



**KTO KARATAY  
ÜNİVERSİTESİ**

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

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

**DERİN ÖĞRENME YAKLAŞIMI İLE RFID TABANLI 2 BOYUTLU KONUM  
BELİRLEME UYGULAMASI**

**Arife Merve İŞLEYİCİ**

**KONYA**

**Ağustos 2019**

DERİN ÖĞRENME YAKLAŞIMI İLE RFID TABANLI 2 BOYUTLU KONUM  
BELİRLEME UYGULAMASI

Arife Merve İŞLEYİCİ

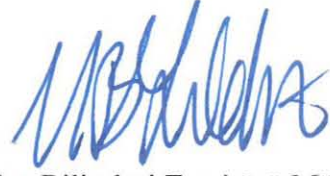
KTO Karatay Üniversitesi Fen Bilimleri Enstitüsü

Elektrik ve Bilgisayar Mühendisliği Ana Bilim Dalı  
Yüksek Lisans Programı

Yüksek Lisans Tezi

*Ağustos, 2019*

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

Merve İŞLEYİCİ, DERİN ÖĞRENME YAKLAŞIMI İLE RFID TABANLI 2 BOYUTLU KONUM BELİRLEME UYGULAMASI 09.08.2019 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: Prof. Dr. Sabri Koçer .....

Üye: Dr. Öğr. Üyesi H. Oktay Altun .....

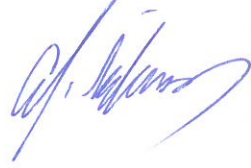
Üye: Dr. Öğr. Üyesi Semih Yumuşak .....

## 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.

Ağustos-2019

Arife Merve İŞLEYİCİ



## Özet

### DERİN ÖĞRENME YAKLAŞIMI İLE RFID TABANLI 2 BOYUTLU KONUM BELİRLEME UYGULAMASI

Arife Merve İŞLEYİCİ

KTO Karatay Üniversitesi,

Fen Bilimleri Enstitüsü,

Elektrik ve Bilgisayar Mühendisliği Anabilim Dalı Yüksek Lisans Tezi

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

Ağustos 2019

Konum bulma teknolojileri için halihazırda GPS, bluetooth, Wi-Fi ve RFID gibi birçok teknoloji mevcuttur. Tüm bu teknolojiler arasında, düşük maliyetli olması ve enerji verimli olması gibi nedenlerle RFID teknolojisinin özel bir yeri vardır. İç mekanlarda konum tespit etme ihtiyacı RFID teknolojisinin önemini daha da artırmıştır. Bu çalışmada piyasadan hazır alınan RFID alıcı ve verici arasındaki iletişim bir dış donanım yardımıyla dinlenmiş, iletişim sonucu elde ettiğimiz verilerle derin öğrenme yaklaşımından faydalanılarak makine öğrenmesi sağlanmış ve belli bir hassasiyette konum tespiti yapılabilmektedir. Sinyalin melspectrogramı derin öğrenme algoritmasına beslenmiş ve nihayetinde sistemin alıcının eksenine göre simetrik yerleştirilen RFID etiketlerindeki eksen simetrisini, deney ortamındaki asimetric yansımalarından dolayı fark edebildiği görülmüştür. Kısa mesafeli bir RFID etiketi ve alıcı/verici sistemi için, iki boyutlu ortamda 1,2 m çözünürlükte bir konum tespiti gerçekleştirilmiştir.

**Anahtar kelimeler:** RFID, derin öğrenme ile konum tespiti, RFID ile konum belirleme

## **Abstract**

### **RFID BASED 2-D LOCALIZATION WITH DEEP LEARNING**

Arife Merve İŞLEYİCİ

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

August 2019

A number of technologies are already available for positioning technologies such as GPS, bluetooth, Wi-Fi and RFID. Among these, RFID technology has a special place due to its low cost and low energy requirements. The need for indoor localization has further increased the importance of RFID technology. In this study, the communication between RFID receiver and transmitter was sniffed with the aid of an SDR receiver and the data obtained as a result of this communication was fed into a deep learning architecture and localization is achieved within a certain sensitivity. We figured that the system was able to distinguish symmetrically placed RFID tags thanks to asymmetric reflections in the experimental indoor environment. For a short-range RFID tag and receiver system, a 1.2 m resolution in position detection was achieved in a 2D environment.

**Keywords:** RFID, deep learning based localization, RFID localization

## TEŐEKKÜR

Çalıřmalarım sürecinde her konuda destek olan sevgili annem ve babama, tezin kodlama ařamasında bana yardımcı olan arkadařım Cihan ÇALIŐIR'a ve deęerli katkılarıyla beni yönlendiren tez danıřmanım Dr. Öğr. Üyesi H. Oktay ALTUN'a sonsuz teőekkürlerimi sunarım.

Arife Merve İŐLEYİCİ  
Aęustos-2019



# İçindekiler

<b>Tez Bildirimi</b>	<b>iv</b>
<b>Özet</b>	<b>v</b>
<b>Abstract</b>	<b>vi</b>
<b>Teşekkür</b>	<b>vii</b>
<b>Şekil Listesi</b>	<b>x</b>
<b>Tablo Listesi</b>	<b>xi</b>
<b>Simge ve Kısaltmalar</b>	<b>xii</b>
<b>1 Giriş</b>	<b>1</b>
<b>2 Literatür Araştırması</b>	<b>3</b>
<b>3 Kuramsal Temeller</b>	<b>7</b>
3.1 Konum Belirleme Teknolojileri	7
3.2 RFID	8
3.2.1 RFID'nin Tarihçesi	9
3.2.2 RFID mi, Barkod mu?	9
3.2.3 RFID Çalışma Sistemi	10
3.2.4 Fonksiyonlarına Göre RFID	10
3.2.5 RFID Kullanım Alanları	10
3.2.6 RFID Gen-2 Protokolü	11
3.3 Haberleşme Çeşitleri	11
3.4 Yapay Sinir Ağları	12



3.4.1	Katmanlar	12
3.4.2	Aktivasyon Fonksiyonları	13
3.5	Derin Öğrenme	13
3.5.1	Konvolüsyonel Sinir Ağları	14
3.5.1.1	Konvolüsyon Katmanı	14
3.5.1.2	Havuzlama Katmanı	15
3.5.1.3	Tam Bağlı Katman	16
<b>4</b>	<b>Metodoloji ve Sonuçlar</b>	<b>17</b>
4.1	Veri Toplanması	17
4.2	Ölçümlerin Alınması	18
4.3	Veri Seti Oluşturulması ve Melspektrogram	20
4.4	Derin Öğrenme Modelinin Oluşturulması	22
4.5	Derin Öğrenme Modelinin Test Edilmesi	23
<b>5</b>	<b>Sonuç</b>	<b>26</b>
<b>6</b>	<b>Ekler</b>	<b>27</b>
	<b>Kaynaklar</b>	<b>33</b>
	<b>Özgeçmiş</b>	<b>36</b>

# Şekil Listesi

3.1	RFID etiket örneği	8
3.2	Barkod örneği	9
3.3	Aktivasyon fonksiyonlarının matematiksel gösterimi	13
3.4	KSA uygulanma aşamaları	14
3.5	Konvolüsyon filtresi örneği	15
3.6	Maksimum havuzlama örneği	16
4.1	Çalışmamızın genel hatlarıyla blok diyagramı	17
4.2	İletişim sistemi	18
4.3	Kullandığımız test düzeneği	19
4.4	Deney düzeneğinin krokisi ve ölçüm noktaları	20
4.5	Yarı çift yönlü iletişim	20
4.6	Şekil 4.3'te tanımlanmış olan (0,0) noktasından alınan sinyalin (2000 × 1)'lik parçası ve aynı sinyalin melspectrogramı	21
4.7	Şekil 4.3'te tanımlanmış olan (2,4) noktasından alınan sinyalin (2000 × 1)'lik parçası ve aynı sinyalin melspectrogramı	22
4.8	Şekil 4.3'te tanımlanmış olan (-2,4) noktasından alınan sinyalin (2000 × 1)'lik parçası ve aynı sinyalin melspectrogramı	22

# Tablo Listesi

3.1	RFID kullanım alanları	11
4.1	Oluřturulan derin öğrenme mimarisi	23
4.2	25 sınıf için karışıklık matrisi ( <i>Confusion Matrix</i> )	24
4.3	5 sınıf için karışıklık matrisi ( <i>Confusion Matrix</i> )	25

# Kısaltmalar

## Kısaltmalar Açıklama

<b>EAS</b>	Elektrik akustik stimülasyon
<b>ELu</b>	Üstel doğrusal birim ( <i>Exponential Linear Unit</i> )
<b>EPC</b>	Elektronik ürün kodu ( <i>Electronic Product Code</i> )
<b>FHSS</b>	Frekans atlamalı yayılmış spektrum ( <i>Frequency Hopping Spread Spectrum</i> )
<b>GPS</b>	Küresel konumlandırma sistemi ( <i>Global Positioning System</i> )
<b>GPU</b>	Grafik işleme ünitesi ( <i>Graphics Processing Unit</i> )
<b>KSA</b>	Konvolüsyonel sinir ağları
<b>OGS</b>	Otomatik geçiş sistemi
<b>ReLU</b>	Doğrultulmuş doğrusal birim ( <i>Rectified Linear Unit</i> )
<b>RF</b>	Radyo frekansı
<b>RFID</b>	Radyo frekanslı tanımlama ( <i>Radio Frequency Identification</i> )
<b>RSSI</b>	Alınan işaret güç göstergesi ( <i>Received Signal Strength Indication</i> )
<b>SARS</b>	Şiddetli akut solunum yolu sendromu ( <i>Severe Acute Respiratory Syndrome</i> )
<b>SDR</b>	Yazılım tabanlı radyo ( <i>Software Defined Radio</i> )
<b>TPU</b>	Tensör işleme ünitesi ( <i>Tensor Processing Unit</i> )
<b>UHF</b>	Ultra yüksek frekans ( <i>Ultra High Frequency</i> )
<b>Wi-Fi</b>	Kablosuz bağlantı alanı ( <i>Wireless Fidelity</i> )
<b>YSA</b>	Yapay sinir ağları

# Semboller

## Semboller Açıklama

$b$	Eşik değeri
$W$	Sinir ağı bağlantılı ağırlık matrisi
$x$	RFID'den alınan sinyale ait resmin matrisi
$y$	Farklı uzaklıktaki sinyallerin girdi sinyaline benzerlik oranı



# 1 Giriş

Konum belirleme problemi, günümüzde üzerinde hala çalışılan ve yakın geçmişte de oldukça hızlı gelişmiş bir alandır. Canlı ya da cansız bir varlığın konumunun minimum hata ile belirlenmesinde bu teknolojiler kullanılmaktadır. Konum belirleme teknolojilerinin depo yönetimi, araç takibi, arama kurtarma çalışmaları ve güvenlik uygulamaları gibi bir çok askeri ve sivil alanda uygulamaları mevcuttur. GPS, bluetooth, Wi-Fi ve RFID gibi teknolojiler, konum bulma probleminin çözümünde kullanılmaktadır. Maliyetinin düşük olması ve alıcıların şebeke enerjisine gereksinim duymamasından dolayı daha avantajlı olan RFID teknolojisi, radyo dalgaları sayesinde konum belirleme uygulamalarında sıklıkla tercih edilmektedir. RFID ile konum belirleme sistemleri çalışma biçimlerine göre ve yerleştirilme biçimlerine göre ayrı ayrı gruplandırılabilir. Kuramsal Temeller Bölümü'nde RFID hakkında daha detaylı bilgi verilecektir.

Modern konum belirleme teknolojilerinin temeli elektromanyetik tanıma teknolojilerine dayanır. Bu teknolojilerin teorik olarak ortaya atılması 1935'li yıllara kadar dayansa da, bunların pratik bir teknolojiye dökülebilmesi 1984 yılını bulmuştur. Philips 2002'de 3,3 m çözünürlükte bir UHF bandında çalışan bir RFID tabanlı konum belirleme sistemi tasarladığını açıkladıktan sonra, yarış tekrar alevlenmiş ve şu anda özel ve pahalı donanımlarla 10 cm çözünürlüklere kadar düşmüştür. Bu teknolojinin hala çok ucuz ve etkili bir ürüne dönüşmemesinin altında, mevcut yaklaşımların yetersizliği yatmaktadır. Derin öğrenme teknikleri bu açığı kapatmada yeni bir soluk getirecektir.

Biz bu çalışmada, bina içi uygulamalarda tek noktadan RFID etiketinin gönderdiği sinyalleri dinleyerek belirli bir hassasiyette iki boyutlu konum tespiti yapılabileceğini gösteriyoruz. Tek antenle yapılan bir dinlemenin, içerideki yansımaları yakalayarak aynı mesafede bulunan iki konumu birbirinden ayırabildiğini ve iç mekan konumlarını tespit edebildiğini göstermeyi amaçlıyoruz.

Probleme yaklaşımımız, biyolojik olarak göz ve beyin arasındaki ilişkiyi andırmaktadır. Göz, optik karmaşıklık ve dış dünyadan gelen sinyallerin işlenmesi açısından beyindeki organizasyon ve karmaşıklıkla kıyaslandığında oldukça ilkel kalmaktadır. Görüntü göz üzerine ters düştüğü gibi, temporal örnekleme de oldukça düşük kalmaktadır. Öte yandan

beyin, gözden gelen gürültülü ve bozuk verileri paralel işleme kabiliyetleri sayesinde düzelterek birleştirmektedir. Biz de bu yaklaşımda, tek antenle ve her türlü enterferansa açık bir ortamdan topladığımız bilgileri (ilkel göz), derin öğrenme algoritması ile karmaşık öğrenme tekniklerinden geçirerek (gelişmiş beyin) konumunu belirliyoruz. Bu yaklaşım, vurguyu anten tasarımından ve alıcıdaki her türlü karmaşıklıktan alarak, asli görevi derin öğrenme mekanizmalarına bindiriyor olması açısından önemlidir.

Konuya göre literatür çalışmasının ardından RFID ile ilgili çalışmalar yapıldığı ancak derin öğrenme yaklaşımının bu teknoloji ile birleştiği çalışmaların yetersiz olduğu gözlemlenmiştir. Literatür Bölümü'nde farklı konular üzerinde RFID teknolojilerinden yararlanılarak oluşturulmuş çalışmalar hakkında bilgi verilecektir. Bölüm 2'de literatür taranmış ve yapılan çalışmalar ile ilgili bilgiler verilmiştir. Bölüm 3'te konum bulma teknolojileri ve derin öğrenme ile ilgili bilgiler detaylandırılmıştır. Bölüm 4'te sinyal veri setinin nasıl oluşturulduğu, sinyallerin nasıl işlemlerden geçtiği ve kullanılan yöntemler incelenmiştir. Bölüm 5'te ise sonuç değerlendirmesi yapılmıştır.

## 2 Literatür Araştırması

W. Gong ve ark. [1] Radyo Frekanslı Tanımlama RFID teknolojisi, tedarik zinciri lojistiği ve stok kontrolünde önemli bir rol oynamaktadır. Bu uygulamalarda, envanter etiketlerinin tamamını kapsayacak şekilde farklı yerlerde bir dizi tarama işlemine ihtiyaç duyulur. Böyle sürekli tarama senaryosunda, bitişik taramalar kaçınılmaz olarak çakışan etiketleri birkaç kez okur. Var olan çoğu yöntem, üst üste binme ve küçükken düşük tarama verimliliğinden muzdariptir, çünkü bunlar, tarama performansının önemli bir faktörü olan üst üste binme boyutunu ayırt etmez. Bu çalışmada, sürekli tarama performansı ile üst üste binme boyutu arasındaki temel ilişki analitik olarak ortaya koyularak, tarama stratejisinin seçimi için kritik bir eşik oluşturulmuştur. Ayrıca, üst üste binmeyi yaklaşık olarak belirlemek için doğru bir tahminci tasarlanmıştır. Tahmini ve kompakt bir veri yapısını birleştiren, düşük iletişim süresi elde etmek için adaptif bir tarama şeması tanıtılmıştır. Detaylı analiz ve kapsamlı simülasyonlar sayesinde, önerilen planın toplam tarama zamanındaki önceki yaklaşımdan önemli ölçüde daha iyi performans gösterdiğini göstermektedir.

S. Sarma ve ark. [2] öngörülen bir bölgedeki varlıkların coğrafi konumunu belirlemek için RFID etiketleri ve mobil RFID okuyucu cihazı kullanma sistemleri ve yöntemleri geliştirmişlerdir. Öngörülen bir bölge içindeki varlıkların geometrik konumlarını çıkarmanın bir yöntemi, bir mobil RFID okuyucunun söz konusu öngörülen bölge boyunca hareket ettirilmesi ve mobil RFID okuyucu tarafından, belirtilen bölge içerisinde hareket ederken birinci RFID konum alıcı-vericisinin kablosuz olarak algılanması sağlanmıştır. Mobil RFID okuyucu tarafından, belirtilen bölge içerisinde hareket ederken en az bir RFID varlık izleme alıcı-vericisinin kablosuz olarak algılanması ve mobil RFID okuyucu tarafından, belirtilen bölge içerisinde hareket ederken ikinci bir RFID konum alıcı-vericisinin kablosuz olarak algılanması sağlanmıştır. Tespit edilen birinci ve ikinci RFID yer transponderleri ile birinci ve ikinci RFID yer transponderlerinin bilinen bir pozisyonu ve tanımlama koduna dayanarak bahsedilen en az bir tespit edilen RFID varlık izleme transponderiyle ilişkili varlıkların coğrafi konumunun belirlenmesi gerçekleştirilmiştir.

Roesner ve ark. [3] bir araç algılama ve konumlandırma sistemi, bir park dizisi boyunca



konumlandırılmış çok sayıda RFID etiketi bulundurmaktadır. Sistem, park dizisi boyunca bir araç tanımlama sistemi ile birlikte hareket edebilen ve RFID etiketlerini sorgulayacak şekilde yapılandırılmış bir RFID okuyucu içermektedir. Aracın konumu, RFID okuyucusu tarafından sorgulamanın, araç tanımlama sistemi tarafından tespit edilen bir tanımlayıcı ile ilişkisine dayanarak belirlenebilmektedir.

Wang ve ark.'nın [4] geliştirdiği parmak izine (*finger printing*) dayalı iç mekan konumlandırma, doğruluk oranının büyüklüğü sebebiyle oldukça merak uyandırmıştır. Bu çalışmada, DeepFi adında kanal durumu bilgisini kullanarak yeni bir derin öğrenme tabanlı iç mekan parmak izi sistemi ortaya çıkarmışlardır. 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.

Yuanqing Zheng ark. [5] ilgili bölgedeki RFID etiketlerinin sayısını tahmin etmek için çalışmalar yaptılar. Bu çalışmada, RFID etiketlerinin yaklaşık sayısını etkili bir şekilde tahmin etmek için yeni bir yaklaşım önerilmiştir. Mevcut yaklaşımlarla karşılaştırıldığında, önerilen Olasılık Tahmini Ağacı (PET) protokolü tahmin verimliliğine ulaşır ve bu da doğruluk ihtiyacını karşılarken tahmin süresini önemli ölçüde azaltır. PET ayrıca, RFID etiketlerinde genel hesaplama ve hafızayı azaltır. Sonuç olarak, PET'i pasif RFID etiketleriyle uygulayabilir ve büyük ölçekli RFID sistemleri için ölçeklenebilir ve ucuz çözümler sağlanabilir. PET'in etkinliği teorik analizlerin yanı sıra kapsamlı simülasyonlar ile onaylanmıştır. Sonuçlar PET'in tahmin doğruluğu, verimlilik ve ek yük açısından mevcut yaklaşımlardan daha iyi performans gösterdiğini göstermektedir.

Dirk Hahnel ve ark. [6] hareketli robotların ve insanların yerlerini tayin edebilmek için RFID teknolojisinin kullanılıp kullanılmayacağına dair araştırma yapmışlardır. RFID etiketlerin uygun biçimde konumlandırılmasına yardım eden RFID okuyucular için olasılıksal ölçüm modeli meydana çıkarılmıştır. Son olarak, global robot lokalizasyonu için hesaplama ihtiyaçlarının RFID bilgisini lazer verileriyle birleştirerek güçlü bir şekilde indirgenebileceğini ifade eden deneyler ortaya koymuşlardır.

Tesoriero ve ark. [7] robot ve insan benzeri otonom yapıların belirli bir yüzeyde doğru olarak yerleştirilmesine olanak sağlayan, aktif olmayan RFID tabanlı kapalı alan konumlandırma sistemi geliştirmek amacıyla RFID nin az maliyetli ve güvenilir teknolojisinin kullanımını tavsiye etmektedirler. Bu sistem robot takip sorununu çözümlmek için geliştirilmiştir. Bu sistemin performansı başka teknolojiler (Wi-Fi ve Bluetooth vb.) üzerine konumlanmış diğer seçeneklerle karşılaştırılarak ölçülmüştür.

Jin ve ark. [8] RFID teknoloji tabanlı kapalı mekan konumlandırma hissetme sistemi olan LANDMARC sistemini analiz etmişlerdir. Ayrıca daha etkili, verimli ve doğru bir mekanizma önerilip problemler LANDMARC sayesinde çözülmüştür. Önerilen sistem konumlandırmadaki gecikmeyi indirerek işlem süresini kısaltmıştır.

Lionel ve ark. [9] binaların içerisine nesnelere konumlandırılması amacıyla RFID teknolojilerinden yararlanan lokasyon hissetme prototip sistemi, LANDMARC'ı önermişlerdir. LANDMARC'ın en belirgin artışı, referans etiketlerin konseptini değerlendirerek nesnelere konumlandırılmasının bir uçtan bir uca doğruluğunu iyileştirmesidir. Deneysel analizlere bağlı olarak, aktif RFID'nin kapalı mekan lokasyon hissetmesi için değişebilir ve ucuz maliyetli olduğu ispatlanmıştır.

Sanpechuda ve ark. [10] var olan RFID konumlandırma yöntemleri incelemiş ve bu teknolojiye dayanan konumlandırmalarla ilgili güncel araştırmaların düşünceleri ifade edilmiştir. Bu çalışmada RFID'nin iki çeşidine göre konumlandırma sınıflandırılmıştır. Bunlar okuyucu ve etiket konumlandırma türüdür. Her tekniğin avantajları ve dezavantajları incelenmiştir.

Bouet ve ark. [11] RFID konumlandırmanın en son teknolojik gelişmelerini araştırmışlardır. Sunulan teknikler yaklaşımlarına göre sınıflandırılmıştır. Bunlar mesafe tahmini, sahne analizi veya topolojik sabitlerdir. Ölçeklenebilirlik ve geçerlilik anlamında, RFID konumlandırma tekniklerinin, gerçek ortamlara uygulandığında kendi önemli özellikleri olduğu sonucuna ulaşılmıştır. 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.

Ali Montaser ve ark. [12] çalışmasında, Ultra Yüksek Frekans (UHF) pasif Radyo Frekansı Tanımlama (RFID) teknolojisini kullanan inşaat projeleri için düşük maliyetli bir iç mekan konum belirleme ve malzeme izleme metodolojisi sunmaktadırlar. Yerinde konum bilgisi olan bilgiler, malzemelerin, işçünün ve ekipmanın konumuyla ilgili mekansal bilgilerin teslim edilmesini otomatikleştirmeye odaklanan bir alandır. Bu mekansal bilgiden inşaat proje durumu ile ilgili bilgi üretmek için yararlanılabilir. Konum tahmini sürecini otomatikleştirmek için iki aşamalı bir algoritma belirlenmiştir ve büyük ölçüde gerçek zamanlı olarak malzeme takibi sağlanmıştır. Bu metodolojide, çalışmanın ilerlediği yerde çeşitli pasif RFID etiketleri dağıtılmaktadır ve bir mobil RFID okuyucusu bir işçi tarafından sahada taşınmaktadır. Her pasif RFID etiketi, önceden tanımlanmış bir bölgede bilinen bir konuma (yer işareti) sahip bir referans noktası olarak dağıtılır. Bilinen konumların referans etiketleri, işçinin yerini belirlemek ve malzemeleri takip etmek için kullanılır. Metodoloji, sinyal ölçümleri için Alınan Sinyal Gücü Göstergesini (RSSI) kullanır. İşçinin yerini belirlemek için iki yöntem (üçgenleme ve yakınlık) kullanılmıştır. Bu metodoloji farklı yerlerde ve farklı inşaat zaman aralıklarında beş test yatağının yerleştirildiği gerçek bir inşaat şantiyesinde test edildi. Ayrıca, bir laboratuvar ortamında

bir test yatağı kurulmuştur. Bu çalışmanın yer tahmini ve iç mekan inşaatının malzeme takibi için düşük maliyetli bir yöntem olduğu sonucuna ulaşılmıştır. Önerilen metodoloji, işçi ve malzeme bölgelerini %100 doğrulukla tespit eder.

Literatürdeki çalışmalara bakıldığında RFID ile konum belirleme üzerine bir çok çalışmanın olduğu görülmektedir. Özellikle iç mekanda konum belirleme ile alakalı uygulamalar geliştirilmiştir. Ancak incelemeler sonucu derin öğrenme yaklaşımından gerektiği kadar yararlanılmadığı ve tek antenle lokalizasyon kabiliyetleri hakkında yeterli çalışmalar bulunmadığı dikkatimizi çekmiştir. Bu nedenle bu çalışmada derin öğrenme yaklaşımı ile iki boyutlu ortamlarda konum tespiti gerçekleştirebilmek adına metodolojiler belirlenmiştir.



## 3 Kuramsal Temeller

### 3.1 Konum Belirleme Teknolojileri

Hızlı bir şekilde gelişen teknoloji birçok ihtiyacı karşılar hale gelmiştir. Çevremizde teknoloji ile gelişmekte olan iç ve dış mekan için konum belirleme yöntemlerine rastlayabiliriz. Askeri ve sivil alanlar olmak üzere karşımıza çıkan birçok amaca bu teknolojik yöntemler çözüm getirmektedirler. Dış mekanlarda bu teknoloji; arama kurtarma çalışmaları, araçlar için konum tespiti, jeolojik hareketlerin takip edilmesi, tarımsal çalışmaların izlenmesi ve ebeveynlerin çocuklarının konumunu belirlemesi gibi alanlarda kullanılırken, iç mekanlarda ise; hizmet organize etme, depo güvenliği sağlama, güvenlik uygulamaları geliştirme, müze gibi ortamlarda yer yön belirleme, görme engelli bireyler için yönlendirme ve personellerin iş yeri içerisinde çalışma yerlerini kontrol etme gibi amaçlara hizmet etmektedir. Tüm bu amaçlar için bluetooth, GPS, Wi-Fi ve RFID gibi teknolojilerden yararlanılarak konum belirleme uygulamaları geliştirilmiştir.

*Global positioning system* (GPS) dünya çevresindeki büyük radyo sinyalleri yayan uyduların arasındaki mesafeye göre konum belirlemeyi sağlayan sistemdir. Uydu sayısı arttıkça konum belirleme hassasiyeti de artmaktadır. Koordinatları belli üç noktaya olan uzaklık bilindiği takdirde konum belirleme işlemi yapılabilecektir. Üç çemberin kesiştiği bir nokta vardır. Böylece yükseklik belirlemek için ihtiyacımız olan dördüncü nokta da elde edilmiş olunur. Kısacası GPS sayesinde bulunduğumuz konumun enlem, boylam ve yükseklik bilgisine erişebiliriz.

GPS ilk başta askeri amaçlarla geliştirilmiştir. Ancak sonraları sivil hayat için de ihtiyaç duyulan dış mekanlarda kullanılmaya başlanmıştır. Günümüzde yer kabuğu hareketleri, araç takibi, insan ve hayvan izleme gibi amaçlarla sıkça kullanılmaktadır. Ayrıca görme engelliler için de bir çok uygulama geliştirilerek engelli bireylerin yaşam standartları yükseltilmiştir.

Bluetooth teknolojisi kablosuz bir şekilde sunucular arası bağlantı sağlayabilen radyo frekans standartlı bir teknolojidir. Bu teknoloji GPS teknolojisine göre daha az güce ihtiyaç duyan ve sınırlı alanda aktif olarak çalışabilen bir teknolojidir. Bluetooth sinyal

alanı içerisinde takip gerçekleştirilir, aksi halde bağlantı sağlanamayacaktır. Bu nedenle bluetooth GPS'in aksine kaybedilen eşyaların konumlarının belirlenebilmesi gibi daha kısa mesafeli günlük ihtiyaçlar için tercih edilmektedir. Mobil cihazlarda, akıllı saatlerde, otomobillerde, kişisel bilgisayarlarda ve sağlık cihazlarında bluetooth teknolojisi kullanılmaktadır.

Wi-Fi teknolojisi *Wireless Fidelity*-Kablosuz Bağlantı Alanı teknolojisi radyo dalgalarını kullanarak kablosuz bir şekilde haberleşmeyi sağlayan sistemdir. Sinyal alanının dışına çıkılması haberleşmenin kesilmesine neden olur. Kişisel bilgisayarlar, yazıcılar, mobil telefonlar, oyun konsolları ve tabletler Wi-Fi teknolojisini destekleyen bazı aygıtlardır.

Wi-Fi'yi destekleyen cihazlar 300 metrelik alanda erişim noktası sağlayabilirler. Birçok erişim noktası ile olan mesafe elde edildiğinde de mobil cihazın konumuna ulaşılabilir. Cihazın konumunun tespiti için Wi-Fi erişim noktalarının konumlarının bilinmesine ihtiyaç vardır. Wi-Fi erişim noktalarının konumları servis sağlayıcılar tarafından farklı teknikler ile haritalanmaktadır. İç mekanlarda Wi-Fi pozisyonlama ile kısa zamanda ve 10 metre hata oranı ile konum tespiti yapılabilmektedir [13].

## 3.2 RFID

Konum belirleme teknolojileri hakkındaki genel bilgilendirmeden sonra bu bölümde çalışmamızın ana konusu olan RFID teknolojisine yoğunlaşacağız. *Radio Frequency Identification* (RFID), üzerindeki etiket sayesinde bir varlığın etiketteki kimlik bilgisi ile hareketlerinin takip edilmesine olanak veren ve radyo dalgaları ile çalışan teknolojidir [14].



Şekil 3.1: RFID etiket [14]

### 3.2.1 RFID'nin Tarihçesi

1950 sonlarında identification friend or foe (IFF) hava trafik kontrol sistemlerinin temelini oluşturuyor. 1958'de Jack Kilby entegre devre sistemlerini Texas Instruments laboratuvarlarında geliştiriyor. 1970 başlarında Sensormatic ve Checkpoint firmaları Elektrik Akustik Stimülasyon (EAS) sistemini güçlendirerek ürünlerin çalınmasına karşı kontrol sistemi geliştiriliyor. 1970'lerde hayvan ve araç takibi çalışmaları gerçekleştiriliyor. 1980'lerde birçok ülkede elektronik ödeme sistemleri (mesela ülkemizdeki OGS gibi) oluşturuluyor. 1990 Amerikan Demiryolları vagon takibi için RFID teknolojisinden yararlanıyor. 1991 Texas Instruments TI-RFID isimli şirket oluşturup ilk etiket ve okuyucularını satışa çıkarıyor. 2003'de Amerikan Ordusu Irak Savaşında RFID teknolojisinden yararlanıyor 2003 EPCGlobal tarafından RFID standartları oluşturuluyor [15].

### 3.2.2 RFID mi, Barkod mu?

Barkod; farklı kalınlıklardaki dik çizgi ve boşluklardan meydana gelmiş ve bilginin otomatik şekilde başka bir ortama iletilmesi amacıyla kullanılan bir teknolojidir. Barkod sadece ürüne ait referans numarası içermelidir. Bu numara bilgisayara tanıtıldıktan sonra ürünle ilgili bilgiler bilgisayara aktarılır. Bu referans numarası sayesinde ürüne ait tüm bilgiye ulaşılabilir [16].

Barkod uygulamalarının RFID uygulamalarına göre sadece veri okuması, kısıtlı alan ve okuma oranı gibi dezavantajları vardır. RFID teknolojisi sayesinde ise daha fazla veri taşınabilir. Bu sayede ürünle ilgili daha detaylı bilgiler etiketlere aktarılabilir. İnsan müdahalesine ihtiyaç duyulmaz. Ayrıca etiket üzerinde hem okuma hem yazma işlemi gerçekleştirilebilir [17].



Şekil 3.2: Barkod örneği [18]

### 3.2.3 RFID Çalışma Sistemi

RFID etiket, mikroçip ve koruyucu filminden meydana gelmiş olup nesnenin bilgilerinin depo edildiği yerdir. RFID anteni ise RFID okuyucu ile RFID etiketi arasında iletişim sağlanır. Daha açık ifade edersek; radyofrekans (RF) alanı içerisindeki etiket depoladığı bilgi sinyalini gönderir ve yine RF alan içerisindeki okuyucu anteni bu sinyali alır ardından arakatman yazılımına yönlendirir.

İç mekanlarda nesnelerin konumunu belirlemek için bu sistem kullanılarak iki farklı durum oluşturulmuştur. İlk durum olarak etiketin sabit tutulup okuyucunun hareket ettirilmesi; diğer durum ise okuyucunun sabit tutulup etiketin hareket ettirilmesidir. İlk senaryo için takibi istenilen nesne üzerine okuyucu yerleştirilirken ikinci senaryo için takip edilecek nesne üzerine etiket yerleştirilir. Bizim çalışmamızda takip etmek istediğimiz nesne üzerine etiket yerleştirilmiştir. Bazı tekniklerde RSSI ile konum tespiti yapıldığı halde biz kanaldaki alıcı/verici sinyalleri taşıyıcı bandında kaydederek konum belirlemede kullandık. Bu değerler ile konumunu belirlemek istediğimiz nesneye göre uzaklık kesinleşecektir. RFID okuyucu ve taşıyıcı arasındaki uzaklığın fazlaca artması sinyali zayıflatacağı için haberleşmenin kopmasına sebep olabilir.

### 3.2.4 Fonksiyonlarına Göre RFID

RFID etiketler fonksiyonlarına göre pasif, aktif ve yarı aktif olmak üzere üç bölümde incelenebilir. Pasif etiketler, okuyucunun meydana getirdiği bir elektromanyetik alan içinde aktifleştirilir ve etikette saklanan bilgiler okuyucuya aktarılır. Etiket antenden gelen radyo dalgaları beslenip üzerindeki veriyi aktarabilir. Aktif etiketler ise, sahip oldukları pil sayesinde aktifleşip antenden bağımsız üzerindeki veriyi aktarır. Yarı-aktif etikette pil sadece entegre devre için kullanılır [19].

### 3.2.5 RFID Kullanım Alanları

Perakende, sağlık, otomotiv, savunma, havacılık ve lojistik gibi sektörlerde RFID teknolojisinin kullanım alanlarından biridir. Bu kullanım alanları Tablo 2.1’de detaylı bir şekilde belirtilmiştir. RFID teknolojisi için en büyük yatırımlar konum belirleme ve demirbaş izleme için yapılmıştır. Sağlık sektöründe ise RFID teknolojisinin kullanımına örnek olarak Amerika’daki Brigham Women’s Hastanesi verilebilir. Bu hastanede 600 cihaz RFID sistemleri sayesinde takip edilmektedir. Bu teknoloji sağlık sektöründe ilk olarak SARS virüsüne yakalanan hastaların takibi için kullanılmıştır. Alzheimer hastalarının takibi, kalp hastalarının takibi, kan stoklarının izlenmesi gibi alanlarda da RFID uygulamaları geliştirilmiştir [19].

<b>Paketlenmiş yiyecekler için;</b>	Üretim ve son kullanma tarihi takibi	Ürün içeriği	Ürün güvenliği
<b>Demirbaş takibi için;</b>	Sahte evrak takibi	Demirbaş hareket takibi	Demirbaş güvenliği
<b>Personel takibi için;</b>	Giriş/Çıkış takibi	Müşteri bilgisi takibi	
<b>Sağlık kurumları için;</b>	Hasta ve tedavi takibi	Tıbbi malzeme takibi	
<b>Araç takibi için;</b>	Plaka takibi	Trafik suçları takibi	Vergi takibi
<b>Hayvan takibi için;</b>	Hayvan ırk takibi	Karantina uygulama takibi	Aşılama takibi
<b>Otopark sistemi için;</b>	Kapasite takibi	Faturalama kolaylığı	Giriş/Çıkış takibi
<b>Kütüphaneler için;</b>	Arşiv takibi	Sayım kolaylığı	Üye takibi

Tablo 3.1: RFID kullanım alanları [15]

### 3.2.6 RFID Gen-2 Protokolü

Elektronik ürün kodu (EPC) özgün rakamlardan meydana gelmiş bir etikettir. EPCglobal ise, ticaret ağı standartlarını geliştirmeye yönelik lider olan kuruluştur. Gen-2 veya EPCglobal Class 1 Generation 2 , 860-960 MHz frekansları aralığında çalışan bir RFID sistemi için fiziksel ve mantıksal ihtiyaçları tanımlar. Okuyucunun etikete güç veren ve yanıtlamasına izin veren bir sinyal iletir. Gen 2, 860 MHz-960 MHz frekans aralığında çalışmaktadır. Bu frekans aralığının frekans ve güç özelliklerini belirleyen bazı organizasyonlar ve yönetim organları vardır. Dolayısıyla hiçbir ülke tüm bant genişliğini kullanamaz. Gen2 protokolü aynı zamanda radyo sinyal iletimi sırasında taşıyıcıyı birçok frekans kanalı arasında hızla değiştiren Frekans atlamalı spread spektrumu (FHSS) kullanır. FHSS, etiketi birden çok ayrı frekansta okur ardından okumanın başarısını belirlemek için sonuçları karşılaştırır [20].

### 3.3 Haberleşme Çeşitleri

Birden fazla aygıt arasındaki bilgi aktarımına haberleşme denir. Haberleşme tam çift yönlü ya da yarı çift yönlü olabilir. Bilginin alınmasının ve gönderilmesinin eşzamanlı şekilde meydana gelmesi tam çift yönlü haberleşmedir. Herhangi bir çakışma meydana gelmeden haberleşme sağlanır. Bu iletişim türüne kablolu ya da kablosuz telefonlar örnek olarak verilebilir. Bilginin gönderilip alınması çift yönlü olarak ancak eşzamanlı olmadan



gerçekleşir. Haberleşme esnasında ethernet protokolü çakışmayı önler. Bu iletişim türü içinse telsizler örnek olarak verilebilir.

## 3.4 Yapay Sinir Ağları

İnsan beyninin çalışma şekline ilham alınarak meydana gelen yapay sinir ağlarını anlamak için öncelikle sinir hücresinin çalışma şekline bakılmalıdır. Sinir sistemi ve beyin fonksiyonlarının ana öğeleri olan nöronlar, hücre gövdesi, dendrit ve akson olmak üzere üç kısımdan oluşmaktadır. Dendrit'ler hücreye gelen girişleri toplarlar. Dendrit tarafından alınan işaretler hücre gövdesinde birleştirilerek bir çıkış darbesi üretilip üretilmeyeceğine karar verilir. Eğer bir iş yapılacaksa üretilen çıkış darbesi aksonlar tarafından taşınarak diğer nöronlarla olan bağlantılara iletilir. Bir nöronun çıkışı ona bağlı olan bütün nöronlara iletilir. Nöronlar arasındaki bağlantılar hücre gövdesinde veya "sinaps" adı verilen dendritlerdeki geçişlerde gerçekleşir [21].

Yapay sinir ağları nöronlardan meydana gelmiştir. Nöronların iletişimi sayesinde sistem çalışır. Ana birim giriş değeri, işlem ve çıktı değerinden oluşan algılayıcıdır. Formüle edilmiş şekli aşağıda belirtilmiştir.

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

$x$  girdi  $y$  girdiye ait benzerlik oranını verir.  $W$  ağırlık parametresi ve  $b$  bias değeri  $y$  değerini iyileştirmek için kullanılmaktadır.

### 3.4.1 Katmanlar

Yapay sinir ağları giriş katmanı, ara katman ve çıkış katmanı olmak üzere üç katmandan oluşmaktadır. Yapay sinir ağına dış dünyadan girdilerin geldiği katman giriş katmanıdır. Bu katmanda dış dünyadan gelecek giriş sayısı kadar nöron bulunmasına rağmen genelde girdiler herhangi bir işleme uğramadan alt katmanlara iletilmektedir. Giriş katmanından çıkan bilgiler ara katmana gelmektedir. Bazı yapay sinir ağlarında ara katman bulunmadığı gibi bazı yapay sinir ağlarında ise birden fazla ara katman bulunmaktadır. Ara katmanlardaki nöron sayıları giriş ve çıkış sayısından bağımsızdır. Birden fazla ara katman olan ağlarda ara katmanların kendi aralarındaki nöron sayıları da farklı olabilir. Ara katmanların ve bu katmanlardaki nöronların sayısının artması hesaplama karmaşıklığını ve süresini arttırmasına rağmen yapay sinir ağının daha karmaşık problemlerin çözümünde de kullanılabilmesini sağlamaktadır. Ara katmanlardan gelen bilgileri işleyerek ağın girdi katmanından gelen verilere karşılık olan çıktıları üreten katman çıkış katmanıdır. Bu katmanda üretilen çıktılar dış dünyaya gönderilir [22].

### 3.4.2 Aktivasyon Fonksiyonları

Bu fonksiyon hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Aktivasyon fonksiyonu genellikle doğrusal olmayan bir fonksiyon seçilir. Yapay sinir ağlarının bir özelliği olan “doğrusal olmama” aktivasyon fonksiyonlarının doğrusal olmama özelliğinden gelmektedir. Aktivasyon fonksiyonu seçilirken dikkat edilmesi gereken bir diğer nokta ise fonksiyonun türevinin kolay hesaplanabilir olmasıdır [23]. Sigmoid fonksiyonu doğrusal olmadığından dolayı oldukça fazla tercih edilen fonksiyon çeşididir. 0 ve 1 arasında çıktı üretir. Softmax fonksiyonu, sınıflandırma problemlerinde çıkış katmanında en çok tercih edilen aktivasyon fonksiyonudur. Çıkış nöronları üzerinde normalleştirilmiş bir olasılık dağılımı sağlar [24]. Rectified linear unit (*ReLU*), gizli katmanlarda kullanımı tercih edilen fonksiyon çeşididir. Çabuk bir şekilde eğitime cevap vermesi sayesinde büyük ağlarda tercih edilir. Eğitim sırasında herhangi bir sorunla karşılaşmamak için öğrenme hızı iyi ayarlanmalıdır. Aksi takdirde nöronlar etkinleşmeyebilir. ELu, ReLu’den farklı olarak negatif girdilere sahiptir. Ayrıca ELu’yu diğer fonksiyonlardan ayıran bir alfa sabiti vardır. Bu sabit pozitif değerlerden oluşur. Elu da Relu gibi pozitif girdiler için kimlik işlevi şeklindedir. Tanh  $[-1,1]$  aralığında doğrusal olmayan bir fonksiyondur.

AKTİVASYON FONKSİYON	DENKLEM	ARALIK
Doğrusal Fonksiyon	$f(x) = x$	$(-\infty, \infty)$
Basamak Fonksiyonu	$f(x) = \begin{cases} 0 & \text{ için } x < 0 \\ 1 & \text{ için } x \geq 0 \end{cases}$	$\{0, 1\}$
Sigmoid Fonksiyon	$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$	$(0, 1)$
Hiperbolik Tanjant Fonksiyonu	$f(x) = \tanh(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})}$	$(-1, 1)$
ReLU	$f(x) = \begin{cases} 0 & \text{ için } x < 0 \\ x & \text{ için } x \geq 0 \end{cases}$	$[0, \infty)$
Leaky (Sızıntı) ReLU	$f(x) = \begin{cases} 0.01 & \text{ için } x < 0 \\ x & \text{ için } x \geq 0 \end{cases}$	$(-\infty, \infty)$
Swish Fonksiyonu	$f(x) = 2x\sigma(\beta x) = \begin{cases} \beta = 0 & \text{ için } f(x) = x \\ \beta \rightarrow \infty & \text{ için } f(x) = 2\max(0, x) \end{cases}$	$(-\infty, \infty)$

Şekil 3.3: Aktivasyon fonksiyonlarının matematiksel gösterimi [25]


## 3.5 Derin Öğrenme

Derin öğrenme, eğitim verilerinin özelliklerini belirlemek amacıyla yapay sinir ağlarından esinlenerek oluşturulmuş çok katmanlı yapıya sahip algoritmalarıdır. Daha detaylı

bilgi vermek gerekirse; yapay zeka, 1950'lerde oluşmuştur ve makinelerin insan yeteneklerine benzer çalışabiliyor olmasıdır. Makine öğrenimi, 1980'lerde ortaya çıkmış daha doğru tespitlerde bulunabilen ve kendisini eğitebilen sistemlerdir. Derin öğrenme ise, 2010'lu yıllarda aktif olarak üzerinde çalışılmış, büyük veri setleri kullanılarak birden fazla katmanda işlemler yapıp daha güçlü sonuçlara ulaşan sistemlerdir. Derin öğrenme projelerinde kullanmak için geliştirilen kütüphanelerden birkaçı TensorFlow, Theano, CNTK, PyTorch, Keras ve Caffe'dir. Çalışmamız için daha gelişmiş kütüphane olması nedeniyle Keras kütüphanesi tercih edilmiştir.

### 3.5.1 Konvolüsyonel Sinir Ağları

Konvolüsyonel sinir ağları (CNN) 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 [26]. CNN algoritmaları görüntü ve ses işlemede işlevsellik elde etmek için veriyi farklı katmanlardan geçirir. Bu katmanlar aşağıdaki şekilde belirtilmiştir.

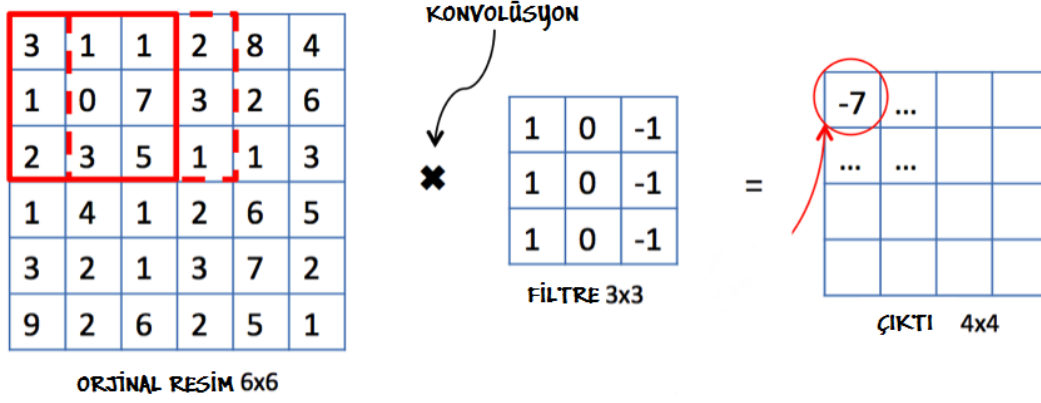


Şekil 3.4: KSA uygulanma aşamaları [27]

#### 3.5.1.1 Konvolüsyon Katmanı

Resmin tanınması görevi konvolüsyon katmanına aittir. Resmin her bir pikseli üzerinden belirli boyutlarda filtre gezdirilir. Resme ait her piksel, filtrenin katsayıları ile çarpılır. Çarpımların toplamı ile yeni bir görüntü matrisi oluşturulur. Böylece resme ait belirgin özellikler ortaya çıkmış olur. Konvolüsyon filtresinin uygulanma şekli aşağıdaki şekilde

belirtilmiştir.

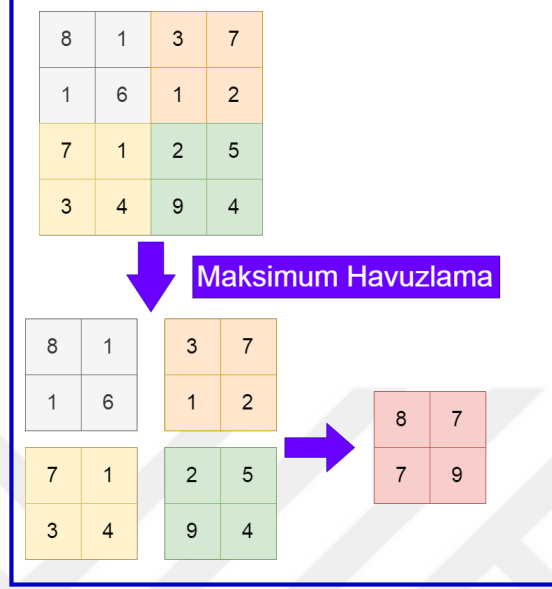


Şekil 3.5: Konvolüsyon filtresi örneği [28]

### 3.5.1.2 Havuzlama Katmanı

Havuzlama katmanında girdi üzerinde belirlenen alan üzerinde filtre gezdirilmesiyle, bu alandaki değerlerin ortalaması ya da maksimumu hesaplanarak girdinin boyutunu düşürme işlemi gerçekleştirilmiş olur. Böylece hesaplama sayısı ve ağdaki parametre

sayısı azaltılır. Aşağıdaki şekilde maksimum havuzlama işlemi gösterilmiştir.



Şekil 3.6: Maksimum havuzlama örneği

### 3.5.1.3 Tam Bağlı Katman

Tam Bağlı katmanın amacı sınıflandırma işlemini gerçekleştirmektir. Bu katman için girdi konvolüsyon ve havuzlama katmanlarından alınır. Çıktı ise sınıf sayısına göre belirlenmektedir.

## 4 Metodoloji ve Sonular

### 4.1 Veri Toplanması

Farklı mesafeler ve farklı konumlardaki etiketlerden saėlanan sinyal lmleri SDR cihazı sayesinde kayıt altına alınmıřtır. Kaydedilen bu sinyallerin belirli kısımları kesilerek eėitim iin kullanılacak yeni veri seti hazırlanmıřtır. Okuyucu ile sinyallerin kayıt edilmesini saėlayan SDR cihazı sabitken etiketin yeri belirlenen her bir alan ierisinde 20 nokta zerinde deėiřtirilerek SdrUno yazılımı kullanılarak ayrı ayrı kaydedilmiřtir. alıřmanın basamakları ařaėıda řema olarak gsterilmiřtir.




řekil 4.1: alıřmamızın genel hatlarıyla blok diyagramı

Yukarıdaki řekilde belirtildiėi gibi; lmler alınmıř ve alınan sinyallere melspectrogram uygulanarak veri seti elde edilmiřtir. Derin ėrenme modeli oluřturulmuř ardından KSA parametre optimizasyonu yapılmıřtır. Son olarak ise bařarı oranı hesaplanmıřtır.

## 4.2 Ölçümlerin Alınması

Ölçüm aşaması için RFID okuyucu, RFID okuyucu cihaz, SDR cihazı, SDRuno yazılımı, etiket, SessionOne yazılımı ve anten kullanılmıştır. Farklı konumlara etiket yerleştirilmiş ve okuyucu ile iletişimi sağlanmıştır. SDR cihazı ile dB değerleri ölçülmüştür. SDRuno yazılımı ile 4-5 saniye aralığında kayıtlar yapılmıştır. Böylece veri setimiz oluşturulmuştur. Ölçüm yapılan alanın dört ayrı kareye bölünmesiyle sınıflar oluşturulmuştur. Oluşturulan bu sınıflar ile veri setimiz derin öğrenme yaklaşımı sayesinde eşleştirilerek yapay sinir ağı eğitimi gerçekleştirilmiştir. Kullanılan araç gereçler ile daha detaylı bilgi aşağıda verilmiştir.

Radyo Frekanslı Tanıma (RFID) teknolojisi, cisimlerin belirli bir mesafeden tanınmasında ve izlenmesi için lojistik, perakendecilik, güvenlik, üretim vs gibi bir çok sektörde kullanılır. Çalışma aşamasında güce ihtiyaç duyup duymama durumlarına göre bu etiketler üçe ayrılır. Bunlar aktif, pasif ve yarı aktif etiketlerdir. Güç kaynağına ihtiyaç duymayan pasif RFID etiketler, RFID okuyucudan gelen radyo dalgalarını kullanırlar. Bu çalışmada pasif RFID etiketi kullanılmıştır. Yazılım Tabanlı Radyo (SDR) radyo sinyalini işlemek için dirençler, kondansatörler, geri besleme devreleri kullanmak yerine, yazılım kullanarak radyo fonksiyonlarının önemli bir kısmını yerine getiren bir radyo teknolojisidir ve sinyallerin modülasyon ve demodülasyon işlemleri için yazılım kullanan radyo iletişim sistemi olarak tanımlanmaktadır. Farklı konumlara bırakılan etiketlerden SDR cihazı sayesinde okunan değerler SDR yazılımı ile kaydedilmiştir. Bu sistem aşağıdaki resimde belirtilmiştir.



Şekil 4.2: İletişim sistemi

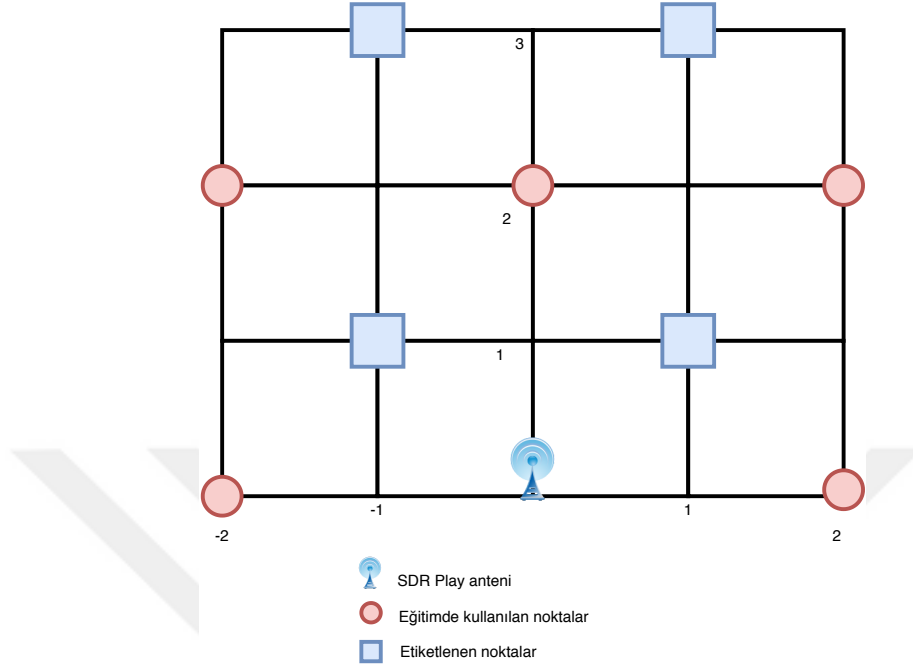


Şekil 4.3: Kullandığımız test düzeneği

SDR; GSM sinyallerini yakalama, uçak pozisyonlarını takip etme gibi bir çok alanda kullanılan bir teknolojidir. Bu çalışmada SDR teknolojisi sinyal kaynaklarının koordinatlarını iki ekseninde tespit etmek amacıyla kullanılmıştır. SDRuno, SDRPlay cihazını kullanabilmek için geliştirilmiş bir yazılımdır. SDRuno yazılımı kullanılarak SDR cihazının ayarları yapılmış ve böylece veriler kaydedilmiştir. Kullandığımız RFID okuyucu, sınıfının en iyisi sayılan Motorola FX7400 modelidir. İç mekan ölçümleri için en iyi performansa sahip olmasından dolayı bu model tercih edilmiştir. Kısacası bu çalışmada kullanılan ürünler: RFID okuyucu Motorola FX7400, anten RFID-500-SC(ANDREW), SDRplay RSP2PRO, SDRuno ve SessionOne yazılımlarıdır. Haberleşmenin sağlanması için SessionOne yazılımında okuyucunun IP'si ile bilgisayarın IP'si ethernet kablosu üzerinden köprülenmiştir. SDRuno yazılımı yaklaşık 866 MHz'de IF output modunda kullanılmıştır. Ölçümler 60 cm kenar uzunluğuna sahip karelerin her köşesine aynı etiket bırakılarak alınmıştır. Etiketten alınan her kayıt 70-100 MB boyutunda olup, her birinin belirli bir parçası MATLAB'da matris olarak okutulduktan sonra gereksiz kısımlar




kesilerek atılmıştır.



Şekil 4.4: Deney düzeneğinin krokisi ve ölçüm noktaları

Yarı çift yönlü iletişim sistemi ile ölçümler alınmıştır. Bu sistem ile eşzamanlı olarak iletişim sağlanamaz. Bir taraf veriyi gönderirken diğer taraf veriyi bekler. Bu iletişim sistemi aşağıda belirtilmiştir;



Şekil 4.5: Yarı çift yönlü iletişim


### 4.3 Veri Seti Oluşturulması ve Melspektrogram

Tüm ölçümlerin wav dosyası şeklinde kaydedilmesinden sonra MATLAB kullanılarak dosyalar okutuldu. Her noktadan alınan kaydın  $100.000 \times 2$ 'lik kısmı kesildi ve kaydedildi. Kaydedilen veri .mat formatı ile google drive platformuna aktarıldı.

Colab; bir çok kütüphane kullanarak derin öğrenme uygulamaları geliştirilmesine yardımcı olan ücretsiz bir şekilde GPU-TPU üzerinde çalışmayı sağlayan bir bulut servistir. Sunduğu imkanlardan dolayı bu çalışma Colab üzerinde geliştirilmiştir.


[Verideki](#)<sup>1</sup> 20 noktadan 5'ine ait (Şekil 4.4'de kırmızı noktalar) matrislerin her birinin ilk sütununa  $2000 \times 1$  boyutunda pencere 1'er kaydırmalı olarak 1000'er kez uygulandı. Her sınıf için 1000'er tane olmak üzere, toplamda 5.000 vektör elde edildi. Alınan bu verilere aşağıda bahsettiğimiz melspektrogram, normalizasyon ve log işlemleri uygulanarak modelimizi eğiteceğimiz veriler (input train ve output train) hazırlandı. Hazırlanan verilerden birkaç tanesinin melspektrogram uygulanmadan önceki ve uygulandıktan sonraki gösterimleri Şekil 4.6, 4.7 ve 4.8'de verilmiştir.

Spektrogram zamanla değişen bir sinyalin frekans spektrumunun görsel bir ifadesidir. Spektrogramlar müzik, sonar, radar gibi alanlarda sıklıkla kullanılmaktadır. Sesin spektrumları sesli kelimeleri fonetik olarak tanımlamak için kullanılabilir. Bir spektrumu yaklaşık olarak mel frekans aralığı genişliklerine bindirmek, spektral bilgileri insanların algılayabilecekleri forma dönüştürmeye izin verir. Yapılan bu işleme melspektrogram denir. Bu işlem Python'da Librosa kütüphanesi kullanılarak gerçekleştirilir.

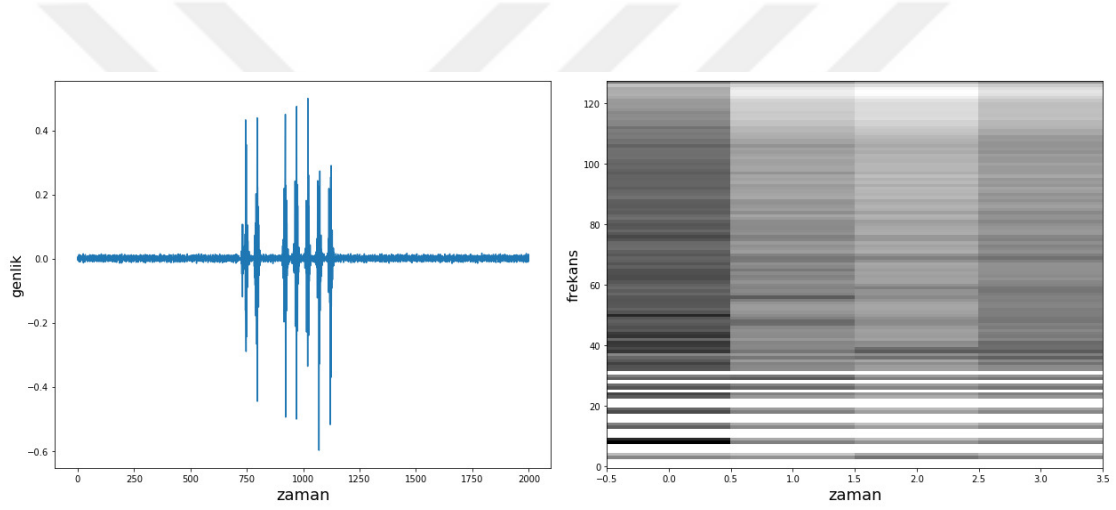


Şekil 4.6: Şekil 4.3'te tanımlanmış olan (0,0) noktasından alınan sinyalin ( $2000 \times 1$ )'lik parçası ve aynı sinyalin melspektrogramı

<sup>1</sup>Tezin dijital versiyonunda verilerin web adresini veren bir hiperlink bulunmaktadır.



Şekil 4.7: Şekil 4.3'te tanımlanmış olan (2,4) noktasından alınan sinyalin  $(2000 \times 1)$ 'lik parçası ve aynı sinyalin melspectrogramı



Şekil 4.8: Şekil 4.3'te tanımlanmış olan (-2,4) noktasından alınan sinyalin  $(2000 \times 1)$ 'lik parçası ve aynı sinyalin melspectrogramı

## 4.4 Derin Öğrenme Modelinin Oluşturulması

İlk olarak konvolüsyon katmanları ile özellikler tespit edilerek daha küçük vektörlere sıkıştırılmıştır. Konvolüsyon katmanının ardından havuzlama katmanı eklenerek giriş matrisinin kanal sayısı sabit tutularak yükseklik ve genişlik bilgisi azaltılmıştır. Bu katman karmaşıklığı azaltarak, hesaplama kolaylığı sağlamıştır. Bu çalışmada maksimum havuzlama kullanılmıştır. Böylece verinin belirli bir kısmındaki en büyük değer seçilerek yükseklik ve genişlik bilgisinde azaltma işlemi yapılmıştır.

Derin öğrenmenin en temel katmanı olan tam bağlantılı katmanlarla önceki katmandaki tüm düğümler mevcut katmandaki düğümlere bağlanarak olabilecek en iyi sınıflandırma mimarisi tamamlanmıştır. En sonuncu katman 5 sınıfı tahmin edecek şekilde 5 nöron- dan oluşmuştur. Çeşitli aktivasyon fonksiyonları ile en iyi çalışan sistem optimizasyon ile bulunmuş ve model eğitilerek test aşamasına geçilmiştir. Çalışmamız için en iyi optimizasyonu sağlayacağını düşündüğümüz Adam algoritması kullanılmıştır.

Katman	Çıktı Şekli
Konvolüsyon	(127, 3, 32)
Maksimum havuzlama	(63, 3, 32)
Konvolüsyon	(62, 2, 32)
Maksimum havuzlama	(31, 2, 32)
Düzleştirme	(1984)
Dense (yoğun) katman	(32)
Dense	(32)
Dense	(32)
Dense	(64)
Dense	(5)

Tablo 4.1: Oluşturulan derin öğrenme mimarisi

## 4.5 Derin Öğrenme Modelinin Test Edilmesi

İlk başta denenen modelde 240 cm uzunluğa 240 cm genişliğe sahip alan belirlenmiş, bu alan kenar uzunluğu 60 cm olan küçük karelere bölünmüştür. Oluşan her karenin köşesinden antenin konumu değiştirilmeden 25 farklı kayıt alınmıştır. Alınan kayıtlardan 25 farklı noktaya göre eğitilen model yine bu noktalardan alınan 100'er vektörle test edilmiştir. Tablo 4.2'de görüldüğü gibi 25 farklı sınıflandırma için model sağlıklı tahmin yapamamıştır. Köşegenlerdeki rakamların büyüklüğü tahminin kısmen de olsa başarılı olduğunu göstermektedir. Hataların, eksen simetrisinin olduğu yerlerde fazla olduğu görülmektedir.

Modelin başarısını artırmak için 5 farklı noktayla eğitilen modele geri dönülmüştür. Eğitimde kullanılan 5 noktanın eğitimde kullanılmayan kısımlarından alınan 100'er numunede model başarı oranı Tablo 4.3'de gösterilmiştir. Bu 5 noktanın 4 tanesi antene göre birbirine ikişer ikişer simetrik olduğundan modelin simetrik tahmin yapabileceği düşünülmüştür. Oluşabilecek bu sorun modeldeki tam bağlantılı katmanlardaki nöron sayısının artırılmasıyla ortadan kaldırılmıştır.

		TAHMİN																								
		S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	S11	S12	S13	S14	S15	S16	S17	S18	S19	S20	S21	S22	S23	S24	S25
<b>S1</b>	25	12	8	5	4	1	2	1	7	2	0	0	0	0	11	4	7	0	1	10	0	0	0	0	0	0
<b>S2</b>	1	32	1	14	9	0	0	5	4	1	15	1	1	3	4	8	0	0	0	1	1	0	0	0	0	0
<b>S3</b>	12	8	19	0	0	1	13	21	1	0	0	0	0	1	6	2	1	0	1	0	8	0	3	0	2	2
<b>S4</b>	21	7	0	65	0	3	0	0	2	0	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0
<b>S5</b>	1	1	25	0	68	0	0	0	0	0	5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
<b>S6</b>	9	2	0	0	0	78	0	0	0	0	0	0	0	0	0	0	0	0	11	0	0	0	0	0	0	0
<b>S7</b>	0	0	0	3	0	0	91	0	0	0	2	0	0	0	1	0	3	0	0	0	0	0	0	0	0	0
<b>S8</b>	0	0	0	17	0	0	0	0	45	0	3	0	0	0	2	0	13	0	0	12	0	0	0	0	0	0
<b>S9</b>	0	0	0	0	0	0	0	0	37	12	2	7	2	3	1	1	1	0	1	25	0	7	1	0	0	0
<b>S10</b>	1	1	3	0	1	0	11	0	0	59	0	0	0	0	13	0	0	0	0	0	1	3	0	0	0	7
<b>S11</b>	0	0	0	0	0	0	15	0	0	0	71	0	0	0	4	0	0	0	0	3	7	0	0	0	0	0
<b>S12</b>	17	2	5	0	9	0	6	0	0	1	1	19	0	1	18	2	0	1	7	3	0	1	7	0	0	0
<b>S13</b>	0	0	0	0	0	0	8	5	0	9	0	0	32	0	11	0	0	12	0	0	0	9	0	9	0	5
<b>S14</b>	0	2	0	0	0	19	0	0	0	0	7	1	2	43	0	0	0	0	13	0	8	0	4	0	1	1
<b>S15</b>	5	0	0	0	0	0	0	0	0	0	0	14	0	0	56	0	0	0	0	21	0	4	0	0	0	0
<b>S16</b>	1	0	0	0	0	0	1	0	9	0	0	1	5	4	0	72	4	0	1	1	1	0	1	0	0	0
<b>S17</b>	0	0	0	4	0	0	4	0	0	2	19	1	0	54	10	0	2	1	0	1	1	0	0	1	0	0
<b>S18</b>	0	0	0	3	0	1	3	1	11	0	0	0	18	0	18	0	24	0	15	0	6	8	0	3	3	4
<b>S19</b>	0	0	0	0	0	0	2	0	0	5	6	0	12	0	21	6	1	0	11	6	0	17	0	13	0	0
<b>S20</b>	0	0	0	0	0	0	0	0	0	0	0	5	0	0	0	0	0	24	0	53	0	13	0	5	0	0
<b>S21</b>	0	0	1	0	0	1	0	1	0	1	0	0	12	0	0	37	0	0	2	0	0	45	0	0	0	0
<b>S22</b>	0	0	0	0	0	2	0	0	0	1	0	1	0	3	0	0	12	1	19	0	0	52	0	0	0	9
<b>S23</b>	0	0	0	0	0	0	0	0	0	7	0	1	12	1	1	2	1	8	24	0	0	0	32	0	11	11
<b>S24</b>	0	1	0	1	0	1	1	0	0	4	0	4	0	0	12	0	0	0	0	2	1	9	0	61	3	3
<b>S25</b>	12	0	0	0	0	0	1	0	0	2	0	0	1	0	0	1	18	4	5	7	21	0	1	8	19	

Tablo 4.2: 25 sınıf için karışıklık matrisi (Confusion Matrix)

		TAHMIN				
		1. Sınıf	2. Sınıf	3. Sınıf	4. Sınıf	5. Sınıf
GERÇEK	1. Sınıf	100	0	0	0	0
	2. Sınıf	0	100	0	0	0
	3. Sınıf	0	0	100	0	0
	4. Sınıf	0	0	0	100	0
	5. Sınıf	0	0	0	0	100

Tablo 4.3: 5 sınıf için karışıklık matrisi (*Confusion Matrix*)

Eğitilen model ayrıca alan içerisindeki farklı noktalardan (Şekil 4.4’de mavi kareler ile gösterilen noktalar) hazırlanan veri ile de test edildi. Model (-1,1) ve (1,1) noktalarından alınan verilerin (0,2) noktasındakine, (-1,3) noktasındakinin (-2,1) noktasındakine ve (1,3) noktasındakinin (2,1) noktasındakine benzer olduğunu tahmin etti. Antenin konumuna göre simetrik bir tahminde bulunan model oldukça iyi sonuçlar vermektedir. Python 3.6’da kodlanan sistem ekler kısmında verilmiştir.

## 5 Sonuç

Bu çalışmada RFID teknolojisi ve derin öğrenme yaklaşımı kullanılarak cisimlerin konum tespiti üzerine yoğunlaşmıştır. Yapılan bu çalışma tek boyutta geliştirilen sistemin 2 ya da 3 boyutta çalışıp çalışamayacağını göstermek amacıyla ve olumlu sonuçlar vermiştir. Öncelikle 60 cm kenara sahip karelerden oluşan alanda, her bir karenin köşesinden olacak şekilde ölçümler alınmıştır. Alınan bu ölçümler belli bir formatta dijital ortama aktararak küçük vektörlere bölünmüş ve eğitim için gerekli olan veri hazırlanmıştır. Bu verilerin belirlenen 5 noktadan alınmış olan kısmı gözetimli derin öğrenme yaklaşımı ile eğitilmiştir. Eğitimde kullanılan 5 noktanın her birinden belli bir miktarda vektör ayrılmış ve diğer kısımlar ile eğitilen sistem test edilmiştir. Eğitilen model küçük iterasyonlarda simetrik cevaplar verse de daha büyük iterasyonlarla simetri durumu ortadan kaldırılmıştır. Model bu şekilde hemen hemen yüzde yüz başarı ile çalışmaktadır. Eğitimde kullanılan kayıtların alındığı noktalara yakın yerlerden toplanan kayıtlarla aynı model bir başka amaçla test edilmiştir. Hiç bilmediği noktaları kendi hafızasındaki en benzer noktalarla simetrik olarak eşleştiren model yine güzel sonuçlar vermektedir. Geliştirebilecek yeni alternatiflerle RFID alanının özellikle konum belirleme alanında, derin öğrenme yaklaşımıyla çok daha kullanışlı hale gelebileceği görülmektedir. Yapılan bu çalışma bu alanda yapılabilecek çalışmalara referans olabilecek potansiyele sahiptir.

## 6 Ekler

```
1 from scipy.io import loadmat
2 import numpy as np
3 from scipy import signal
4 import librosa
5 from numpy import inf
6 from google.colab import drive #Colab'a drive hesabini aktarma
7 drive.mount("/content/drive")
8 x = loadmat('drive/My Drive/firstdata/veri.mat') #drive'dan gerekli veriyi yukleme
9 data=x['newaudiocut'] #verininin icinden gerekli kismi kesme
10 for i in range(25):
11     data[1,i]=data[1,i].reshape(5000000) #25 noktadan alınan verileri aynı vektöre donusturme
```

Kod 6.1: Verilerin çekilmesi

```
1
2 inp_train = []
3 out_train = []
4
5 #!pip install librosa
6
7 for t in range(25): #25 noktayı tarama
8
9     if t==20: #egitimde sadece 5 noktayı için 5 farklı nokta sorgusu
10         for c in range(1000): #her noktadan 1000 vektor alma
11             m=data[1,t][c:c+2000] #mini pencereyi bir bir kaydırarak vektorleri alma
12             mel_spectrogram = librosa.feature.melspectrogram(m, sr=2000000, n_fft=2048, hop_length
13                 ↪ =512) #her vektöre melspectrogram uygulama
14             dBS = 10 * np.log10(mel_spectrogram) #log uygulama
15             a,b=dBS.shape
16             for w1 in range(0,a): #gereksiz kısımları atma
17                 for w2 in range(0,b):
18                     if dBS[w1,w2]==-inf or dBS[w1,w2]==inf:
19                         dBS[w1,w2]=0
20             dBS=(abs(dBS))
```



```

20     dBS /= dBS.max() # normalize etme
21     inp_train.append(dBS) #modeli egitim verisine ekleme
22     out_train.append(0)
23 if t==5:
24     for c in range(1000):
25         m=data[1,t][c:c+2000]
26         mel_spectrogram = librosa.feature.melspectrogram(m, sr=2000000, n_fft=2048, hop_length
↪ =512)
27         dBS = 10 * np.log10(mel_spectrogram)
28         a,b=dBS.shape
29         for w1 in range(0,a):
30             for w2 in range(0,b):
31                 if dBS[w1,w2]==-inf or dBS[w1,w2]==inf:
32                     dBS[w1,w2]=0
33         dBS=(abs(dBS))
34         dBS /= dBS.max()
35         inp_train.append(dBS)
36         out_train.append(1)
37 if t==7:
38     for c in range(1000):
39         m=data[1,t][c:c+2000]
40         mel_spectrogram = librosa.feature.melspectrogram(m, sr=2000000, n_fft=2048, hop_length
↪ =512)
41         dBS = 10 * np.log10(mel_spectrogram)
42         a,b=dBS.shape
43         for w1 in range(0,a):
44             for w2 in range(0,b):
45                 if dBS[w1,w2]==-inf or dBS[w1,w2]==inf:
46                     dBS[w1,w2]=0
47         dBS=(abs(dBS))
48         dBS /= dBS.max()
49         inp_train.append(dBS)
50         out_train.append(2)
51
52 if t==12:
53     for c in range(1000):
54         m=data[1,t][c:c+2000]
55         mel_spectrogram = librosa.feature.melspectrogram(m, sr=2000000, n_fft=2048, hop_length
↪ =512)
56         dBS = 10 * np.log10(mel_spectrogram)
57         a,b=dBS.shape
58         for w1 in range(0,a):
59             for w2 in range(0,b):
60                 if dBS[w1,w2]==-inf or dBS[w1,w2]==inf:
61                     dBS[w1,w2]=0
62         dBS=(abs(dBS))
63         dBS /= dBS.max()
64         inp_train.append(dBS)
65         out_train.append(3)

```

```

66
67
68 if t==22:
69     for c in range(1000):
70         m=data[1,t][c:c+2000]
71         mel_spectrogram = librosa.feature.melspectrogram(m, sr=2000000, n_fft=2048, hop_length
↪ =512)
72         dBS = 10 * np.log10(mel_spectrogram)
73         a,b=dBS.shape
74         for w1 in range(0,a):
75             for w2 in range(0,b):
76                 if dBS[w1,w2]==-inf or dBS[w1,w2]==inf:
77                     dBS[w1,w2]=0
78                 dBS=(abs(dBS))
79                 dBS /= dBS.max()
80                 inp_train.append(dBS)
81                 out_train.append(4)
82
83
84 inp_train=np.asarray(inp_train)
85 out_train=np.asarray(out_train)
86 print(inp_train.shape)

```

Kod 6.2: Eğitim verisinin hazırlanması

```

1 from keras.models import Sequential
2 from keras.layers import Conv2D, MaxPooling2D, Dense, Flatten, Dropout
3
4 from keras.utils.np_utils import to_categorical
5 inp_train=inp_train.reshape(-1,128,4,1)
6 out_train=to_categorical(out_train)
7
8 model=Sequential()
9 model.add(Conv2D(32,(2,2),input_shape=(128,4,1), activation='selu'))
10 model.add(MaxPooling2D(pool_size=(2,1)))
11 model.add(Conv2D(32,(2,2),activation='selu'))
12 model.add(MaxPooling2D(pool_size=(2,1)))
13 model.add(Flatten())
14 model.add(Dense(32, activation='relu'))
15 model.add(Dense(32, activation='relu'))
16 model.add(Dense(32, activation='sigmoid'))
17 model.add(Dense(64, activation='sigmoid'))
18 model.add(Dense(5, activation='softmax'))
19 #Modeli compile edelim.
20 model.compile(optimizer='adam',
21               loss='categorical_crossentropy'
22               )

```

```

23 model.summary()
24 model.fit(inp_train, out_train,
25         batch_size=2000,
26         epochs=120,
27         verbose=1
28         )

```

Kod 6.3: Modelin kurulması ve eğitilmesi

```

1 inp_test = []
2 out_test = []
3
4
5
6 for t in range(25):
7
8     if t==20:
9         for c in range(100):
10            m=data[1,t][c+3000:c+5000]
11            mel_spectrogram = librosa.feature.melspectrogram(m, sr=2000000, n_fft=2048, hop_length
12            ↪ =512)
13            dBS = 10 * np.log10(mel_spectrogram)
14            a,b=dBS.shape
15            for w1 in range(0,a):
16                for w2 in range(0,b):
17                    if dBS[w1,w2]==-inf or dBS[w1,w2]==inf:
18                        dBS[w1,w2]=0
19            dBS=(abs(dBS))
20            dBS /= dBS.max()
21            inp_test.append(dBS)
22            out_test.append(0)
23
24     if t==5:
25         for c in range(100):
26            m=data[1,t][c+3000:c+5000]
27            mel_spectrogram = librosa.feature.melspectrogram(m, sr=2000000, n_fft=2048, hop_length
28            ↪ =512)
29            dBS = 10 * np.log10(mel_spectrogram)
30            a,b=dBS.shape
31            for w1 in range(0,a):
32                for w2 in range(0,b):
33                    if dBS[w1,w2]==-inf or dBS[w1,w2]==inf:
34                        dBS[w1,w2]=0
35            dBS=(abs(dBS))
36            dBS /= dBS.max()
37            inp_test.append(dBS)
38            out_test.append(1)
39
40     if t==7:

```

```

37     for c in range(100):
38         m=data[1,t][c+3000:c+5000]
39         mel_spectrogram = librosa.feature.melspectrogram(m, sr=2000000, n_fft=2048, hop_length
↪ =512)
40         dBS = 10 * np.log10(mel_spectrogram)
41         a,b=dBS.shape
42         for w1 in range(0,a):
43             for w2 in range(0,b):
44                 if dBS[w1,w2]==-inf or dBS[w1,w2]==inf:
45                     dBS[w1,w2]=0
46                 dBS=(abs(dBS))
47                 dBS /= dBS.max()
48                 inp_test.append(dBS)
49                 out_test.append(2)
50     if t==12:
51         for c in range(100):
52             m=data[1,t][c+3000:c+5000]
53             mel_spectrogram = librosa.feature.melspectrogram(m, sr=2000000, n_fft=2048, hop_length
↪ =512)
54             dBS = 10 * np.log10(mel_spectrogram)
55             a,b=dBS.shape
56             for w1 in range(0,a):
57                 for w2 in range(0,b):
58                     if dBS[w1,w2]==-inf or dBS[w1,w2]==inf:
59                         dBS[w1,w2]=0
60                     dBS=(abs(dBS))
61                     dBS /= dBS.max()
62                     inp_test.append(dBS)
63                     out_test.append(3)
64
65     if t==22:
66         for c in range(100):
67             m=data[1,t][c+3000:c+5000]
68             mel_spectrogram = librosa.feature.melspectrogram(m, sr=2000000, n_fft=2048, hop_length
↪ =512)
69             dBS = 10 * np.log10(mel_spectrogram)
70             a,b=dBS.shape
71             for w1 in range(0,a):
72                 for w2 in range(0,b):
73                     if dBS[w1,w2]==-inf or dBS[w1,w2]==inf:
74                         dBS[w1,w2]=0
75                     dBS=(abs(dBS))
76                     dBS /= dBS.max()
77                     inp_test.append(dBS)
78                     out_test.append(4)
79
80
81
82 inp_test=np.asarray(inp_test)

```

```
83 out_test=np.asarray(out_test)
84 from sklearn.metrics import confusion_matrix
85 from sklearn.metrics import accuracy_score
86 predicted=[]
87 #i_test=np.asarray(i_test)
88 for t in range(inp_test.shape[0]):
89     pr = model.predict_classes(inp_test[t].reshape((-1,128,4,1)))
90     predicted.append(pr)
91 results = confusion_matrix(out_test, predicted)
92 print ('Confusion Matrix :')
93 print(results)
```

Kod 6.4: Tez verisinin hazırlanması ve modelin test edilmesi



# Kaynaklar

- [1] Wei Gong, Haoxiang Liu, Xin Miao, Kebin Liu, Wenbo He, Lan Zhang, and Yunhao Liu. Fast and adaptive continuous scanning in large-scale rfid systems. *IEEE/ACM Transactions on Networking (TON)*, 24(6):3314–3325, 2016.
- [2] Sanjay Sarma and Brian Subirama. Method and system for performing mobile rfid asset detection and tracking, July 2 2013. US Patent 8,477,013.
- [3] Bruce B Roesner. Vehicle detection system with rfid-based location determination, November 8 2012. US Patent App. 13/100,997.
- [4] 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.
- [5] Yuanqing Zheng and Mo Li. Pet: Probabilistic estimating tree for large-scale rfid estimation. *IEEE Transactions on Mobile Computing*, 11(11):1763–1774, 2011.
- [6] Dirk Hahnel, Wolfram Burgard, Dieter Fox, Ken Fishkin, and Matthai Philipose. Mapping and localization with rfid technology. In *IEEE International Conference on Robotics and Automation, 2004. Proceedings. ICRA'04. 2004*, volume 1, pages 1015–1020. IEEE, 2004.
- [7] 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.
- [8] 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.
- [9] 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.
- [10] 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.
- [11] 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.
- [12] Osama Moselhi Ali Montaser. Rfid indoor location identification for construction projects. *Automation in Construction*, 39:167–179, 2014.
- [13] Konum belirleme teknikleri. <http://sinyal9.com/konum-belirleme-yontemleri/>.
- [14] Rfid nedir? <http://www.rfid-turkiye.com/RFID-Nedir>.
- [15] Dr. Alp ÜSTÜNDAĞ. Rfid ve tedarik zinciri, 29.08.08.
- [16] Barkod nedir? [http://kutlubilisim.com.tr/barkod/barkod\\_nedir.htm](http://kutlubilisim.com.tr/barkod/barkod_nedir.htm).
- [17] Rfid ile barkodun farkı. <http://otomasyondergisi.com.tr/arsiv/yazi/rfid-mi-barkod-mu/>.
- [18] Barkod nedir? <http://www.sembolbarkod.net/barkod-nedir-ne-ise-yarar/>.
- [19] Pınar Ayşem Karamustafaoğlu. Rfid (radyo frekanslı tanıma) teknolojilerinin İşletme performansı Üzerindeki etkileri. Dokuz Eylül Üniversitesi, 2010.
- [20] Gen-2 protokolü. [https://skyrfid.com/Mid-Range\\_RFID.php](https://skyrfid.com/Mid-Range_RFID.php).
- [21] Esen Ersoy and Ömer Karal. Yapay sinir ağları ve insan beyni. *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 1(2):188–205, 2012.
- [22] Yapay sinir ağları. <https://yapayzeka.ai/yapay-sinir-aglarinin-katmanlari-ve-siniflandirilmesi-3/>.
- [23] İbrahim Çayıroğlu. İleri algoritma analizi-5 yapay sinir ağları. *Karabük Üniversitesi Mühendislik Fakültesi*, 2015.
- [24] John S Bridle. Probabilistic interpretation of feedforward classification net-work outputs, with relationships to statistical pattern recognition. *International Journal of Machine Tools and Manufacture*, pages 227–236, 1990.

- [25] Aktivasyon fonksiyonlarının gösterimi. <https://medium.com/@ayyucekizrak/derin-%C3%B6%C4%9Frenme-i%C3%A7in-aktivasyon-fonksiyonlar%C4%B1n%C4%B1n-kar%C5%9F%C4%B1la%C5%9Ft%C4%B1r%C4%B1lmas%C4%B1-cee17fd1d9cd>.
- [26] Seda Kul. Konvolüsyonel sinir ağı kullanarak gerçek zamanlı araç tipi sınıflandırması. *Kocaeli Üniversitesi-Bilgisayar mühendisliği*.
- [27] Convolutional neural network. <https://www.ayasdi.com/blog/artificial-intelligence/using-topological-data-analysis-understand-behavior-convolutional-neural-networks/>.
- [28] Convolutional neural networks. <https://medium.com/machine-learning-bites/deeplearning-series-convolutional-neural-networks-a9c2f2ee1524>.



# ÖZGEÇMİŞ

## Kişisel Bilgiler

Soyadı, adı : İŞLEYİCİ, Arife Merve  
Uyruğu : TC  
Doğum Yeri ve Tarihi : 19/03/1991  
Medeni Hali : Bekar  
e-mail : merveisleyici91@gmail.com

## Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Lisans	: KTO Karatay Üniversitesi	Haziran-2015
Yüksek Lisans	: KTO Karatay Üniversitesi	Ağustos-2019 (Beklenen)

## İş Deneyimi

Yıl	Yer	Görev
2017	AKINSOFT	AR-GE Temsilcisi

## Yabancı Dil

İngilizce (İyi), Çince (Başlangıç)

## Yayımlar

-