

## Derin Öğrenme Kullanılarak Oda Seviyesinde Wi-Fi Parmak izi Tabanlı İç Ortam Konumlandırma

Işıl KARABEY AKSAKALLI<sup>1\*</sup>, Levent BAYINDIR<sup>2</sup>

<sup>1</sup> Bilgisayar Mühendisliği Bölümü, Erzurum Teknik Üniversitesi, Erzurum, Türkiye

<sup>2</sup> Bilgisayar Mühendisliği Bölümü, Atatürk Üniversitesi, Erzurum, Türkiye

Geliş / Received: 15/10/2019, Kabul / Accepted: 01/06/2020

### Öz

Kablosuz iletişim teknolojisi ve akıllı cep telefonlarının gelişimi ile Wi-Fi ve cep telefonlarına dayalı konumlandırma hizmetlerine talep gün geçtikçe artmaktadır. Dış ortamlarda insanların veya nesnelerin konumlandırılması için GPS gibi küresel konumlandırma sistemleri kullanılırken iç ortamlarda duvar, kapı gibi engellerden dolayı uydu bağlantısı yeterli olmadığı için iç ortam konumlandırma yöntemleri tercih edilmektedir. İç ortam konumlandırma için önerilen birçok yöntem içerisinde parmak izi yöntemi günlük hayatta mevcut olan sinyal kaynaklarını kullanabildiğinden ve bu sinyalleri ekstra bir donanıma gerek duymadan cep telefonları ile elde edilebildiğinden diğer yöntemlere göre daha avantajlı bir hale gelmektedir. Bu çalışmada odaları birbirinden ayırt etmek amacı ile ev ortamında 6 farklı odadan alınan Wi-Fi sinyalleri ile oluşturulan veri kümesi, klasik bazı makine öğrenmesi yöntemleri ve derin öğrenme yaklaşımı uygulanarak oda seviyesinde sınıflandırılmıştır. Derin öğrenme uygulanması sonucunda makine öğrenmesi yöntemlerinden en yüksek sınıflandırma doğruluğuna sahip olan Rastgele Orman' a göre %8 daha yüksek doğruluk oranı elde edilmiştir. Kendi veri kümemizin yanı sıra farklı sayıda veri ve özneliklere sahip veri kümelerinde (WASP ve WILDS) de makine öğrenmesi yöntemleri ile derin öğrenmenin bir yöntemi olan Evrişimsel Sinir Ağı (ESA) karşılaştırılmış ve ESA'nın %98 doğruluğa ulaştığı görülmüştür. Çalışma sonucunda ESA ile uygulanan derin öğrenmenin veri sayısı fazla ve etiket sayısı az olan veri kümelerinde daha iyi performans gösterdiği gözlemlenmiştir.

**Anahtar Kelimeler:** derin öğrenme, iç ortam konumlandırma, Wi-Fi kullanarak parmak izi yöntemi, nesnelerin interneti, evrişimsel sinir ağları (ESA)

### Room-Level Wi-Fi Fingerprinting Based Indoor Localization Using Deep Learning

#### Abstract

With the development of wireless communication technology and smartphones, demand for Wi-Fi and mobile phone-based positioning services is increasing day by day. While the global positioning systems such as GPS are used to detect the position of people or objects in outdoor environments, indoor localization methods are preferred because satellite connections are not sufficient due to obstacles such as walls and doors. The fingerprint method is more advantageous than the other methods since it can use the signal sources available in daily life from many recommended methods for indoor localization and these signals can be obtained with mobile phones without the need for extra equipment. In this study, the data set using Wi-Fi signals obtained from 6 different rooms in the home environment to differentiate the rooms is classified in the room level by using some classical machine learning methods and deep learning approach. As a result of the deep learning, 8% higher accuracy than the Random Forest which has the highest classification accuracy has been obtained from the machine learning methods. In addition to our own data set, data sets with different numbers of data and attributes (WASP and WILDS) are compared with the methods of machine learning, and the Convolutional Neural Network (ESA) which is a method of deep learning, and it is observed that the ESA reached the highest accuracy rate with %98. As a result of the study, it is observed that deep learning with ESA performed better in data sets with a high number of data and a low number of labels.

**Keywords:** deep learning, indoor localization, fingerprinting technique using Wi-Fi, internet of things, convolutional neural network (CNN)

## 1. Giriş

Konum bilgisi, yaygın bilişim (ubiquitous computing) ve nesnelerin interneti alanlarında üst seviye çıkarımlar yapmak için kullanılan önemli bir durum (context) bilgisidir. Dış ortamlarda konum elde etmek için kullanılan GPS teknolojisi, iç ortamlarda uydu bağlantısı sağlanamadığından dolayı konum kestirim hatalarına sebep olmaktadır. Bu yüzden iç ortamlar için etkili ve düşük maliyetli çözümler üretilmeye devam edilmektedir. İç ortamlarda konumlandırma; hava alanı, alışveriş merkezi, tren istasyonu, hastane, müze, üniversite gibi kapalı ortamlarda kullanıcıların konumlarının bilinmesi, bir mağazada aranan bir ürünün bulunabilmesi, mağazalardaki promosyon ve indirimlerden yararlanılabilmesi, bir AVM' de kullanıcının arabasını park ettiği yeri bulabilmesi (Lan, 2014), ev ortamında yeri unutulmuş bir eşyanın bulunabilmesi (Huynh et al., 2015), görme engelli bir bireyin kapalı bir alanda otomatik yönlendirilmesi (Serrao et al., 2015) gibi günümüzde bir çok alanda kullanılabilen önemli bir ihtiyaç haline gelmiştir. 2017 yılında yayınlanan PRNewswire dergisinde yer alan makalede (ReportLinker, 2018) iç ortam konumlandırma marketinin 2023 yılına kadar 58 milyar dolara yükseleceği tahmin edilmektedir. Ayrıca MarketsandMarkets (MarketandMarkets Research, 2018) şirketinin yayınladığı rapora göre, 2016 yılında 5.22 milyar dolar piyasası olan küresel iç ortam konumlandırma pazarı, 2017 yılında 7.11 milyar dolar olmuştur ve bu rakamın 2022'de 40.99 milyar dolara erişeceği öngörülmektedir.

İç ortam konumlandırma sistemleri (1) ek donanım gerektiren algılayıcı sistemler ve (2) ortamda var olan algılayıcı sistemler olmak üzere ikiye ayrılmaktadır. Ek donanım gerektiren algılayıcı sistemler, konum bilgisi için kask, ayağa bel bölgesine monte edilen ve bileklik vb. cihazlar aracılığıyla sinyal toplayabilmektedir. Bu sistemlerin geliştirilmesi ve ortama veya insan vücuduna yerleştirilmesi, konum kestirim hatasını minimuma indirme gibi avantajlara sahip olmakla birlikte sistemin kurulum ve donanım masrafları, kullanıcının yeni sisteme adaptasyonu gibi dezavantajları da beraberinde getirmektedir. Ortamda var olan algılayıcı sistemler ise GSM, Wi-Fi, Bluetooth, FM radyo gibi ortamda mevcut olan sinyal kaynaklarını kullanan algılayıcı sistemlerdir. Bu sistemler kurulum masrafı ve ek donanım ihtiyacı gerektirmediğinden ve kullanıcının her an yanında bulundurabileceği cihazlar (cep telefonu, tablet vb.) aracılığıyla kullanılabilirdiğinden bireysel ve genel amaçlı kullanıma daha uygundurlar.

Kapalı alanlarda konum bilgisi elde etmek için parmak izi (fingerprinting), üçgenleme (triangulation), üç yanlılama (trilateration), yaklaşma (proximity) ve parakete hesabı (dead reckoning) gibi pek çok yöntem literatürde önerilmektedir (Krumm, 2016). Bu yöntemlerden parmak izi yöntemi, ortamda var olan sinyal kaynaklarını (Wi-Fi, Bluetooth, FM, GSM) kullandığından ve bu sinyaller cep telefonu ile algılanıp işlenebildiğinden diğer yöntemlere göre daha fazla tercih edilmektedir. Örnek olarak parmak izi yönteminde, cep telefonu ile ortamda yer alan Wi-Fi erişim noktalarından alınan sinyaller ve bu sinyal değerlerinin

alındığı erişim noktası adı, bir veri kümesine kaydedilmektedir. Bu veri kümesi sınıflandırma yöntemleri ile işlenerek bulunulan oda tespit edilebilmektedir. Odalardan toplanan sinyal ölçümleri, ilgili odanın tespitinde adeta bir parmak izi gibi kullanıldığından bu yönteme parmak izi yöntemi denilmektedir (Wang et al., 2017).

Çalışmanın geri kalan kısmı şu şekilde devam etmektedir: İkinci bölümde parmak izi yöntemi kullanarak yapılan iç ortam konumlandırma çalışmalarına yer verilmektedir. Bir sonraki başlıkta, kullanılan yöntemden bahsedilerek sınıflandırma için kullanılan yöntemler ve deneysel sonuçlar hakkında bilgi verilmektedir. Çalışma son olarak sonuç ve tartışmalar bölümü ile sonlandırılmaktadır.

## 2. İlişkili Çalışmalar

İç ortam konumlandırma için yaygın olarak kullanılan YPH (Yaya Parekete Hesabı), TOA (Varış Zamanı-Time of Arrival), TDOA (Varış Zaman Farkı-Time Difference of Arrival), AOA (Varış açısı-Angle of Arrival) ve RSSI gibi yöntemler birçok problem içermektedir. Bunlardan YPH ardışık konum tahminlerinde dezavantaja sahipken TOA ve TDOA alıcı ve gönderici arasında doğru bir saat senkronizasyonu gerektirmektedir. AOA'da ise belirli cihazların bulunması gerekmekte ve bu da ek donanım ihtiyacını doğurmaktadır.

Cep telefonlarının yaygın kullanımı ile Bluetooth ve Wi-Fi alıcılarının bu cihazlara gömülü olması ve ek donanıma ihtiyaç duyulmaması parmak izi olarak adlandırılan iç ortam konumlandırma yöntemlerini popüler kılmaktadır. Fakat iç ortam konumlandırma işleminin radyo haritası parmak izi oluşumu için zahmetli ve zaman alıcı bir çevrimdışı süreci ve Wi-Fi sinyallerinin mekân içerisinde

zaman zaman sönümlenmesi zorlukları bulunmaktadır.

Yapılan literatür araştırması, parmak izi yöntemi ile elde edilen Wi-Fi sinyallerini kullanan çalışmalar, Wi-Fi ile birlikte ortamdaki diğer sinyallerden yararlanmak için farklı algılayıcıları kullanan çalışmalar ve son olarak derin öğrenmeyi iç ortam konumlandırmada değerlendiren çalışmalar olmak üzere üç kısımda incelenmiştir. Her bir kısımda birçok çalışma olmasına rağmen bu çalışmada sadece performansı yüksek olan çalışmalarla birlikte, uygulanan yöntemlere benzer yöntemleri ele alan çalışmalar, karşılaştırma yapılarak değerlendirilmiştir.

### 2.1. Wi-Fi Kullanarak Parmak İzi Yöntemi

Toh ve Lau (2016) sadece var olan Wi-Fi altyapısı ve cep telefonları kullanarak bir üniversite binasında cep telefonu aracılığı ile toplanan Wi-Fi bilgilerinden konum kümeleri (location clusters) üretmişlerdir. Daha sonra bu kümelere DCCLA (Density-based Clustering Combined Localisation Algorithm) algoritması kullanılarak parmak izleri elde edilmiştir. Karşılaştırma yapmak üzere iki farklı değerlendirme yapılmıştır. İlk değerlendirmede doğruluk aralığı %97.28 ile %99.85 arasında değişmektedir. Akıllı telefon bir sandalyeye yerleştirilip her zaman sabit bırakıldığından doğruluk oranının yüksek olduğu düşünülmüştür. Fakat RSSI değerlerinin veri toplama boyunca tüm konumlar için statik olmadığı, ikinci veri kümesinde görülen 3 dBm'lik varyasyon olduğu zaman anlaşılmıştır. İkinci değerlendirmede de doğruluk oranı %81.82 ile %92.31 arasında değişerek ilk veri kümesine göre özellikle etrafı açık bir lobi ortamında doğruluğun daha düşük olduğu görülmüştür. Bu da özellikle açık alanlarda Wi-Fi kullanılarak daha yüksek

konumlandırma doğruluğu görülmesinin zor olduğunu göstermektedir. Wang et al. (2015), deney ortamındaki odaların içerisinde radyo imzaları kurmak ve kat haritasında farklı konumları tespit etmek için büyük kitle kaynaklı (crowd-sourced) Wi-Fi RSS (Received Signal Strength) verilerini kullanarak adaptif bir konumlandırma sistemi önermektedir. Çalışmada kitle kaynaklı kullanıcı izlerinden, önerilen Otomatik İz Korelasyon Tanıma (Auto-Trace Correlation Recognition) algoritması ile sabit bölümler çıkarılmaktadır. Daha sonra oda içi ve oda dışı izleri ayırt etmek için bir varyans eşikleme yöntemi kullanılmaktadır. Aynı ALS (Atomic Location Segments) boyunca iz bölümlerini kümelemek için ise K-ortalama (K-means) algoritması uygulanarak kümeleme doğruluğunu artırmak için yeni gelen izler kullanılmaktadır. Deneysel sonuçlara bakıldığında kullanıcının odaya girişi ve ayrılışına kadar elde edilen RSS izleri analiz edilerek bir kat haritası üzerinde oda tespiti yapılabileceği, ayrıca odaların RSS parmak izlerinin, kitle kaynaklı kullanıcı verileri kullanılarak uyarlanabilir bir şekilde güncellenebileceği belirtilmiştir.

Parmak izi yöntemini kullanan bir diğer çalışmada Niu et al. (2015) zaman alıcı bir süreç olan parmak izi toplama için yapılan alan araştırması yerine veri kümesi oluşturmak için kullanıcının aktif katılımı olmadan Wi-Fi sinyallerinin yanı sıra kullanıcı hareketlerini de kaydetmektedir. Kitle kaynaklı çalışma (Crowdsourcing) ve Wi-Fi parmak izine dayanan bu yöntem WicLoc olarak adlandırılmış olup bu sistemde veri toplama işleminden sonra ilgili konumların her birinin parmak izlerini oluşturmak için bir model tasarlanmaktadır. Çalışmada oda seviyesinde konumlandırma ve erişim noktalarına farklı ağırlıklar atamak için ağırlıklı en yakın komşu (Weighted

KNN) algoritması önerilmektedir. Kullanıcıların mutlak koordinatlarını kalibre etmek için bağlantı noktalarının bulunduğu odalar ve koridorlarda ilgili konumların koordinatlarını hesaplamak için MDS-C (Multi-Dimensional Scaling with Calibrations) isimli yeni bir MDS algoritması tasarlanmaktadır. Deneysel sonuçlar LiFS ve EZ gibi diğer Wi-Fi tabanlı yöntemlere göre rekabetçi bir konumlandırma doğruluğuna erişildiğini göstermektedir. Bununla birlikte aynı ortamdan elde edilen parmak izleri ile LiFS'te 5.6 m, EZ'de 7 m konumlandırma hatası görülürken bu hata oranının WicLoc ile 4.6 m'ye düşürüldüğü gösterilmektedir.

Bahsedilen çalışmalarda Wi-Fi parmak izi yöntemi tek başına kullanılmakta ve bu yöntemin yanı sıra ekstra donanımlar ve hibrit kullanımlar da alt başlıklarda özetlenmektedir.

## 2.2. Wi-Fi ile Birlikte Farklı Algılayıcılar Kullanan Çalışmalar

Wu et al. (2015) Wi-Fi sinyallerine dayalı RSSI iç ortam konumlandırma işleminde daha uzak mesafelerde konumlandırma doğruluğunu geliştirmek için ekstra bir donanım olan ayarlanabilir emisyon güç yönlendirici ile olasılıksal konumlandırma yöntemini kullanmıştır. Hem çevrimdışı veri toplama safhası, hem de çevrimiçi konumlandırma testi her bir yönlendiricinin gücünü ayarlamak için kullanılmıştır. Benzetim ve gerçek deney sonuçlarına bakıldığında konumlandırmanın kesinliği, sadece üç yönlendirici kullanılmasına rağmen, katı radyasyon gücüne (solid radiation power) göre daha iyi sonuç verdiği görülmüştür. Ayarlanabilir güç ile 100 mW, 80 mW ve 64 mW, 50 mW ve 25 mW katı emisyon gücü karşılaştırılmış olup tüm analizlerde ayarlanabilir emisyon gücü katı

emisyonundan daha doğru sonuç vermiştir. Yazarlar, akıllı ayarlanabilir emisyon gücü yönlendiricisinin piyasada hala yapılmamasına rağmen, önerilen yöntemin karmaşık iç mekânlarda, özellikle geçici görünen engellerde daha etkili olabileceğini düşünülmektedirler.

Ban et al. (2015) Yaya Parekete Hesabı-YPH (Pedestrian Dead Reckoning) ve Wi-Fi sinyalleri ile birlikte manyetik alan kullanarak yüksek doğruluklu bir iç ortam konumlandırma yöntemi önermektedir. Önerilen yöntem, hedef haritadaki manyetik alan ve Wi-Fi radyo dalgalarını önceden ölçerek oluşturulan Wi-Fi ve manyetik alan parmak izlerini kullanmaktadır. Parmak izleri, hesaplama yükünü azaltmak adına Gauss Karışım Modeli (Gaussian Mixture Model) ile ifade edilmiştir. Yöntem, pozisyonları yaya sensörü (pedestrian sensor) ve parmak izi değerlerini parçacık filtreler kullanılarak karşılaştırmakta ve konum tahmini yapmaktadır. Gerçek ortamda önerilen yöntemin testi yapılmış olup ortalama 8 m'den daha az hata oranı ile var olan diğer yöntemlerden daha doğru sonuç elde edildiği belirtilmektedir.

Hibrit yöntem kullanan bir diğer çalışmada Zou et al. (2017), akıllı telefona gömülü atalet ölçü birimi (inertial measurement unit), parçacık filtreye dayalı iBeacon düzeltmeleri ve alınan Wi-Fi sinyal gücü ölçümleri kullanarak konumlandırma ve takip sistemi önermektedir. Kullanıcının yönünü ve yürüme mesafesini tahmin etmek için ivmeölçer, jiroskop ve magnetometreye sahip akıllı telefonda yararlanan YPH yaklaşımı kullanılmaktadır. Wi-Fi parmak izi tabanlı yaklaşım ile tahmin edilen konum, sürüklenme hatasını azaltmak için YPH ile birleştirilmektedir. Ayrıca Wi-Fi yönlendiricilerinin sayısı, büyük ölçekli iç

ortamlarda sınırlı olduğundan dolayı, Wi-Fi kapsama alanının zayıf olduğu yerlerde YPH'nin sürüklenme hatasını düzeltmek için de iBeacon teknolojisi kullanılmaktadır. Ortalama konumlandırma hatası deneysel sonuçlarla belirlenmiş olup sadece YPH ile 2.732 m, sadece Wi-Fi ile 1.968 m, YPH ve Wi-Fi ile 1.480 m ve son olarak YPH, Wi-Fi ve iBeacon'ın birlikte kullanıldığı sistemde 0.594 m ortalama hata tespit edilmektedir.

### 2.3. Derin Öğrenme Kullanan Çalışmalar

İç ortam konumlandırmada veri toplama işlemi yapıldıktan sonra cep telefonundan alınan ve etiketi bilinmeyen bir sinyalin, etiketli veriler ile karşılaştırılıp bir tahmin elde edilmesinde genellikle çeşitli makine öğrenmesi yöntemleri kullanılmaktadır. Son yıllarda görüntü ve video işleme için oldukça yaygın bir şekilde kullanılan derin öğrenme yöntemi, iç ortam konumlandırma için de kullanılmıştır. Derin öğrenmeyi iç ortam konumlandırmaya uyarlayan Wang et al. (2015), bu yaklaşım ile otomatik olarak öğrenilen Wi-Fi sinyallerinden ayırt edici özellikleri; konum, aktivite ve eşzamanlı mimik tanımayı gerçekleştirmek için soft-max regresyonu tabanlı makine öğrenmesi çerçevesinde birleştirmektedir. Dağınık bir iç mekân laboratuvarında ve sekiz adet kablosuz düğümü bulunan bir apartmanda 802.15.4 Zigbee donanım test yatağı ile yapılan deneylerde derin öğrenme, zaman alanı, frekans alanı ve hem zaman hem frekans alanı olmak üzere 4 farklı özellik tipi ile ve farklı derin öğrenme parametreleri üzerinde doğruluk oranı incelenmektedir. Deneyler sonucunda öğrenilen özellikler kullanılarak cihaz bağımsız iç ortam konumlandırma sisteminin %88'e kadar doğruluğa ulaşabildiği görülmektedir. Derin öğrenmenin iç ortam konumlandırmaya uyarlandığı bir başka çalışmada Wang et al. (2017) tarafından

kanal durum bilgisini (Channel State Information) kullanan ve DeepFi adı verilen derin öğrenme tabanlı bir yöntem geliştirilmektedir. DeepFi, bir aygıt sürücüsü üzerinden CSI bilgilerini toplayarak bu verileri dört gizli katmandan oluşan derin ağda analiz etmektedir. Parmak izlerini temsil eden ağırlıklar ve ağırlık eğitimi için karmaşıklığı azaltmak adına açgözlü (greedy) öğrenme yaklaşımı uygulanmaktadır. Çeşitli parametreler kullanılarak performans değerlendirmesi yapılan DeepFi yönteminin standart sapma, ortalama hata ve ortalama çalışma zamanı açısından diğer çalışmalarda referansı verilen FIFS, Horus ve ML (Maximum Likelihood) yöntemlerinden daha iyi sonuç verdiği gözlemlenmektedir. Derin öğrenmenin iç ortam tespitinde kullanıldığı çalışmalarda (Le et al. 2018, Zheng et al. 2017) da Destek Vektör Makineleri, kNN gibi geleneksel regresyon tekniklerine göre bu yöntemin daha iyi sonuç verdiği belirtilmektedir. Bu çalışmalardan Le et al. (2018), geliştirdikleri yaklaşımın testi için UJIIndoorLoc isimli veri kümesini kullanmıştır. Bir diğer çalışmada (Zheng et al. 2017), Wi-Fi ile birlikte manyetik alan bilgisi kullanılmıştır. Wang et al. (2015) ise çalışmalarında test ortamı olarak ZigBee test yatağını kullanmıştır. Yapılan bu çalışmada herhangi bir kullanıcı müdahalesi olmamasına özen gösterilerek (ortamda bulunan Wi-Fi alıcılarının yeri değiştirilmeden) bir ev ortamında akıllı telefona özel geliştirilen bir uygulama ile ortamda var olan Wi-Fi sinyallerini bir csv dosyasına kaydeden bir yöntem geliştirilmiştir. Ayrıca ek bir donanım gerektirmeden sistemin performansı değerlendirilmektedir.

Hsieh et al. (2019), hem Wi-Fi sinyal güçlerini (RSSI) hem de kanal durum bilgisini (Channel State Information-CSI) kullanarak derin öğrenme tabanlı bir iç ortam konumlandırma

yaklaşımı önermektedir. Oda seviyesinde konumlandırma yapan yazarlar bir oda düzlemini iki boyutlu bloklara ayırarak her bir bloğu bir sınıf olarak kabul etmektedir. RSSI ve CSI kullanarak bir odadaki nesnenin konumunu tahmin etmek için çok katmanlı algılayıcı (Multilayer Perceptron-MLP) ve tek boyutlu evrimsel sinir ağı (1D-CNN) ile uygulanan dört derin sinir ağı geliştirmektedirler. Yapılan deneyler sonucunda CSI bilgilerini kullanan 1D-CNN'in düşük ağ karmaşıklığı ile MLP'ye göre çok daha iyi performans gösterdiği gözlemlenmektedir. CSI ölçümlerini özellik olarak kullanan bir başka çalışmada (Schmidt et al., 2019) derin öğrenme ile Wi-Fi yazılım tanımlı radyo alıcısı (SDR-Fi) sunulmaktadır. 802.11n SDR alıcı platform tabanlı LabView uygulaması üzerinden CSI ölçümleri elde edilerek ileri beslemeli bir sinir ağı (Feed-Forward Neural Network-FFNN) ve 1D evrimsel sinir ağının (1D-CNN) performansı kapalı bir laboratuvar alanında değerlendirilmektedir. Önerilen 1D-CNN ve FFNN modellerinin CSI tabanlı DeepFi yöntemine ve RSS tabanlı Horus yöntemine göre karşılaştırmalı sonuçları sunulmaktadır. Elde edilen sonuçlar doğrultusunda önerilen 1D-CNN modelinin FFNN modeline ve 1D-CNN kullanan diğer çalışmalara göre 0.99 m ortalama ve 0.63 m standart sapma doğruluğu ile daha iyi performans gösterdiği gözlemlenmektedir.

### 3. Yöntem

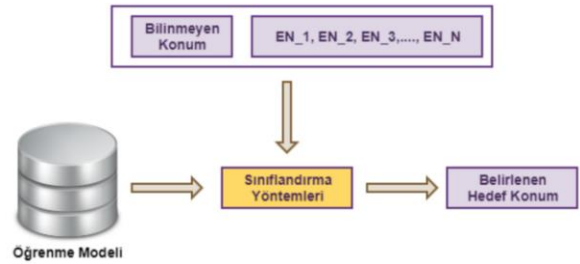
Parmak izi yöntemi çevrimdışı (veri toplama) ve çevrim içi (konumlandırma) olmak üzere iki aşamadan oluşmaktadır. Veri toplama aşaması olarak da bilinen çevrimdışı aşamada ortamda var olan sinyal güçleri bir veri kümesine kaydedilmektedir. Daha sonra test aşaması olan çevrimiçi aşama gerçekleştirilmektedir. Burada konumu bilinmeyen bir ortamdan elde edilen sinyallerin eldeki veri kümesi aracılığıyla hangi ortama ait olduğunu belirlemeye yarayan yöntemler kullanılarak sınıflandırma işlemi yapılmaktadır. Verilerin toplandığı çevrimdışı aşama Şekil 1’de gösterilmiştir.



Şekil 1. Çevrimdışı (Veri Toplama) safhası

Çevrimdışı (Veri Toplama) safhasında hareketli bir birey üzerinde bulunan akıllı cep telefonu ile Wi-Fi sinyallerinin toplanarak bir veri kümesine kaydedilmesi işlemi gerçekleştirilmektedir. EN<sub>1</sub>, EN<sub>2</sub>,... EN<sub>N</sub>

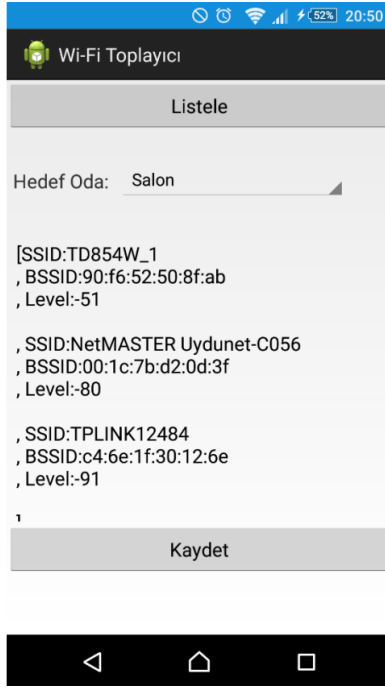
erişim noktalarından elde edilen sinyallerin şiddetidir. Konumlandırma işleminin başlangıcı olan bu safhada, bir mobil cihaz aracılığıyla bulunulan ortamda görülen Wi-Fi sinyalleri, ortamın ismi (örneğin bir evin herhangi bir odası) ile birlikte bir veri kümesine kaydedilir. Bu veri kümesindeki her bir kayıt parmak izi olarak adlandırılmaktadır. Her bir parmak izinde, ortamda görülen Wi-Fi sinyallerinin ayırt edici ismi ve sinyal güçleri bulunur. İkinci aşama olan çevrimiçi aşamasında (Şekil 2) gerçek zamanlı uygulamalarda kullanıcının konumu belirlenmektedir. Konumu bilinmeyen bir sinyalin hangi odaya ait olduğunu belirlemek amacıyla, kullanıcının hareketi esnasında alınan sinyaller, birinci safhada oluşturulan veri kümesindeki konumu bilinen sinyaller ile karşılaştırılır ve bir sınıflandırma yöntemi kullanılarak sinyalin ait olduğu konum tahmin edilir. Daha sonra sinyalin gerçekte ait olduğu konum ve tahmin edilen konumun birbirleriyle aynı olması durumuna göre sınıflandırma doğruluğu belirlenir.



Şekil 2. Çevrimiçi konumlandırma safhası

### 3.1. Veri Toplama

Daha önce yaptığımız bir ön çalışmada (Karabey, 2015) kullanıcının bulunduğu odayı seçip o ortamdaki Wi-Fi sinyallerini elde edebileceği bir uygulama tasarlanmıştır. Uygulamanın ekran görüntüsü Şekil 3'te verilmiştir.



**Şekil 3.** Wi-Fi sinyal verilerini toplamak için geliştirilen Android uygulaması

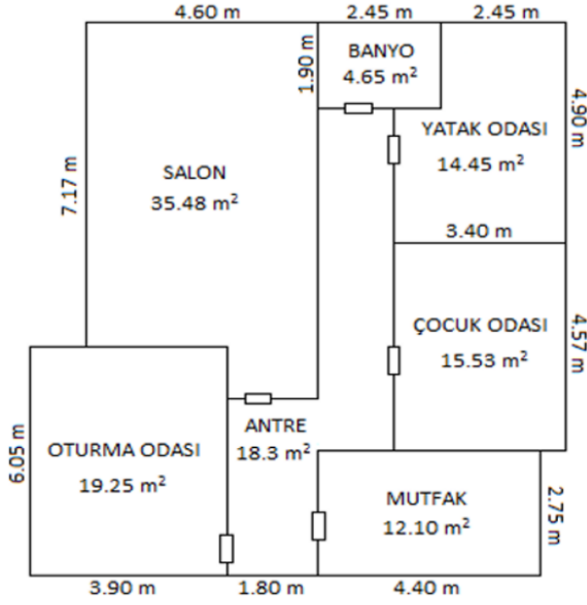
Ev ortamında oda tespiti yapıldığından oda seçimi yapıldıktan sonra kendisine en yakın erişim noktalarından alınan Wi-Fi sinyal seviyelerini, erişim noktası adı (SSID) ve erişim noktasının donanım adresi (BSSID) ile birlikte bu uygulama aracılığıyla listelenmektedir. Yapılan ön çalışmada çevrimdışı aşaması için seçilen odaya ait Wi-Fi sinyal seviyeleri toplanarak bir CSV dosyasına otomatik olarak kaydedilmektedir. Uygulamada kullanıcının bulunduğu odayı seçerek listele butonuna tıklaması ile o ortamda görülen Wi-Fi sinyallerinin ayırt edici ismi ve sinyal güçleri listelenmektedir. Kaydet butonu ile de verilerin CSV dosyasına kayıt işlemi yapılmaktadır. Veri toplama aşamasında elde edilen veri kümemizin örnek bir görüntüsü Tablo 1’ de verilmiştir.

**Tablo 1.** 600 veri ve 21 erişim noktasından oluşan veri kümesinin bir bölümü (EN: Erişim Noktası)

EN1	EN2	EN3	EN4	EN5	EN6	...	EN21	Etiket
0	0	86	0	0	0	...	45	Salon
0	80	0	76	0	0	...	0	Salon
69	52	0	87	0	0	...	0	Çocuk odası
89	70	0	74	94	0	...	0	Salon
73	68	0	0	0	87	...	87	Mutfak
63	58	0	82	0	0	...	0	Çocuk odası
0	76	0	81	0	0	...	0	Oturma odası
81	76	0	90	0	0	...	0	Oturma odası
76	68	0	0	88	0	...	0	Yatak odası
91	70	0	84	89	0	...	0	Banyo

Veri kümesi, 6 odadan oluşan yaklaşık 140 m<sup>2</sup>’lik bir evden (Şekil 4) elde edilen veriler ile oluşturulmuştur. Bu eve ait bir adet erişim noktası olsa da bir kullanıcının odalarda dolaşması sonucu gerçekleştirilen deneylerde, çevrede bulunan toplam 21 adet erişim noktasından sinyal alınmıştır. Bulunulan ortamda bir erişim noktasından alınan sinyal gücü yok ise 0, var ise sinyal gücünün değeri kaydedilmektedir. Verilerin kaydedildiği CSV dosyası her odadan 100 tane parmak izi olmak üzere 600 adet parmak izinden oluşmaktadır.





**Şekil 4.** Oluşturduğumuz veri kümesinin toplandığı evin krokisi

#### 4. Sınıflandırma

Çalışma kapsamında daha önceden kullanılan kNN, Redpin, WASP, Geri Yayılım ve Rastgele Orman isimli makine öğrenmesi yöntemleri ile birlikte son yılların oldukça popüler sınıflandırıcısı olan derin öğrenme yöntemi uygulanmıştır. Bu yöntemlerin sınıflandırma aşaması için 10-katlamalı çapraz doğrulama (k-fold cross validation) kullanılmış ve yöntemlerin kullanıldıkları parametrelerin varsayılan değerleri Tablo 2' de gösterilmiştir. 10-katlamalı çapraz doğrulama yönteminde veri kümesi 10 parçaya bölünmekte ve her bir parça baştan başlanarak test veri kümesi, geri kalan 9 parça da eğitim veri kümesi olarak kullanılmaktadır. Böylece her parça test verisi olarak kullanılıp ayrı ayrı doğruluk değeri bulunmaktadır. Bulunan 10 adet doğruluk değerinin ortalaması (bulunan doğruluk değerleri toplanıp 10'a bölünerek elde edilir) alınarak genel ortalama doğruluk değeri bulunmaktadır.

Bu yöntemler içerisinde kNN, Naive Bayes (NB), Destek Vektör Makinesi (DVM), Geri Yayılım (GY) ve Rastgele Orman (RO) yöntemi klasik makine öğrenmesi algoritmaları olup Redpin (Bolliger, 2008) ve WASP (Lin, 2009) yöntemleri, iç ortam konumlandırmaya özel olarak önerilen sınıflandırma yöntemleridir. İç ortam konumlandırmaya özel bu yöntemler ve bu çalışmada uygulanan Evrişimsel Sinir Ağı (ESA) yöntemi aşağıda alt başlıklar halinde açıklanmaktadır.

#### 4.1. Redpin

Redpin adlı sistem Bolliger tarafından 2008 yılında mobil cihazlar için geliştirilmiş parmak izi tabanlı bir iç ortam konumlandırma yöntemidir (Bolliger, 2008). Redpin ile cihaz üzerinde Wi-Fi erişim noktaları, Bluetooth ve GSM sinyal gücü tespit edilebilmekte ve zaman alıcı öğrenme safhasını en az süreye indirmek için bir sınıflandırma yaklaşımı kullanılmaktadır. Bu yaklaşım, kullanıcı tarafından oluşturulan elektronik etiketlerden türetilen bir sınıflandırma sistemidir. Ayrıca, sistemin hızlı bir şekilde çevresel değişikliklere adapte olmasını sağlamaktadır. Çevresel değişikliklere örnek olarak yer değiştiren erişim noktaları verilebilir.

Kullanım ve kurulum kolaylığı ile kullanıcı etkileşimli bir sistem olması ve açık kaynak lisans altında olması Redpin'in en önemli iki özelliğidir. Redpin mimarisi, (1) algılayıcı (2) yer belirleyici olmak üzere iki bileşenden oluşmaktadır. Algılayıcı bileşeninde parmak izi oluşturmak için farklı kablosuz cihazlar hakkında bilgi toplanmaktadır. Bu bileşenin mobil cihazlar üzerinde çalışması zorunludur. Algılayıcı ölçümünde GSM, Wi-Fi, Bluetooth olmak üzere 3 farklı sinyal kaynağı ölçülmektedir. Ayrıca mümkün olduğunda

farklı kaynakların sinyal değerleri okunmaya çalışılmaktadır. Bluetooth cihazları her zaman kısa sürede tespit edilemediğinden ölçümler aynı anda ve aynı yerde alınsa bile farklılık gösterebilmektedir. Bu üç sinyal tipinin birleştirilmesinin en büyük avantajı gerçek ölçümler ile sistemin çalışma performansının test edilebilmesidir.

Redpin sistemi, sınıflandırma yöntemi olarak k en yakın komşu (kNN) yöntemini temel almaktadır. Fakat bu sistem görünür ve görünmez erişim noktaları olarak erişim noktalarını birbirinden ayırdığı için kNN'den farklıdır. Bu yöntemde öklit mesafesi yerine vektörel yakınlık hesabı ile birlikte Redpin yönteminde benzer (NCAP) ve benzer olmayan (NNAP) erişim noktalarının sayısı ve erişim noktalarının benzerliği (SIM) göz önüne alınarak yeni bir fonksiyon geliştirilmiştir. Önerilen mesafe fonksiyonunun formülü aşağıdaki gibidir.

$$Redpin(E_{Ap}, T_{Ap}) = \alpha NCAP(E_{Ap}, T_{Ap}) + \beta NNAP(E_{Ap}, T_{Ap}) + \gamma SIM(E_{Ap}, T_{Ap}) \quad (1)$$

Formülde yer alan  $E_{Ap1}$ ,  $E_{Ap2}$ ,  $E_{ApN}$  sembolleri, N adet erişim noktası sayısına sahip olan bir eğitim veri kümesinde bulunan sinyal güçlerini  $T_{Ap1}$ ,  $T_{Ap2}$ ,  $T_{ApN}$  ise test veri kümesinde bulunan sinyal güçlerini ifade etmektedir. NCAP ve NNAP değerleri ile veri kümesinde bulunan sinyal gücü değerlerine göre erişim noktalarının benzer olup olmadığına bakılmaktadır. NCAP eğitim ve test kümesinden alınan sinyal örneklerinde benzer sinyallere sahip erişim noktalarının sayısını verirken, NNAP benzer olmayan sinyallere ait erişim noktalarının sayısını hesaplamaktadır. Bu değerlerin hesaplanmasında  $\delta$  fonksiyonu kullanılmakta ve  $\delta$  fonksiyonu, sinyal gücü 0'dan farklı ise 1, değilse 0 döndürecek şekilde tanımlanmaktadır.

## 4.2. WASP

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

Sinyal dalgalanmasının etkisini azaltmak için bir yerdeki erişim noktalarının görünümü her zaman aynı değildir. Çünkü çevresel değişimler aynı yerde Wi-Fi sinyallerinin dalgalanmasına sebep olurlar. Bu yüzden bir yerde daha çok görünen Wi-Fi sinyallerinin etkisi (daha yüksek ağırlık değerleri kullanılarak) arttırılmıştır. Yani bir Wi-Fi sinyalinin bir yerde görülme sıklığına göre ağırlıklandırılmış erişim noktaları bulunmaktadır (Lin et al. 2009). WASP yönteminde Redpin'de gerçekleştirilen işlemlerle birlikte ağırlıklı erişim noktalarının benzerliğine bakılmıştır. Bir ortamda sıklıkla bulunan erişim noktaları tespit edilerek iç ortamlarda oluşan sinyal dalgalanmalarının etkisi azaltılmaya çalışılmıştır. WASP yönteminin mesafe fonksiyonunun genel formülü aşağıdaki gibidir (Lin, 2009):

$$WASP(E_{Ap}, T_{Ap}) = \alpha NCAP(E_{Ap}, T_{Ap}, L) + \beta NNAP(E_{Ap}, T_{Ap}, L) + \gamma SIM(E_{Ap}, T_{Ap}) \quad (2)$$

WASP yönteminde Redpin yönteminden farklı olarak NCAP ve NNAP fonksiyonlarına parmak izinin L konumunda olup olmadığını hesaplayan olasılık fonksiyonu eklenmiştir. Olasılık fonksiyonunun detaylı gösterimi Karabey, 2015 referanslı çalışmada yer almaktadır.

## 4.3. Evrişimsel Sinir Ağları-ESA

Evrişimsel sinir ağları (Convolutional Neural Network), yapay sinir ağlarına çok

benzemekle birlikte yapay sinir ağlarından daha fazla ara katmanı, öğrenilebilir ağırlık ve yanlılığa sahip nöronları bulduran bir ağ yapısıdır. 80'lerin başında ortaya atılan ESA fikri, 2012 yılında ESA AlexNet, ImageNet Büyük Ölçekli Görsel Tanıma Mücadelesi'ni (ILSVRC) kazandığı zaman daha popüler hale gelmiştir (Vilamala, 2017). O zamandan bu yana ESA'lar, ILSVRC'nin performanslarını test etmek için tercih edilen önemli bir ölçüt haline gelmiştir. AlexNet, beş adet evrimsel katman, maksimum havuz katmanları ve üç adet tamamen bağlı katmandan oluşmaktadır. AlexNet'den sonra 2013 yılında ZFNet, 2014 yılında GoogLeNet 22 katman ile rekabeti kazandıktan sonra son olarak 2015 yılında evrimseller ve aktivasyonların özellik haritalarının bir dönüşüm fonksiyonundan ziyade kimlik fonksiyonundan sapmayı hesapladığı artık bloklar kullanan 152 katmanlı bir ESA geliştirilmiştir (Vilamala, 2017). ESA'ların yapay sinir ağlarına göre avantajı, daha fazla sayıda katman kullanarak daha etkili bir şekilde eğitim aşamasını gerçekleştirmesidir.

Şekil 5'te geliştirdiğimiz ESA modelinin aşamaları gösterilmektedir. İlk aşamalar konvolüsyon ve aktivasyon katmanlarından oluşmakta, son aşamada ise tam bağlı katman ile birlikte sınıflandırma katmanına geçilmektedir. ESA'daki ara katmanların fazla olması bu mimarinin art arda yerleştirilmiş birden fazla eğitim aşamasından oluştuğunu göstermektedir.

Veriler eğitim aşamasından geçtikten sonra sınıflandırma işlemi sonucunda bir çıktı elde edilir ve gerçek çıktı ile karşılaştırılır. Elde edilen sonuç ile istenilen sonuç arasındaki fark kadar hata oranı elde edilir. Bu hata değerinin nöronların tüm ağırlıklarına aktarılması için de yapay sinir ağlarında olduğu gibi geriye yayılım algoritması

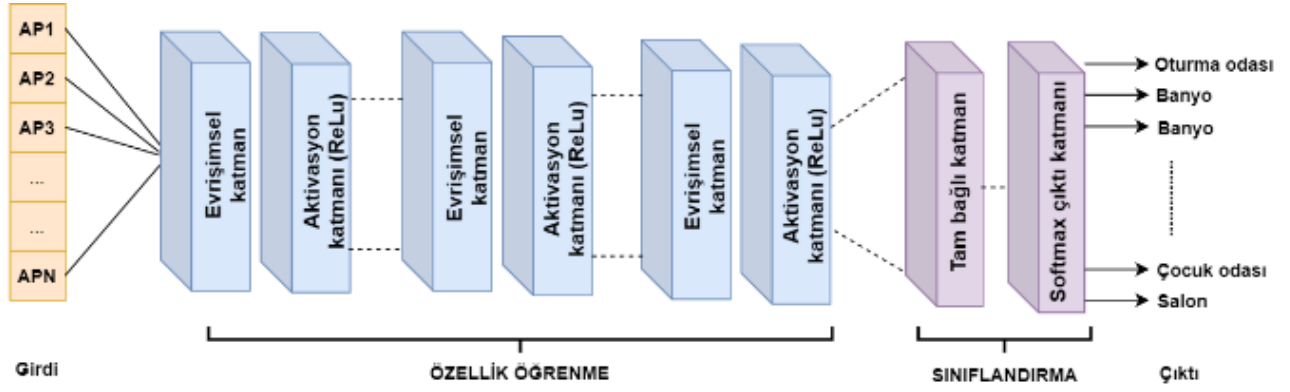
kullanılmaktadır. Geriye yayılımdaki amaç, her bir iterasyon ile ağırlık güncellenmesi yapılarak hata oranını azaltmaktır.

Herhangi bir sinyalden oluşabilen ESA girdi verisi daha çok literatürde görüntü sınıflandırmada kullanılmaktadır. Bu çalışmada ev ortamından elde edilen Wi-Fi sinyallerine ESA uygulanarak derin öğrenme ile ortam tespiti yapılmıştır.

Derin öğrenmede, probleme göre seyreltme (dropout) değeri, katman sayısı, kullanılan aktivasyon fonksiyonu ve nöron sayısı farklılık göstermektedir. Kullanılan veri kümesine göre değişiklik gösteren bu parametreler hiper-parametreler olarak adlandırılmaktadır (Çarkacı, 2018). Derin öğrenmede bulunan bir çok parametrenin optimum şekilde belirlenebilmesi, bu yöntemin en zorlu aşamalarından biridir. Bu hiper-parametreler aşağıda listelenmektedir:

- Veri kümesinin boyutu
- Mini-Batch boyutu
- Öğrenme oranı
- Optimizasyon algoritması
- Eğitim tur sayısı
- Ağırlık başlangıç değerleri
- Aktivasyon fonksiyonu
- Gizli katman ve birim sayısı
- Seyreltme katmanı

*Veri kümesinin boyutu:* Derin öğrenmede veri kümesi ne kadar büyük olursa öğrenme o oranda da iyi olacaktır fakat öğrenme başarısı veri kümesinin büyüklüğüne göre sürekli artmamaktadır. Her veri boyutunun bir durak noktası bulunmaktadır. Başarım oranı boyut ile birlikte çeşitlilik gösteren verilerde de artış göstermektedir.



Şekil 5. Wi-Fi Sinyalleri Kullanılarak Tasarlanan ESA Mimarisi

*Mini-Batch boyutu:* ESA modelinin tasarlanma aşamasında modelin aynı anda kaç adet veriyi işleme alacağı mini-batch parametresi ile belirlenmektedir. Böylece öğrenme işlemi seçilen mini-batch parametre değerine göre küçük gruplar halinde yapılmaktadır. Belirlenen batch değerinin GPU belleğine sığması gerektiğinden ikinin katları şeklinde belirlenmelidir. Aksi halde başarımda ani düşmeler meydana gelmektedir.

*Öğrenme hızı:* Öğrenme hızı optimizasyon algoritmasında ağırlıkların ne kadarının güncelleneceğini kontrol eder. SGD, Adam, Adagrad, AdaDelta veya RMSProp gibi optimize edici seçeneklere bağlı olarak, sabit öğrenme oranı, yavaş yavaş öğrenme oranı, momentum bazlı yöntemler veya uyarlanabilir öğrenme oranları kullanılabilir. Öğrenme oranı değeri genelde varsayılan değer olarak 0.01 kullanılmakta belli bir eğitim turundan sonra 0.001'e düşürülmektedir (Çarkacı, 2018).

*Eğitim tur (Epoch) sayısı:* Tüm eğitim setinin kaç kere sinir ağı üzerinden geçeceğini belirleyen bir parametredir. Test hatası ile eğitim hatası arasında az bir fark görene kadar tur sayısı artırılmalıdır.

*Aktivasyon fonksiyonu:* Aktivasyon fonksiyonu, normal şartlarda doğrusal olan bir

modeli doğrusal olmayan şekle dönüştürmektedir. Gizli katmanlarda doğrusal bir fonksiyonda matris çarpımı ile nöron ağırlıkları hesaplandıktan sonra çıktı doğrusal olmayan bir değere dönüştürülmektedir. Derin öğrenmede en yaygın kullanılan aktivasyon fonksiyonlarından biri ReLu'dur. Diğer alternatifler, sigmoid, tanh, softmax ve diğer aktivasyon fonksiyonlarıdır. Çalışma kapsamında ara katmanlarda ReLu fonksiyonu kullanılmış olup (3) numaralı denklem ile ifade edilmektedir. Bu fonksiyona giriş 0'dan küçükse çıkış 0'a, aksi takdirde ise ham çıkışa sahiptir. Yani, giriş 0'dan büyükse, çıkış girişe eşittir.

$$f(x) = \begin{cases} 0 & \text{eğer } x < 0 \text{ ise} \\ x & \text{eğer } x \geq 0 \text{ ise} \end{cases} \quad (3)$$

Oluşturduğumuz ESA modelinin sınıflandırma aşamasında ise Softmax kullanılmış olup bu fonksiyon (4) numaralı denklemde ifade edilmektedir.

$$\sigma(z)_j = \frac{e^z_j}{\sum_{k=1}^K e^z_k}, \quad j=1,2,3,\dots,k \quad (4)$$

Softmax genellikle girdi verilerini ağıncıkışında [0,1] aralığına eşlemek için kullanılmaktadır. Matematiksel olarak 4. denklemdaki ifadede z çıkış katmanına verilen girişlerin bir vektörüdür. j ise çıktı birimlerini indekslemektedir.

*Gizli katman ve birim sayısı:* Test hatasının iyileşebileceği son noktaya kadar katman eklemek genellikle tercih edilen bir durumdur. Gizli katman sayısına bağlı olarak verilerin eğitim sayısı da artmakta ve test hatası en aza indirgenmektedir. Fakat katman sayısının artışı, veri boyutunun artışı gibi bir noktadan sonra başarı oranına etki etmemektedir.

*Ağırlık-W başlangıç değerleri:* Ölü nöronları önlemek için ağırlıklar küçük rastgele sayılarla başlatılmalıdır, ancak bu değer, sıfır gradyanı önlemek için çok küçük olmamalıdır.

*Optimizasyon algoritması:* Doğrusal olmayan problemlerin çözümü için optimizasyon yöntemleri kullanılmaktadır. Bir optimizasyon problemi olan derin öğrenmede de genellikle stochastic gradient descent, adagrad, adadelta, adam, adamax gibi algoritmalar kullanılmaktadır. Derin öğrenme modellerinde genelde varsayılan olarak kullanılan optimizasyon algoritması Stochastic Gradient Descent (SGD)'dir. AdaGrad seyrek parametreler için büyük güncellemeler yaparken sık parametreler için daha küçük güncellemeler yapar. Bu nedenle NLP ve resim tanıma gibi seyrek veriler için daha uygundur. Bu yöntemde her parametrenin kendi öğrenme hızı vardır ve algoritmanın özelliklerine göre bu oran giderek azalmaktadır. RMSprop ve benzeri olan AdaDelta, AdaGrad'ın bu sorununu çözerek bu hızlı düşüşü önler (Çarkacı, 2018).

*Seyreltme (Dropout) Katmanı:* ESA ile sınıflandırma yaparken dikkat edilecek en önemli hususlardan birisi ağın ezberleme yaparak yüksek bir doğruluk oranı elde etmesidir. Bu durumun engellenmesi için ara katmanlarda bulunan bazı düğümler kaldırılmaktadır. Varsayılan değer olarak 0.5

değeri test için iyi bir seçim olarak belirlenmiştir (Lau, 2018).

Bu çalışma kapsamında ESA modeli, Keras kütüphanesi ve Python programlama dili kullanılarak oluşturulmuştur. Hiper parametre olarak öğrenme hızı, optimizasyon algoritması, katman sayısı, eğitim tur sayısı, ağırlık başlangıç değerleri ve aktivasyon fonksiyonları değiştirilerek en iyi sonuca ulaşılmaya çalışılmıştır. Oluşturduğumuz veri kümesinin en yüksek doğruluk oranı ile sınıflandırılması için Tablo 2'de görülen en uygun parametre değerleri belirlenmiştir.

**Tablo 2.** Uygulanan sınıflandırma yöntemlerinin varsayılan parametre değerleri

ALGORİTMA	VARSAYILAN DEĞER
kNN	k=1 Mesafe fonksiyonu=Öklit
Redpin, WASP	a=1, b=-0.4, gama=0.2, s=0.2, w=10, c=1.0
GY	Gizli katman=15 Öğrenme oranı=0.3 Momentum=0.2
RO	Ağaç sayısı=50
ESA	Katman sayısı= 3 Aktivasyon fonksiyonu=ReLU Seyreltme (dropout) değeri=0.2 Mini-batch boyutu=16 Optimizer=Adam Tur (epoch) sayısı=10000 Hesaplanan toplam parametre sayısı=36,743

## 5. Araştırma Bulguları

Bu çalışmada bir ev ortamından elde edilen Wi-Fi sinyallerinden oluşturulan veri setinin yanı sıra, farklı öznelik ve veri sayılarına sahip (WASP ve WILDS) veri kümeleri üzerinde derin öğrenme yöntemi uygulanmış ve deneysel sonuçlar karşılaştırılmıştır.

### a. Kendi Veri Kümemiz ile Elde Edilen Sonuçlar

Oluşturduğumuz veri kümesine önceki bölümlerde bahsedilen sınıflandırma

yöntemleri kullanılarak yapılan sınıflandırma sonucunda elde edilen doğruluk yüzdeleri Tablo 3’ te verilmektedir. 600 veri ve 6 adet etiketten oluşan bu veri kümesine uygulanan derin öğrenme yöntemi sonucunun diğer algoritmalarından daha yüksek doğruluk oranı verdiği gözlemlenmektedir.

**Tablo 3.** Veri kümesi üzerinde uygulanan yöntemlerin doğruluk yüzdeleri (%)

YÖNTEM	k=1	k=2	k=3	k=4	k=5
kNN	%68	%66	%66	%66	%65
Redpin	%66	%63	%66	%66	%68
WASP	%67	%65	%67	%68	%69
NB	%55				
DVM	%65				
GY	%68				
RO	%72				
ESA	%80				

Derin öğrenme yöntemi, veri sayısı 600 olan bir veri kümesinde makine öğrenmesi yöntemlerinden en iyi başarıyı elde eden Rastgele Orman’dan %8 daha fazla sonuç vermektedir. Çalışmada bu yöntem, veri sayılarının daha fazla olduğu veri kümeleri üzerinde de değerlendirilmektedir.

### b. Literatürde Bulunan Veri Kümelerinde Elde Edilen Sonuçlar

Makalenin 4.3 numaralı başlığında bahsedildiği gibi derin öğrenme yönteminde verinin boyutu, sınıflandırma performansını oldukça etkilemektedir. Çalışmada Wi-Fi sinyalleri ile oluşturduğumuz veri kümesine uygulanan derin öğrenme yöntemi, makine öğrenmesi yöntemlerinden daha iyi sonuç verse de literatürde yapılan araştırmalara göre daha yüksek doğruluk oranlarının elde edilmesi gerektiği kanısına varılmıştır. Bu durumun veri boyutunun yetersizliğinden veya Wi-Fi alıcılarından elde edilen anomali değerlerinin elenmemesinden kaynaklanabileceği düşünülmüştür.

Veri boyutunun derin öğrenme yöntemine etkisini incelemek adına Wi-Fi sinyallerinden oluşan benzer özelliklerde fakat farklı veri sayısı ve etiketine sahip iki veri kümesine derin öğrenme yöntemi uygulanmaktadır. Bu veri kümelerinden Wireless Indoor Localization Data Set (WILDS) isimi veri kümesi (UCI, 2018) 2000 adet veriden oluşmakta, 7 adet erişim noktası ve 4 adet etiket bulunmaktadır. Diğer bir veri kümesi olan WASP (Lin et al., 2009)' ta ise toplamda 1002 adet veri, 16 adet erişim noktası ve 9 adet etiket bulunmaktadır. Veri kümelerine uygulanan bu yöntem ile yazarların kendi çalışmalarında değerlendirilen bazı makine öğrenmesi yöntemlerinin sonuçları ise Tablo 4' te verilmektedir.

**Tablo 4.** Farklı veri kümelerine uygulanan ESA ve diğer makine öğrenmesi yöntemlerinin karşılaştırılması (X ile gösterilen kısımlar yapılan çalışmalarda değerlendirilmemiştir)

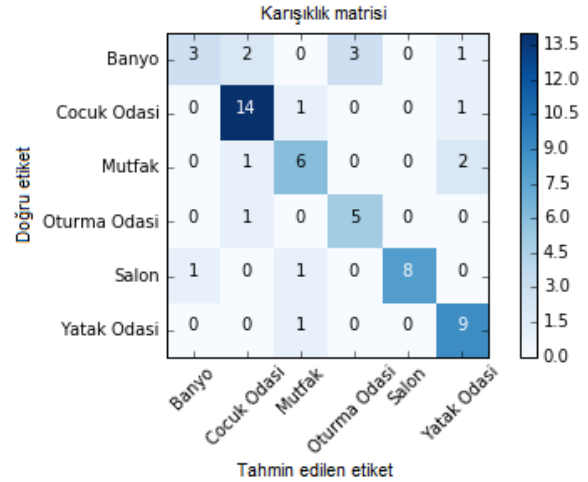
YÖNTEM	VERİ KÜMESİ VE DOĞRULUK ORANI(%)		
	WASP (Lin et al. (2009))	WILDS (Rohra et al. (2017))	Oluşturulan veri kümesi (Bu çalışma)
kNN	79	X	68
Redpin	81	X	68
WASP	87	X	69
NB	61	90.47	55
DVM	80	92.68	65
GY	78	X	68
RO	87	X	72
Rohra et al. (2017) tarafından önerilen NN	X	95.16	X
ESA	82	98	80

Tablo 4’teki sonuçlar incelendiğinde, veri sayısı 2000 olan WILDS veri kümesinde oldukça yüksek başarı elde edilerek NB, DVM ve Rohra et al. tarafından önerilen yapay sinir ağı yöntemini geride bırakmaktadır. 1002 veriden oluşan WASP veri kümesinde ise yazarların (Lin et al., 2009) bu veri kümesine özgü önerdikleri WASP

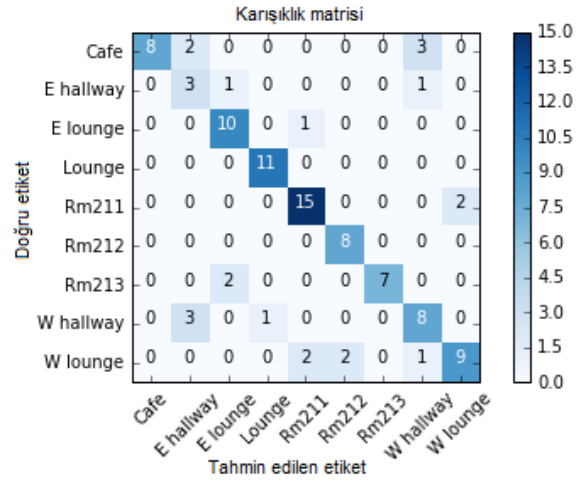
yönteminin sonucuna derin öğrenme yönteminin doğruluk değerinin oldukça yaklaştığı görülmektedir. Farklı etiket ve veri sayısına sahip bu üç veri kümesinin en uygun parametreler kullanılarak (Tablo 2) ESA ile sınıflandırılması sonucunda elde edilen karışıklık matrisleri Şekil 6'da verilmektedir.

Şekil 6' da derin öğrenme uygulanması sonucu elde edilen karışıklık matrislerine bakıldığında oluşturulan veri kümesinde en çok "Banyo" etiketinin diğer odalar ile karıştığı görülmektedir. Bu durum da ev içerisinde bulunan banyonun, çocuk odası, oturma odası ve yatak odası arasında olduğu için bu etiketlerle karışmasının muhtemel olduğunu göstermektedir. WASP veri kümesinden elde edilen karışıklık matrisinde ise etiket sayısının diğer veri kümelerinden fazla olduğu ve en iyi RM211 (%13 hata) ve RM212 (%0 hata) sınıflarını başarı ile sınıflandırdığı görülmektedir. Son olarak WILDS veri kümesinde yalnızca 2 numaralı sınıfın 3 numaralı sınıf ile karıştırıldığı 3 adet veri, 4 numaralı sınıfın ise 3 numara ile karıştırıldığı 1 adet veri bulunmaktadır. Böylece bu veri kümeleri içerisinde WILDS veri kümesinin %100'e yakın oranla (%98) derin öğrenme yönteminde en yüksek başarı oranına sahip olduğu görülmektedir.

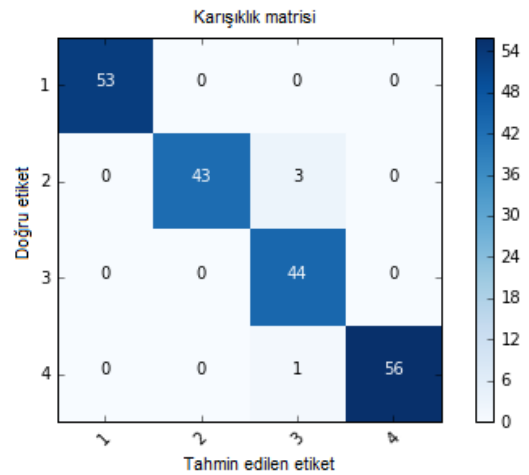
Farklı etiket ve veri sayılarına sahip üç veri kümesinde derin öğrenme performansları incelendiğinde, ESA'nın veri sayısının fazla, etiket sayısının az olduğu veri kümelerinde daha yüksek performans gösterdiği gözlenmektedir.



a) Oluşturulan veri kümesi



b) WASP veri kümesi



c) WILDS veri kümesi

Şekil 6. Derin öğrenme sonucu WASP, WILDS ve oluşturulan veri kümelerinden elde edilen karışıklık matrisleri

## 6. Sonuç ve Tartışma

Bu çalışmada, iç ortam konumlandırmada kullanılan parmak izi yaklaşımı, 6 odalı bir ev ortamından elde edilen veri kümesine uygulanan yedi farklı makine öğrenmesi yöntemi ve son yıllarda popülerliği giderek artan Evrişimsel Sinir Ağları (ESA) karşılaştırılmıştır. Daha önceki çalışmamızda (Karabey, 2015) makine öğrenmesi yöntemleri kendi içerisinde karşılaştırılarak en iyi yöntemin Rastgele Orman (RO) olduğu öngörülmüş, çalışmaya ek olarak derin öğrenme yöntemi uygulanarak bu yöntemin %8 oranında başarıyı artırdığı gözlemlenmiştir.

Ayrıca aynı parametreler kullanarak farklı etiket sayısına ve veri boyutuna sahip farklı veri kümeleri üzerinde ESA'nın başarı oranı test edilmiştir. 600 adet veriden oluşturulan veri kümesine ek olarak 1002 adet veriye sahip veri kümesi (Lin, 2009) ve 2000 adet veriye sahip veri kümesi (UCI, 2018) üzerinde performans değerlendirmesi yapılmıştır. Elde edilen sonuçlara bakıldığında veri sayısının en fazla olduğu ve etiket sayısının en az olduğu WILDS veri kümesinde %98 başarı oranı ile geçmiş çalışmalara göre çok daha başarılı olduğu gözlemlenmiştir.

Genel olarak uygulanan ESA modelinin makine öğrenmesi yöntemlerine göre daha başarılı olduğu görülmekte, fakat WASP veri setine özel oluşturulan WASP yönteminin doğruluğunun ESA yöntemine göre daha fazla olduğu gözlemlenmektedir. Bunun sebebi ise WASP yönteminde ağırlıklı erişim noktalarının benzerliğine bakılarak bir ortamda sıklıkla bulunan erişim noktalarının tespit edilmesi ile iç ortamlarda oluşan sinyal dalgalanmalarının etkisinin en aza indirgenmesidir. Ayrıca tüm veri setlerine standart parametreler ile ESA modeli

uygulanarak veri ve etiket sayısının performansa etkisini incelemek hedeflendiği için WASP veri setinde performansı artırmak için daha farklı parametrelerden oluşan bir ESA modeli de bulunabilmektedir.

Gelecek çalışmalarda ESA için veri setinin boyutu genişletilerek yeni özniteliklerin ve farklı algılayıcı (ısı, ışık vb.) verilerinin yöntemin doğruluğuna etkileri incelenecektir. Ayrıca model üzerinde çeşitli parametreler değiştirilerek parametrelerin model performansına etkisi araştırılacaktır.

## 7. Kaynaklar

Ban, R., Kaji, K., Hiroi, K., and Kawaguchi, N., 2015. "Indoor positioning method integrating pedestrian Dead Reckoning with magnetic field and Wi-Fi fingerprints", *Mobile Computing and Ubiquitous Networking (ICMU)*, pp.167-172

Bolliger, P., 2008. "Redpin-adaptive, zero-configuration indoor localization through user collaboration", *The first ACM international workshop on Mobile entity localization and tracking in GPS-less environments*, 55-60

Çarkacı, N., <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4>, Son erişim tarihi: 10 Haziran 2018

Goga, N., Vasilateanu, A., Mihailescu, M. N., Guta, L., Molnar, A., and Bocicor, I., Bolea, L., and Stoica, D., 2016. Evaluating indoor localization using WiFi for patient tracking. *IEEE Fundamentals of Electrical Engineering (ISFEE)*, pp. 1-4

Huynh, S. M., David, P., Fong, A.C.M and Tang, J., 2014. Novel RFID and ontology based home localization system for misplaced



- objects. *IEEE Transactions on Consumer Electronics*, cilt 60, pp.402-410
- Hsieh, C., Chen J., and Nien B., 2019. Deep Learning-Based Indoor Localization Using Received Signal Strength and Channel State Information. *IEEE Access*, vol. 7, pp. 33256-33267
- Karabey, I., Bayindir, L., 2015. “An evaluation of fingerprint-based indoor localization techniques”, *IEEE Signal Processing and Communications Applications Conference (SIU)*, pp. 2254-2257
- Krumm, John, 2016. “Ubiquitous computing Fundamentals”, CRC Press
- Lan, K., Shih, W., 2014. “An intelligent driver location system for smart parking”, *Expert Systems with Applications Elsevier*, 41, pp.2443-2456
- Lau, S., <https://towardsdatascience.com/a-walkthrough-of-convolutional-neural-network-7f474f91d7bd>, Son erişim tarihi: 01.12.2018
- Le, D. V., Meratnia, N., Havinga P. J. M., 2018. “Unsupervised Deep Feature Learning to Reduce the Collection of Fingerprints for Indoor Localization using Deep Belief Networks”, *International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, 24-27 September, Nantes, France
- Lei, X., Zhu, X., Chi, H., & Jiang, S. (2015). “Privacy-preserving use of genomic data on mobile devices”, 2015 *IEEE/CIC International Conference On Communications In China (ICCC)*.
- Lin, H., Zhang, Y., Griss, M., Landa, I., 2009. “WASP: an enhanced indoor locationing algorithm for a congested Wi-Fi environment”, *ACM international workshop on Mobile entity localization and tracking in GPS-less environments*, pp. 183-196
- MarketandMarkets Research, <https://www.marketsandmarkets.com/Market-Reports/indoor-positioning-navigation-ipin-market-989.html>, Son erişim tarihi: 31.03.2019
- Naveed, M., Ayday, E., Clayton, E. W., Fellay, J., Gunter, C. A., Hubaux, J. P., ... Wang, X. (2015). “Privacy in the Genomic Era”, *ACM computing surveys*, 48(1), 6.
- NCBI, <https://www.ncbi.nlm.nih.gov/projects/SNP/>, Son erişim tarihi: 02.12.2018
- Niu, J., Wang, B., Cheng, L., Rodrigues, J., 2015. “WicLoc: An indoor localization system based on WiFi fingerprints and crowdsourcing”, *IEEE Communications (ICC)*, pp. 3003-3013
- NIH, “Guidance for Institutions Submitting Grant Applications and Contract Proposals under the NIH Genomic Data Sharing Policy for Human and Non-Human Data”, [https://gds.nih.gov/pdf/GDS\\_Policy\\_Guidance\\_Grant\\_App\\_Contract\\_Proposals.pdf](https://gds.nih.gov/pdf/GDS_Policy_Guidance_Grant_App_Contract_Proposals.pdf). 17.04.2017.
- Nyholt, D. R., Yu, C. E., & Visscher, P. M. (2009). “On Jim Watson's APOE status: genetic information is hard to hide”, *European journal of human genetics : EJHG*, 17(2), 147–149.
- ReportLinker, <https://www.prnewswire.com/news-releases/global-indoor-location-market-analysis-2017-2023-300561176.html>, Son erişim tarihi: 31.03.2019

- Perl, H., Mohammed, Y., Brenner, M., & Smith, M. (2012). "Fast confidential search for bio-medical data using Bloom filters and Homomorphic Cryptography", 2012 IEEE 8Th International Conference On E-Science.
- Perl, H., Mohammed, Y., Brenner, M., & Smith, M. (2014). "Privacy/performance trade-off in private search on bio-medical data", *Future Generation Computer Systems*, 36, 441-452.
- Rohra, J.G., Perumal, B., Narayanan, S. J., Thakur, P., and Bhatt, R. B, 2017. "User Localization in an Indoor Environment Using Fuzzy Hybrid of Particle Swarm Optimization & Gravitational Search Algorithm with Neural Networks", *Proceedings of Sixth International Conference on Soft Computing for Problem Solving*, 286-295.
- Schmidt, E., Inupakutika, D., Mundlamuri, R., and Akopian, D., 2019. "SDR-Fi: Deep-Learning-Based Indoor Positioning via Software-Defined Radio", *IEEE Access*, vol. 7, pp. 145784-145797
- Schneier B., (1993). "Applied Cryptography: Protocols, Algorithms, and Source Code in C", John Wiley & Sons, Inc. New York, NY, USA
- Serrao, M., Shahrabadi, S., Moreno, M. Jose, J.T., Rodrigues, J.I., and Rodrigues, J.M.F., and du Buf, JM Hans, 2015. "Computer vision and GIS for the navigation of blind persons in buildings", *Universal Access in the Information Society*, pp. vol. 14, 67-80
- Sweeney L., (2002). "k-anonymity: a model for protecting privacy", *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 5-10, 557-570.
- Sweeney, L. (1997). "Weaving Technology and Policy Together to Maintain Confidentiality", *The Journal Of Law, Medicine & Ethics*, 25(2-3), 98-110.
- Sweeney, L., Abu, A., & Winn, J. (2013). "Identifying Participants in the Personal Genome Project by Name", *SSRN Electronic Journal*.
- Toh, C., and Lau, S.L., 2016. "Indoor localisation using existing WiFi infrastructure—A case study at a university building", *Virtual System & Multimedia (VSMM)*, pp. 1-5
- UCI,  
<https://archive.ics.uci.edu/ml/datasets/Wireless+Indoor+Localization>, Son erişim tarihi: 05.11.2018
- Vilamala, A., Madsen, K. H., and Hansen, L. K., 2017. "Deep Convolutional Neural Networks for Interpretable Analysis of EEG Sleep Stage Scoring", *Proceedings of the 2017 IEEE 27th International Workshop on Machine Learning for Signal Processing (MLSP)*
- Wang, Y., and Wong, A. K., and Cheng, R.S., 2015. "Adaptive room-level localization system with crowd-sourced WiFi data", *SAI Intelligent Systems Conference (IntelliSys)*, pp. 463-469
- Wang, Y., Zhang X., Gao Q., Yue, H., and Wang, H., 2017. "Device-Free Wireless Localization and Activity Recognition: A Deep Learning Approach", *IEEE Transactions On Vehicular Technology*, pp. 6258 – 6267
- Wang, B. 2016 "Search over Encrypted Data in Cloud Computing", PhD, Faculty of

Virginia Polytechnic Institute and State University, Blacksburg, VA, USA

Wang, X., Gao, L., Mao, S., Pandey, S., 2017. “CSI-based Fingerprinting for Indoor Localization: A Deep Learning Approach”, IEEE Transactions On Vehicular Technology, vol. 66, pp.763-776

Wu, F., Xing, J., Dong, B., 2015. “An Indoor Localization Method Based on RSSI of Adjustable Power WiFi Router”, Instrumentation and Measurement, Computer, Communication and Control (IMCCC), pp. 1481-1484

Zou, H., Chen, Z., Jiang, H., Xie, L., and Spanos, C., 2017. “Accurate indoor localization and tracking using mobile phone inertial sensors, WiFi and iBeacon”, IEEE International Symposium on Inertial Sensors and Systems (INERTIAL), 1-4

Zheng, L., Hu, B., and Chen, H., 2017. “A high resolution time-reversal based approach for indoor localization using commodity WiFi devices”, Cooperative Positioning and Service (CPGP), pp. 300-304

Zheng, W., Sengupta, R., Fodero, J., Li, X., 2017. “DeepPositioning: Intelligent Fusion of Pervasive Magnetic Field and WiFi Fingerprinting for Smartphone Indoor Localization via Deep Learning”, 16th IEEE International Conference on Machine Learning and Applications, pp. 7-13.