

# Yapay Sinir Ağı Sınıflandırma ile Akıllı Telefonun Kullanıcı Üzerindeki Konum Tespiti

## Detection of Smart Phone Position on User using Artificial Neural Network Classifier

Veli BAYAR, Mehmet Önder EFE

Bilgisayar Mühendisliği, Otonom Sistemler Araştırma Laboratuvarı  
Hacettepe Üniversitesi  
Ankara, Türkiye  
[velibayar@hacettepe.edu.tr](mailto:velibayar@hacettepe.edu.tr), [onderefe@gmail.com](mailto:onderefe@gmail.com)

**Özetçe**— İç ortam konumlandırma sistemlerinde akıllı telefon kullanımı popülerdir. Yaygın olarak kullanılan alınan sinyal gücü (RSS) tabanlı konumlandırma yöntemlerinde mevcut problem radyo frekansı sinyal karakteristikleri nedeniyle RSS değerlerinin zamanla değişmesidir. Kullanıcı/cihaz oryantasyonu dâhil olmak üzere insan varlığı, sinyal özellikleri üzerinde önemli etkiye sahip olmakla birlikte konumlandırma hassasiyetini düşürmektedir. Parmak izi veya geometrik yöntemlere dayalı konumlandırma algoritmalarında kullanılan RSS değerlerinin güncellenmesi hassasiyeti artırmak için iyi bir çözümdür. Yapılan çalışmada akıllı telefonun kullanıcı üzerindeki yerini algılayan bir ara çözüm önerilmektedir. Log-Sigmoid fonksiyonu ve Softmax regresyonu, çapraz entropi maliyet ölçüsü ile aktivasyon fonksiyonları olarak seçilerek sınıflandırma amaçlı yapay sinir ağı kullanılmaktadır. Akıllı telefonun atalet sensörü verileri kullanılarak 9 hedef sınıf başarıyla sınıflandırılmaktadır. Oluşturulan veri seti üzerinde 50 kez oluşturulan testlerde %95'in üzerinde başarı oranı elde edilmektedir.

**Anahtar Kelimeler** — iç ortam konumlandırma sistemleri; yapay sinir ağı; alınan sinyal gücü; sınıflandırma.

**Abstract**— Smart phone use in indoor positioning systems are popular. In the case of commonly used received signal strength (RSS) based positioning methods, the problem is that RSS values vary with time due to radio frequency signal characteristics. Human presence, including user/device orientation, decrease positioning accuracy, with significant influence on signal characteristics. Updating the RSS values used in positioning algorithms based on fingerprint or geometric methods is a good solution to increase accuracy. In this study, an intermediate solution is proposed that recognizes the location of the smartphone on user. Log-Sigmoid function and Softmax regression are selected as activation functions with cross entropy measure and artificial neural networks are used for classification purpose. Using inertial sensor data of the smartphone, 9 target classes are successfully classified. Over 95% success rate is achieved for 50 runs within generated dataset.

**Keywords**— indoor position systems; artificial neural network; received signal strength; classification.

### I. GİRİŞ

Bağlamsal bilgi sağlama ile ilişkili olarak, bir kişinin veya bir cihazın yerini elde etmek giderek önem kazanmıştır. GPS teknolojisi uzun yıllardır navigasyon, haritalama ve rehberlik gibi uygulamalarda kullanılmaktadır. Alışveriş merkezleri, iş merkezleri ve benzeri karmaşık ve büyük binalarda insanlar giderek fazla zaman harcadıklarından, kapalı ortam konum bilgisi ihtiyaç olarak ortaya çıkmaktadır. Buna ek olarak, reklam ve sosyal ağlar gibi ticari uygulamalar için pozisyon bilgileri yakın zamanda yaygın olarak kullanılmaktadır. Bununla birlikte, GPS teknolojisi, açık görüş hattı ve sinyal özellikleri eksikliği nedeniyle açık alanlarda sınırlıdır. Bu nedenle, kapalı ortamlarda GPS kullanarak güvenilir konum bilgisi üretmek mümkün değildir. Böylece, kapalı ortamlarda konum bilgisi ihtiyacını karşılamak için iç ortam konumlandırma (IPS) ve navigasyon (INS) sistemleri sunulmaktadır. İç ortam konumlandırma ve navigasyon sistemleri kızılötesi, sesüstü, kamera, lazer, radyo frekansı (RF) ve benzeri çeşitli sinyal teknolojilerini kullanmaktadır. Binalardaki mevcut altyapı nedeniyle RF sinyalleri özellikle Wi-Fi sinyalleri yaygın şekilde kullanılmaktadır. Ayrıca mobil cihazlar, uyumlu iletişim arabirimine sahip oldukları için bu sistemlerde mobil düğüm olarak kullanılmaktadır. Sensör düğümlerinden toplanan sinyal gücü verileri çoğunlukla konum bilgisini hesaplamak için kullanılmaktadır.

Verilen konum bilgileriyle RSS değerlerini bir veritabanına toplama ve kaydetme, parmak izi alma olarak bilinmektedir. Genel olarak, kapalı ortamda bir ızgara yapısı oluşturulmaktadır. Ardından, RSS değerleri, çevrimdışı fazda belli aralıklar ile belirtilen ölçüm noktalarında toplanmaktadır. RF haritası yeterli bilgi ile oluşturulduğunda, çevrimiçi fazda bir kullanıcı cihazından yeni RSS ölçüm seti alınmaktadır. En yakın noktanın konum bilgisine sahip olması için RF harita veritabanında elde edilen RSS ölçüm seti aranmaktadır. Diğer bir yol ise trilaterasyon gibi geometri tabanlı konumlandırma algoritmalarını kullanmaktır. Bu durumda RSS ölçümleri, RF yayılım yasaları yardımıyla mesafe değerlerine dönüştürülmektedir. Son olarak, konumlandırma algoritması,

hesaplanan uzaklık değerlerini kullanarak bir konum çıkışı üretmektedir. Bununla birlikte, RSS değerleri her iki durumda da zamanla değiştiği için konumlandırma doğruluğu düşük olmaktadır. Bina yapısı, cihaz çeşitliliği ve insan varlığı gibi birçok neden RSS değerinin zamanla neden değiştiğini açıklamaktadır. Konumlandırma sistemlerinde mobil cihazlardan elde edilen bilgilerin kullanılması, RSS değişimini telafi ederek daha iyi bir doğruluk elde etmeye yönelik çalışma alanı oluşturmaktadır. Akıllı telefonlardan kolaylıkla elde edilebilen atalet sensör verilerinin kullanımı, telefonların mobil düğüm olarak kullanılmasına olanak sağlamaktadır [1].

Literatürde konumlandırma için atalet sensörlerinin verilerini kullanan çalışmaların örnekleri bulunmaktadır. Çalışma [2]'de, RSS değişkenliği probleminin üstesinden gelmek için akıllı telefon tabanlı yaya takip sistemi geliştirilmiştir. Cihaz tipi, cihaz yerleşimi, kullanıcı yönü ve çevre değişiklikleri parmak izi yöntemi ile analiz edilmektedir. Dijital pusula, ivmeölçer ve Wi-Fi sinyal verileri kaydedilmektedir. Oluşan veri kümesi konum hesaplayan bir parçacık filtresi içinde birleştirilmektedir. Başka bir çalışmada ise [3], navigasyon yetenekleri için Apple iPhone 4, Samsung Galaxy SII, HTC EVO 3D ve Nokia X7 olan dört farklı akıllı telefon incelenmektedir. Yapılan testlerin amacı, bu akıllı telefonlarda sensörlerin sağladığı verilerin değerlendirilmesi; konumlandırma ve navigasyon amacıyla akıllı telefonların kullanılmasının fizibilitesinin belirlenmesidir. Çalışma [4]'te benzer şekilde pozisyon ve oryantasyon tahmini için yeni bir yaklaşım önerilmektedir. Kullanıcı üzerinde göğüs ve sırt kısmına monte edilmiş iki RF alıcısı kullanılmaktadır. Sensörlerden toplanan sinyal kuvvetlerinin farkını kullanarak kullanıcı yönelimi tahmin edilmektedir. Ölçülen RSS değerlerinin ortalaması da konumlandırma işlemi için kullanılmaktadır. Çalışma [5]'te temel amaç, kullanıcı mobil cihazı herhangi bir konumda tutarken hareketin yönünü bulmaktır. Sağlanan test sonuçları, navigasyonun bu durumla da mümkün olduğunu göstermektedir. Çalışma [6]'da yönlü değişikliklerden kaynaklanan hataların azaltılması sorunu, gelişmiş yönlendirme tahminiyle çözülmektedir. iPhone 4S ile yapılan deneyler geleneksel çözümlerle karşılaştırıldığında 2.42 kat daha iyi doğruluk elde edilmektedir.

Atalet sensörleri ağırlıklı olarak, kullanıcı oryantasyonunu ve baş açısı bilgilerini hesaplamak için kullanılmaktadır. Konumlandırma sistemleri için geometri temelli yöntemleri kullanmak ise hesaplamasal maliyet nedeniyle tercih edilmektedir. Bununla birlikte, bu yöntemleri kullanmanın temel dezavantajı, güvenilir RSS değerleri nedeniyle RSS değerlerinin mesafeye dönüşümünde büyük hatalara neden olmasıdır. Atalet sensör verileri RSS değerlerini güncellemek için kullanılabilir. Akıllı telefonun insan vücudundaki yerini, insan faaliyetlerini tespit etmek için benzer sınıflandırma biçiminde bilmek değerli bilgi sağlayacaktır. Çalışma [7]'de iç ortam konumlandırma sistemleri, cihaz çeşitliliği, farklı frekans bantları ve cihaz yönelimi gibi çeşitli yönler göre doğruluk açısından incelenmiştir. Ayrıca, kullanıcı düz bir çizgiyle hareket ettiği zaman daha doğru konum verisi elde edilmektedir. Hatalı oryantasyon bilgisi kullanıldığında ise konum hassasiyeti azalmaktadır. Çalışma [8]'de RF temelli konumlandırma sistemlerinde insan vücudundan kaynaklanan gölgelendirme etkisi analiz

edilmektedir. Başka bir çalışmada ise [9], WLAN konumlandırma için mobil kullanıcı oryantasyonu araştırılmaktadır. Hücre kimliği ve uzay bölütleme yöntemleri kullanılmaktadır. Her iki durumda da, kullanıcı oryantasyonu, uygulanan yöntemle bağlı olarak konumlandırma doğruluğunu etkilemektedir. Çalışma [10]'da kapalı bir ortamda insan varlığı tespit sistemi önerilmektedir. Sistem, insan varlığına bağlı olarak RSS değerlerindeki değişikliklere göre çalışmaktadır. Benzer bir çalışmada [11], insan bedeni ve telefonu elde tutma şekline göre RSS kaybı araştırılmaktadır. Hata analizi, mesafe dönüşümü yoluna dayalı ölçümler kullanılarak gerçekleştirilmektedir. Sonuçlar, insan faktörleri dikkate alınmazsa, konumlandırma hassasiyetinin sınırlı olduğunu göstermektedir.

İnsan faaliyetlerinin tanınması başlı başına bir başka araştırma konusudur. Sinir ağı çözümleri, insan faaliyet çalışmaları için yaygın olarak uygulanmaktadır. Jozsef ve Stefan, insan faaliyetlerinin saptanmasında kullanılan yapay sinir ağlarının (ANN) etkinliğini araştırmaktadır [12]. Deneysel sonuçlara göre parametre seçimi uygun yapıldığında yapay sinir ağlarının diğer makine öğrenme yöntemlerinden daha iyi sonuçlar verdiğini göstermektedir. Çalışma [13]'de, insan aktivitesi tanıma (HAR) için sinir ağı tabanlı sınıflandırıcı uygulanmaktadır. Her bir ivmeölçer ekseninden elde edilen farklı veri kümeleri analiz edilmektedir. Akıllı telefon pantolon cebinde tutulurken durma, yürüme ve koşma etkinlikleri kaydedilmektedir. Farklı bir çalışmada [14] ise University of California (UCI) HAR veri setleri üzerinde farklı sinir ağına dayalı sınıflandırıcılar kullanılarak karşılaştırılmaktadır. Başka bir çalışmada ise [15], olasılıksal sinir ağı ve ayarlanabilir bulanık kümelemeyi içeren artımlı öğrenme yöntemi çalışılmaktadır. Önerilen yöntem, önceki eğitim verilerini kullanmadan yeni eğitim verilerinden ek öğrenme kabiliyeti sağlamaktadır.

Bu çalışmada, RSS tabanlı konumlandırma sistemlerine hassasiyeti artırmak amacı ile akıllı telefonun kullanıcı üzerindeki konumundan yararlanılması hedeflenmektedir. Bunun için, akıllı telefonun sabit tutulduğu durumda atalet sensörlerinden 500 ms ölçüm sıklığı ile kaydedilen veriler kullanılmaktadır. Bu veriler, tasarlanan yapay sinir ağı sınıflandırıcısına girdi olarak verilerek 9 hedef sınıf için ayrıştırma hedeflenmektedir. Çalışmada yapay sinir ağı kullanılmasının temel sebebi sinir ağlarının doğrusal olmayan problemlere çözüm üretebilmesidir. Veri seti tanımlaması Bölüm II'de, yapay sinir ağı tasarımı ve detayları Bölüm III'te verilmektedir. Deneyler ve analizler Bölüm IV'de verilirken, son bölümde elde edilen sonuçlar ve gelecek çalışmalar hakkında bilgilere yer verilmektedir.

## II. VERİ SETİ TANIMI

Veri seti AndroSensor mobil uygulamasının kayıt dosyalarından hazırlanmaktadır. AndroSensor ücretsiz bir Android uygulaması olup, akıllı telefon üzerindeki atalet sensör verilerini toplamaktadır. Uygulama içerisinde kaydedilecek veriler için ölçüm birimleri ve ölçüm sıklığı ayarlanabilmektedir. İvmeölçer, yerçekimi, doğrusal ivme, jiroskop, manyetik alan ve oryantasyon bilgileri X, Y ve Z eksenlerinde kaydedilmektedir. Sınıf tanımlamaları ve

etiketleri Tablo 1'de verilmektedir. Kullanıcı üzerindeki pozisyon bilgisine göre 9 sınıf tanımlaması yapılmaktadır.

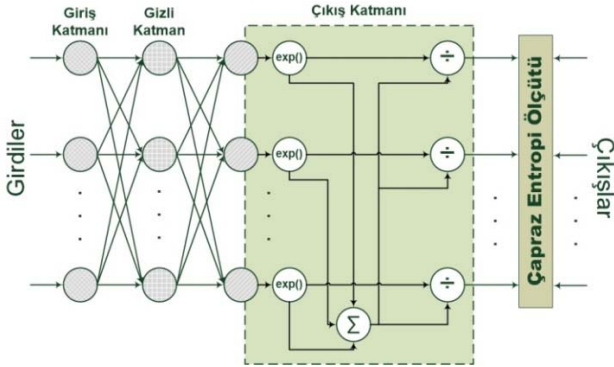
TABLO I. SINIF TANIMLARI VE ETİKETLER

Sınıf İsimleri	Sınıf Etiketleri
Pantolon Sağ Cep	RTP
Pantolon Sol Cep	LTP
Pantolon Sağ Arka Cep	RBP
Pantolon Sol Arka Cep	LBP
Avuç içi (Sağ el)	OH
Sağ Yan Cep	RSP
Sol Yan Cep	LSP
Sağ Göğüs Cep	RCP
Sol Göğüs Cep	LCP

Veri seti oluşturulurken bir kullanıcı uygulamayı başlatarak, akıllı telefonu tanımlı sınıfta yer alan pozisyon için yerleştirmektedir. Rastgele bir yolda yaklaşık 3 dakika yürüyerek, süre sonunda uygulama durdurulmakta ve kaydedilen veri alınmaktadır. Bu süre içerisinde 500 ms örnekleme zamanı ile 380 gözlem verisi kaydedilebilmektedir. Her durum için akıllı telefon oryantasyonu veri setinin tutarlılığı için sabit tutulmaktadır. Farklı olarak elde tutulan durum için telefon bel ile göğüs hizası arasında taşınmaktadır. Kaydedilen verilerin güvenilirliği için her sınıf için toplanan verilerin başından ve sonunda belli miktarda gözlem verisi silinmekte, her sınıf için 320 gözlem verisi saklanmaktadır. Kaydedilen verilerin birleştirilmesi sonucunda 9 sınıfa ait toplam 2880 gözlem verisi ile veri seti tamamlanmaktadır.

### III. YAPAY SINIR AĞI TASARIMI

Yapay sinir ağı tasarımında birden fazla sınıf için ayırım yapabilen sınıflandırma modeli kullanılmaktadır. Ağ tasarımında Şekil 1'de gösterildiği üzere giriş katmanı, saklı katman ve çıkış katmanı olmak üzere 3 katman bulunmaktadır.



Şekil 1. Yapay Sinir Ağı Tasarımı

Log-Sigmoid ve Softmax regresyon fonksiyonları saklı ve çıkış katmanları için aktivasyon fonksiyonları olarak kullanılmaktadır. Softmax fonksiyonu her olası sınıf için olasılık hesaplamaktadır. Bu nedenle, çıkış katmanında elde edilen çıkış değerleri 0 ile 1 arasında bulunmaktadır. Tüm çıkış değerleri toplamı 1'e eşit olmakla birlikte, en yüksek olasılık değeri hedef sınıfa ait olmaktadır. Softmax fonksiyonu Denklem (1) ile gösterilmektedir.

$$f(x_i) = \frac{e^{x_i}}{\sum_{j=1}^k e^{x_j}} \text{ where } i = 1, 2, \dots, k \quad (1)$$

Formülü Denklem (2) ile gösterilen çapraz entropi ölçütü ise maliyet fonksiyonu olarak kullanılmaktadır.  $y_i$  ve  $\tau_i$  sırası ile hedef ve hesaplanan çıkış değerlerini göstermektedir.

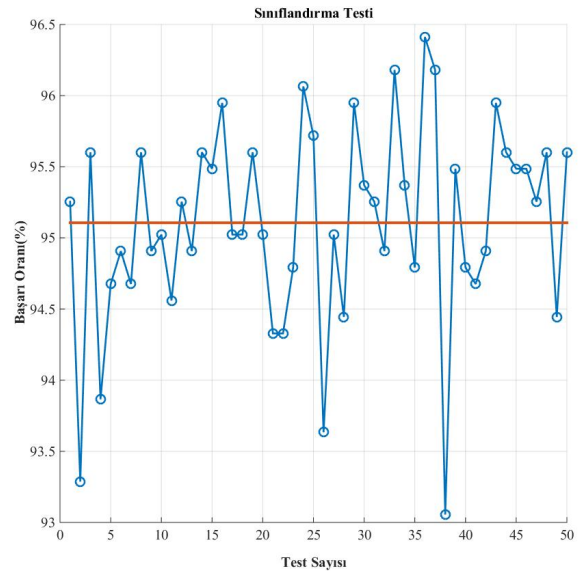
$$E = -\left(\frac{1}{n}\right) \left(\sum_{i=1}^n (y_i \log \tau_i) + (1 - y_i) \log(1 - \tau_i)\right) \quad (2)$$

Scaled Conjugate Gradient (SCG) algoritması, yapay sinir ağını eğitmek için kullanılmaktadır [18]. Bu algoritmanın Conjugate Gradient algoritmalarından farkı hesaplamasal maliyeti artıran arama sürecinden kaçınmasıdır. Ayrıca sinir ağı girdi değerleri birbirinden farklı aralıklara sahip olduğundan ön işleme tabi tutulmaktadır. Giriş değerlerini benzer aralıkta tutmak için standartlaştırma ve normalleştirme işlemlerinden biri yapılmaktadır. Normalleştirme işlemi, girdi verileri -1 ile 1 arasında eşitlenmektedir. Standartlaştırma için ise, her girdi kümesi için ortalama ve popülasyon standart sapması hesaplanmaktadır.

### IV. TESTLER VE ANALİZ

Saklı düğüm sayısı ve ön işleme yöntemleri, ağ performansını etkileyebilecek değişken parametrelerdir. En iyi ağ parametrelerini seçmek için sınıflandırıcı, ayrıntıları Bölüm II'de verilmiş veri setiyle test edilmektedir. İlk olarak, veri kümesi sırasıyla %70 ve %30 oranında bölünerek eğitim ve test kümesine ayrılmaktadır. Ön işleme seçimi ve gizli düğüm sayısı belirli aralıkta değiştirilerek her yapılandırma için sınıflandırma başarı oranı hesaplanmaktadır. Ağ yapılandırması için en iyi durum, saklı düğüm sayısı 32 olarak seçildiğinde ve ön işleme süreci standartlaştırma ile yapıldığında sağlanmaktadır. Sınıflandırma testlerinde kullanılan ağ ayarları Tablo 2'de verilmektedir.

Sınıflandırma testi, aynı veri kümesiyle 50 kez çalıştırılmaktadır. Veri kümesi benzer şekilde ağ yapılandırma testinde olduğu gibi eğitim ve test kümelerine ayrılmaktadır. Başarı oranları ve iterasyon sayıları her tur için kaydedilmektedir. Test sonuçları Şekil 2'de verilmektedir. Maksimum başarı oranı % 96.41, minimum başarı oranı ise %93.05'tir.



Şekil 2. Yapay Sinir Ağı Tasarımı

TABLO II. YAPAY SINIR AĞI AYARLARI

Parametre	Değer
Giriş düğüm sayısı	18
Gizli düğüm sayısı	32
Çıkış düğüm sayısı	9
Ağırlık üst limiti	0.1
Ağırlık alt limiti	-0.1
Başlangıç bayas değeri	0.0
Maksimum iterasyon	1000
Hata limit	0.01
Örnek sayısı	2016
Ön işleme	1 : Standartlaştırma

Ortalama sınıflandırma başarı oranı %95.11 olarak elde edilmektedir. Sınıflandırma performansı için karışıklık matrisinin bir örneği Tablo 3'te verilmektedir. Eğitim ve test setleri için iki farklı karışıklık matrisi oluşturulmuştur ve daha sonra bu matrislerin toplamı, tüm gözlem sınıflandırma sonuçlarını göstermek için analiz edilmektedir.

TABLO III. KARIŞIKLIK MATRİSİ

	1	2	3	4	5	6	7	8	9
1	300	9	2	1	0	0	0	0	0
2	7	308	0	0	0	0	0	7	0
3	0	0	318	1	0	0	0	0	0
4	0	0	0	318	0	0	0	0	0
5	10	0	0	0	320	0	0	0	0
6	0	0	0	0	0	320	0	0	0
7	0	0	0	0	0	0	320	0	0
8	2	3	0	0	0	0	0	313	0
9	1	0	0	0	0	0	0	0	320

RTP (1) ve LTP (2) sınıfları, maksimum sayıda hatalı sınıflandırılmış gözlemleri barındırmaktadır. Diğer sınıflar için elde edilen sınıflandırma sonuçları beklentileri karşılamaktadır.

## V. SONUÇLAR VE DEĞERLENDİRME

Kullanıcı üzerinde akıllı telefon yerinin tespiti, RSS tabanlı iç ortam konumlandırma sistemlerinin doğruluğunu artıracak bir aracı çözüm olarak incelenmiştir. Akıllı telefonun atalet sensör verileri, sinir ağı sınıflandırıcı sisteme girdi olarak sağlanmaktadır. Yapılandırma testi sonuçlarına göre elde edilen ağ parametrelerinin kullanıldığı sınıflandırıcı ile elde edilen başarı sonucunu %95'in üzerindedir. Sistemin çıktısı, RSS değerlerini güncellemek için konumlandırma işlemi girdisi olarak kullanılabilir niteliktedir. Gelecek çalışmalarda birden fazla kullanıcının yürüme dışında etkinliklerinin ve fazla sayıda gözlem verisinin sınıflandırmaya etkisi araştırılacaktır.

## KAYNAKLAR

- [1] R. F. Brena, J.P. Garcia-Vazquez, C. E. Galvan-Tejada, D. Munoz-Rodriguez, C. Vargas-Rosales, and J. Fangmeyer Jr., "Evolution of Indoor Positioning Technologies: A Survey", *Journal of Sensors*, 2017.
- [2] Y. Kim, H. Shin, and H. Cha, "Smartphone -based Wi-Fi Pedestrian-Tracking System Tolerating the RSS Variance Problem", *IEEE International Conference on Pervasive Computing and Communications*, pp. 11-19, Mar. 2012.
- [3] G. Retscher and T. Hocht, "Investigation of Location Capabilities of four Different Smartphones for LBS Navigation Applications.", *International Conference on Indoor Positioning and Indoor Navigation*, Nov. 2012.
- [4] F. Seco, A. R. Jimenez, and F. Zampella, "Joint Estimation of Indoor Position and Orientation from RF Signal Strength Measurements",

- International Conference on Indoor Positioning and Indoor Navigation*, Oct. 2013.
- [5] S. Ayub, B. M. Heravi, A. Bahraminasab, and B. Honary, "Pedestrian Direction of Movement Determination using Smartphone", *Sixth International Conference on Next Generation Mobile Applications, Services and Technologies*, pp. 64-69, 2012.
- [6] W. Kang, S. Nam, Y. Han, and S. Lee, "Improved Heading Estimation for Smartphone-Based Indoor Positioning Systems", *IEEE 23<sup>rd</sup> International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC)*, pp. 2449-2453, 2012.
- [7] G. Jekabsons, V. Kairish, and V. Zuravlyov, "An Analysis of Wi-Fi Based Indoor Positioning Accuracy", *Scientific Journal of Riga Technical University*, Vol. 47, pp. 131-137. 2011.
- [8] S. Schmitt, S. Adler, and M. Kyas, "The Effects of Human Body Shadowing in RF-based Indoor Localization", *International Conference on Indoor Positioning and Indoor Navigation*, pp. 307-313, Oct. 2014.
- [9] B.R. Ignjatovic, B. B. Andjelinic, M. I. Simic, "Impact of the User Orientation on WLAN Positioning Based upon the Access Point with the Strongest Signal", *TELSIKS*, pp. 233-236, Oct. 2013.
- [10] B. Mrzovac, B. M. Todorovic, M. Z. Bjelica, and D. Kukolj, "Reaching the Next Level of Indoor Human Presence Detection: An RF Based Solution", *TELSIKS*, pp. 297-300, 2013.
- [11] F. D. Rosa, M. Pelosi, and J. Nurmi, "Human-Induced Effects on RSS Ranging Measurements for Cooperative Positioning", *International Journal of Navigation and Observation*, 2012.
- [12] J. Suto and Stefan Oniga, "Efficiency investigation of artificial neural networks in human activity recognition", Springer, May 2017.
- [13] Y. Kwon, K. Kang, and C. Bae, "Analysis and Evaluation of Smartphone-based Human Activity Recognition Using a Neural Network Approach", *Publication in a Scientific Journal of the Series of Scientific Journal of RTU*, 2015.
- [14] B. Çatalbaş, B. Çatalbaş, Ö. Morgül, "Human Activity Recognition with Different Artificial Neural Network Based Classifiers", *Signal Processing and Communications Applications Conference*, 2017.
- [15] Z. Wang, M. Jiang, Y. Hu, H. Li, "An Incremental Learning Method Based on Probabilistic Neural Networks and Adjustable Fuzzy Clustering for Human Activity Recognition by Using Wearable Sensors", *IEEE Transactions on Information Technology in Biomedicine*, Vol. 16, No. 4, pp. 691-699, 2012.
- [16] (2017) Google Play website. [Online]. Available : <https://play.google.com/store/apps/details?id=com.fivasim.androsensor&hl=tr>
- [17] F. Ichikawa, J. Chipchase, R. Grignani, "Where's the Phone? A study of Mobile Phone Location in Public Spaces", *International Conference on Mobile Technology, Applications and Systems*, 2005.
- [18] M. F. Moller, "A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning", *Neural Networks*, Vol. 9, pp. 525-533, 1993.