeyen parametreler sebebi ile oluşan) kullanabilmek için, veriler üzerinde

kalibrasyon yapılarak veri tabanına kayıt edilmiştir. Bu kalibrasyon özet olarak; simülasyon ortamında aynı sistem parametreleri kullanılarak elde edilen RSSI değerlerinin konum bazlı oransal etkilerinin gerçek ölçüm verileri üzerine uygulanarak ayarlanması şeklinde olmuştur (bu düzeltmeler sonucunda modellerin daha etkin eğitildikleri gözlenmiştir, asıl amaç makine öğrenmesi modellerinin en iyi sonuçları üretecek şekilde eğitilmesidir).




Şekil 3.3. Çalışma Sahasına Bluetooth Vericilerin Yerleşim Düzeni

Çalışma sahasında vericilerin sinyalleri ile girişime neden olabilecek elektromanyetik dalgalar yayan bilgisayarlar, monitörler ve kablosuz cihazların bulunması veriler üzerinde etkili dış faktörlerdendir ve ölçümler üzerinde bozucu etkileri mevcuttur. Ayrıca zaman gecikmesinin olmaması ve vericilerden daha sık sinyalin okunabilmesi için her bir vericinin sinyal yayın aralığı 300 ms olarak ayarlanmıştır (fakat kullanılan cihazlarda oluşan donanım farklılıkları sebebi ile bu parametrelerde hepsinin davranışları aynı olmamıştır, bir önceki paragrafta bahsedilen düzeltmeler ile sistemin ürettiği verilerin tutarlılığı sağlanmaya çalışılmıştır).

Vericilerin ve sistemin konfigüre edilmesinin ardından, mobil cihaza sinyallerinin okunması için üçüncü parti bir yazılım yüklenmiş ve bu okunan sinyallerin kaydedilmesi için bilgisayara bir veri tabanı kurularak tüm çalışma ekipmanları hazır hale getirilmiştir.

3.2. Veri Setinin Hazırlanması

Çalışma ekipmanlarının kurulumları ve konfigürasyonlarının tamamlanmasıyla vericilerden RSSI bilgilerinin toplanıp veri setinin hazırlanmasının daha kolay olabilmesi için çalışma sahası, 6x9 şeklinde 54 bölgeye ayrılmış ve her bir bölgede ayrı ayrı veriler toplanarak veri tabanına kaydedilmiştir. Şekil 3.4’de çalışma sahasının bölgelere ayrılmış hali gösterilmiştir.



Şekil 3.4. Bölgelere Ayrılmış Çalışma Sahası

Çalışma sahasında bulunan her bir bölge için mobil cihazla vericilerden sinyal okuması yapılmıştır. Mobil cihaz 1 saniyelik aralıklarla vericilerden gelen sinyalleri dinlemiş ve aldığı sinyal değerlerini bilgisayara göndererek veri tabanına kaydı yapılmıştır. Ölçüm yapılan ortamda sinyal yayıcılar mesafelerdeki değişim aralıkları yakın olduğu için RSSI değerlerindeki değişimlerde özellikle kısa mesafelerde küçük farklılıklarla oluşmaktadır. Oluşan veriler arasındaki bu ufak değişimler gerçekleştirilen kalibrasyon çalışmaları ile (similasyon ile oluşturulan modelin aynı mesafelerdeki değişimlerinin (aynı parametreler ile) oransal farklılıkları göz önüne alınarak, üretilen veriler üzerinde düzeltmeler yapılmıştır) veri seti Makine öğrenmesi yaklaşımları için daha kullanışlı hale getirilmiştir. Toplamda her bir bölge için 25 ve tüm veri seti için 1350 veri kalibrasyon düzeltmeleri yapılarak kaydedilmiştir. Ayrıca 250 veriden oluşan ikinci bir veri seti de oluşturulan modellerin başarısını ölçmek için

aynı şekilde kaydedilmiştir. Tablo 3.1’de her bir bölgeden her bir vericiden alınan RSSI bilgileriyle oluşturulmuş ve düzeltilmiş verilerin bölgelere göre sınıflandırılmış bir veri serisi örneği gösterilmiştir.

Tablo 3.1. Çalışma Sahasındaki Bölgelerdeki Vericilerden Alınan RSSI (dBm) Veri Serisi Örneği

Bölge \ Verici	Beacon1	Beacon2	Beacon3	Beacon4
(1,1)	-56	-92	-75	-99
(2,5)	-74	-98	-56	-87
(3,3)	-64	-88	-73	-95
(4,2)	-69	-75	-80	-84
(5,4)	-83	-83	-74	-75
(6,5)	-84	-80	-70	-72
(7,2)	-83	-64	-97	-72
(8,1)	-85	-56	-94	-73
(9,5)	-98	-73	-89	-59

Tablo 3.2’de bazı bölgelerdeki her bir vericiden alınan ortalama RSSI deęerleri gösterilmiřtir.


Tablo 3.2. Bazı Bölgelerdeki Ortalama RSSI (dBm) Deęerleri

Verici Bölge	Beacon1	Beacon2	Beacon3	Beacon4
(1,1)	-52,92	-89,24	-72,52	-96,16
(2,5)	-71	-95,16	-59,12	-87,6
(3,3)	-62,2	-87,2	-70	-93,12
(4,2)	-69,32	-72,36	-80,56	-83,28
(5,4)	-80,96	-81,2	-72	-72,04
(6,5)	-82,92	-80,44	-72,24	-68,72
(7,2)	-86,36	-60,92	-94,68	-72,36
(8,1)	-88,08	-56,16	-95,2	-71,88
(9,5)	-95	-71,16	-88,6	-55,84

3.3. ANFIS Modelinin Kurulması ve Eğitilmesi

Veri setinin hazırlanmasının ardından ANFIS modelinin kurulma sürecine başlanmıştır. ANFIS modelinin kurulması ve modelin eğitilmesi MATLAB programı kullanılarak gerçekleştirilmiştir.


Kurulan ANFIS modeli iki mekanizmadan oluşmaktadır. İlk mekanizma eğitim veri setinde bulunan 4 RSSI bilgisi ile bu 4 RSSI bilgisine karşılık gelen x koordinatı bilgisini giriş olarak alarak, her bir x koordinatı verisi için y' koordinat bilgisini çıktı olarak üretir. İkinci mekanizma ise eğitim veri setinde bulunan 4 RSSI bilgisi ile bu 4 RSSI bilgisine karşılık gelen y koordinat bilgisini giriş olarak alarak, her bir y koordinat verisi için x' koordinat bilgisini çıktı olarak üretir. İki mekanizmadan üretilen (x',y') koordinat bilgisi çiftlerinden oluşturulan koordinat verileri grubu sonuçlardan k-En Yakın Komşu algoritması kullanılarak gerçek değere en yakın olan sonuç seçilmektedir. Şekil 3.5'de kurulan ANFIS modeli gösterilmiştir.



Şekil 3.5. Kurulan ANFIS Modeli

ANFIS modelinde FIS (Fuzzy Inference Systems, Bulanık Çıkarım Sistemi) oluşturulurken kimliklendirme yöntemi olarak Izgara Bölümleme (Grid Partition) ve öğrenme algoritması olarak da Hibrid Öğrenme algoritması seçilmiştir. Ayrıca her bir

giriş verisi için üyelik fonksiyonu sayısı (inputmf) 3 olarak seçilmiştir. Şekil 3.6’da kurulan ANFIS modelinin yapısı gösterilmiştir.



Şekil 3.6. Kurulan ANFIS Modeli Yapısı

ANFIS modelinin eğitilmesi için kullanılacak 1350 veriden oluşan veri seti “Eğitim Seti”, “Doğrulama Seti” ve “Test Seti” olarak üç bölüme ayrılmıştır. Bu ayırma işlemi %70’lik kısmı eğitim, %15’lik kısmı doğrulama ve %15’lik kısmı ise test olarak ayrılmış ve bu veri setlerine değerler rasgele olarak atanmıştır. Tablo 3.3’de veri setlerinin belirlenen oranlarda ayrılması ve ayrılan veri setlerine değerlerin rasgele atanması için gereken MATLAB kodları gösterilmiştir.

Tablo 3.3. Veri Setini ANFIS Modelinin Eğitimi İçin Bölümlere Ayıran
MATLAB Kodu

```
egitimInd : Eğitim veri seti için üretilen indis numaraları
dogrulamaInd : Doğrulama veri seti için üretilen indis numaraları
testInd : Test veri seti için üretilen indis numaraları

dosyaAdi="Tüm veri setinin bulunduğu excel dosyasının ismi"
sayfaAdi="Tüm veri setinin bulunduğu excel sayfasının ismi"
excelDosya=xlsread(dosyaAdi,sayfaAdi);
[Q,R]=size(veriSeti);
veriSeti=veriSeti';
egitimOran=0.70; // Eğitim veri seti oranı
dogrulamaOran=0.15; // Doğrulama veri seti oranı
testOran=0.15; // Test veri seti oranı
[egitimInd,dogrulamaInd,testInd]=dividerand[Q,egitimOran,dogrulamaOran,testOran];
egitimSeti=(veriSeti(:,egitimInd))'; // Eğitim veri seti
dogrulamaSeti=(veriSeti(:,dogrulamaInd))'; // Doğrulama veri seti
testSeti=(veriSeti(:,testInd))'; // Test veri seti
```

Eğitim, doğrulama ve test veri setinin ayrılması ve bu veri setlerine değerlerin atanmasının ardından modelin eğitim veri seti ile eğitilmesi safhasına geçilmiştir. Modelin eğitim safhasında devir sayısı (epoch) olarak çeşitli sayılar denenmiş ve en iyi sonuç ise devir sayısının 250 olduğu durumda alınmıştır. Ayrıca modelin eğitimi için tüm üyelik fonksiyonları denenmiş ve dsigmf, gaussmf ve trimf üyelik fonksiyonlarının daha başarılı olduğu gözlenmiştir.

Tablo 3.4. ANFIS Modelinin Özelliklerinin Belirlendiği ve Eğitimin
Yapılmasını Sağlayan MATLAB Kodu

```
mfSayisi=[3 3 3 3 3];
mfTipi=char('trimf','trimf','trimf','trimf','trimf');
cikisTipi='linear';
fismat=genfis(egitimSeti,mfSayisi,mfTipi,cikisTipi);
trnOpt=[250,0,0.01,0.09,1.1];
[fismat1,error1,ss,fismat2,error2]=anfis[egitimSeti,fismat,trnOpt,[],testSeti];
```

3.4. ANFIS Modelinin Test Edilmesi ve Sonuçların Alınması

ANFIS modelinin kurulmasının ardından modelin başarısının ölçülmesi safhasına geçilmiştir. Farklı üyelik fonksiyonları ile eğitilen ANFIS modellerinin ürettiği MSE (Mean Squared Error, Ortalama Hata Karesi), R^2 korelasyon katsayısı ve MAPE (Mean Absolute Percentage Error, Ortalama Mutlak Hata Yüzdesi) değerleri tablo 3.5’de gösterilmiştir.

MAPE (Swamidass 2000): Tahminlerin ortalama mutlak hata yüzdesi

MSE (Sammut, Webb 2011): Tahminlerin ortalama hata karesi


R^2 (Hayes 2019): Bağımlı değişken içindeki bağımsız değişkenden tahmin edilebilir varyansın oranı

Tablo 3.5. Farklı Üyelik Fonksiyonları ile Eğitilen ANFIS Modelinin Sonuç Kontrol Değerleri

Veri Setleri		Eğitim Veri Seti		Doğrulama Veri Seti		Test Veri Seti	
Üyelik Fonk.		x	y	x	y	x	y
dsigmf	MSE	0,0629	0,0608	0,0674	0,0613	0,1228	0,0617
	R^2	0,9824	0,9852	0,98	0,9846	0,9528	0,9831
	MAPE	0,0460	0,0436	0,0506	0,0442	0,1071	0,0467
gaussmf	MSE	0,0880	0,0623	0,0985	0,0614	0,1203	0,0599
	R^2	0,9797	0,9839	0,9791	0,9829	0,9574	0,9811
	MAPE	0,0516	0,0475	0,0524	0,0466	0,1026	0,0504
trimf	MSE	0,1248	0,1226	0,1306	0,1317	0,1458	0,1318
	R^2	0,9778	0,9798	0,9772	0,9786	0,9446	0,9786
	MAPE	0,0541	0,0515	0,0547	0,0531	0,1143	0,0530

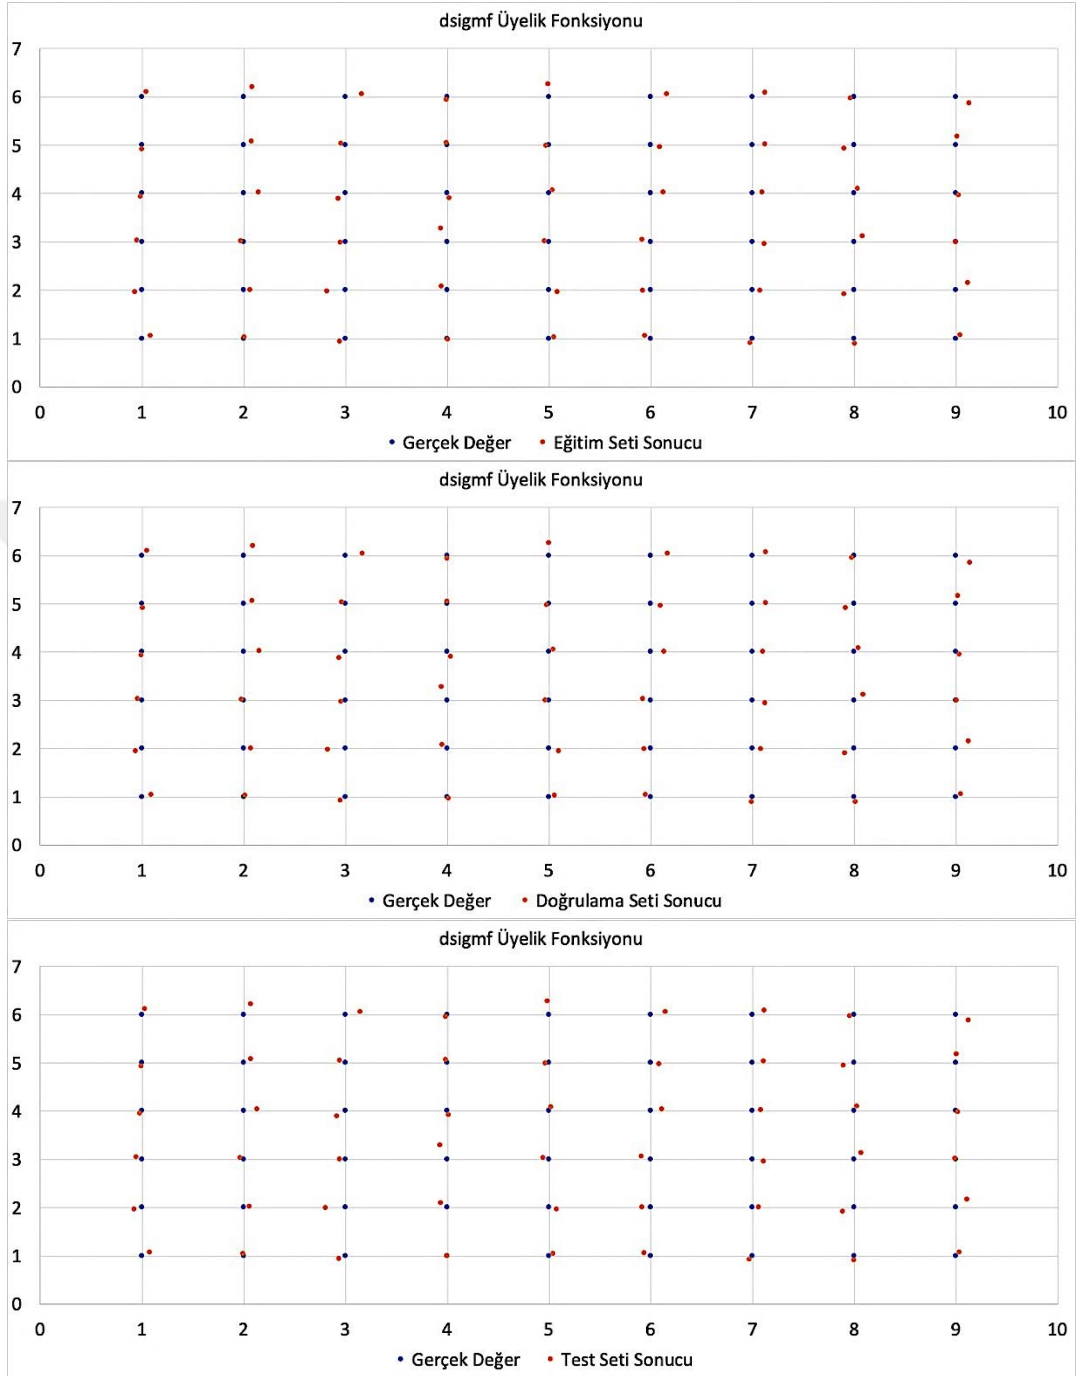
Şekil 3.7’de ANFIS modellerinin ürettiği sonuçlar ve k-En Yakın Komşu algoritması ile seçilen en yakın sonucun bir örneği gösterilmiştir (görselin daha anlaşılabilir olması açısından diğer konumlardaki ölçüm görselleri temizlenerek bu

grafik oluşturulmuştur). Şekilde gerçek değer mavi, elde edilen en yakın sonuç kırmızı ve diğer sonuçlar ise turuncu renkle gösterilmiştir.




Şekil 3.7. ANFIS Modellerinin Ürettiği Sonuçlar Örneği

Şekil 3.8’de dsigmf üyelik fonksiyonu ile eğitilen ANFIS modellerinin eğitim, doğrulama ve test veri setleri üzerindeki gerçek çıkış değerleri ve üretilen çıkış değerlerinden k-En Yakın Komşu algoritması ile seçilen en yakın değer gösterilmiştir (görselde sadece ölçüm noktasına en yakın sonucu üreten konum değeri gösterilmiş, diğer üretilen değerler görselin daha anlaşılır olabilmesi için dahil edilmemiştir).



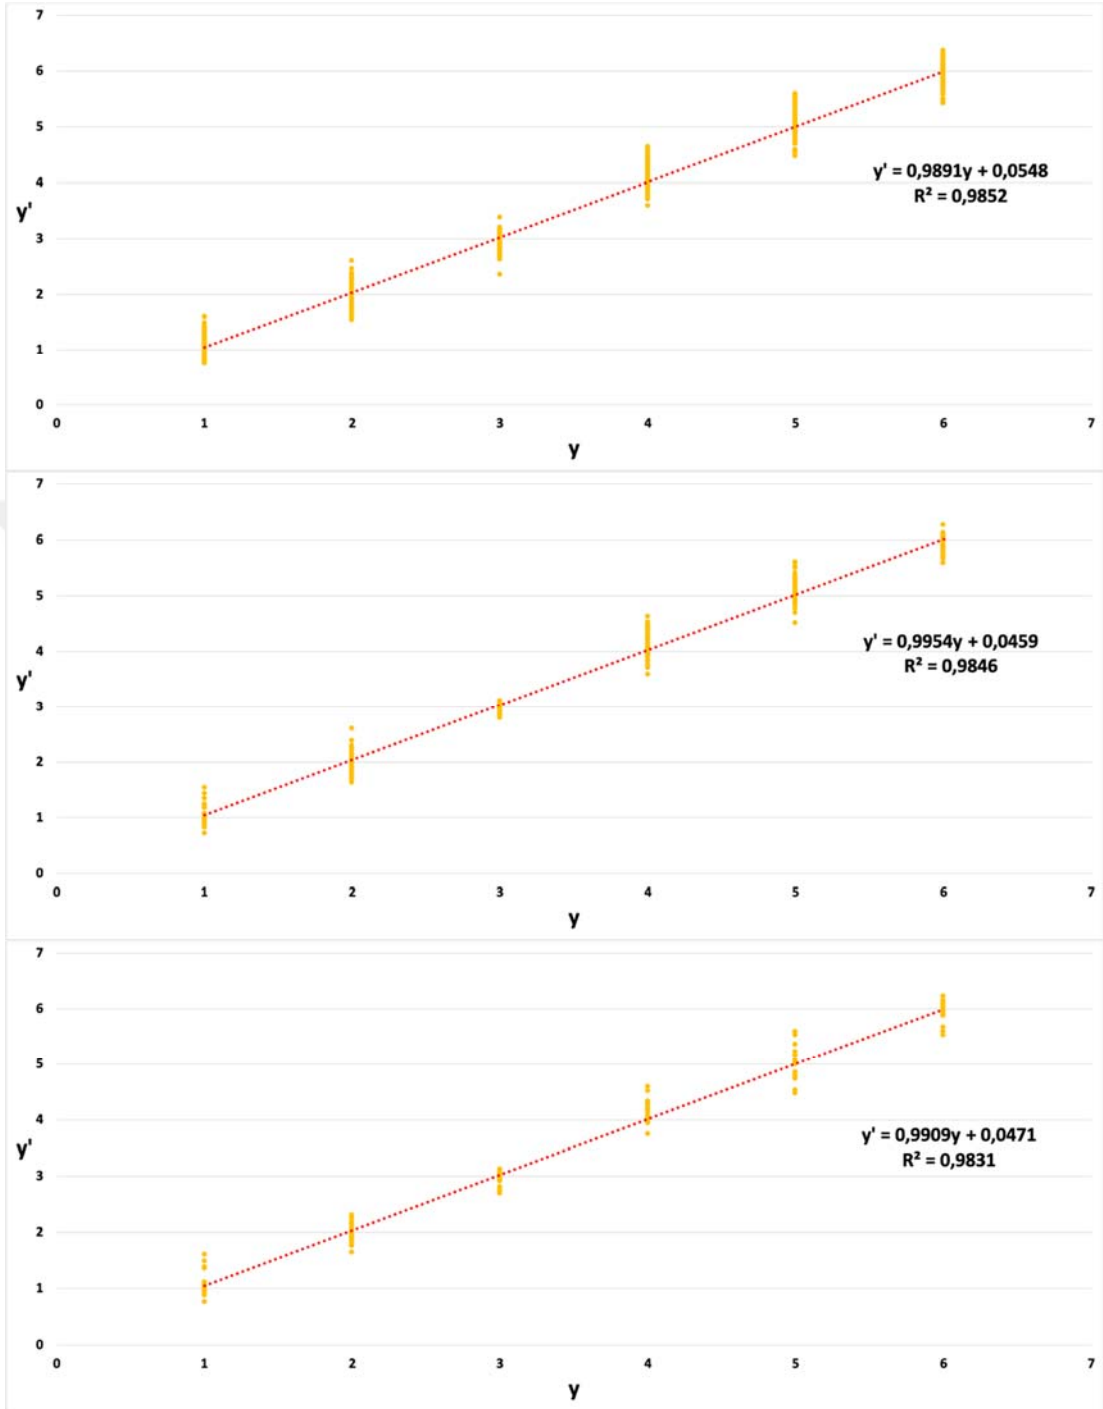
Şekil 3.8. ANFIS Modelinin dsigmf Üyelik Fonksiyonuna Ait Sonuç Grafikleri

Şekil 3.9’da dsigmf üyelik fonksiyonu ile eğitilen ANFIS modellerinin eğitim, doğrulama ve test veri setleri üzerindeki x değerlerine ait regresyon grafikleri gösterilmiştir.



Şekil 3.9. dsigmf Üyelik Fonksiyonu Eğitim, Doğrulama ve Test Veri Setleri Üzerindeki x Değerlerine Ait Regresyon Grafikleri

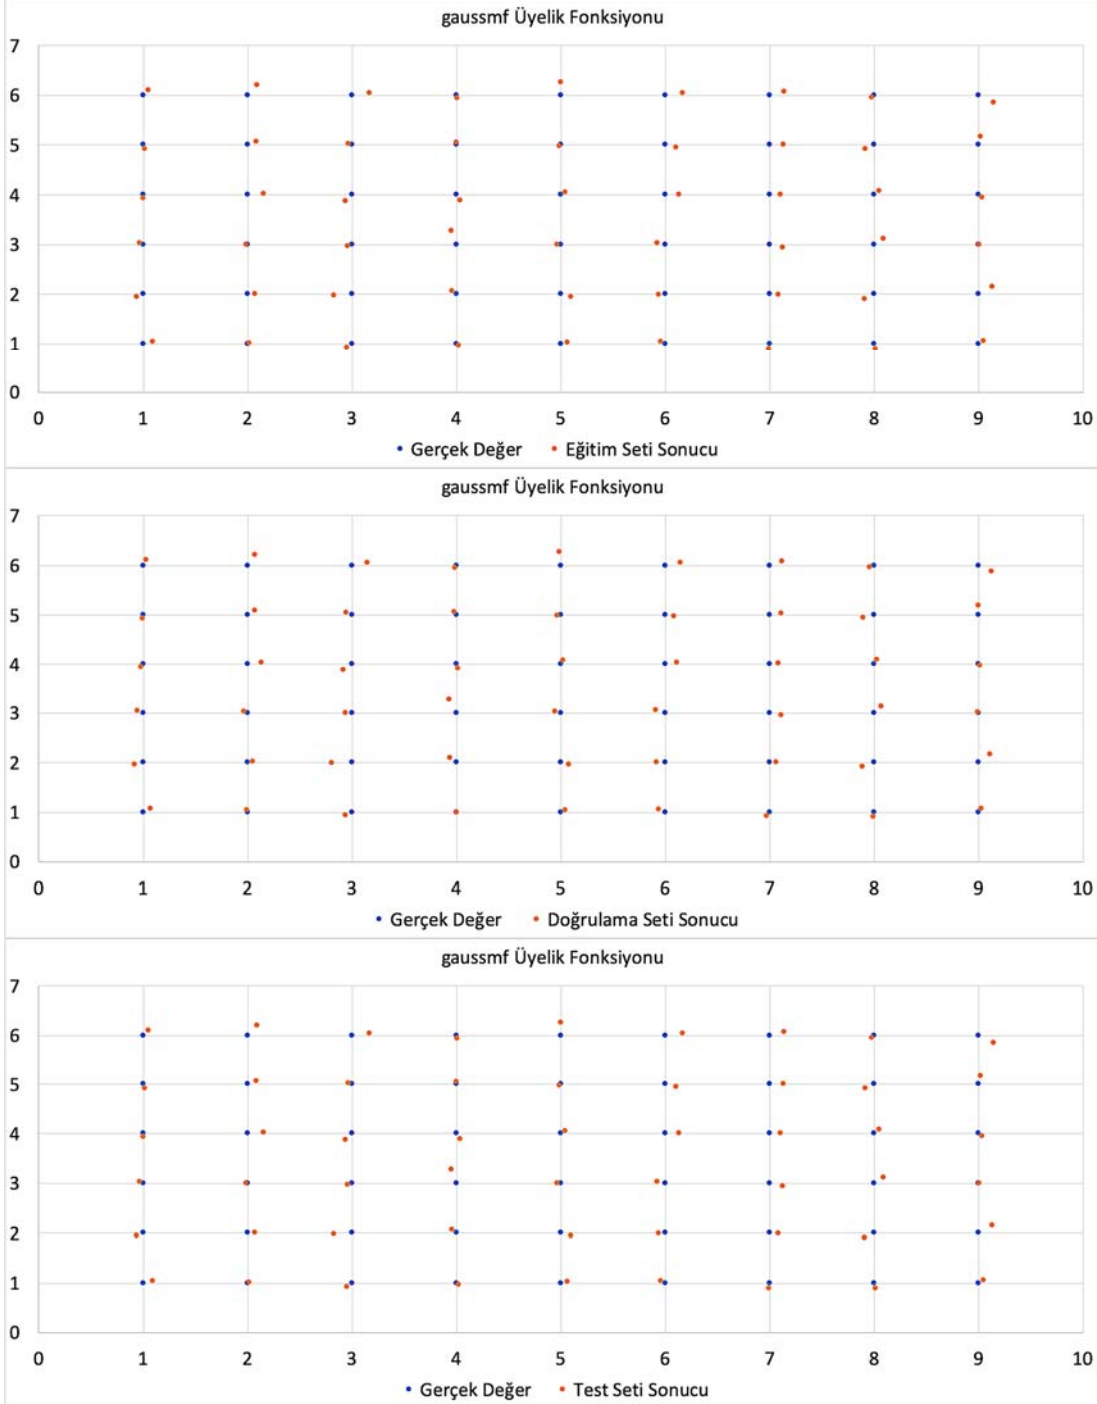
Şekil 3.10'da dsigmf üyelik fonksiyonu ile eğitilen ANFIS modellerinin eğitim, doğrulama ve test veri setleri üzerindeki y değerlerine ait regresyon grafikleri gösterilmiştir.



Şekil 3.10. dsigmf Üyelik Fonksiyonu Eğitim, Doğrulama ve Test Veri Setleri Üzerindeki y Değerlerine Ait Regresyon Grafikleri


Şekil 3.11'de gaussmf üyelik fonksiyonu ile eğitilen ANFIS modellerinin eğitim, doğrulama ve test veri setleri üzerindeki gerçek çıkış değerleri ve üretilen çıkış değerlerinden k-En Yakın Komşu algoritması ile seçilen en yakın değer gösterilmiştir

(görselde sadece ölçüm noktasına en yakın sonucu üreten konum değeri gösterilmiş, diğer üretilen değerler görselin daha anlaşılır olabilmesi için dahil edilmemiştir).



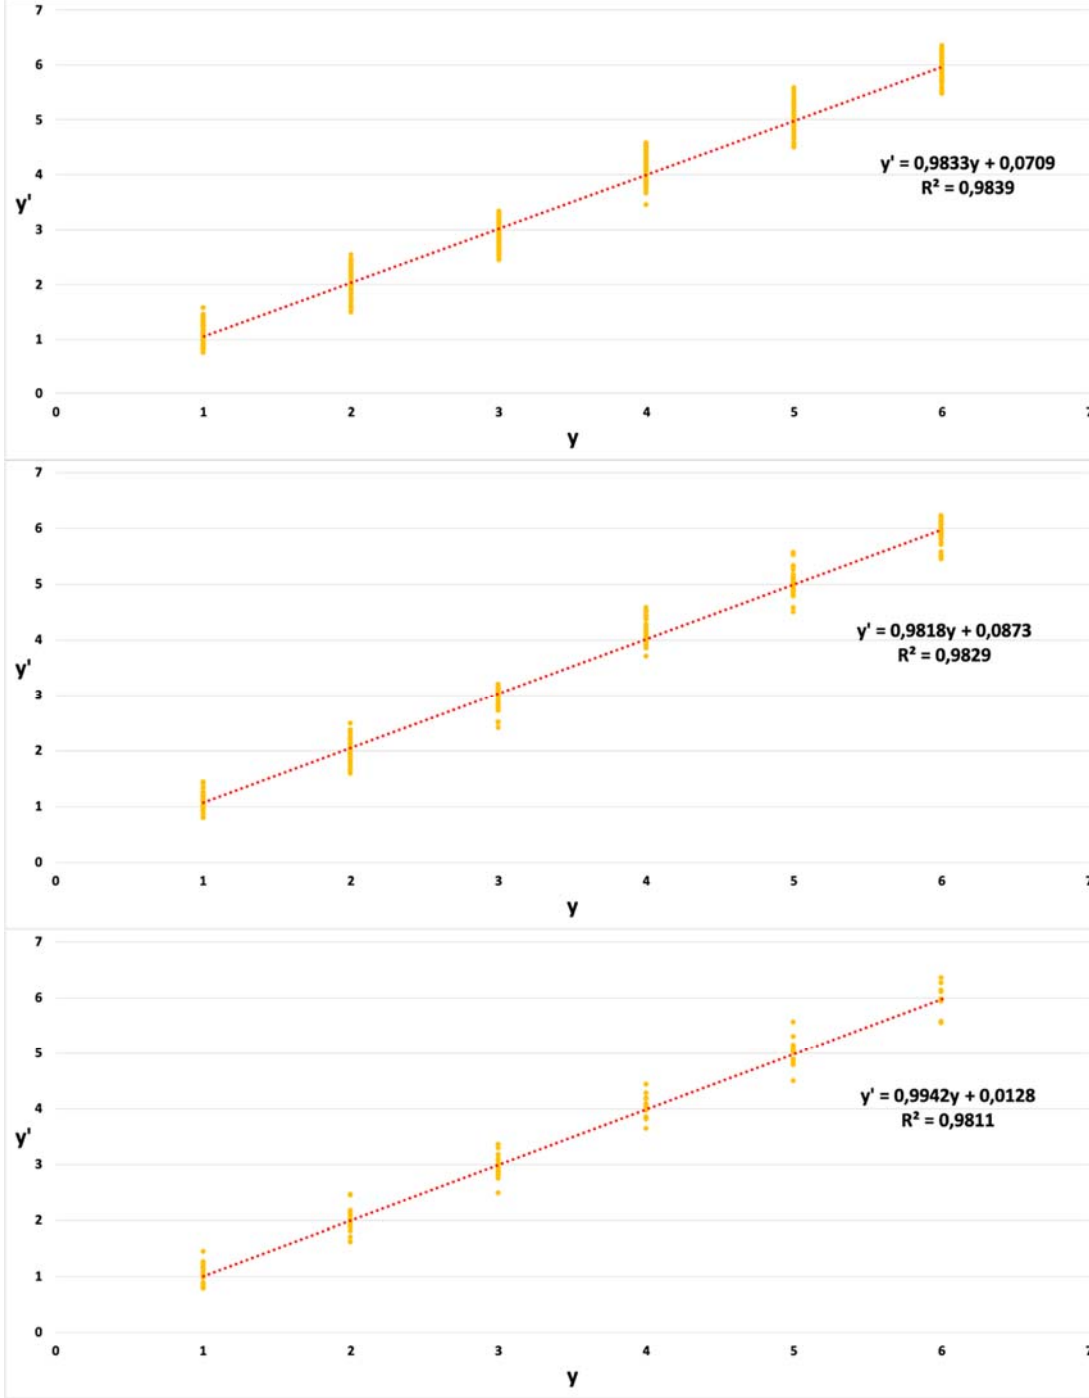
Şekil 3.11. ANFIS Modelinin gaussmf Üyelik Fonksiyonuna Ait Sonuç Grafikleri

Şekil 3.12’de gaussmf üyelik fonksiyonu ile eğitilen ANFIS modellerinin eğitim, doğrulama ve test veri setleri üzerindeki x değerlerine ait regresyon grafikleri gösterilmiştir.



Şekil 3.12. gaussmf Üyelik Fonksiyonu Eğitim, Doğrulama ve Test Veri Setleri Üzerindeki x Değerlerine Ait Regresyon Grafikleri

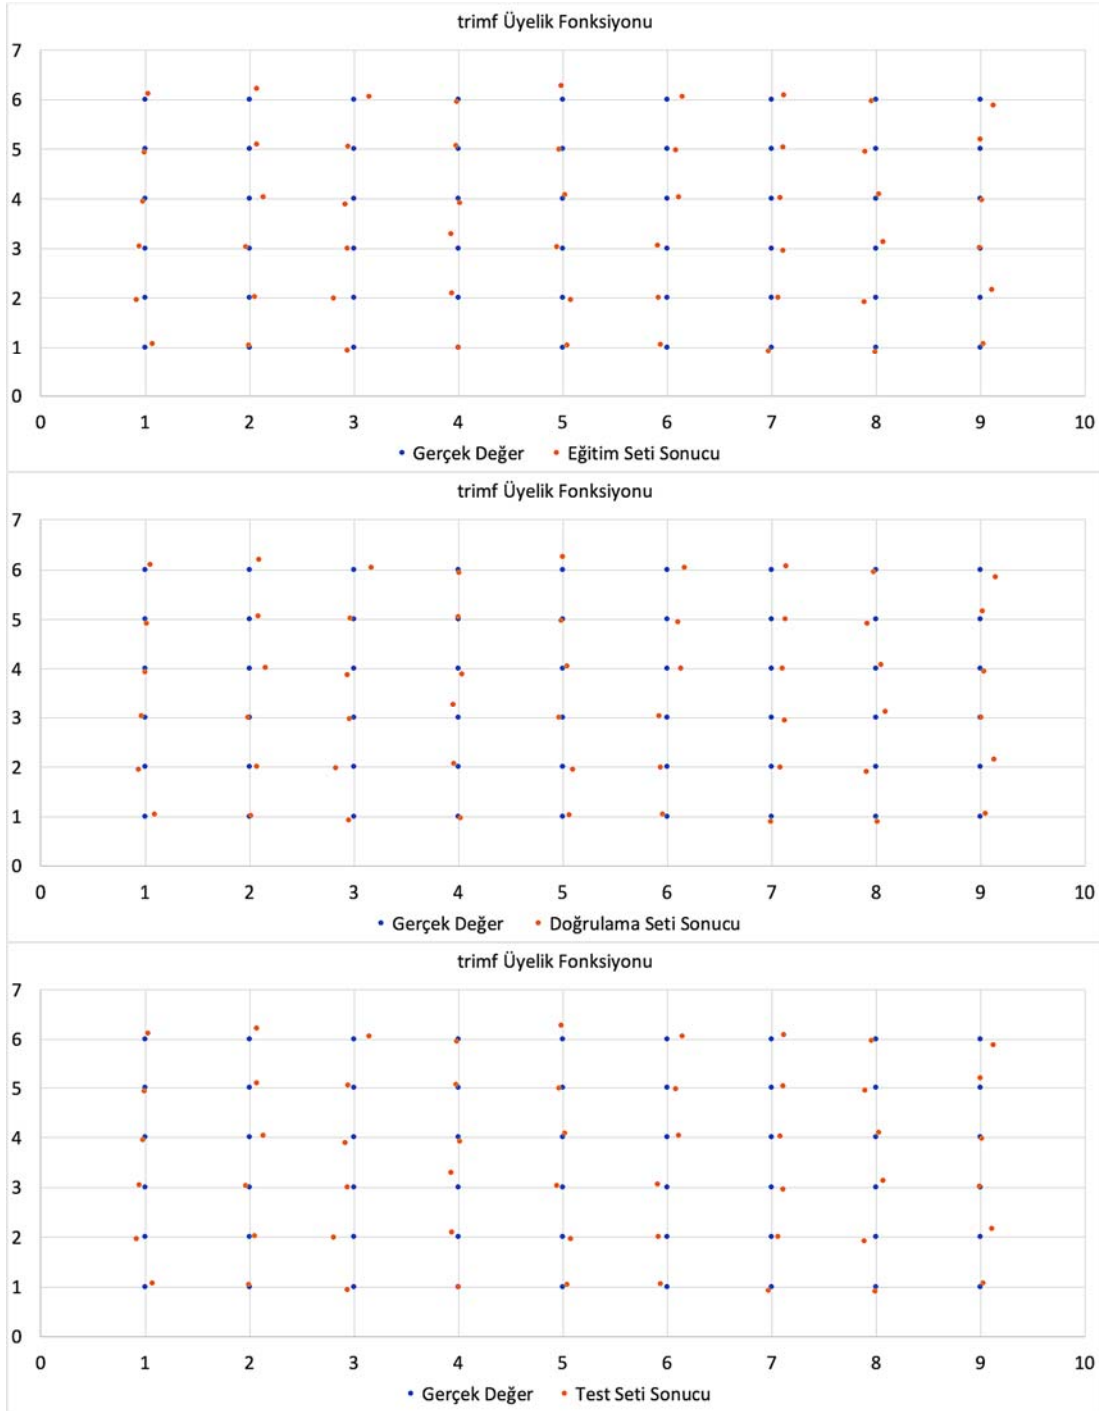
Şekil 3.13’de gaussmf üyelik fonksiyonu ile eğitilen ANFIS modellerinin eğitim, doğrulama ve test veri setleri üzerindeki y değerlerine ait regresyon grafikleri gösterilmiştir.



Şekil 3.13. gaussmf Üyelik Fonksiyonu Eğitim, Doğrulama ve Test Veri Setleri Üzerindeki y Değerlerine Ait Regresyon Grafikleri


Şekil 3.14’de trimf üyelik fonksiyonu ile eğitilen ANFIS modellerinin eğitim, doğrulama ve test veri setleri üzerindeki gerçek çıkış değerleri ve üretilen çıkış değerlerinden k-En Yakın Komşu algoritması ile seçilen en yakın değer gösterilmiştir (görselde sadece ölçüm noktasına en yakın sonucu üreten konum değeri gösterilmiş, diğer üretilen değerler görselin daha anlaşılır olabilmesi için dahil edilmemiştir).





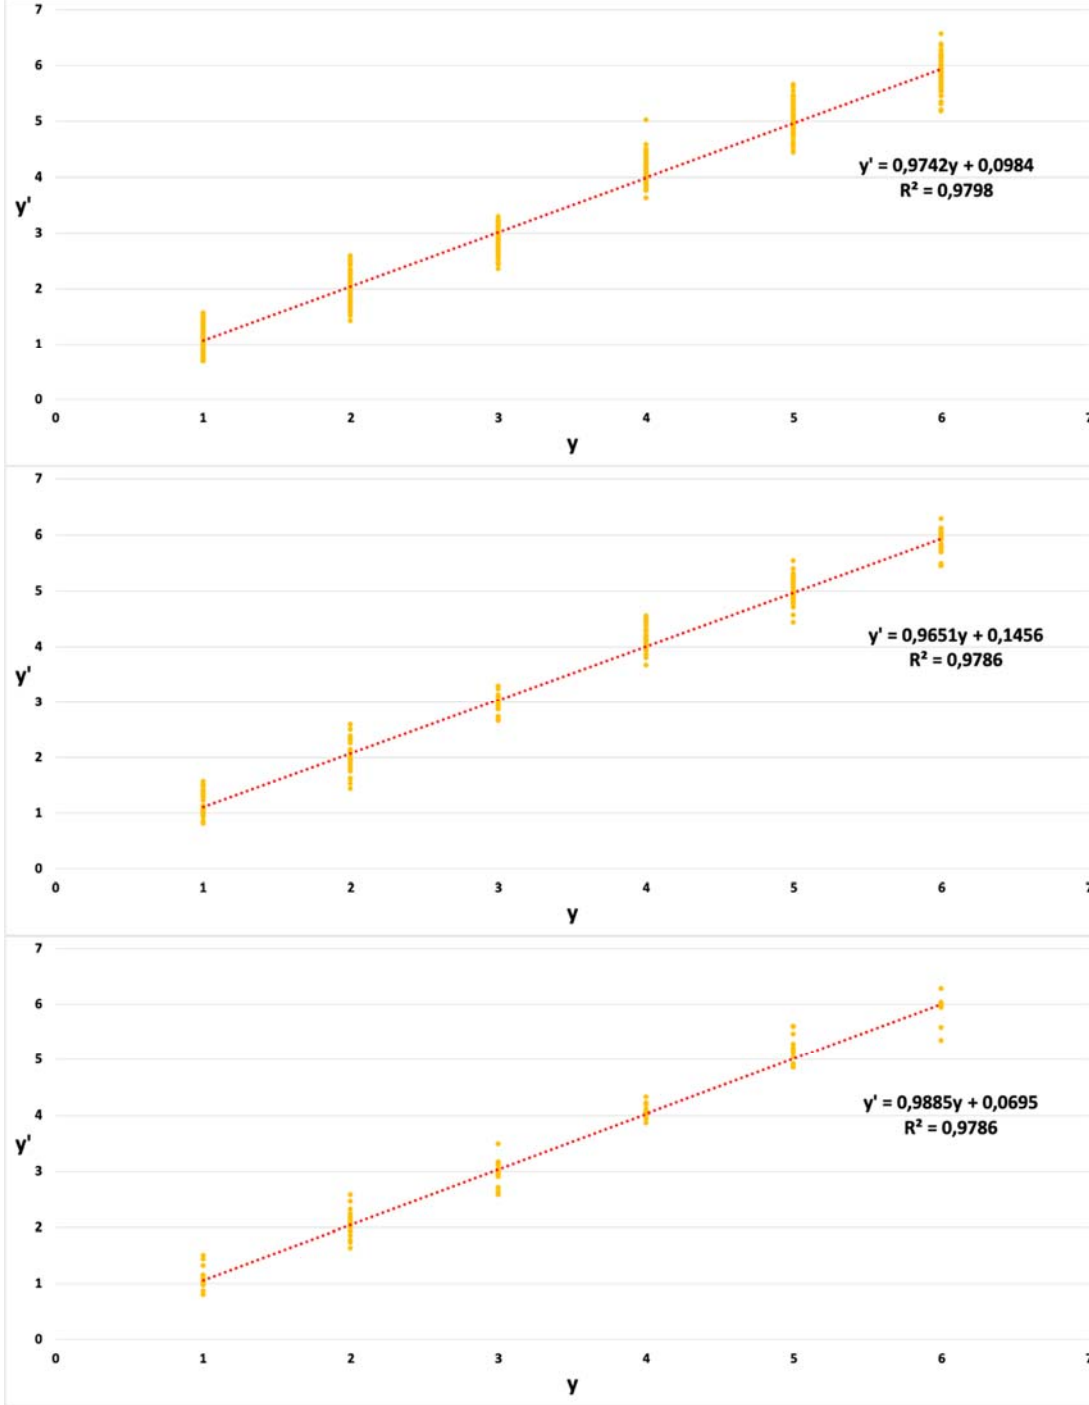
Şekil 3.14. ANFIS Modelleri trimf Üyelik Fonksiyonuna Ait Sonuç Grafikleri

Şekil 3.15’de trimf üyelik fonksiyonu ile eğitilen ANFIS modellerinin eğitim, doğrulama ve test veri setleri üzerindeki x değerlerine ait regresyon grafikleri gösterilmiştir.



Şekil 3.15. trimf Üyelik Fonksiyonu Eğitim, Doğrulama ve Test Veri Setleri Üzerindeki x Değerlerine Ait Regresyon Grafikleri

Şekil 3.16’da trimf üyelik fonksiyonu ile eğitilen ANFIS modellerinin eğitim, doğrulama ve test veri setleri üzerindeki y değerlerine ait regresyon grafikleri gösterilmiştir.




Şekil 3.16. trimf Üyelik Fonksiyonu Eğitim, Doğrulama ve Test Veri Setleri Üzerindeki y Değerlerine Ait Regresyon Grafikleri

Kurulan ANFIS modelinin başarısı, veri setinin hazırlanması aşamasında ikinci bir test verisi olarak hazırlanan ve 250 veriden oluşan bir veri seti ile de test edilmiştir. ANFIS modelinin ikinci test veri seti ile ürettiği MSE, R^2 korelasyon katsayısı ve MAPE değerleri tablo 3.6’da gösterilmiştir.

Tablo 3.6. Farklı Üyelik Fonksiyonları ile Eğitilen ANFIS Modelinin İkinci Test Veri Seti İçin Sonuç Kontrol Değerleri


Üyelik Fonksiyonu	Veri Seti	İkinci Test Veri Seti	
		x	y
dsigmf	MSE	0,1310	0,0616
	R^2	0,972	0,9835
	MAPE	0,0559	0,0462
gaussmf	MSE	0,1296	0,0626
	R^2	0,9786	0,9826
	MAPE	0,0513	0,0472
trimf	MSE	0,1306	0,1304
	R^2	0,975	0,977
	MAPE	0,0534	0,0531

Şekil 3.17’de ANFIS modellerinin ikinci test veri seti ile test edildiğinde ürettiği sonuçlar ve k-En Yakın Komşu algoritması ile seçilen en yakın sonucun bir örneği gösterilmiştir. Şekilde gerçek değer mavi, elde edilen en yakın sonuç kırmızı ve diğer sonuçlar ise turuncu renkle gösterilmiştir.




Şekil 3.17. ANFIS Modellerinin İkinci Test Setiyle Ürettiği Sonuçlar Örneği

Şekil 3.18’de dsigmf üyelik fonksiyonu ile eğitilen ANFIS modellerinin ikinci test veri seti üzerindeki gerçek çıkış değerleri ve üretilen çıkış değerlerinden k-En Yakın Komşu algoritması ile seçilen en yakın değer gösterilmiştir.




Şekil 3.18. dsigmf Üyelik Fonksiyonu ile Eğitilen ANFIS Modellerinin İkinci Test Veri Seti İçin Sonuç Grafiği

Şekil 3.19’da dsigmf üyelik fonksiyonu ile eğitilen ANFIS modellerinin ikinci test veri seti üzerindeki x ve y değerlerine ait regresyon grafikleri gösterilmiştir.




Şekil 3.19. dsigmf Üyelik Fonksiyonu ile Eğitilen ANFIS Modelinin İkinci Test Veri Seti Üzerindeki x ve y Değerlerine Ait Regresyon Grafikleri

Şekil 3.20'de gaussmf üyelik fonksiyonu ile eğitilen ANFIS modellerinin ikinci test veri seti üzerindeki gerçek çıkış değerleri ve üretilen çıkış değerlerinden k-En Yakın Komşu algoritması ile seçilen en yakın değer gösterilmiştir.




Şekil 3.20. gaussmf Üyelik Fonksiyonu ile Eğitilen ANFIS Modellerinin İkinci Test Veri Seti İçin Sonuç Grafiği

Şekil 3.21’de gaussmf üyelik fonksiyonu ile eğitilen ANFIS modellerinin ikinci test veri seti üzerindeki x ve y değerlerine ait regresyon grafikleri gösterilmiştir.




Şekil 3.21. gaussmf Üyelik Fonksiyonu ile Eğitilen ANFIS Modelinin İkinci Test Veri Seti Üzerindeki x ve y Değerlerine Ait Regresyon Grafikleri

Şekil 3.22’de trimf üyelik fonksiyonu ile eğitilen ANFIS modellerinin ikinci test veri seti üzerindeki gerçek çıkış değerleri ve üretilen çıkış değerlerinden k-En Yakın Komşu algoritması ile seçilen en yakın değer gösterilmiştir.



Şekil 3.22. trimf Üyelik Fonksiyonu ile Eğitilen ANFIS Modellerinin İkinci Test Veri Seti İçin Sonuç Grafiği

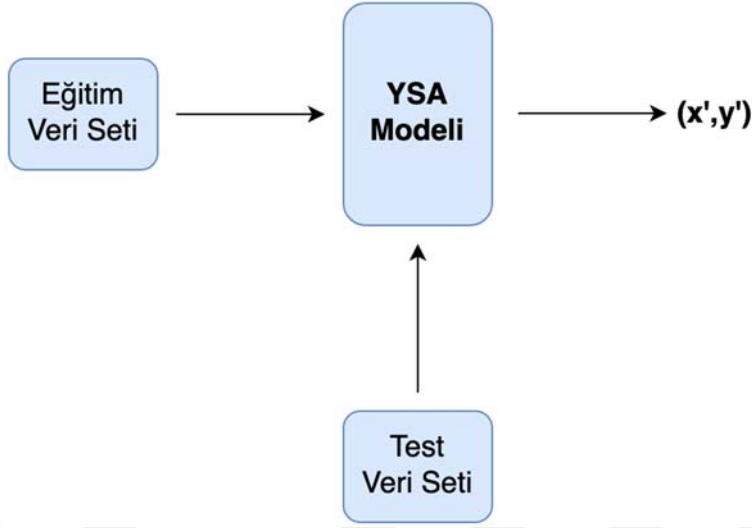
Şekil 3.23’de trimf üyelik fonksiyonu ile eğitilen ANFIS modellerinin ikinci test veri seti üzerindeki x ve y değerlerine ait regresyon grafikleri gösterilmiştir.



Şekil 3.23. trimf Üyelik Fonksiyonu ile Eğitilen ANFIS Modelinin İkinci Test Veri Seti Üzerindeki x ve y Değerlerine Ait Regresyon Grafikleri

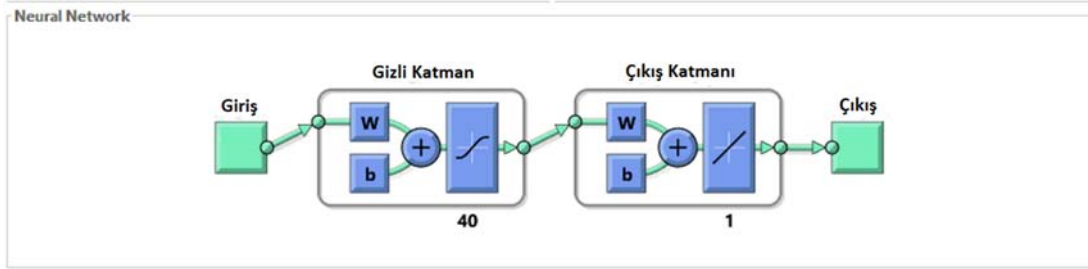
4.5. YSA Modelinin Kurulması ve Eğitilmesi

Veri setinin hazırlanmasının ardından YSA modelinin kurulma sürecine başlanmıştır. YSA modelinin kurulması ve modelin eğitilmesi MATLAB programı kullanılarak gerçekleştirilmiştir. YSA modeli eğitim veri setindeki 4 RSSI bilgisi ile (x,y) bölge bilgisini giriş olarak almaktadır. Model test veri setinde bulunan 4 RSSI bilgisine çıktı olarak (x',y') bölge bilgisini vermektedir. Şekil 3.24'de kurulan YSA modeli gösterilmiştir.



Şekil 3.24. Kurulan YSA Modeli

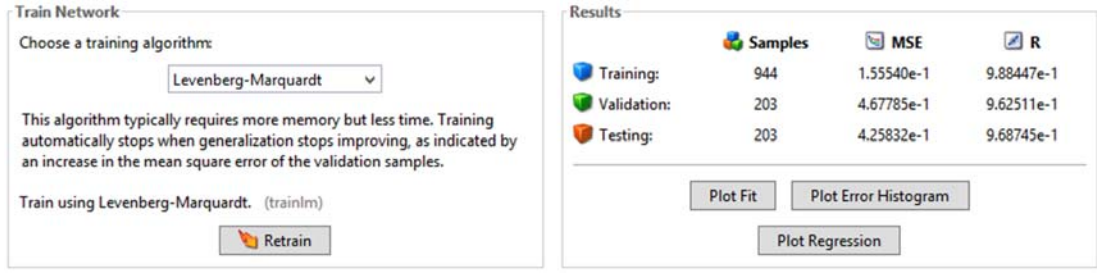
Şekil 3.25’de kurulan YSA modelinin yapısı gösterilmiştir.



Şekil 3.25. Kurulan YSA Modelinin Yapısı


YSA modelinin kurulmasının ardından, modelin eğitilmesi MATLAB programında yapılmış ve Levenberg-Marquardt ile Bayesian Regularization algoritmalarıyla modelin eğitimi sağlanmıştır. 1350 veri içeren veri setinin %70’i eğitim, %15’i doğrulama ve %15’i ise test veri seti olarak parçalara ayrılmıştır. Ayrılan veri setlerine verilerin atanması ise rasgele olarak yapılmıştır.

Şekil 3.26’da Levenberg-Marquardt algoritması ile eğitilen modelin MSE ve R^2 korelasyon katsayısı gösterilmiştir.



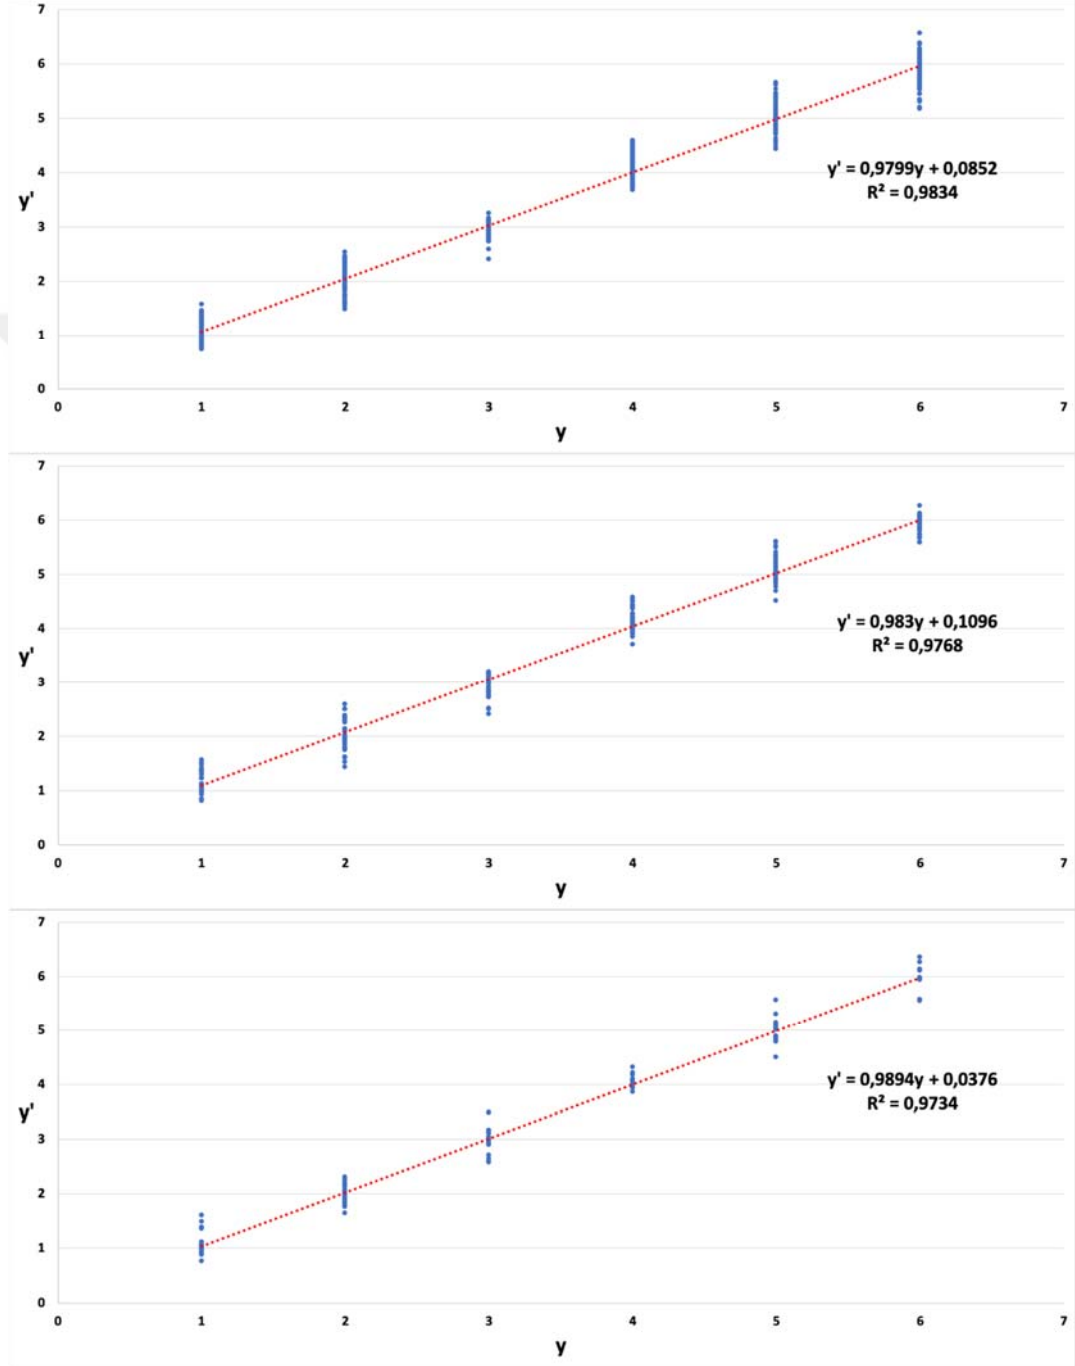
Şekil 3.26. Levenberg-Marquardt Algoritması ile Eğitilen YSA Modelinin Sonuç Kontrol Değerleri

Şekil 3.27’de Levenberg-Mardquardt algoritması ile eğitilen modelin eğitim, doğrulama ve test veri setleri üzerindeki x değerlerine ait regresyon grafikleri gösterilmiştir.



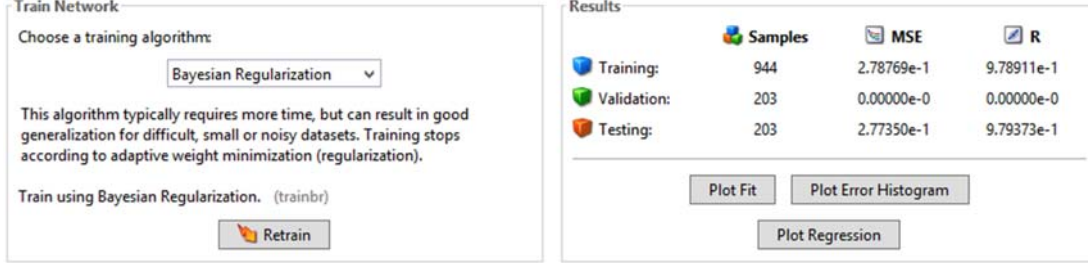
Şekil 3.27. Levenberg-Marquardt Algoritması ile Eğitilen YSA Modelinin Eğitim, Doğrulama ve Test Veri Setleri Üzerindeki x Değerlerine Ait Regresyon Grafikleri

Şekil 3.28’de Levenberg-Marquardt algoritması ile eğitilen modelin eğitim, doğrulama ve test veri setleri üzerindeki y değerlerine ait regresyon grafikleri gösterilmiştir.




Şekil 3.28. Levenberg-Marquardt Algoritması ile Eğitilen YSA Modelinin Eğitim, Doğrulama ve Test Veri Setleri Üzerindeki y Değerlerine Ait Regresyon Grafikleri

Şekil 3.29’da Bayesian Regularization algoritması ile eğitilen modelin MSE ve R^2 korelasyon katsayısı gösterilmiştir.




Şekil 3.29. Bayesian Regularization Algoritması ile Eğitilen YSA Modelinin Sonuç Kontrol Değerleri

Şekil 3.30’da Bayesian Regularization algoritması ile eğitilen modelin eğitim ve test veri setleri üzerindeki x değerlerine ait regresyon grafikleri gösterilmiştir.



Şekil 3.30. Bayesian Regularization Algoritması ile Eğitilen YSA Modelinin Eğitim ve Test Veri Setleri Üzerindeki x Değerlerine Ait Regresyon Grafikleri

Şekil 3.31'de Bayesian Regularization algoritması ile eğitilen modelin eğitim ve test veri setleri üzerindeki y değerlerine ait regresyon grafikleri gösterilmiştir.



Şekil 3.31. Bayesian Regularization Algoritması ile Eğitilen YSA Modelinin Eğitim ve Test Veri Setleri Üzerindeki y Değerlerine Ait Regresyon Grafikleri

Tablo 3.7’de farklı algoritmalar ile eğitilen YSA modelinin ikinci veri seti ile ürettiği MSE, R^2 korelasyon katsayısı ve MAPE değerleri gösterilmiştir.

Tablo 3.7. Farklı Algoritmalar ile Eğitilen YSA Modelinin İkinci Test Veri Seti İçin Sonuç Kontrol Değerleri

Algoritma	Veri Seti	İkinci Test Veri Seti	
		x	y
Levenberg-Mardquardt	MSE	0,1315	0,0610
	R ²	0,9695	0,9744
	MAPE	0,0624	0,0573
Bayesian Regularization	MSE	0,1227	0,0621
	R ²	0,9799	0,9841
	MAPE	0,0516	0,0473



SONUÇ

Son yıllarda bilgi teknolojilerinde yaşanan hızlı değişim ve gelişim ile birlikte mobil cihaz ve bağlantılı teknolojilerin sayısının artması iç mekân konumlandırma teknolojileri ve yöntemlerinin öneminin artmasına sebep olmuştur. Ayrıca nesnelerin internetinin giderek popülarite kazanması, iç mekân konumlandırmanın değerini artıran bir başka etmendir. Bu bağlamda iç mekân konumlandırmanın en doğru ve tutarlı bir şekilde yapılması optimal bir iç mekân konumlandırma sistemin elde edilmesinin en önemli basamağıdır. Bu amaca ulaşmak için hem akademik düzeyde hem de endüstri seviyesinde yürütülen pek çok çalışmalar mevcuttur.

Literatür üzerinde iç mekân konumlandırma problemi için çeşitli yöntemler ve teknolojiler kullanılmıştır. Bunlar arasında WiFi, Bluetooth, Ultrasound, ZigBee vb. teknoloji ile Gelen Ginyal Gücü Seviyesi, Parmak İzi, Geliş Açısı, Geliş Zamanı vb. gibi yöntemlerin yanı sıra yapay sinir ağları, makine öğrenmesi ve yapay zekâ teknolojileri gibi birçok yöntem ve teknoloji sayılabilir. Bu tez çalışmasında ise diğer çalışmalardan farklı olarak YSA ve ANFIS modelleri üzerinde iç mekân konumlandırma yapan iki farklı sistem kullanılmıştır.

İç mekân konumlandırmada Bluetooth teknolojisi, kullanımının ve kurulmasının kolay olması, özel bir ekipman gerektirmemesi, düşük maliyeti, yüksek enerji verimliliği ve Bluetooth ekosistemine kolay entegrasyonu gibi avantajlar sağlarken; Parmak İzi yöntemi ise ücretsiz olması, esneklik sunması ve her cihaz ve ortama uygunluk sağlayabilmesi yönünden avantajlar sunmaktadır.

Bu çalışmada Bluetooth teknolojisini kullanan iç mekân konumlandırma sistemlerindeki konumlandırma hassasiyeti ve başarısının artırılması için parmak izi yöntemi ve makine öğrenmesi yöntem ve tekniklerinin beraber kullanılması yöntemi önerilmiştir. Parmak izi yöntemiyle oluşturulan ve eğitim, kontrol ve test olmak üzere üç veri setine ayrılan 1350 verilik veri seti ile makine öğrenmesi modellerinin eğitimleri yapılmış ve başarıları test edilmiştir. Ayrıca oluşturulan 250 verilik bir başka veri seti ile makine öğrenmesi modellerinin başarısı doğrulanmaya çalışılmıştır.

Bu çalışmada geliştirilen YSA ve ANFIS makine öğrenmeleri modelleri MATLAB programı kullanılarak oluşturulmuştur. Modellerin eğitimi için 1350 verilik

veri setinin %70'i kullanılmıştır. Eğitim sürecinde YSA modeli için Levenberg-Mardquardt ve Bayesian Regularization algoritmaları ve ANFIS modeli için ise ızgara bölümlleme (grid-partition) yöntemi kullanılmıştır.

İç mekân konumlandırmadaki başarı, mekân koşulları ve bina malzemelerinin yapısına göre farklılık gösterebilmektedir. RSSI değerlerinin çevresel etmenlerden etkilenmesi ve bu etmenlerin tamamen kontrol edilememesi tatmin edici sonuçların alınamamasına neden olabilmektedir.

Bu tez çalışmasında elde edilen sonuçlar, kapalı bir mekânda konumlandırma yapan sistemin tasarımı ve kurulumu hakkında da bilgiler vermektedir. Tatmin edici bir başarı oranı elde edebilmek için sistemdeki erişim noktalarının sayısı ve yerleşim şekli, verilerin sayısı ve veri toplanma şekli gibi parametrelerin iyi belirlenmesi gerekmektedir. İlerleyen çalışmalarda bu parametrelerin daha optimal olarak belirlenerek sistemin başarısı artırılabilir. Sistemdeki erişim noktalarının daha iyi yerleşimi ve maliyet ile doğruluk arasındaki dengenin daha iyi sağlanabilmesi için makine öğrenmesi yaklaşımı kullanılabilir. Sistemin başarısında makine öğrenmesi modellerinin iyi eğitilmesi gerekliliği göz önüne alınırsa daha fazla eğitim verisi ile sistemin eğitilmesi sağlanabilir.

KAYNAKÇA

- Aalto Lauri, Göthlin Nicklas, Korhonen Jani ve Ojala Timo (2004). Bluetooth and WAP Push Based Location-Aware Mobile Advertising System. *Proceedings of the 2nd international conference on Mobile systems, applications, and services* (ss. 49-58) doi:10.1145/990064.990073
- Ahmadi Hanen, Ridha Bouallegue (2017). Exploiting machine learning strategies and RSSI for localization in wireless sensor networks: A survey. *2017 13th International Wireless Communications and Mobile Computing Conference (IWCMC)* (ss. 1150-1154). 2017 13th International Wireless Communications and Mobile Computing Conference (IWCMC). doi:10.1109/IWCMC.2017.7986447
- Ahson Syed A. ve Ilyas Mohammad (2010). *Location-Based Services Handbook: Applications, Technologies, and Security*. CRC Press, (ss. 328).
- Akyılmaz Orhan ve Ayan Tefvik (2010). Esnek hesaplama yöntemlerinin jeodezide uygulamaları. *İTÜDERGİSİ/d*, 5(1) (ss. 261-268). http://itudergi.itu.edu.tr/index.php/itudergisi_d/article/view/634 (Erişim Tarihi: 19.07.2019)
- Al-Amr Mai A., Alhadhrami Suheer, Al-Salman Abdulmalik, Alarifi Aabdulrahman, Al-Khalifa Hend S., Alnafessah Ahmad ve Alsaleh Mansour (2014). Comparative Survey of Indoor Positioning Technologies, Techniques, and Algorithms. *2014 International Conference on Cyberworlds* (ss. 245-252). 2014 International Conference on Cyberworlds. doi:10.1109/CW.2014.41
- AlHajri Mohamed Ibrahim, Ali Nazar ve Shubair Raed (2019). Indoor Localization for IoT Using Adaptive Feature Selection: A Cascaded Machine Learning Approach. *IEEE Antennas and Wireless Propagation Letters* (ss. 2306-2310). doi:10.1109/LAWP.2019.2915047
- Anderson, James A. (1995). *An Introduction to Neural Networks*. MIT Press, (ss. 650). <https://mitpress.mit.edu/books/introduction-neural-networks> (Erişim Tarihi: 27.08.2019)

- Arslan Kadir ve Kirbař İsmail (2016). Nesnelerin İnterneti Uygulamaları İin Algılayıcı/Eyleyici Kablosuz Dğüm İlkörneđi Geliřtirme. *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 7(Özel (Special) 1), (ss. 35-43).
- Atsuumi Keita ve Sano Manabu (2010). Indoor IR azimuth sensor using a linear polarizer. *2010 International Conference on Indoor Positioning and Indoor Navigation* (ss. 1-5). 2010 International Conference on Indoor Positioning and Indoor Navigation. doi:10.1109/IPIN.2010.5647328
- Bai, Yuntian Brian (2016). *Development of a WiFi and RFID based indoor location and mobility tracking system*. (Yayınlanmış Doktora Tezi), (ss. 233). <http://researchbank.rmit.edu.au/view/rmit:161662> (Eriřim Tarihi: 04.07.2019).
- Baronti Paolo, Pillai Prashant, Chook Vinve W. C., Chessa Stefano, Gotta Alberto ve Hu Y. Fun (2007). Wireless sensor networks: A survey on the state of the art and the 802.15.4 and ZigBee standards. *Computer Communications, Wired/Wireless Internet Communications*, 30(7), (ss. 1655-1695). doi:10.1016/j.comcom.2006.12.020
- Belloni, Fabio (2010). Bringing Navigation Indoors. *Nokia Research Center Radio Systems Laboratory, Finland*, (ss. 41).
- Biehl Jacob T., Cooper Matthew, Filby Gerry ve Kratz Sven (2014). LoCo: A Ready-to-deploy Framework for Efficient Room Localization Using Wi-Fi. *Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing, UbiComp'14* (ss. 183–187). New York, NY, USA: ACM. doi:10.1145/2632048.2636083
- Buragohain, Mrinal (2009). *Adaptive network based fuzzy inference system (ANFIS) as a tool for system identification with special emphasis on training data minimization*. (Yayınlanmış Doktora Tezi), (ss. 141).
- Carrera Jose Luis V., Zhao Zhongliang, Braun Torsten, Luo Haiyong ve Zhao Fang (2018). Discriminative Learning-based Smartphone Indoor Localization, *IEEE Transaction on Mobile Computing*, (ss. 1-14). *ArXiv:1804.03961 [cs, eess]*. <http://arxiv.org/abs/1804.03961> (Eriřim Tarihi: 20.06.2019)

- Casas Roberto, Cuartielles David, Marco Alvaro, Gracia Hector J. ve Falco Jorge L. (2007). Hidden Issues in Deploying an Indoor Location System. *IEEE Pervasive Computing*, 6(2), (ss. 62-69). doi:10.1109/MPRV.2007.33
- Ching-Chieh, Chiu (2017). Indoor Positioning System with BLE and Wi-Fi technology—Data Analysis and Accuracy Improvement, (Yayınlanmış Yüksek Lisans Tezi), (ss. 81). <https://dspace.cvut.cz/handle/10467/70519> (Erişim Tarihi: 13.06.2019)
- Ching-Sheng Wang, Chun-Hong Huang, Yong-Si Chen ve Li-Jie Zheng (2009). An implementation of positioning system in indoor environment based on active RFID. *2009 Joint Conferences on Pervasive Computing (JCPC)* (ss. 71-76). *2009 Joint Conferences on Pervasive Computing (JCPC)*, doi:10.1109/JCPC.2009.5420212
- Chuenurajit Thanapong, Phimmasean Sisongkham ve Cherntanomwong Panarat (2013). Robustness of 3D indoor localization based on fingerprint technique in wireless sensor networks. *2013 10th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology* (ss. 1-6). *2013 10th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology*. doi:10.1109/ECTICon.2013.6559523
- Cybenko, George (1989). Approximation by superpositions of a sigmoidal function. *Math Cont Sig Syst (MCSS)* 2:303-314. *Mathematics of Control, Signals, and Systems*, 2, (ss. 303-314). doi:10.1007/BF02551274
- Dädeby Sebastian ve Hesselgren Joakim (2017). *A system for indoor positioning using ultra-wideband technology*. (Yayınlanmış Yüksek Lisans Tezi), (ss. 78). <https://hdl.handle.net/20.500.12380/249898> (Erişim Tarihi: 12.06.2019)
- Deak Gabriel, Curran Kevin ve Condell Joan (2012). Review: A survey of active and passive indoor localisation systems. *Computer Communications*, 35(16), (ss. 1939-1954). doi:10.1016/j.comcom.2012.06.004
- Dempsey, M. (2003). The fundamentals of indoor positioning systems in healthcare. *Biomed Instrum Technology*, (ss. 293-297).

- Dias, Joao Antonio da Cruz (2016). *Indoor Positioning System with Android*. (Yayınlanmış Doktora Tezi), (ss. 118). <http://hdl.handle.net/1822/46551> (Erişim Tarihi: 04.07.2019)
- Diaz Javier J. M., Maués Rodrigo de A., Soares Rodrigo B., Nakamura Eduardo F. ve Figueiredo Carlos M. S. (2010). Bluepass: An indoor Bluetooth-based localization system for mobile applications. *The IEEE symposium on Computers and Communications* (ss. 778-783). The IEEE symposium on Computers and Communications. doi:10.1109/ISCC.2010.5546506
- Doiphode Siddhesh R., Bakal Jagdish W. ve Gedam Madhuri (2016). Survey of Indoor Positioning Measurements, Methods and Techniques, *International Journal of Computer Applications*, 140(7), (ss. 1-4). doi:10.5120/ijca2016909361
- Dwiyasa, Felis (2018). *Machine learning for indoor positioning based on received signal strength*. (Yayınlanmış Doktora Tezi), (ss. 143). <https://dr.ntu.edu.sg/handle/10356/89317> (Erişim Tarihi: 01.07.2019)
- Dziubany Matthias, Machhamer Rüdiger, Laux Hendrik, Schmeink Anke, Gollmer Klaus-Uwe, Burger Guido ve Dartmann Guido (2018). Machine Learning Based Indoor Localization Using a Representative k-Nearest-Neighbor Classifier on a Low-Cost IoT-Hardware. *2018 26th European Signal Processing Conference (EUSIPCO)* (ss. 2050-2054). 2018 26th European Signal Processing Conference (EUSIPCO). doi:10.23919/EUSIPCO.2018.8553155
- Efe Mehmet Önder ve Kaynak Okyay (2000). *Yapay sinir ağları ve uygulamaları*. Boğaziçi Üniversitesi Yayınları, (ss. 141).
- Fagan Derek ve Meier Rene (2011). Intelligent time of arrival estimation. *2011 IEEE Forum on Integrated and Sustainable Transportation Systems* (ss. 60-66). 2011 IEEE Forum on Integrated and Sustainable Transportation Systems. doi:10.1109/FISTS.2011.5973595
- Faheem, Faheem (2016). *Ibeacon based proximity and indoor localization system*. (Yayınlanmış Yüksek Lisans Tezi), (ss. 116). https://docs.lib.purdue.edu/open_access_theses/767/ (Erişim Tarihi: 19.06.2019)

- Fausett, Laurene (1994). *Fundamentals of neural networks: Architectures, algorithms, and applications*. USA: Prentice-Hall, Inc, (ss. 461).
- Fine, Terrence L. (1999). *Feedforward Neural Network Methodology*. Information Science and Statistics. New York: Springer-Verlag, (ss. 309).
doi:10.1007/b97705
- Franklin Gene F., Powell David J. ve Workman Michael L. (1998). *Digital control of dynamic systems* (C. 3). Addison-wesley Menlo Park, CA, (ss. 742).
- Gao, Xiangjian (2018). *UWB Indoor Localization System*. (Yayınlanmış Yüksek Lisans Tezi), (ss. 178).
<https://search.proquest.com/docview/2046991731/abstract/BEFAD603B2C34C18PQ/1> (Erişim Tarihi: 04.07.2019)
- Gentner Christian ve Jost Thomas (2013). Indoor positioning using time difference of arrival between multipath components. *International Conference on Indoor Positioning and Indoor Navigation* (ss. 1-10). International Conference on Indoor Positioning and Indoor Navigation. doi:10.1109/IPIN.2013.6817908
- Géron, Aurélien (2017). *Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent*. O'Reilly Media, (ss. 820). <https://www.oreilly.com/library/view/hands-on-machine-learning/9781491962282/ch04.html> (Erişim Tarihi: 31.10.2019)
- Goguen, J. A. (1973). L. A. Zadeh. Fuzzy sets. *Information and control*, vol. 8 (1965), pp. 338–353. - L. A. Zadeh. Similarity relations and fuzzy orderings. *Information sciences*, vol. 3 (1971), (pp. 177–200). *The Journal of Symbolic Logic*, 38(4), 656-657. doi:10.2307/2272014
- Gonzalez-Castano, Francisco J. ve Jaime García-Reinoso. (2002). Bluetooth location networks. *IEEE Global Telecommunications Conference, 2002. GLOBECOM'02* (C. 1, ss. 233-237 c.1). IEEE Global Telecommunications Conference, 2002. GLOBECOM '02. doi:10.1109/GLOCOM.2002.1188075
- Graupe, Daniel. (2007). *Principals of Artificial Neural Networks*, World Scientific, (ss. 363). doi:10.1142/9789812770578_0006

- Gu Yanying, Lo Anthony C. C. ve Niemegeers Ignas G. (2009). A survey of indoor positioning systems for wireless personal networks. *IEEE Communications Surveys & Tutorials*, 11, (ss. 13-32). doi:10.1109/SURV.2009.090103
- Güney Kerim ve Sarıkaya Nurcan (2008). Dairesel mikroşerit antenlerin yama yarıçapının çeşitli algoritmalarla optimize edilen bulanık mantık sistemine dayalı uyarlanırlar ağırlar ile hesaplanması. ELECO`2008 ELEKTRİK - ELEKTRONİK - BİLGİSAYAR MÜHENDİSLİĞİ SEMPOZYUMU, ELECO, (ss. 100-104).
- Han, Zou (2016). *Robust and accurate localization algorithms for indoor positioning and navigation*, (Yayınlanmış Doktora Tezi), (ss. 244).
<https://dr.ntu.edu.sg/handle/10356/69226> (Erişim Tarihi: 05.11.2019)
- Hara Shinsuke, Dapeng Zhao, Yanagihara Kentaro, Taketsugu Jumpei, Fukui Kiyoshi, Fukunaga Shigeru ve Kitayama Ken-Ichi (2005). Propagation characteristics of IEEE 802.15.4 radio signal and their application for location estimation. *2005 IEEE 61st Vehicular Technology Conference (C. 1, ss. 97-101 Vol. 1)*. 2005 IEEE 61st Vehicular Technology Conference. doi:10.1109/VETECS.2005.1543257
- Hauschildt Daniel ve Kirchhof Nicolaj (2010). Advances in thermal infrared localization: Challenges and solutions (ss. 1-8). 2010 International Conference on Indoor Positioning and Indoor Navigation, IPIN 2010 - Conference Proceedings. doi:10.1109/IPIN.2010.5647415
- Hazas Mike ve Hopper Andy (2006). Broadband ultrasonic location systems for improved indoor positioning. *IEEE Transactions on Mobile Computing*, 5(5), (ss. 536-547). doi:10.1109/TMC.2006.57
- Haznedar, Bülent (2017). *Benzetilmiş Tavlama Algoritması ile Adaptif Ağ Tabanlı Bulanık Mantık Çıkarım Sisteminin (ANFIS) Eğitilmesi*. (Yayımlanmış Doktora Tezi), (ss. 174). Erciyes Üniversitesi.
- Haznedar Bülent ve Kalınlı Adem (2016). Training ANFIS using genetic algorithm for dynamic systems identification. *International Journal of Intelligent Systems and Applications in Engineering*, (ss. 44-47).

- Hightower Jeffrey, Vakili Chris, Borriello Gaetano ve Want Roy (2001). Design and Calibration of the SpotON Ad-Hoc Location Sensing System, (ss. 18).
- Hímer Zoltan Kovács Jenő, Benyó Imre ve Kortela Urpo (2004). Neuro-Fuzzy Modeling and Genetic Algorithm Optimization for Flue Gas Oxygen Control. *IFAC Proceedings Volumes*, 37(16), (ss. 121-125).
- Hornik, Kurt (1991). Approximation capabilities of multilayer feedforward networks. *Neural Networks*, 4(2), (ss. 251-257). doi:10.1016/0893-6080(91)90009-T
- Hornik Kurt, Stinchcombe Maxwell ve White Halbert (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5), (ss. 359-366). doi:10.1016/0893-6080(89)90020-8
- Hsieh Jia-You, Fan Chun-Hung, Liao Jian-Zhi, Hsu Jyh-Yih ve Chen Huan (2019). Study on the application of indoor positioning based on low power Bluetooth device combined with Kalman filter and machine learning. *EasyChair*, (ss. 1-9). <https://easychair.org/publications/preprint/VhvV>
- Jain, Anshul (2019). *Comparative analysis of indoor localization using machine learning models*, (Yayınlanmış Yüksek Lisans Tezi), (ss. 57). <http://hdl.handle.net/10211.3/210277> (Erişim Tarihi: 05.07.2019)
- Jang Jyh-Shing Roger ve Sun Chuen-Tsai (1995). Neuro-fuzzy modeling and control. *Proceedings of the IEEE*, 83(3), (ss. 378-406).
- Jang, Jyh-Shing Roger (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3), (ss. 665-685).
- Jang, Jyh-Shing Roger (1991). Fuzzy modeling using generalized neural networks and kalman filter algorithm. *AAAI* (C. 91, ss. 762-767).
- Kotanen Antti, Hannikainen Marko, Leppakoski Helena ve Hamalainen Timo D. (2003). Experiments on local positioning with Bluetooth. *Proceedings ITCC 2003. International Conference on Information Technology: Coding and Computing* (ss. 297-303). Proceedings ITCC 2003. International Conference on

Information Technology: Coding and Computing.

doi:10.1109/ITCC.2003.1197544

Kotaru Manikanta, Joshi Kiran, Bharadia Dinesh ve Katti Sachin (2015). SpotFi: Decimeter Level Localization Using WiFi. *Proceedings of the 2015 ACM Conference on Special Interest Group on Data Communication, SIGCOMM'15* (ss. 269–282). New York, NY, USA: ACM. doi:10.1145/2785956.2787487

Kriz Pavel, Maly Filip ve Kozel Tomas (2016). Improving Indoor Localization Using Bluetooth Low Energy Beacons. *Mobile Information Systems*, (ss. 1-11). doi:10.1155/2016/2083094

Laitinen Elina ve Lohan Elena Simona (2016). On the Choice of Access Point Selection Criterion and Other Position Estimation Characteristics for WLAN-Based Indoor Positioning. *Sensors*, 16(5), 737, (ss. 1-15). doi:10.3390/s16050737

Liu Hui, Darabi Houshang, Banerjee Pat ve Liu Jing (2007). Survey of Wireless Indoor Positioning Techniques and Systems. *IEEE Transactions on Systems, Man and Cybernetics, Part C (Applications and Reviews)*, 37(6), (ss. 1067-1080). doi:10.1109/TSMCC.2007.905750

Liu, Junjie (2018). Survey of Wireless Based Indoor Localization Technologies, *Department of Science & Engineering Washington University*, (ss. 1-17). <https://www.cse.wustl.edu/~jain/cse574-14/ftp/indoor/> (Erişim Tarihi: 28.11.2019)

Luo Chengwen, Cheng Long, Chan Mun Choon, Gu Yu, Li Jianqiang ve Ming Zhong (2017). Pallas: Self-Bootstrapping Fine-Grained Passive Indoor Localization Using WiFi Monitors. *IEEE Transactions on Mobile Computing*, 16(2), (ss. 466-481). doi:10.1109/TMC.2016.2550452

Malavalli Rahul, Earthperson Arjun ve Gupta Nilesh (2017). Indoor Localization Through Machine Learning on WiFi Fingerprints. *International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, (ss. 1-4).

- Mamdani Ebrahim H. ve Assilian S. (1975). An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, 7(1), (ss. 1-13). doi:10.1016/S0020-7373(75)80002-2
- Marill, Keith (2004). Advanced Statistics: Linear Regression, Part II: Multiple Linear Regression. *Academic emergency medicine: Official journal of the Society for Academic Emergency Medicine*, 11, (ss. 94-102). doi:10.1197/j.aem.2003.09.005
- Mascharka David ve Manley Eric (2016). Machine Learning for Indoor Localization Using Mobile Phone-Based Sensors. *2016 13th IEEE Annual Consumer Communications & Networking Conference (CCNC)*, (ss. 968-971). doi:10.1109/CCNC.2016.7444919
- Mautz, Rainer (2009). The challenges of indoor environments and specification on some alternative positioning systems. *Navigation and Communication 2009 6th Workshop on Positioning* (ss. 29-36). Navigation and Communication 2009 6th Workshop on Positioning. doi:10.1109/WPNC.2009.4907800
- Mautz, Rainer (2012). Indoor Positioning Technologies, (Yayınlanmış Yüksek Lisans Tezi), (ss. 129). doi:10.3929/ethz-a-007313554
- Miller James D. ve Forte Rui Mihuel (2017). *Mastering Predictive Analytics with R - Second Edition*, (ss. 448).
https://subscription.packtpub.com/book/big_data_and_business_intelligence/9781787121393/5/ch05lv11sec38/the-biological-neuron (Erişim Tarihi: 19.02.2020)
- Murphy, Kevin P. (2012). *Machine Learning: A Probabilistic Perspective*. The MIT Press, (ss. 1104).
- Müller Andreas C. ve Guido Sarah (2016). *Introduction to Machine Learning with Python: A Guide for Data Scientists*. O'Reilly Media, Inc, (ss. 400).
- Nuaimi Klaithem Al ve Kamel Hesham (2011). A survey of indoor positioning systems and algorithms. *2011 International Conference on Innovations in Information Technology* (ss. 185-190). 2011 International Conference on Innovations in Information Technology.
doi:10.1109/INNOVATIONS.2011.5893813

- Oguntala George, Abd-Alhameed Raed, Jones Stephen, Noras James, Patwary Mohammad ve Rodriguez Jonathan (2018). Indoor location identification technologies for real-time IoT-based applications: An inclusive survey. *Computer Science Review*, 30, (ss. 55-79). doi:10.1016/j.cosrev.2018.09.001
- Ou Chung-Wei, Chao Chin-Jung, Chang Fa-Shian, Wang Shun-Min, Liu Guan-Xun, Wu Min-Ren, Cho Kai-Yi, Hwang Lih-Tyng, Huan Yi-Ying (2017). A ZigBee position technique for indoor localization based on proximity learning. *2017 IEEE International Conference on Mechatronics and Automation (ICMA)* (ss. 875-880). 2017 IEEE International Conference on Mechatronics and Automation (ICMA). doi:10.1109/ICMA.2017.8015931
- Özçalık Hasan Rıza, Uygur Ali Fazıl (2003). Dinamik sistemlerin uyumlu sinirsel-bulanık ağ yapısına dayalı etkin modellenmesi. *KSÜ Fen ve Mühendislik Dergisi*, 6(1), (ss. 36-46).
- Özgan Ercan, Kap Tuncay, Beycioğlu Ahmet ve Emiroğlu Mehmet (2009). Asfalt Betonunda Marshall Stabilitésinin Uyarlamalı Sinirsel Bulanık Mantık Yaklaşımı ile Tahmini. 5th international technology symposium (IATS 2009), (ss. 1-4).
- Öztemel, Ercan (2003). Yapay sinir ağları. *Papatya Yayıncılık, İstanbul*, (ss. 44).
- Palancıoğlu H. Mustafa ve Beşdok Erkan (2005). Hareketli objelerin ulaşım ağındaki hareketlerinin bulanık mantık metotları ile modellenmesi. 2. Mühendislik Ölçmeleri Sempozyumu, (ss. 421-465).
- Peterson, Leif E. (2009). K-Nearest Neighbor, Scholarpedia. *Scholarpedia*, 4(2), (ss.1883). doi:10.4249/scholarpedia.1883
- Priyantha Nissanka B., Chakraborty Anit ve Balakrishnan Hari (2000). The Cricket location-support system. *Proceedings of the 6th annual international conference on Mobile computing and networking—MobiCom '00* (ss. 32-43). the 6th annual international conference. Boston, Massachusetts, United States: ACM Press. doi:10.1145/345910.345917

- Salamah Ahmed H., Tamazin Mohamed, Sharkas Maha A. ve Khedr Mohamed (2016). An enhanced WiFi indoor localization system based on machine learning. *2016 International Conference on Indoor Positioning and Indoor Navigation (IPIN)* (ss. 1-8). 2016 International Conference on Indoor Positioning and Indoor Navigation (IPIN). doi:10.1109/IPIN.2016.7743586
- Sammut C. ve Webb G. I. (2011). *Encyclopedia of machine learning*. Springer Link. *SpringerLink*, Springer Science & Business Media, (ss. 1335). https://link.springer.com/referenceworkentry/10.1007/978-0-387-30164-8_528 (Erişim Tarihi: 29.01.2020)
- Samuel, A. L. (1959). Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development*, 3(3), (ss. 210-229). doi:10.1147/rd.33.0210
- Sarı Nevzat İhsan, Arslan Ersoy (2007). Geoit Yüksekliğinin ANFIS ile Adım Adım Hesaplanması. *HKM Jeodezi Jeoinformasyon Arazi Yönetimi Dergisi*, (96), (ss. 31-38).
- Seco Fernando, Plagemann Christian, Jiménez Antonio R. ve Burgard Wolfram (2010). Improving RFID-based indoor positioning accuracy using Gaussian processes. *2010 International Conference on Indoor Positioning and Indoor Navigation* (ss. 1-8). 2010 International Conference on Indoor Positioning and Indoor Navigation. doi:10.1109/IPIN.2010.5647095
- Shirehjini Ali Asgar Nazari Yassine Abdulsalam ve Shirmohammadi Shervin (2012). An RFID-Based Position and Orientation Measurement System for Mobile Objects in Intelligent Environments. *IEEE Transactions on Instrumentation and Measurement*, 61(6), (ss. 1664-1675). doi:10.1109/TIM.2011.2181912
- Sugeno, Michio (1985). *Industrial Applications of Fuzzy Control*. USA: Elsevier Science Inc, (ss. 269).
- Sumitra Irfan Dwiguna, Supatmi Sri ve Hou R. (2018). Enhancement of Indoor Localization Algorithms in Wireless Sensor Networks: A Survey. *IOP Conference Series: Materials Science and Engineering*, 407, 012068, (ss. 1-9). doi:10.1088/1757-899X/407/1/012068

- Svalastog, Mari Saua (2007). *Indoor Positioning—Technologies, Services and Architectures*, (Yayınlanmış Yüksek Lisans Tezi), (ss. 133).
<https://www.duo.uio.no/handle/10852/9742> (Erişim Tarihi: 31.07.2019)
- Swamidass, P.M. (2000). *Encyclopedia of Production and Manufacturing Management*. Springer Link. *SpringerLink*, (ss. 980).
https://link.springer.com/referenceworkentry/10.1007%2F1-4020-0612-8_580
(Erişim Tarihi: 31.10.2019)
- Terán Marco, Carrillo Henry ve Parra Carlos (2018). WLAN-BLE Based Indoor Positioning System using Machine Learning Cloud Services. *2018 IEEE 2nd Colombian Conference on Robotics and Automation (CCRA)* (ss. 1-6). 2018 IEEE 2nd Colombian Conference on Robotics and Automation (CCRA).
doi:10.1109/CCRA.2018.8588127
- Tsoukalas Lefteri H. ve Uhrig Robert E. (1997). Fuzzy and neural approaches in engineering, Michigan University, (ss. 587).
- Uradzinski Marcin, Guo Hang, Liu Xiaokang ve Yu Min (2017). Advanced Indoor Positioning Using Zigbee Wireless Technology. *Wireless Personal Communications*, 97(4), (ss. 6509-6518). doi:10.1007/s11277-017-4852-5
- Vandenabeele, Thomas (2017). *Study of Wi-Fi Fingerprint-Based Indoor Positioning on a smartphone*, (Yayınlanmış Yüksek Lisans tezi), (ss. 82).
- Wang Jue, Adib Fadel, Knepper Ross, Katabi Dina ve Rus Daniela (2013). RF-compass: Robot Object Manipulation Using RFIDs. *Proceedings of the 19th Annual International Conference on Mobile Computing & Networking, MobiCom'13* (ss. 3–14). New York, NY, USA: ACM.
doi:10.1145/2500423.2500451
- Want Roy, Hopper Andy, Falcao Veronica ve Gibbons Jonathan (1992). The Active Badge Location System. *ACM Trans. Inf. Syst.*, 10, (ss. 91-102).
doi:10.1145/128756.128759

- Ward Andy, Jones Alan ve Hopper Andy (1997). A new location technique for the active office. *IEEE Personal Communications*, 4(5), 42-47.
doi:10.1109/98.626982
- Wittek, Peter (2014). *Quantum Machine Learning: What Quantum Computing Means to Data Mining*. Academic Press, (ss. 176).
- Wymeersch Henk, Lien Jaime ve Win Moe Z. (2009). Cooperative Localization in Wireless Networks. *Proceedings of the IEEE*, 97(2), (ss. 427-450).
doi:10.1109/JPROC.2008.2008853
- Xu Li Da, Xu Eric L. ve Li Ling (2018). Industry 4.0: State of the art and future trends. *International Journal of Production Research*, 56(8), (ss. 2941-2962).
doi:10.1080/00207543.2018.1444806
- Yang Chu-Sing, Tsai Pang-Wei, Liao Ming-Yi, Huang Chun-Chia ve Yeh C. Eugene (2010). Location-Based Mobile Multimedia Push System. *2010 International Conference on Cyber-Enabled Distributed Computing and Knowledge Discovery* (ss. 181-184). 2010 International Conference on Cyber-Enabled Distributed Computing and Knowledge Discovery. doi:10.1109/CyberC.2010.40
- Ye, Xiaoyi (2012). WiFiPoz-an accurate indoor positioning system. *EWU Masters Thesis Collection*, (Yayınlanmış Yüksek Lisans Tezi), (ss. 84).
<https://dc.ewu.edu/theses/81> (Erişim Tarihi: 02.07.2019)
- Yılmaz Mehmet, Arslan Ersoy (2005). Bulanık Mantığın Jeodezik Problemlerin Çözümünde Kullanılması, *Harita ve Kadastro Mühendisleri Odası, Mühendislik Ölçümleri STB Komisyonu*, (ss. 23-25).
- Yüksek, Ahmet Gürkan (2007). *Hava kirliliği tahmininde çoklu regresyon analizi ve yapay sinir ağları yönteminin karşılaştırılması*. Cumhuriyet Üniversitesi, Sivas, (Yayınlanmış Doktora Tezi), (ss. 281).
- Zadeh, Lütfi Aliasker (1965). Fuzzy sets. *Information and Control*, 8(3), (ss. 338-353).
doi:10.1016/S0019-9958(65)90241-X

- Zadeh, Lütü Aliasker (2008). Fuzzy logic, *Scholarpedia*, 3(3), (ss. 1776). doi: 10.4249/scholarpedia.1766 http://www.scholarpedia.org/article/Fuzzy_logic (Erişim Tarihi : 27.07.2019)
- Zafari Faheem, Gkelias Athanasios ve Leung Kin (2017). A Survey of Indoor Localization Systems and Technologies, *IEEE Communications Surveys & Tutorials*, 21(3), (ss. 2568-2599). *ArXiv:1709.01015 [cs]*. <http://arxiv.org/abs/1709.01015> (Erişim Tarihi: 22.05.2019)
- Zandian, Reza (2019). Ultra-wideband Based Indoor Localization of Mobile Nodes in ToA and TDoA Configurations, (Yayınlanmış Doktora Tezi), (ss. 255). <https://pub.uni-bielefeld.de/record/2934897> (Erişim Tarihi: 04.08.2019)
- Zeimpekis Vasileios, Giaglis George M. ve Lekakos George A. (2002). A taxonomy of indoor and outdoor positioning techniques for mobile location services. *ACM SIGecom Exchanges*, (ss. 19-27).
- Zhang Ying (2012). *Accurate indoor tracking in WLANs with reduced calibration effort*. Hong Kong University of Science and Technology, (Yayınlanmış Doktora Tezi), (ss. 137).

İnternet Kaynakları

- Chegg (2018). *Regression Analysis*. <https://www.chegg.com/homework-help/definitions/regression-analysis-31> (Erişim Tarihi: 15.10.2019)
- Chen, James (2019). Investopedia. *Investopedia*. <https://www.investopedia.com/terms/n/neuralnetwork.asp> (Erişim Tarihi: 02.11.2019)
- Chugh, Jay (2017). Oracle Blog. <https://blogs.oracle.com/ai/types-of-machine-learning-and-top-10-algorithms-everyone-should-know> (Erişim Tarihi: 09.09.2019)
- Edureka (2018). *Edureka*. <https://www.edureka.co/blog/what-is-machine-learning/> (Erişim Tarihi: 08.09.2019)
- Ehdp (2019). <https://www.ehdp.com/methods/least-squares-regression-1.htm> (Erişim Tarihi: 05.11.2019)

- Hackernoon (2019). <https://hackernoon.com/types-of-linear-regression-w4o227s5>
(Eriřim Tarihi: 05.11.2019)
- Harrison, Onel (2019). TowardsDataScience. *Medium*.
<https://towardsdatascience.com/machine-learning-basics-with-the-k-nearest-neighbors-algorithm-6a6e71d01761> (Eriřim Tarihi: 14.07.2019)
- Hatipođlu, Ekrem (2018). Machine Learning-Prediction Algorithms-Multiple Linear Regression. *Medium*. <https://medium.com/@ekrem.hatipoglu/machine-learning-prediction-algorithms-multiple-linear-regression-part-3-c25a5a4205b6> (Eriřim Tarihi: 12.11.2019)
- Hayes, Adam (2019). Investopedia. *Investopedia*.
<https://www.investopedia.com/terms/r/r-squared.asp> (Eriřim Tarihi: 14.07.2019)
- İTÜ (2013). İTÜ. *İTÜ*. <https://bidb.itu.edu.tr/sevir-defteri/blog/2013/09/07/zigbee>
(Eriřim Tarihi: 21.05.2019)
- Kenton, Will (2018). Investopedia. *Investopedia*.
<https://www.investopedia.com/terms/l/least-squares-method.asp> (Eriřim Tarihi: 02.11.2019)
- Loon Ronald van (2018). Big Data Made Simple. *Big Data Made Simple*.
<https://bigdata-madesimple.com/machine-learning-explained-understanding-supervised-unsupervised-and-reinforcement-learning/> (Eriřim Tarihi: 28.11.2019)
- MathWorks (2018). <https://www.mathworks.com/discovery/machine-learning.html>
(Eriřim Tarihi: 05.07.2019)
- Matlab-Fuzzy* (2018). <https://www.mathworks.com/help/fuzzy/index.html> (Eriřim Tarihi: 05.07.2019)
- Proente (2019, 8 Nisan). *Proente*. <https://proente.com/nesnelerin-interneti-nedir/>
(Eriřim Tarihi: 05.08.2020)
- Ray, Sunil (2015). Analytics Vidhya. *Analytics Vidhya*.
<https://www.analyticsvidhya.com/blog/2015/08/comprehensive-guide-regression/> (Eriřim Tarihi: 30.10.2019)

ResearchAndMarkets (2018). *Research and Markets*.

<https://www.researchandmarkets.com/reports/4756900/indoor-location-market-to-2027-global-analysis> (Erişim Tarihi: 12.02.2020)

RFID Türkiye (2007). RFID Türkiye. *Www.rfid-turkiye.com*, <http://www.rfid-turkiye.com/WhatIsRfid.aspx> (Erişim Tarihi: 21.05.2019)

Scott, Gordon (2019). Investopedia. *Investopedia*.

<https://www.investopedia.com/terms/f/fuzzy-logic.asp> (Erişim Tarihi: 29.01.2020)

SearchEnterpriseAI (2017). *SearchEnterpriseAI*,

<https://searchenterpriseai.techtarget.com/definition/machine-learning-ML> (Erişim Tarihi: 05.07.2019)

Simplilearn. (2017). *Simplilearn.com*. <https://www.simplilearn.com/what-is-perceptron-tutorial> (Erişim Tarihi: 24.02.2020)

Stark, Randy (2018). <https://www.cisin.com/coffee-break/Enterprise/highlights-the-advantages-and-disadvantages-of-machine-learning.html> (21.04.2020)

Sonitor. (1997). *Sonitor*, <https://www.sonitor.com/> (Erişim Tarihi: 19.06.2019)

SurveyGizmo (2018). *SurveyGizmo*,

<https://www.surveygizmo.com/resources/blog/regression-analysis/> (Erişim Tarihi: 15.10.2019)

Swaminathan, Saishruthi (2019). TowardsDataScience. *Medium*.

<https://towardsdatascience.com/linear-regression-detailed-view-ea73175f6e86> (Erişim Tarihi: 31.10.2019)

Yale Courses (2019). *Yale University Online Courses*.

<http://www.stat.yale.edu/Courses/1997-98/101/linreg.htm> (Erişim Tarihi: 01.11.2019)

Zonith (2000). *Zonith*, <https://zonith.com/rtls/> (Erişim Tarihi: 18.06.2019)

ÖZ GEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Emre YÜKSEK
Uyruğu : Türkiye Cumhuriyeti
Doğum Tarihi ve Yeri : 1993/Sivas
e-posta : emreyukse@outlook.com

EĞİTİM

Derece	Kurum	Mezuniyet Yılı
Lisans	Ankara Üniversitesi	2017
Yüksek Lisans	Sivas Cumhuriyet Üniversitesi	2020