



**KTO KARATAY  
ÜNİVERSİTESİ**

**T.C.  
KTO Karatay Üniversitesi  
Fen Bilimleri Enstitüsü**

**ELEKTRİK VE BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI  
TEZLİ YÜKSEK LİSANS PROGRAMI**

**DERİN ÖĞRENME İLE RFID TABANLI  
KONUM BELİRLEME UYGULAMASI**

**Seda GÜLER**

**KONYA**

**Aralık 2018**

DERİN ÖĞRENME İLE RFID TABANLI  
KONUM BELİRLEME UYGULAMASI

Seda GÜLER

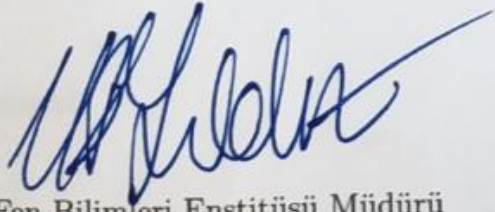
KTO Karatay Üniversitesi Fen Bilimleri Enstitüsü

Elektrik ve Bilgisayar Mühendisliği Ana Bilim Dalı  
Yüksek Lisans Programı

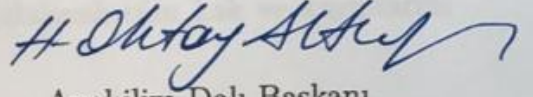
Yüksek Lisans Tezi

*Aralık, 2018*

Fen Bilimleri Enstitü Onayı

  
Fen Bilimleri Enstitüsü Müdürü  
Prof. Dr. Hüseyin Bekir Yıldız

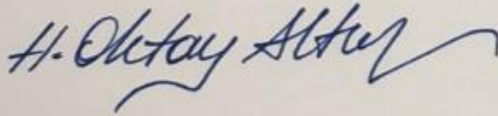
Bu tezli yüksek lisans tezinin yapılması gereken bütün gerekliliklerinin yerine getirdiğini onaylıyorum.

  
Anabilim Dalı Başkanı  
Dr. Öğr. Üyesi H. Oktay Altun

Seda GÜLER tarafından hazırlanan DERİN ÖĞRENME İLE RFID TABANLI KONUM BELİRLEME UYGULAMASI başlıklı bu çalışma 12.12.2018 tarihinde yapılan savunma sınavı sonucunda başarılı bulunarak jüri tarafından tezli yüksek lisans tezi olarak kabul edilmiştir.

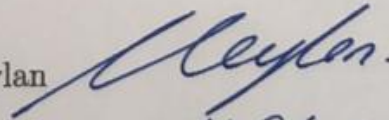
Tez Danışmanı

Dr. Öğr. Üyesi H. Oktay Altun

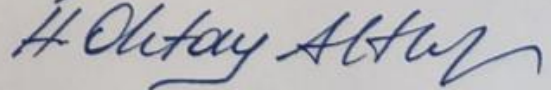


Jüri Üyeleri

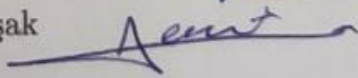
Başkan: Doç. Dr. Murat Ceylan



Üye: Dr. Öğr. Üyesi H. Oktay Altun



Üye: Dr. Öğr. Üyesi Semih Yumuşak

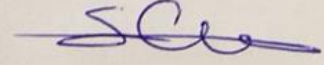


## Tez Bildirimi

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada orjinal olmayan her türlü kaynağa eksiksiz atıf yapıldığını, kullanılan verilerde herhangi bir değişiklik yapmadığımı, bu tezde sunduğum çalışmanın özgün olduğunu bildirir aksi bir durumda aleyhime doğabilecek tüm hak ve kayıplarımı kabullendiğimi beyan ederim.

Aralık-2018

Seda GÜLER



## Özet

### DERİN ÖĞRENME İLE RFID TABANLI KONUM BELİRLEME UYGULAMASI

Seda GÜLER

KTO Karatay Üniversitesi,

Fen Bilimleri Enstitüsü,

Elektrik ve Bilgisayar Mühendisliği Anabilim Dalı Yüksek Lisans Tezi

Tez Danışmanı: Dr. Öğr. Üyesi H. Oktay ALTUN

Aralık 2018

Konum bulma teknolojileri arasında GPS, bluetooth, Wi-Fi, ultrasound ve RFID gibi teknolojileri sayabiliriz. RFID teknolojileri bunlar arasında özellikle maliyet, üretim kolaylığı ve enerji tüketimi açısından özel bir konuma sahiptir. Bina içi konum belirleme ihtiyacının hızla arttığı günümüzde, RFID ile konum belirleme teknikleri önemini korumaktadır. Biz bu çalışmada, RFID alıcı ve verici arasındaki haberleşmeyi dışarıdan bir donanımla dinledik ve derin öğrenme teknikleri ile bu veriyi kullanarak RFID etiketinin konumunu belirlemeye çalıştık. Haberleşme kanalını belirlenen bant genişliğinde dışarıdan SDR algılayıcı ile dinleyerek I/Q kanal bilgilerini kaydettik. Belirlediğimiz uzaklıklar ile, bu uzaklıklardan RFID etiketiyle verici arasındaki haberleşmenin sinyal bilgisini bir derin konvolüsyonel sinir ağına networküne öğrettik. Tek boyutta, 10 metrelik bir çizgideki uzaklık bilgisini 2,5 metre çözünürlükle doğru olarak tahmin edebildik.

**Anahtar kelimeler:** RFID, Derin Öğrenme, Konum Belirleme, SDR Algılayıcı I/Q Kanal Verileri Üzerinden Konum Belirleme

## **Abstract**

### AN RFID BASED POSITION ESTIMATION METHOD VIA DEEP LEARNING

Seda GÜLER

KTO Karatay University,  
The Graduate School of Natural and Applied Sciences,  
Master of Science Thesis in Electrical and Computer Engineering

Advisor: Asst. Prof. H. Oktay ALTUN

December 2018

Location estimation technologies include GPS, bluetooth, Wi-Fi, ultrasound and RFID. RFID technologies have a special place among them, especially in terms of production cost and low power. Nowadays, RFID and positioning techniques are important, especially when the need for in-house location is rapidly increasing. In this study, we have listened the communication between an RFID receiver and transmitter with an external hardware and using this information, we tried to determine the location of the RFID tag with deep learning techniques. We have been able to estimate the one dimensional location information on a 10 meter line with a 2,5 meter resolution in our work via I/Q signals obtained from an SDR dongle.

**Keywords:** RFID, Deep Learning, Position Estimation, I/Q Channel Based Localization via SDR Data

## Teşekkür

Çalışmalarım boyunca her konuda destek olan sevgili aileme, tezin kodlama aşamasında büyük emeği olan arkadaşım Cihan ÇALIŞIR'a ve değerli katkılarıyla beni yönlendiren tez danışmanım Dr. Öğr. Üyesi H. Oktay ALTUN'a sonsuz teşekkürler.

Seda GÜLER  
Aralık-2018



# İçindekiler

Tez Bildirimi	iv
Özet	v
Abstract	vi
Teşekkür	vii
Şekil Listesi	x
Tablo Listesi	xi
Simge ve Kısaltmalar	xii
<b>1 Giriş</b>	<b>1</b>
<b>2 Literatür</b>	<b>3</b>
<b>3 Kuramsal Temeller</b>	<b>5</b>
3.1 Konum Belirleme Teknolojileri	5
3.2 RFID	5
3.2.1 RSSI	7
3.2.2 RFID Gen-2 Protokolü	7
3.3 Haberleşme Çeşitleri	7
3.4 Yapay Sinir Ağları	8
3.4.1 Katmanlar	8
3.4.2 Aktivasyon Fonksiyonları	9
3.5 Derin Öğrenme	10
3.5.1 Konvolüsyonel Sinir Ağları	10



3.5.1.1	Konvolüsyon Filtreleri	12
3.5.1.2	Pooling Katmanı	12
3.5.1.3	Düzleşme Katmanı ve Tam Bağlı Katman	13
<b>4</b>	<b>Metodoloji</b>	<b>14</b>
4.1	Giriş	14
4.2	Ölçümlerin Alınması	15
4.3	Sinyallere Melspectogram Uygulanması ve Veri Seti Oluşturulması	17
4.4	Derin Öğrenme Modelinin Oluşturulması	20
4.4.1	KSA Parametre Optimizasyonu	22
<b>5</b>	<b>Sonuç</b>	<b>23</b>
<b>6</b>	<b>Ekler</b>	<b>24</b>
	<b>Kaynaklar</b>	<b>28</b>
	<b>Özgeçmiş</b>	<b>31</b>

# Şekil Listesi

3.1	Bazı aktivasyon fonksiyonları	9
3.2	Bir araba resmi üzerine KSA uygulanması	11
3.3	Konvolüsyon filtresi örneği	12
3.4	Pooling işlemi	13
4.1	Blok Diagram	15
4.2	İletişim sistemi	16
4.3	SDR Play	16
4.4	Yarı çift yönlü iletişim	17
4.5	50 cm ölçümü için karşılaştırma grafikleri	18
4.6	300 cm ölçümü için karşılaştırma grafikleri	19
4.7	550 cm ölçümü için karşılaştırma grafikleri	19
4.8	800 cm ölçümü için karşılaştırma grafikleri	20
4.9	Oluşturulan modele ait detaylar	21

# Tablo Listesi

4.1 Hata Matrisi

22



# Kısaltmalar

Kısaltmalar	Açıklama
GPS	Küresel konumlandırma sistemi ( <i>Global positioning system</i> )
CNN	<i>Convolutional neural network</i>
RFID	Radyo frekanslı tanımlama ( <i>Radio Frequency Identification</i> )
LF	Düşük frekans ( <i>Low frequency</i> )
HF	Yüksek frekans ( <i>High frequency</i> )
UHF	Ultra yüksek frekans ( <i>Ultra high frequency</i> )
SHF	Süper yüksek frekans ( <i>Super high frequency</i> )
KSA	Konvolüsyonel sinir ağları
RSSI	<i>Received signal strength indication</i>
EPC	<i>Electronic product code</i>
UPC	<i>Universal product code</i>
FHSS	<i>Frequency hopping spread spectrum</i>
CNTK	<i>Cognitive toolkit</i>
SDR	<i>Software defined radio</i>
IF	<i>Intermediate frequency</i>
YSA	Yapay sinir ağları

# Semboller

## Semboller Açıklama

$x$	RFID'den alınan sinyale ait resmin matrisi
$y$	Farklı uzaklıktaki sinyallerin girdi sinyaline benzerlik oranı
$W$	Her girdinin ağırlığı
$b$	Eşik değeri



# 1 Giriş

Konum belirleme teknikleri, genel anlamda, bir nesnenin ya da canlının konumunun tespiti için kullanılan tekniklerdir. Bir cismin konumunun belirlenmesinde birçok farklı yöntem kullanılabilir. Konum belirlenirken dikkat edilmesi gereken unsur, en az ölçüm hatası ile tespit yapmaktır. Hataya sebep olabilecek dış etkenlerin ortadan kaldırılması ya da en aza indirgenmesi büyük önem taşır. Konum belirleme birçok alanda kullanılmaktadır. Bunlardan bazıları; jeoloji, işaretleme, izleme, navigasyon, yüzey ölçümü, harita yapımı, arama kurtarma ve keşif gibi konulardır. İzleme başlığı altındaki konulara daha yakından bakacak olursak, bina içi konum bulma ve askeri alanlarda yapılan çalışmalar en popüler çalışma konularındandır.

Konum bulma problemlerine getirilen çözümlerde kullanılan farklı teknolojiler vardır. GPS, bluetooth, Wi-Fi, ultrasound ve RFID bunlardan birkaçıdır. Bu tekniklerden bazıları dış ortamlarda konum bulma problemi için güzel sonuçlar verirken, diğer bazıları iç ortamlar için etkilidir. Mesela dış ortamlar için vazgeçilmez olan GPS teknolojisi, iç ortamlar için duvarların sinyal zayıflatıcı etkisinden dolayı etkisiz kalmaktadır. Bina içi konum belirleme teknikleri bluetooth, ultra-geniş bantlı ve RFID gibi tekniklerden yararlanarak konum bulmayı amaçlar. Bina içi konumlandırma teknolojilerinde genellikle amaç radyo sinyallerinin karakteristiklerinin kullanılarak kullanıcının bir vericiye göre pozisyonunun belirlenmesi prensibine dayanır. Bu metodların büyük kısmı çoklu yollu yayılım (multi-path propagation), sinyal zayıflaması, gürültüye ve girişime maruz kalma gibi etkilerden dolayı zayıf kalmaktadır.

RFID, avantajları açısından bu teknolojiler içerisinde farklı bir konuma sahiptir. Gerek ucuzluğu, gerekse enerjiye ihtiyaç duymadan çalışması büyük avantaj sağlamaktadır. Radio frequency identification (RFID), cisimleri radyo dalgaları ile tanımlama için kullanılan teknolojiye verilen genel isimdir. RFID sistemlerinde okuyucu ve taşıyıcı olmak üzere temel iki bileşen vardır. RFID teknolojisinde, okuyucu ve taşıyıcı birbirlerini doğrudan görmelerine gerek kalmadan aralarında iletişim kurabilmektedirler. RFID'nin diğer bir özelliği ise, birçok taşıyıcının aynı anda okunabilmesinin mümkün olmasıdır [1]. Kurumsal arkaplan bölümünde RFID teknolojisi

detaylı bir şekilde anlatılacaktır.

Son zamanlarda Wi-Fi tabanlı parmakizi (fingerprinting) algoritmaları yaygın olarak iç mekan konumlandırma için kullanılmaya başlanmıştır. Bu metodda binanın içindeki Wi-Fi çekim gücü önceden haritalanır ve bir veri bankası oluşturulur. Anlık alınan sinyal gücü indeksi (RSSI) verileri bu veri bankası ile kıyaslanarak konum tahmin edilir. Bu şekilde 6-8 m arası konum tahmin edilebilmektedir. Erişim noktalarının sayısı artırılarak bu çözünürlük daha da artırılabilir.

Konuyla ilgili, literatüre bakıldığında RFID teknolojisi üzerine birçok çalışma yapıldığı görülmektedir. En yaygın uygulamalar tahsilat sistemleri, havaalanı güvenlik ve bagaj otomasyonu, geçiş kontrol, üretim takibi, otopark otomasyonu ve envanter takibidir. Şirketler RFID'yi tedarik zincirlerini takip etmek gibi süreçlerde de kullanmaktadır. Literatür bölümünde günümüze kadar yapılan çalışmalar ile ilgili detaylı bilgi verilecektir.

Yapılan çalışmaları incelediğimizde, yansıma örüntülerini derin öğrenme tekniklerinin daha iyi yakalayabileceği kanısına vardık. Burada eksik olan nokta ise, RFID ve derin öğrenmenin sentezidir. Biz kullandığımız metod ile yansılardan bağımsız sonuç elde ederek, derin öğrenme ile farklı bir bakış açısı ve daha güvenilir sonuçlar getirmeyi hedefledik.

Makine öğrenmesi teknikleri ve derin öğrenme tekniklerindeki hızlı gelişmeler, analitik tekniklerdeki ve fingerprinting tekniklerindeki gürültü ve belirsizliklerle başedebilmede oldukça iyi sonuçlar verme potansiyeli göstermektedir. Biz bu çalışmada RFID etiketi ve vericisi arasındaki iletişimi bir SDR algılayıcı cihazla dinleyerek elde ettiğimiz I/Q kanalını bir denetimli öğrenme algoritmasına besleyerek bir konvolüsyonel sinir ağı mimarisini eğittik. Sonuçları tezimizin ilerleyen kısımlarında raporladık.

Bu tezde, öncelikle Bölüm 2'de çalışmanın arka planının anlaşılması için konum bulma teknolojileri hakkında temel bilgiler verilmiş ve derin öğrenmeden bahsedilmiştir. Bölüm 3'te, yapılan literatür araştırmalarımızdan bahsedilerek bu çalışmanın literatürdeki yerine değinilmiştir. Bölüm 4'te, sinyal datalarının nasıl temin edildiği, sinyallerin geçirdiği işlemler ve hangi yöntemler kullanılarak sonuca ulaşıldığından bahsedilmiştir. Ayrıca, uygulanan yöntemler dahilinde elde edilen sonuçlar değerlendirilmiştir. Bölüm 5'de ise alınan sonuçlardan bahsedilmiştir.

## 2 Literatür

Tesoriero ve ark. [2] robot ve insan gibi otonom yapıların belirli bir yüzeyde doğru olarak yerleştirilmesini sağlayan pasif RFID tabanlı kapalı mekan konumlandırma sistemi geliştirmek için RFID nin ucuz ve güvenilir teknolojisinin kullanımını önermektedirler. Bu sistem robot takip problemini çözmek için uygulanmıştır. Teknolojik sistemin performansı farklı teknolojiler (Wi-Fi, bluetooth ve ultrason, vb.) üzerine konumlanmış diğer alternatiflerle kıyaslanmış ve hesaplanmıştır.

Lionel ve ark. [3] binaların içerisine nesnelerin yerleştirilmesi için RFID teknolojisini kullanan lokasyon hissetme prototip sistemi, LANDMARC'ı sunmuşlardır. LANDMARC'ın en temel avantajı, referans etiketlerin konseptini değerlendirerek nesnelerin yerleştirilmesinin bir uçtan bir uca doğruluğunu geliştirmesidir. Deneysel analizlere dayandırılarak, aktif RFID'nin kapalı alan lokasyon tahmini için değişebilir ve fiyat olarak en uygun olduğu kanıtlanmıştır. RFID kapalı alan lokasyon tahmini için tasarlanmamasına rağmen, RFID teknolojilerinin bu yeni ve büyüyen piyasada rekabetçi olması için üç temel özelliğin eklenmesi gerektiği vurgulanmıştır.

Hahnel ve ark. [4] son RFID teknolojilerinin hareketli robotların ve insanların kendi çevrelerinde yerleştirilmesinin geliştirilmesinde kullanılıp kullanılmayacağını analizini yapmışlardır. Özellikle RFID etiketlerinin bir çift RFID antenleriyle donatılmış hareketli platform ile yerleştirilmesi problemini çalışmışlardır. RFID etiketlerinin ortama doğru bir şekilde yerleştirilmesini sağlayan, RFID okuyucaları için olasılıksal bir ölçüm modeli sunulmuştur. Aynı zamanda bu saptamaların robot veya insanların kendi çevrelerinde yerleştirilmesinde nasıl kullanılacağı gösterilmiştir. Son olarak, global robot yerleştirilmesinin lazer data ile RFID bilginin kullanımıyla fazlasıyla düşürülebileceğini gösteren deneyler sergilenmiştir.

Jin ve ark [5] RFID teknoloji tabanlı kapalı alan konumlandırma hissetme sistemi olan LANDMARC sistemi analiz edilmiş ve daha etkili, verimli ve doğru bir mekanizma önerilmiş ve problemler LANDMARC ile çözülmüştür. Önerilen mekanizma hesaplama süresini komşu etiketler için adayların sayısını azaltarak yani



konumlandırmadaki gecikmeyi azaltarak hesaplama süresini düşürmüştür.

Sanpechuda ve ark. [6] mevcut RFID konumlandırma teknikleri gözden geçirilmiş ve bu teknolojiye dayanan konumlandırmalarla ilgili güncel araştırmaların detayları verilmiştir. Bu çalışmada RFID'nin iki tipine dayalı konumlandırma kategorize edilmiştir. Okuyucu ve etiket konumlandırma. Her bir tekniğin belirli uygulamalar için avantajları ve dezavantajları da tartışılmıştır.

Bouet ve ark. [7] RFID konumlandırmanın en son teknolojik gelişmelerini araştırmışlardır. Sunulan teknikler yaklaşımlarına göre sınıflandırılmıştır. Ölçeklenebilirlik ve geçerlilik anlamında, RFID konumlanma tekniklerinin, gerçek ortamlara uygulandığında kendi önemli karakteristikleri olduğu sonucuna varılmıştır. Teknik ve teknoloji (pasif veya aktif etiketler) seçimi, konumlandırma bilgisinin tanecikliğini ve doğruluğunu, aynı zamanda da toplam maliyeti ve RFID sistemin etkinliğini önemli ölçüde etkilemektedir.

Wang ve ark. [8] parmak izine dayalı iç mekan konumlandırma, yüksek doğruluğu nedeniyle önemli derecede ilgi çekmiştir. Yaptıkları çalışmada, DeepFi adı verilen kanal durumu bilgisini kullanarak yeni bir derin öğrenme tabanlı iç mekan parmak izi sistemi sunmuşlardır. Çalışma üzerindeki üç hipoteze dayanarak, DeepFi sistem mimarisi bir çevrimdışı eğitim aşaması ve bir çevrimiçi lokalizasyon aşaması içerir. Çevrimdışı eğitim aşamasında, derin bir ağı tüm ağırlıklarını parmak izi olarak eğitmek için derin öğrenme kullanılmaktadır. Lokalizasyon aşamasında, tahmini konumu elde etmek için radyal temel fonksiyonuna dayalı olasılıksal bir metod kullanmışlardır. Deneysel sonuçlar, DeepFi'nin iki temsili iç ortamdaki mevcut üç yöntemle karşılaştırıldığında konum hatasını etkili bir şekilde azaltabildiğini doğrulamak için sunulmuştur. Literatürdeki çalışmalar incelendiğinde RFID ile konum bulma konusunda birçok çalışma yapıldığı görülmektedir. Bu noktada RFID-Derin Öğrenme sentezinin eksikliği farkedilmiştir.

## 3 Kuramsal Temeller

### 3.1 Konum Belirleme Teknolojileri

Konum belirleme problemlerine getirilen çözümlerde kullanılan teknolojilerin bazıları GPS, bluetooth, wifi, ultrasound ve RFID'dir. Global positioning system (GPS), küresel yer belirleme sistemi ya da küresel konumlandırma sistemi anlamına gelmektedir. Düzenli olarak kodlanmış bilgi yollayan bir uydu ağıdır. Uydular arası mesafeyi ölçerek dünya üzerindeki kesin yeri tespit etmeyi sağlar [9].

Bluetooth teknolojisi, sunucular arası bağlantılarda kablo kullanmak yerine düşük enerji ve düşük maliyet gerektiren kablosuz bir alternatif olarak tasarlanmıştır. Bluetooth; kişisel bilgisayarlar, mobil cihazlar, ev otomasyonları, araçlar, tıbbi ekipmanlar ve buna benzer birçok ortamda bulunabiliyor.

Wi-Fi teknolojisinin açılımı, wireless fidelity'dir. Anlamı ise kablosuz bağlantı alanıdır. Wifi açılımından da anlaşılacağı üzere wifi sinyal alanıdır ve bu alanda bulunan tabletler, telefonlar, akıllı saatler, ses oynatıcıları, televizyonlar ve benzeri cihazlarla internete kablosuz bir şekilde erişilebilmektedir [10]. Son olarak RFID teknolojisi, cisimleri radyo dalgaları ile tanımda kullanılan teknolojiye verilen genel isimdir [11]. RFID ile ilgili bilgiler alt başlıkta detaylı olarak verilecektir.

### 3.2 RFID

RFID taşıyıcıları, elektrik gücünün kaynağına göre aktif ve pasif olmak üzere iki genel kategoride incelenir. Aktif taşıyıcılar, genellikle bir pilden elde ettikleri kendi güç kaynaklarına sahiptirler. Pasif taşıyıcılar ise güçlerini okuyucunun sinyalinden alırlar [1]. RFID sistemlerinde iki temel bileşen okuyucu ve taşıyıcıdır. Bunun yanında sistemi daha etkin hale getirmek için anten, bilgisayar ve veritabanı kullanılabilir. Bir diğer önemli unsur okuyucunun frekans aralığıdır. Mevcut frekanslar, Low frequency (LF), High frequency (HF), Ultra high frequency (UHF)

ve Super high frequency (SHF)'dir.

RFID teknolojisinde veriler, elektronik veri aygıtlarında saklanmaktadır. Diğer taraftan, veri taşıyan aygıt için gerekli güç ve okuyucu ile veri taşıyan aygıt arasındaki veri değişimi temas yüzeyinden bağımsız olarak elektromanyetik alanlarla sağlanır. RFID taşıyıcıda saklanan veriyi alabilmek için bir okuyucuya ihtiyaç duyulur. Pasif RFID'lerde okuyucu, taşıyıcının hafızasında bulunan veriyi almak için önce antenine enerji yükler. Bu sayede, anten radyo sinyalleri yayar ve taşıyıcı aktif hale gelir. Aktif hale gelen taşıyıcı ise hafızasındaki veriyi bırakır. Anten, okuyucu ve taşıyıcı arasındaki iletişimi sağlar. Antenin şekline ve boyutuna bağlı olarak frekans aralığı gibi sistemin performansını etkileyen bazı özellikleri de farklılık gösterir. RFID ile konum belirleme tekniklerini çalışma şekillerine göre veya sistemin birer parçası olan okuyucu ve taşıyıcıların yerleştirilme şekillerine göre sınıflandırabiliriz. Genellikle, taşıyıcı sabit okuyucu hareketli sistemler ve okuyucu sabit taşıyıcı hareketli sistemler olmak üzere iki başlık altında incelenmektedir.

İç mekânlarda kişilerin konumlarını belirlemek için tasarlanmış birçok sistem vardır. Mevcut sistemleri, sistemlerin çalışma şekillerini göz önünde bulundurarak veya sistemin bir parçası olan okuyucu ve taşıyıcıların yerleşim düzenine bakarak kategorilendirebiliriz. Takip edilmek istenilen nesnenin üzerine yerleştirilmiş bir RFID okuyucunun olduğu veya çok kullanıcı bir sistem için okuyucu yerine taşıyıcıların takip edildiği sistemler iki başlık altında incelenebilir. Bunlardan ilki, taşıyıcı sabit okuyucu hareketli sistemlerdir. Bu gruptaki sistemlerde adından da anlaşılacağı üzere, taşıyıcılar sabit, okuyucular ise hareketlidirler. Bina içerisinde belirlenmiş konumlara taşıyıcılar ve takip edilecek cismin üzerine ise RFID okuyucular yerleştirilmektedir. Bu tip sistemlerde taşıyıcıların bilinen konumlarından faydalanılarak takip edilen nesnenin beraberindeki RFID okuyucunun konumu belirlenmektedir [1]. İkincisi ise, okuyucu sabit taşıyıcı hareketli sistemlerdir. Bu gruptaki sistemlerde, taşıyıcılar takip edilmek istenilen nesnenin üzerinde ve hareketli, okuyucular ise bina içerisinde önceden belirlenmiş konumlarda sabittir. RFID taşıyıcısından alınan *Received signal strength indication* (RSSI) değerleri kullanılarak uzaklık tahmin edilmektedir. RSSI değerlerini elde edebilmek için taşıyıcıdan alınan sinyal gücünü ölçebilen özellikte okuyucuya ihtiyaç vardır. Taşıyıcı ve RFID okuyucu arasındaki fiziksel mesafenin artması, taşıyıcıdan alınan sinyal gücünü ters orantıda etkilemektedir. Fiziksel mesafenin belirli bir düzeyi aşması durumunda taşıyıcı ve okuyucunun iletişimi kopacaktır.

### 3.2.1 RSSI

RSSI veya alınan sinyal gücü göstergesi, cihazın bir erişim noktasından veya yönlendiriciden gelen bir sinyali ne kadar iyi duyabileceğinin ölçümüdür denebilir. İyi bir kablosuz bağlantı elde etmek için yeterli sinyalin olup olmadığını belirlemek için kullanılacak bir değerdir [12]. Kablosuz haberleşme türlerinde, verici cihaz tarafından yayılan sinyalin, alıcı cihazda ölçülen değeridir ve bu değer sıfıra ne kadar yakınsa diğer bir deyişle ne kadar büyükse sinyal gücü o kadar iyi demektir.

RSSI, alınan sinyalin kalitesini ölçmek için kullanılan bir kavramdır. En belirgin özelliği bir mutlak değere sahip olmasıdır [13]. Bu çalışmada veri seti RSSI prensibine göre oluşturulmuştur. Etiketten dönen sinyal genliklerinin matrise dönüştürülmüş halleri kullanılmış ve burada RSSI mantığından yararlanılmıştır.

### 3.2.2 RFID Gen-2 Protokolü

Gen-2 protokolünü anlayabilmek için öncelikle EPC kavramının tanımını yapmalıyız. Elektronik ürün kodu (EPC), birçok öge etiketinde bulunan eski evrensel ürün kodu (UPC) yerine kullanılmaya başlanan rakamlardan oluşan etikettir. EPCglobal kavramı ise, günümüz küresel ticaret ağlarında RFID kullanımını desteklemek için EPC'ye yönelik sektörün küresel standartlarının geliştirilmesine öncülük eden kuruluş ya da kuruluşlara verilen genel isimdir.

Gen-2 veya EPCglobal Class 1 Generation 2 , 860-960 MHz frekansları aralığında çalışan bir RFID sistemi için fiziksel ve mantıksal gereksinimleri tanımlar. Gen 2, 860-960 MHz frekans aralığında çalışır. Bu frekans aralığının frekans ve güç özelliklerini düzenleyen birtakım organizasyonlar ve yönetim organları olduğu için , hiçbir ülke yasal olarak tüm bant genişliği üzerinde çalışamaz. Çalışmanın iki temel frekansı vardır. 860-868 MHz ve 902-928 MHz. 860-960 MHz frekans aralığında çalışmasına ek olarak, Gen2 protokolü aynı zamanda radyo sinyal iletimi sırasında taşıyıcıyı birçok frekans kanalı arasında hızla değiştiren Frekans atlamalı spread spektrumu (FHSS) kullanır. FHSS, etiketi birkaç farklı frekansta okur ve daha sonra, okunmanın başarılı olup olmadığını belirlemek için sonuçları karşılaştırır [14].

## 3.3 Haberleşme Çeşitleri

İki ya da daha fazla cihazın bilgi iletişimine haberleşme denir. Haberleşme, tam çift yönlü ya da yarı çift yönlü olarak iki ana başlıkta incelenebilir. Tam çift yönlü ha-

berleşmede, veri alma ve veri gönderme işlemi aynı zamanda gerçekleşir. Bir sinyal kaynağı aynı anda veri alabilir ve gönderebilir. Noktadan noktaya iletişim nasıl haberleşileceğini data-link katmanı belirler. Tam çift yönlü iletişim için verilebilecek en güzel örnek telefonlardır. Yarı çift yönlü haberleşmede ise, bir kaynak veri gönderirken diğeri bekler ve veriyi aldıktan sonra kendisi gönderme işlemi yapabilir. Çift yönlü olarak veri gönderip alsalar bile bu eş zamanlı olmayacaktır. Aynı anda birden fazla sinyal kaynağı ya da verici gönderim yaparsa, ethernet protokolü devreye girerek bilgi çakışması önlenir. Telsizler bu tip iletişime güzel bir örnektir.

## 3.4 Yapay Sinir Ağları

Yapay sinir ağları, insan beyni örneklenerek geliştirilmiş bir teknolojidir [15]. İnsan beyninden esinlenerek geliştirilmiş, her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapıları olarak da tanımlanabilir. [16].

Yapay sinir ağlarının yapısına en geniş çerçeveden baktığımızda nöron düğümlerinden oluştuğunu söyleyebiliriz. Sistemdeki akış ise, nöronların birbirleri ile haberleşmesiyle gerçekleşir. Yapay sinir ağları modellerindeki en basit birim algılayıcıdır. Algılayıcı, giriş değeri, işlem ve çıktı değerinden oluşur. Herhangi bir algılayıcı için formülizasyon aşağıdaki gibidir.

$$y = Wx + b, \quad (3.1)$$

$x$ , RFID'den alınan sinyale ait bir resmin matrisi,  $y$  ise farklı uzaklıktaki sinyallerin girdi sinyaline benzerlik oranını verir.  $W$  ve  $b$  parametreleri ise  $y$  değerini iyileştirmek için kullanılmaktadır. Amaç bizi en iyi sonuca götürecek  $W$  ve  $b$  değerlerini hesaplamaktır.

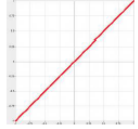
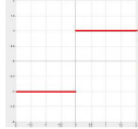
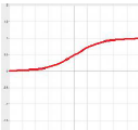
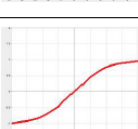
### 3.4.1 Katmanlar

Yapay sinir ağlarında nöronlar katmanlar içinde konumlanmıştır. YSA, 3 katmandan oluşur; giriş katmanı, gizli katman ve çıkış katmanı. Giriş katmanı, yapay sinir ağına dış dünyadan girdilerin ulaştığı katmandır. Her katman kendi girdi elemanını bir önceki katmandan alır ve ürettiği çıktıları bir sonraki katmana iletir. Giriş katmanının düğüm sayısını girdi verilerinin boyutları belirler. Ara katman olarak da adlandırılan, giriş ve çıkış katmanı arasında yer alan gizli katman, ağ içindeki hesaplamaların yapıldığı yerdir. Bazı sinir ağlarında ara katman bulunmadığı gibi

bazılarında ise birden fazla bulunabilir. Gizli katmandaki nöron sayısı ne kadar çok olursa, model o denli derindir denebilir. Üçten fazla gizli katmanı olan sinir ağları, derin sinir ağları olarak adlandırılır [17].

### 3.4.2 Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları, hücreye gelen net girdi elemanını işler ve bu elemana karşı üretecek çıktıyı belirler. Bu fonksiyonlar çoğunlukla doğrusal değildirler. Yapay sinir ağlarının doğrusal olmama özelliği aktivasyon fonksiyonlarının doğrusal olmamasından gelmektedir. Aşağıda bazı aktivasyon fonksiyonları için detayları görebilirsiniz.

Doğrusal (Lineer) Aktivasyon Fonksiyonu		$F(\text{NET})=A \cdot \text{NET}$ (A sabit bir sayı)	Doğrusal problemler çözmek amacıyla aktivasyon fonksiyonu doğrusal bir fonksiyon olarak seçilebilir. Toplama fonksiyonundan çıkan sonuç, belli bir katsayı ile çarpılarak hücrenin çıktısı olarak hesaplanır.
Adım (Step) Aktivasyon Fonksiyonu		$F(\text{Net})= \begin{cases} 1 & \text{if Net} > \text{Eşik Değer} \\ 0 & \text{if Net} \leq \text{Eşik Değer} \end{cases}$	Gelen Net girdinin belirlenen bir eşik değerinin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerini alır.
Sigmoid Aktivasyon Fonksiyonu		$F(\text{Net})= \frac{1}{1+e^{-\text{Net}}}$	Sigmoid aktivasyon fonksiyonu sürekli ve türevi alınabilir bir fonksiyondur. Doğrusal olmayışı dolayısıyla yapay sinir ağı uygulamalarında en sık kullanılan fonksiyondur. Bu fonksiyon girdi değerlerinin her biri için 0 ile 1 arasında bir değer üretir.
Tanjant Hiperbolik Aktivasyon Fonksiyonu		$F(\text{Net})= \frac{e^{\text{Net}} + e^{-\text{Net}}}{e^{\text{Net}} - e^{-\text{Net}}}$	Tanjant hiperbolik fonksiyonu, sigmoid fonksiyonuna benzer bir fonksiyondur. Sigmoid fonksiyonunda çıkış değerleri 0 ile 1 arasında değişirken hiperbolik tanjant fonksiyonunun çıkış değerleri -1 ile 1 arasında değişmektedir.
Eşik Değer Aktivasyon Fonksiyonu		$F(\text{Net})= \begin{cases} 0 & \text{if Net} \leq 0 \\ \text{Net} & \text{if } 0 < \text{Net} < 1 \\ 1 & \text{if Net} \geq 1 \end{cases}$	Gelen bilgilerin 0 dan küçük-eşit olduğunda 0 çıktısı, 1 den büyük-eşit olduğunda 1 çıktısı, 0 ile 1 arasında olduğunda ise yine kendisini veren çıktılar üretilir.
Sinüs Aktivasyon Fonksiyonu		$F(\text{Net}) = \sin(\text{Net})$	Öğrenilmesi düşünülen olayların sinüs fonksiyonuna uygun dağılım gösterdiği durumlarda kullanılır.

Şekil 3.1: Bazı aktivasyon fonksiyonları [18]

Bu fonksiyonların seçiminde bir diğer dikkat edilmesi gereken unsur fonksiyonun türevinin kolay alınabilir olmasıdır. Günümüzde en yaygın olarak kullanılan çok katmanlı algılayıcı modelinde genel olarak aktivasyon fonksiyonu olarak sigmoid

fonksiyonu tercih edilmektedir. Ancak, yapılan çalışmaların özellikleri ve parametrelere göre fonksiyon seçimleri farklılık göstermektedir.

Ayrıca, softmax fonksiyonu, sınıflandırma problemlerinde çıkış katmanında en çok tercih edilen aktivasyon fonksiyonudur. Çıkış nöronları üzerinde normalleştirilmiş bir olasılık dağılımı sağlar [19].

ReLU (*Rectified linear unit*), gizli katmanda en çok kullanılan aktivasyon fonksiyonudur. Giriş değerinin 0'dan küçük olduğu durumda 0, büyük olduğu durumlarda ise giriş değerini döndüren fonksiyonlardır [20].

Elu, üstel doğrusal birim ya da onun yaygın olarak bilinen adı ELU, maliyeti daha hızlı sifra yakınlştırma ve daha doğru sonuçlar üretme eğilimi gösteren bir işlevdir. Diğer aktivasyon fonksiyonlarından farklı olarak, ELU, pozitif sayı olması gereken bir ekstra alfa sabitine sahiptir. ELU, negatif girdiler dışında RELU'ya çok benzer. Her ikisi de negatif olmayan girdiler için kimlik işlevi biçimindedir.

## 3.5 Derin Öğrenme

Derin öğrenme, bilimsel toplulukta dikkat çeken ve konuşma ve görsel tanıma gibi alanlarda ölçüt kayıtlarını kıran bir makine öğrenme yöntemleri ailesidir [21]. Derin öğrenmeye, makinelerin öğrenme yeteneği kazanmasını sağlamak adına geliştirilen bir yöntem de denebilir. Bu konuda yapılan ses tanıma ve görsel tanıma alanındaki çalışmalar temel kullanım alanlarıdır. Derin öğrenme konusundaki hızlı gelişimi teknolojik gelişime bağlamak yanlış olmayacaktır [22].


Derin öğrenme mantığı üzerine halen birçok çalışma yapılmaktadır. Projelerde uygulanabilirliğinin kolaylığı açısından farklı kütüphaneler geliştirilmiştir. Bunlardan başlıcaları, TensorFlow, Theano, CNTK, PyTorch, Keras ve Caffe'dir [23].

Bu projede Keras kütüphanesi kullanılmıştır. Bunu tercih etmemizin sebebi, diğerlerine göre daha gelişmiş bir kütüphane olması ve hızlı çalışmalar için uygun olmasıdır.

### 3.5.1 Konvolüsyonel Sinir Ağları

Bu teknolojiye tüm tanımlamalar sinir ağlarının yapısına ve çalışma şekline dayandırılmaktadır. Derin sinir ağları konusundaki yapılan çalışmalarda bir alt başlık olarak konvolüsyonel sinir ağları (CNN) 'mı inceleyeceğiz. CNN, konvolüsyonel katmanları kullanarak, girdi verilerini ve öğrenen verileri kullanır, bu prensibe göre bir mimari tasarlar. Manuel özellik ortaya çıkarmaya gerek duymayan

bu mimari, sınıflandırma yapmak için tanımlama yapmaya da ihtiyaç duymaz. Doğrudan özellik çıkarması sayesinde, bilgisayarların öğrenme modelleri de hassas hale gelir [24]. Konvolüsyonel sinir ağları ismini konvolüsyon operatöründen almaktadır. Konvolüsyonun temel amacı ise giriş görüntüsünün özelliklerini çıkarmaktır. Konvolüsyon giriş verisinin küçük karelerini kullanarak ve görüntü özelliklerini öğrenerek pikseller arasındaki uzaysal ilişkiyi korur [25].




Şekil 3.2: Bir araba resmi üzerine KSA uygulanması [26]

Şekil 3.2'deki örnekte de görüldüğü gibi KSA, konvolüsyon katmanı, pooling katmanı ve tam bağlantılı katman gibi farklı yapılar içerir.



### 3.5.1.1 Konvolüsyon Filtreleri

Genel bir konvolüsyon işlemini aşağıda görebilirsiniz.



Şekil 3.3: Konvolüsyon filtresi örneği [27]


Konvolüsyon işlemi, görüntü işlemede bir resim üzerinde kare bir filtrenin sol üst köşeden başlanarak, filtrenin merkezi her bir piksel üzerinden geçecek şekilde bütün resmin taranması işlemidir denebilir. Daha geniş bakacak olursak, konvolüsyon katmanı resmin tanınmasından sorumludur. Bu tarama işleminde filtre içerisinde kalan her bir piksel filtrenin katsayıları ile çarpılıp bu çarpımların toplamı, yeni resimde maskenin merkezinin geldiği konuma yazılır.

### 3.5.1.2 Pooling Katmanı

Pooling katmanı, ardışık konvolüsyon katmanları arasında sık kullanılan bir katmandır. Katmanın görevi ise, gösterimin kayma boyutunu, ağ içindeki parametreleri ve hesaplama sayısını azaltmaktır. Bu görevi ile ağdaki uyumsuzluğun kontrol

edilmesini sağlar. Farklı farklı pooling işlemleri vardır, ancak en popülerleri max pooling olarak bilinir. Yine aynı prensibe dayalı average pooling ve l2-norm pooling algoritmaları da mevcuttur.

Pooling işlemini şekil üzerinden açıklayacak olursak, 22 boyutunda bir filtre olduğunu varsayalım. Bu filtreyi 44 boyutunda bir resim üzerine uygulayacak olursak, filtre kapsadığı alan içinde en büyük sayıyı alır. Böylelikle sinir ağının doğru sonucu vermesi için yeterli bilgiyi içeren daha küçük çıktılar kullanılmış olur. Aşağıdaki şekilde detayları görebilirsiniz.



Şekil 3.4: Pooling işlemi [28]

### 3.5.1.3 Düzleşme Katmanı ve Tam Bağlı Katman

Düzleşme katmanında, tam bağlı katman için girdi verileri hazırlanır. Genellikle sinir ağları, giriş verilerini tek boyutlu bir diziden almaktadır. Bu sinir ağındaki veriler ise konvolüsyon ve pooling katmanından gelen matrislerin tek boyutlu diziyeye çevrilmiş halidir.

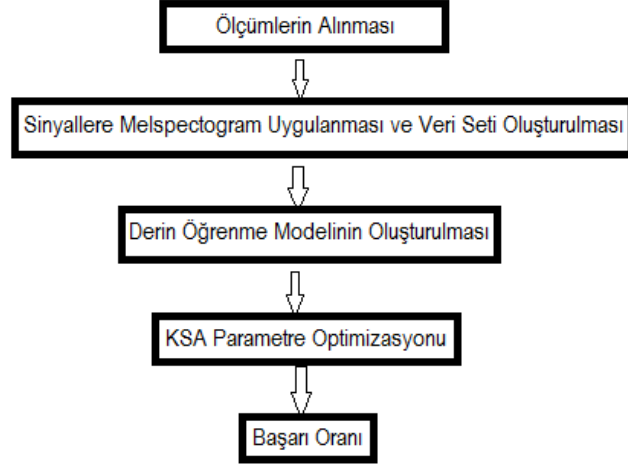
Tam bağlı katman ise en son ve en önemli katmandır. Verileri flattening yani düzleşme katmanından alır ve sinir ağı yoluyla öğrenme işlemini gerçekleştirir. [28]

# 4 Metodoloji

## 4.1 Giriş

Veri kavramı, bilgilerin isteğe göre şekillendirilerek kayıt altına alınmasıdır. Veri seti ise daha kolay analiz ya da işlem yapılabilmesi adına bu bilgilerin bir araya getirilmesidir. Bu çalışmada yapılması gerekenlerden en temeli sinyal veri setini oluşturmak idi. Veri setini oluştururken aşamalar sırasıyla sinyal genliği ölçümü, yapılan ölçümlerde alınan verilerin hangi işlemlerden geçtiği ve nasıl veri seti haline geldiğidir. Veri setini oluşturduktan sonra ise derin öğrenme algoritmalarında ağ eğitim süreçleri incelenmiştir. Bahsedilen veri seti oluşturma ve derin öğrenme ağ eğitim sürecinden sonra yapılan çalışma sonunda ulaşılan sonuçlar detaylı bir şekilde anlatılacaktır.

Veri setini oluşturma aşamasında ilk olarak RFID - etiket haberleşmesinden alınan sinyal kayıtları ile aradaki sinyal genliğinin zamana göre ölçümü alınmıştır. Bu ölçüm farklı mesafelerde yapılmıştır. Yapılan ölçümler SDR cihazı kullanılarak kaydedilmiştir. Alıcı ve verici sinyal ayrıştırılmış, bizim konum belirlemede işimize yarayacak RFID sinyali verici sinyalinden ayrılmıştır. Bu ayrıştırılmış halleri ile veri seti oluşturulmuştur. Yapılan deneylerde okuyucu ile sinyallerin kaydını gerçekleştiren SDR cihazı sabit tutulup, etiketin yeri doğrusal olarak değiştirilmiştir. Bu çalışmada izlenen yol şematik olarak aşağıda gösterilmiştir.



Şekil 4.1: Blok Diagram


## 4.2 Ölçümlerin Alınması

Çalışmada, farklı uzaklıklardan etiket ve okuyucu haberleştirilmiş ve bu esnada SDR aygıtı ile dB değerleri ölçülüp, SDRuno yazılımı ile ara ara kaydedilmiştir. Elde edilen veriler birtakım işlemlerden geçirilmiş ve bir veri seti oluşturulmuştur. Veri setindeki veriler derin öğrenme yaklaşımı vasıtasıyla elimizdeki ölçüm uzaklığı değerleri ile eşleştirilerek yapay sinir ağı eğitilmiştir. Bu aşamada kullanılan ekipmanlar RFID okuyucu, SDR cihazı ve bilgisayara aktarılmasında kullanılan SDRuno yazılımı, etiket, RFID okuyucu cihaz için SessionOne yazılımı ve antendir. Ekipmanları daha yakından tanımak adına aşağıda ilgili bilgiler verilmiştir.

RFID etiketleri aktif, pasif ve yarı aktif etiketler olmak üzere üç ayrı şekilde inceleyebiliriz. Pasif RFID etiketler, güç kaynağına ihtiyaç duymazlar ve RFID okuyucudan gelen radyo dalgalarını kullanırlar. Aktif RFID etiketler, güç kaynağına ihtiyaç duyarlar ve bu sayede sinyal verici olarak kullanılabilirler. Güç kaynağı barındırmaları sebebiyle genellikle performans sorunu yaşamazlar. Yarı aktif RFID etiketlerin ise, üzerlerinde küçük bir kaynak vardır. Çalışma şekilleri pasif etiketler ile aynıdır ancak biraz daha hızlıdır. Bu çalışmada kullanılan pasif RFID etiketinden gelen bilginin hem RFID okuyucu hem de SDR cihazı tarafından okunması sağlanmıştır.

SDR ürünlerini inceleyecek olursak, bu ürünler antenleri vasıtası ile sinyallerin bilgisayar ortamına aktarımını sağlarlar. Software defined radio yani yazılım tabanlı radyo, kısaca radyo iletişimi sağlayan cihazlara ait bileşenlerin donanım katmanı

yerine yazılım katmanında kullanılması prensibine dayanıyor [29]. SDR cihazı ile farklı konumlardaki etiketler için okunan değerler SDR yazılımı ile görüntülenmiş ve kaydedilmiştir. Ardından elde edilen verilerle bir derin öğrenme algoritması eğitilmiştir. Uygulanan sistemin detaylarını aşağıdaki şekilde görebilirsiniz.



Şekil 4.2: İletişim sistemi

Ayrıca, SDR'in kullanım alanlarından bazıları; şifrelenmemiş telsizleri dinleme, hava trafik kontrol konuşmalarını dinleme, uçakların pozisyonlarını takip edebilme, gemilerin pozisyonlarını takip edebilme, telsiz telefonları ve bebek dinleme cihazlarını tarama, meteorolojik amaçlı kullanılan hava balonlarının verilerini alma, kablolu yayıncı yapan sıcaklık ölçüm cihazlarını okuma, GSM sinyallerini yakalama ve işleme gibi sıralanabilir [29]. Bizim kullanma amacımız ise sinyal kaynaklarının yerini tespit etmektir diyebiliriz. SDR cihazının kullanımında, ayarların yapılabilmesi ve verilerin kaydedilmesi için SDRuno yazılımı kullanılmıştır. SDRuno, SDRplay firması tarafından geliştirilmiş bir yazılımdır. SDR cihazının görünümü aşağıdaki gibidir.



Şekil 4.3: SDR Play [30]


Son olarak, RFID okuyucu cihaz ve SessionOne yazılımına yakından bakacağız. Kullandığımız RFID okuyucu, motorola FX7400 modelidir. Bunu seçme sebebi-

miz barındırdığı özellikler doğrultusunda sınıfının en iyilerinden biri olmasıdır. İç mekan ölçümlerinde üstün performansta çalışması, boyutu ve gereksinimleri karşılaması açısından tercih sebebimiz olmuştur. SessionOne yazılımı ise, okuyucu ve antenlerden kablosuz veri bilgilerini kaydeder.

Bu çalışmada kullanılan ürünler özet olarak, RFID okuyucu motorola FX7400, SDR ürünü olarak SDRplay RSP2PRO, anten RFID-500-SC(ANDREW), SDRuno ve SessionOne olarak sıralanabilir. Yazılımlarda yapılan ayarlardan bahsedecek olursak, SDRuno yazılımı 860-900 MHz aralığında IF output modunda çalıştırılmıştır. SessionOne yazılımında okuyucunun IP'si ile bilgisayarın IP'si ethernet kablosu üzerinden haberleşebilir hale getirilmiştir.

Ölçümler 50 cm aralıklarla yapıldı. Mesafe değişimi ise etiketin yeri doğrusal olarak değiştirilerek sağlandı. İlk ölçümde anten ile etiket arasındaki mesafe 50 cm idi. Bir sonraki ölçümde 300 santimetre olarak ayarlandı ve 250'şer santimetre olarak artırılarak devam edildi. Her sinyal genliği ölçümünün büyüklüğü boyutu yaklaşık 20 MB civarında olacak şekilde kayıtlar yapıldı.

Ölçümlerin alınmasındaki sistemde temel prensip yarı çift yönlü iletişimdir. Bu iletişim sistemini şekil olarak aşağıdaki gibi gösterebiliriz;



Şekil 4.4: Yarı çift yönlü iletişim [31]

Kaydedilen sinyallerin ham hallerinden kullanılabilir veri haline dönüştürülmesi aşamasından bir sonraki bölümde bahsedilecektir.

### 4.3 Sinyallere Melspectogram Uygulanması ve Veri Seti Oluşturulması


İlk aşama olan ölçüm ve ölçülen sinyal genliklerini kaydetme aşamasından sonra tüm ölçümler wav dosyası olarak kaydedildi. Sonrasında Matlab aracılığıyla dosyalar okutuldu ve herbiri matris olarak kaydedildi. Her matrisin boyutları eşitlenerek (5.000.000 x 2 boyutunda) hücreye (cell'e) kaydedildi. Ardından mat dosya formatında dosya kaydedildi ve google drive ortamına yüklendi.

Bu çalışmada, Google'ın geliştiricilere ücretsiz olarak sunduğu bulut servisi olan Colab kullanılmıştır. Colab ile ücretsiz bir şekilde GPU üzerinde derin öğrenme


uygulamaları geliştirilebilmektedir.

Datadaki her matrisin (50 santimetreden başlayan ve 2,5 metre atlama ile 800 santimetrede sonlanan 5.000.000 x 2 boyutundaki) ilk sütunundan 2.000 x 1 boyutunda pencere ve 1 kaymayla 2.000'er, toplamda 1000 tane 2.000 x 1'lik veriler alındı. Alınan bu verilere melspectogram, normalizasyon ve log işlemleri uygulanarak modelimizi eğiteceğimiz datalar (input train ve output train) hazırlandı.

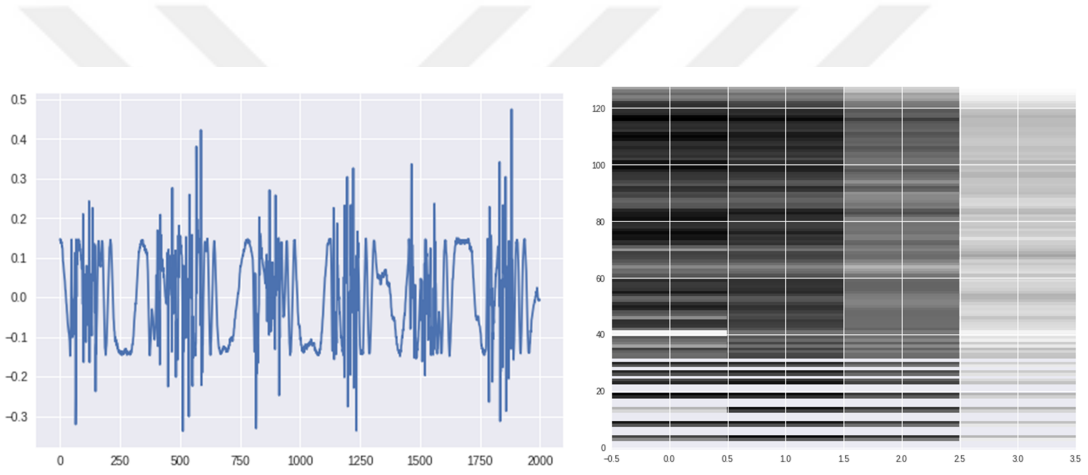
Her 4 ölçüm içinde sinyallere melspectogram uygulanmış ve uygulanmamış hallerini aşağıdaki şekillerde görebilirsiniz. Melspectrogram, sinyalin gücüne bakarak dB 'e çevrilmesidir diyebiliriz Daha farklı bir deyişle, bir sesin zaman-frekans gösterimini temsil eder. Sinyallerin ilk halleri için gösterilen grafiklerde x eksenı zamanı, y eksenı sinyal genliğini gösterir. Melspectrogram uygulandıktan sonraki grafiklerde ise x eksenı zamanı ve y eksenı frekansı gösterir.



Şekil 4.5: 50 santimetreden alınan sinyalin (2000x1) lik parçası ve melspectogram uygulanmış hali




Şekil 4.6: 300 santimetreden alınan sinyalin (2000x1) lik parçası ve melspectogram uygulanmış hali



Şekil 4.7: 550 santimetreden alınan sinyalin (2000x1) lik parçası ve melspectogram uygulanmış hali






Şekil 4.8: 800 santimetreden alınan sinyalin (2000x1) lik parçası ve melspectogram uygulanmış hali

## 4.4 Derin Öğrenme Modelinin Oluşturulması

Konvolüsyon katmanından sonra gelen pooling katmanı ağırlık sayısını azaltır ve uygunluğunu kontrol eder. En popüler pooling işlemi bu projede de kullanılan max-pooling işlemidir. Max-pooling, mantığı gereği kapsadığı alandaki en büyük sayıyı alır. Bu katmanın kullanılma zorunluluğu yoktur. Dense katmanı ve tam bağlantılı katmanın her ikisi de, derin öğrenmenin en temel ve en basit katmanlarıdır. Bu modellerin temel mantığı, her nöronun rastgele başlatılan sabit bir sayıya sahip olmasıdır. Nöronlar arasındaki bağlantılar ağırlıklardır, her bağlantı ağa bağlandığında değişecek bir değere sahiptir.



Şekil 4.9: Oluşturulan modele ait detaylar

#### 4.4.1 KSA Parametre Optimizasyonu

Doğrusal olmayan problemlerin çözümünde optimum değerleri bulmak için kullanılan yöntemlerdir. Verileri eğitmeden önce, optimizasyon algoritması seçimi önemlidir. Bu projede en iyi sonucu veren ve parametreleri en iyi optimize eden algoritma Adam algoritması olmuştur. Adam optimizasyon algoritması, yakın zamanda bilgisayarla görme ve doğal dil işlemede derin öğrenme uygulamaları için daha fazla kabul görmüş bir algoritmadır.

Adam, eğitim verilerine dayanarak yinelemeli ağırlıklarını güncellemek için klasik stokastik gradyan iniş prosedürü yerine kullanılabilecek bir optimizasyon algoritmasıdır. Yöntem, farklı parametreler için bireysel uyarlamalı öğrenme oranlarını, gradyanların birinci ve ikinci anlarının tahminlerinden hesaplar. [32] Başarı oranını aşağıda görebilirsiniz.

		Tahmin			
		50 cm	300 cm	550 cm	800 cm
Gerçek	50 cm	969	31	0	0
	300 cm	0	1000	0	0
	550 cm	0	0	1000	0
	800 cm	0	0	0	1000

Tablo 4.1: Hata Matrisi

## 5 Sonu

Bu alıřmada, ilk olarak konum belirleme teknolojilerinden olan RFID kullanılarak, belli aralıklara gre sinyaller kaydedilmiř ve kaydedilen sinyaller grltlerinden arındırılarak veri seti oluřturulmuřtur. Oluřturulan veri setinin lmleri belirli uzaklıklara gre dzenlenmiřtir. Bahsedilen veri seti, derin ğrenme sayesinde bir ağı eđitmede kullanılmıřtır. Asıl ama yansılardan bağımsız sonular elde ederek ağın ğreniminin test edilmesi ve bu sayede herhangi bir sinyal verisinin optimum konumunu tespit etmektir. Bu alıřma sonucunda, tek bir dođrultuda 2,5 metre ara ile etiketten alınan sinyaller kullanılarak, %99,9 oranında bařarı elde edilmiřtir.

## 6 Ekler

```
1 !pip install -U -q PyDrive
2 import os
3 from pydrive.auth import GoogleAuth
4 from pydrive.drive import GoogleDrive
5 from google.colab import auth
6 from oauth2client.client import GoogleCredentials
7
8 # 1. Authenticate and create the PyDrive client.
9 auth.authenticate_user()
10 gauth = GoogleAuth()
11 gauth.credentials = GoogleCredentials.get_application_default()
12 drive = GoogleDrive(gauth)
13
14 from google.colab import drive
15 drive.mount("/content/drive")
16
17 !ls "/content/drive/My Drive"
18
19 from scipy.io import loadmat
20 data = loadmat('/content/drive/My Drive/audiocut.mat')
21 x=data['audiocut']
```

Kod 6.1: Sisteme giriş ve verilerin colab'a aktarılması

```
1 !pip install librosa
2 mel_spectrogram = librosa.feature.melspectrogram(x[0,0][2000:4000,0], sr=500000, n_fft=2048,
   ↪ hop_length=512)
3 dBS = 10 * np.log10(mel_spectrogram)
4 mel_spectrogram1 = librosa.feature.melspectrogram(x[0,10][2000:4000,0], sr=500000, n_fft
   ↪ =2048, hop_length=512)
5 dBS1 = 10 * np.log10(mel_spectrogram1)
6 mel_spectrogram2 = librosa.feature.melspectrogram(x[0,15][2000:4000,0], sr=500000, n_fft
   ↪ =2048, hop_length=512)
7 dBS2 = 10 * np.log10(mel_spectrogram2)
```

```

8 mel_spectrogram3 = librosa.feature.melspectrogram(x[0,20][0:2000,0], sr=500000, n_fft=2048,
  ↪ hop_length=512)
9 dBS3 = 10 * np.log10(mel_spectrogram3)
10
11 import matplotlib.pyplot as plt
12
13 plt.figure(figsize=(10, 8))
14 plt.imshow(dBS, aspect='auto', origin='lower')
15 #plt.plot(x[0,0][2000:4000,0])
16 print(dBS.shape)
17
18 plt.plot(x[0,0][2000:4000,0])
19
20 plt.figure(figsize=(10, 8))
21 plt.imshow(dBS1, aspect='auto', origin='lower')
22
23 plt.plot(x[0,5][2000:4000,0])
24
25 plt.figure(figsize=(10, 8))
26 plt.imshow(dBS2, aspect='auto', origin='lower')
27
28 plt.plot(x[0,10][2000:4000,0])
29
30 plt.figure(figsize=(10, 8))
31 plt.imshow(dBS3, aspect='auto', origin='lower')
32
33 plt.plot(x[0,15][0:2000,0])

```

Kod 6.2: Verilere melspectrogram uygulanması ve bazı değerlerin çizdirilmesi

```

1 import numpy as np
2 from scipy import signal
3 import librosa
4 from numpy import inf
5 inp_train = []
6 out_train = []
7 out_test = []
8 inp_test = []
9 for t in range(0,22):
10     for c in range(0,1000):
11
12         if t%5==0 and t<17:
13             m=x[0,t][c:c+2000,0]
14             mel_spectrogram = librosa.feature.melspectrogram(m, sr=500000, n_fft=2048,
15 ↪ hop_length=512)
16             dBS = 10 * np.log10(mel_spectrogram)
17             a,b=dBS.shape

```

```

17     for w1 in range(0,a):
18         for w2 in range(0,b):
19             if dBS[w1,w2]==-inf or dBS[w1,w2]==inf:
20                 dBS[w1,w2]=0
21     dBS=(abs(dBS))
22     dBS /= dBS.max()
23     inp_train.append(dBS)
24     out_train.append((t/5))

```

Kod 6.3: Verinin bölümlere ayrılması

```

1 inp_train=np.asarray(inp_train)
2 out_train=np.asarray(out_train)
3 out_test=np.asarray(out_test)
4 inp_test=np.asarray(inp_test)
5 print(inp_train.shape)
6
7
8 from keras.models import Sequential
9 from keras.layers import Conv2D, MaxPooling2D, Dense, Flatten, Dropout
10
11 from keras.utils.np_utils import to_categorical
12 inp_train=inp_train.reshape(-1,128,4,1)
13 out_train=to_categorical(out_train)
14
15 model=Sequential()
16 model.add(Conv2D(32,(2,2),input_shape=(128,4,1), activation='elu'))
17 #model.add(Dense(512, activation='relu'))
18 model.add(MaxPooling2D(pool_size=(2,1)))
19 model.add(Dense(256, activation='relu'))
20 model.add(Conv2D(32,(2,2),activation='elu'))
21 #model.add(Dense(512, activation='relu'))
22 model.add(MaxPooling2D(pool_size=(2,1)))
23 model.add(Dense(512, activation='relu'))
24 model.add(Conv2D(32,(2,2), activation='elu'))
25 model.add(MaxPooling2D(pool_size=(2,1)))
26 model.add(Flatten())
27 model.add(Dense(32, activation='relu'))
28 #model.add(Dense(22, activation='relu'))
29 model.add(Dense(4, activation='softmax'))
30 #Modeli compile edelim.
31 model.compile(optimizer='adam',
32               loss='categorical_crossentropy'
33               )
34
35 model.fit(inp_train,
36           out_train,

```

```

37     verbose=1,
38     epochs=20
39 )
40
41 inp_test=[]
42 actual=[]
43 for t in range(0,16):
44     if t%5 == 0:
45         for i in range(0,1000):
46             m=x[0,t][i+3000:i+5000,0]
47             mel_spectrogram = librosa.feature.melspectrogram(m, sr=500000, n_fft=2048,
↪ hop_length=512)
48             dBS = 10 * np.log10(mel_spectrogram)
49             a,b=dBS.shape
50             for w1 in range(0,a):
51                 for w2 in range(0,b):
52                     if dBS[w1,w2]==-inf or dBS[w1,w2]==inf:
53                         dBS[w1,w2]=0
54                     dBS=(abs(dBS))
55                     dBS /= dBS.max()
56                     #m=m.reshape(20,20)
57                     inp_test.append(dBS)
58                     actual.append(t/5)
59
60 inp_test=np.asarray(inp_test)
61 print(inp_test[0].shape)
62 predicted=[]
63 for k in range(0,4000):
64     pr = model.predict_classes(inp_test[k].reshape((-1,128,4,1)))
65     predicted.append(pr)
66
67 from sklearn.metrics import confusion_matrix
68 from sklearn.metrics import accuracy_score
69
70
71 results = confusion_matrix(actual, predicted)
72 print ('Confusion Matrix :')
73 print(results)
74 print ('Accuracy Score :',accuracy_score(actual, predicted) )
75 print ('Report : ')
76 print( classification_report(actual, predicted) )

```

Kod 6.4: Modelin oluşturulması ve eğitim-test aşamaları



# Kaynaklar

- [1] Emrullah Demiral, İsmail Rakıp Karas, and Muhammed Kamil Turan. Rfid sistemleri ile konum belirleme uygulamaları. *TMMOB Harita ve Kadastro Mühendisleri Odası*, 14:14–17, 2013.
- [2] Ricardo Tesoriero, R Tebar, José A Gallud, María Dolores Lozano, and Victor M Ruiz Penichet. Improving location awareness in indoor spaces using rfid technology. *Expert Systems with Applications*, 37(1):894–898, 2010.
- [3] Lionel M Ni, Yunhao Liu, Yiu Cho Lau, and Abhishek P Patil. Landmarc: indoor location sensing using active rfid. In *Pervasive Computing and Communications, 2003.(PerCom 2003). Proceedings of the First IEEE International Conference on*, pages 407–415. IEEE, 2003.
- [4] Dirk Hahnel, Wolfram Burgard, Dieter Fox, Ken Fishkin, and Matthai Philipose. Mapping and localization with rfid technology. In *Robotics and Automation, 2004. Proceedings. ICRA'04. 2004 IEEE International Conference on*, volume 1, pages 1015–1020. IEEE, 2004.
- [5] Guang-yao Jin, Xiao-yi Lu, and Myong-Soon Park. An indoor localization mechanism using active rfid tag. In *Sensor Networks, Ubiquitous, and Trustworthy Computing, 2006. IEEE International Conference on*, volume 1, pages 4–pp. IEEE, 2006.
- [6] T Sanpechuda and L Kovavisaruch. A review of rfid localization: Applications and techniques. In *Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology, 2008. ECTI-CON 2008. 5th International Conference on*, volume 2, pages 769–772. IEEE, 2008.
- [7] Mathieu Bouet and Aldri L Dos Santos. Rfid tags: Positioning principles and localization techniques. In *Wireless Days, 2008. WD'08. 1st IFIP*, pages 1–5. IEEE, 2008.

- [8] Xuyu Wang, Lingjun Gao, Shiwen Mao, and Santosh Pandey. Csi-based fingerprinting for indoor localization: A deep learning approach. *IEEE Transactions on Vehicular Technology*, 66(1):763–776, 2017.
- [9] Gps nedir? nasıl Çalışır? ne İşe yarar. <https://teknolojiprojeleri.com/teknik/gps-nedir-nasil-calisir-ne-ise-yarar>, 2008. erişim tarihi: 6 Eylül 2018.
- [10] Wifi nedir? nasıl Çalışır? <https://noktadannoktaya.com/wifi-sistemleri-nedir-nasil-calisir/>, 2008. erişim tarihi: 6 Eylül 2018.
- [11] Dilaver TENGİLİMOĞLU and Vahit YİĞİT. Tıbbi malzeme yönetiminde verimliliği artırıcı bir teknoloji: Radyo frekanslı tanıma sistemi (rfid).
- [12] Understanding rssi. <https://www.metageek.com/training/resources/understanding-rssi.html>, 2018. erişim tarihi: 1 Kasım 2018.
- [13] Rssi – received signal strength indication. <https://www.hayrisezer.net/rssi-nedir.html> year = 2015, note =.
- [14] Rfid gen 2. [http://skyrfid.com/RFID\\_Gen\\_2.What\\_is\\_it.php](http://skyrfid.com/RFID_Gen_2.What_is_it.php), 2015. erişim tarihi: 6 Eylül 2018.
- [15] Halit Ergezer, Mehmet Dikmen, and Erkan Özdemir. Yapay sinir ağları ve tanıma sistemleri. *PiVOLKA*, 2(6):14–17, 2003.
- [16] Murat Çuhadar and Cengiz Kayacan. Yapay sinir ağları kullanılarak konaklama işletmelerinde doluluk oranı tahmini: Türkiye’deki konaklama işletmeleri üzerine bir deneme. *Anatolia: Turizm Arastirmalari Dergisi*, 16(1), 2005.
- [17] Juri Fedjaev. Decoding eeg brain signals using recurrent neural networks. *Journal of machine learning research*, 2017.
- [18] Yapay sinir ağları. <http://www.derinogrenme.com/2017/03/04/yapay-sinir-aglari/>, 2017. erişim tarihi: 13 Kasım 2018.
- [19] John S Bridle. Probabilistic interpretation of feedforward classification network outputs, with relationships to statistical pattern recognition. In *Neurocomputing*, pages 227–236. Springer, 1990.
- [20] Kevin Jarrett, Koray Kavukcuoglu, Yann LeCun, et al. What is the best multi-stage architecture for object recognition? In *Computer Vision, 2009 IEEE 12th International Conference on*, pages 2146–2153. IEEE, 2009.
- [21] Sandra Vieira, Walter HL Pinaya, and Andrea Mechelli. Using deep learning to investigate the neuroimaging correlates of psychiatric and neurological di-

- sorders: Methods and applications. *Neuroscience & Biobehavioral Reviews*, 74:58–75, 2017.
- [22] Abdulkadir Şeker, Banu Diri, and Hasan Hüseyin Balık. Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3):47–64.
- [23] Derin Öğrenme (deep learning). <https://medium.com/ai-magazine/derin-%C3%B6%C4%9Frenme-deep-learning-5f9a803853a7>, 2017. erişim tarihi: 6 Eylül 2018.
- [24] Deep learning derin Öğrenme nedir? <http://www.tr.artificialbrain.xyz/deep-learning-derin-ogrenme-nedir/>, 2018. erişim tarihi: 6 Eylül 2018.
- [25] İsabek Tashiev, Seda Kul, Ali Şentaş, Fatmanur Küçükayvaz, Süleyman Eken, Ahmet Sayar, and Yaşar Becerikli. Konvolüsyonel sinir ağı kullanarak gerçek zamanlı araç tipi sınıflandırması real-time vehicle type classification using convolutional neural network.
- [26] What is a convolutional neural network? <https://www.mathworks.com/solutions/deep-learning/convolutional-neural-network.html>.
- [27] Matlab görüntü İşleme. <https://erencelik.com/matlab-goruntu-isleme-konvolusyon-prewitt-ve-sobel-filtreleri/>, 2013. erişim tarihi: 1 Kasım 2018.
- [28] A beginner’s guide to understanding convolutional neural networks part 2. <https://adeshpande3.github.io/adeshpande3.github.io/A-Beginner’s-Guide-To-Understanding-Convolutional-Neural-Networks-Part-2/>, 2016. erişim tarihi: 1 Kasım 2018.
- [29] Sdr / software defined radio (yazılım tabanlı radyo). <https://www.muratcileli.com/sdr-software-defined-radio-yazilim-tabanli-radyo.html>, 2015. erişim tarihi: 6 Eylül 2018.
- [30] Sdr play. <https://www.sdrplay.com/>, 2014. erişim tarihi: 6 Eylül 2018.
- [31] Yarı Çift yönlü İletişim. <http://www.networxsecurity.org/members-area/glossary/f/full-duplex.html>, 2017. erişim tarihi: 9 Eylül 2018.
- [32] Gentle introduction to the adam optimization algorithm for deep learning. <https://machinelearningmastery.com/adam-optimization-algorithm-for-deep-learning/> year = 2017, note =.

# ÖZGEÇMİŞ

## Kişisel Bilgiler

Soyadı, adı : GÜLER, Seda  
Uyruğu : TC  
Doğum Yeri ve Tarihi : 12/02/1992  
Medeni Hali : Bekar  
Tel : +90 0551 714 54 27  
Fax : -  
e-mail : sedaguler63@gmail.com

## Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Lisans	: KTO Karatay Üniversitesi	Haziran-2016
Yüksek Lisans	: KTO Karatay Üniversitesi	Aralık-2018
Phd	: -	

## İş Deneyimi

Yıl	Yer	Görev
2016	Ericsson	Yazılım Test Mühendisi
2018	NYX Telecommunications	Network Operasyon Mühendisi

## Yabancı Dil

İngilizce(İyi), Çince(Başlangıç)

## Yayımlar

-