



İç mekân konum tespitinde sinyal haritasının küçültülmesi ve performans analizi

Serpil Ustebay*^{ID}, Ergün Gümüş^{ID}, Muhammed Ali Aydın^{ID}, Ahmet Sertbaş^{ID}
İstanbul Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği, 34320 Avcılar, İstanbul, Türkiye

Ö N E Ç I K A N L A R

- Çok binalı/katlı yapılar için etkili bir kullanıcı konumlandırma sistemi tasarlanmıştır
- Parmak izi, Temel Bileşen Analizi yardımıyla küçültülmüştür
- Konumlandırma modeli için üç farklı makine öğrenme yöntemi kullanılmıştır

Makale Bilgileri

Geliş: 11.07.2016
Kabul: 27.04.2017

DOI:

10.17341/gazimmfd.369507

Anahtar Kelimeler:

İç mekân konumlandırma, kablosuz erişim noktası seçimi, parmak izi küçültme, temel bileşen analizi, k-en yakın komşuluk, destek vektör makineleri, doğrusal ayırtaç analizi

ÖZET

İç mekân konum tespitinde farklı yaklaşımlar geliştirilmiş olsa da mekânın “parmak izi” adı verilen sinyal haritasını kullanan yöntemler popülerliğini korumaktadır. Bu yöntemlerin; ekstra bir maliyet gerektirmemesi ve hali hazırda kurulmuş olan Kablosuz Erişim Noktalarını (KEN) kullanması en önemli avantajlarından biridir. Bu sistemlerde konum tespiti: (i) sinyal haritasının oluşturulması ve (ii) bu harita üzerinden kişinin konum tespitinin yapılması şeklinde iki aşamadan oluşmaktadır. Sinyal haritasını oluşturmak için kullanılan KEN sayısı ve konumu; sistemin maliyetini, konumlandırma doğruluğunu ve çalışma hızını etkileyen önemli faktörlerdir. Bu çalışma ile konumlandırma doğruluğundan ödün vermeden, daha düşük maliyetli ve daha hızlı bir sistemin oluşturulması için etkisiz KEN’leri eleyen bir küçültme yöntemi önerilmektedir. Bu amaçla başarılı bir boyut azaltım yöntemi olan Temel Bileşen Analizi (TBA) yöntemine başvurulmuştur. Önerilen yaklaşım, küçültülmüş sinyal haritası ve kullanıcının seçtiği üç farklı makine öğrenme yöntemini (K-En Yakın Komşuluk, Destek Vektör Makineleri, Doğrusal Ayırtaç Analizi) kullanan bir konumlandırma modelinden oluşmaktadır. Uygulama sonucunda, KEN sayısı %70 azaltılmış modelin, K-En Yakın Komşuluk yöntemi kullanıldığında %91 doğrulukla ve sinyal haritası küçültülmesi yapılmamış modele göre ortalama %75 (test süresi üzerinden) daha hızlı bir şekilde kişinin konumunu tespit edebildiği görülmüştür.

Signal map reduction for indoor localization and performance analysis

H I G H L I G H T S

- An efficient user localization system is designed for multi building / floor structures
- Fingerprint is reduced with utilization of Principal Component Analysis
- Three types of machine learning methods are used for localization model

Article Info

Received: 11.07.2016
Accepted: 27.04.2017

DOI:

10.17341/gazimmfd.369507

Keywords:

Indoor localization, wireless access point selection, fingerprint reduction, principal component analysis, k-nearest neighbors, support vector machines, linear discriminant analysis

ABSTRACT

Although different approaches have been developed for indoor localization, methods using the signal map called “fingerprint” of the space keep their popularity. Most important advantages of these methods are; not requiring extra cost and using existing established Wireless Access Points (WAP). In these systems, localization consists of two steps: (i) generating a signal map and (ii) locating the person over the map. The number and position of WAPs used to generate the signal map are important factors affecting the cost of the system, localization accuracy and operating speed. This work proposes a minimization method that avoids ineffective KENs to create a lower cost and faster system without compromising localization accuracy. For this purpose, Principal Component Analysis (PCA) method which is a successful dimension reduction tool has been utilized. The proposed system consists of a reduced signal map and a localization model using three different machine learning methods (K-Nearest Neighbor, Support Vector Machines, Linear Discriminant Analysis) chosen by the user. As a result of the application, it was seen that the model with 70% less WAPs was able to detect the position of the person with 91% accuracy using K-Nearest Neighbors method and 75% (over the test time) faster compared to the model of non-reduced signal map.

*Sorumlu Yazar/Corresponding Author: serpil.ustebay@istanbul.edu.tr / Tel: +90 212 473 7070

1. GİRİŞ (INTRODUCTION)

Son yıllarda, farklı teknolojilerin internet gibi ortak bir alt yapı ile bütünleştirilmesi herhangi bir ortamda bağlantıya hazır farklı uygulamaların geliştirilmesini sağlamıştır. Özellikle “nesnelerin interneti” kavramıyla birlikte konum bilgisine ulaşmak popüler bir araştırma alanı haline gelmiştir. Dış mekânlarda konum bulmak için kullanılan en yaygın yöntemlerden biri olan GPS (Global Positioning System) çok yüksek başarı sağlamasına rağmen iç mekân söz konusu olduğunda aynı başarıdan söz edilememektedir. Bundan dolayı iç mekânlar için düşük maliyetli çözüm arayışına girilmiştir.

Kapalı mekânlarda kişi bazlı konum tespiti pek çok alanda kullanılabilir. Doğal afet sonucu girilmesi zor alanlarda sıkışmış insanların olup olmadığı taşıdıkları mobil cihazlar ile uzaktan tespit edilebilir. Büyük kurumlarda, personel izleme modülü kullanarak personelin kurum içerisinde nerede olduğu, hangi birimler ile sürekli iletişimde olduğu takip edilebilir. Hastanelerde, araç/hasta izleme modülü ile pahalı ekipmanların kaybolması önlenir, ihtiyaç halinde en yakın ekipmanın nerede olduğu bilgisi alınabilir veya hastaların yönlendirilmesi sağlanabilir. Müzelerde kullanılmak üzere hazırlanan konum bazlı elektronik rehberler ile ziyaretçiler bilgilendirilebilir. Büyük alışveriş merkezlerinde (AVM) kişinin kendi konumunu kolayca tespit edip istediği mağazayı uygun yönlendirmeler ile aramadan kolayca tespit etmesi sağlanabilir. Yine haftalık veya aylık hazırlanacak istatistiksel veriler ile AVM’lerdeki yoğun bölgeler tespit edilip bu alanlardaki reklam çalışmaları düzenlenebilir veya nispeten az rağbet görmüş alanlar tespit edilerek özel kampanyalar ve etkinlikler ile bu alana olan ilgi artırılabilir. Askeri uygulamalarda hafif, az maliyetli, metre seviyesinde hassas doğrulukta sistemler operasyonlar sırasında hayati önem arz eder.

Bu çalışmada “parmak izi” adı verilen ve konum bulmada kullanılan kablosuz erişim noktalarından (KEN) alınan sinyal gücü kayıtlarından oluşturulmuş bir sinyal haritası üzerinde yapılan etkin küçültme işleminin konumlandırma başarısına etkisi incelenmiştir. Bu bağlamda KEN uzayındaki konum-sinyal gücü ölçümleri Temel Bileşen Analizi (TBA) yöntemiyle yeni bir veri uzayına aktarılmış ve bu yeni uzayda kademeli boyut azaltımına gidilerek konumlandırma başarımındaki etkisi düşük olan KEN modülleri sinyal haritasından çıkartılmıştır. Kademeli olarak küçültülen haritadaki ölçümler üzerinden K-En Yakın Komşuluk (K-EYK), Destek Vektör Makineleri (DVM) ve Doğrusal Ayırtaç Analizi (DAA) yöntemleriyle sınıflandırma (konumlandırma testleri) yapılarak başarımdan ödün vermeden konumlandırma için gerekli olan KEN alt kümesini tespit eden bir model oluşturulmuştur. Çalışma sonuçları “Daha fazla KEN = Daha fazla başarı” algısının çoğunlukla doğru olmadığını göstermektedir. Çalışmaya ait MATLAB uygulama kodlarına <http://ce.istanbul.edu.tr/serpilustebay> adresinden erişilebilir. Çalışmanın sonraki kısımları şu şekilde organize edilmiştir:

2. bölüm konumlandırma konusunda literatürde öne çıkan çalışmaların bir özetini içermektedir. 3. bölümde bu çalışmada kullanılan veri kümesi (sinyal haritası) ve konumlandırma için faydalanılan makine öğrenme algoritmaları tanıtılmaktadır. Tasarlanan KEN seçim modeli ve elde edilen deneysel sonuçlar 4. bölümde sunulmuştur. Çalışmanın sonuçları literatürde rapor edilen diğer sonuçlarla beraber 5. bölümde değerlendirilmiştir.

2 İLGİLİ ÇALIŞMALAR (RELATED WORKS)

Sinyal gücüne dayanarak iç mekân konum tespiti fikrinin temeli 2000 yılında atılmıştır [1]. Bu çalışmada bina içerisine dağıtılan farklı KEN’lerden toplanan sinyal güçleri kayıt altına alınmış ve parmak izi adı verilen sinyal haritası oluşturulmuştur. Sonrasında bu sinyal haritası ve K-EYK yöntemi kullanılarak bina içindeki bir kişinin konumu tespit edilmeye çalışılmıştır. Bu çalışmadan itibaren iç mekân konum tespiti büyük bir araştırma alanı olarak görülmüş ve büyük firmaların bu konudaki yatırımlarıyla Yıllık Bileşik Büyüme Oranı (YBBO) %44,87 ye varan bir pazara dönüşmüştür [2]. Ekahau [3] ve AeroScout [4] gibi birçok büyük firma bu alanda çalışmalarına devam etmektedir ve araştırmacılar daha düşük maliyetli çözümler üzerinde de çalışmaktadır [5].

Sinyal haritaları düzenli ve düzensiz olmak üzere iki farklı şekilde oluşturulabilir. Düzenli formda, alan küçük karelere bölünür [6] ve bu karelerin köşelerinden [7] veya ortasından ölçüm alınır [8]. Düzensiz formda ise alan üzerinde rastgele noktalardan ölçüm yapılır [9]. Mekân içeriside yürünerek veriler toplanır [10]. Ancak her iki yaklaşımda da sinyal haritasının oluşturulması zorlu ve karmaşık bir süreçtir. Yanlış konumlandırılan KEN’ler neden oldukları gürültü nedeniyle konumlandırma başarısına olumsuz yönde etki edebilmektedir. Gürültüye sebep olan veya konumlandırma başarısına belirgin bir etkisi olmayan KEN’lerin elenmesi sistemin başarısını ve maliyetini olumlu yönde etkileyecektir. Literatürde, gereksiz KEN’lerin elenerek sinyal haritasının küçültülmesi için önerilen çeşitli yöntemler bulunmaktadır. Fisher Değeri, Newton-Raphson modeline dayanan birbirinden bağımsız değişkenler arasında ki ilişkilerin temsil edilmesi için geliştirmiş özellik seçme algoritmasıdır. Temel fikri; verilen veri setinin bir alt kümesini bulmaktır. Bunun için veri seti; aynı sınıftaki veri noktaları arasındaki uzaklık mümkün olduğunca küçültülürken, farklı sınıftaki veri noktaları arasındaki uzaklık artırılır. Her bir özellik için fisher değeri adı verilen bir ağırlık değeri hesaplanır [11]. Başka bir yaklaşım olan Ki-Kare Testi, çıkarımsal istatistik analizinde yaygın olarak kullanılan niteliksel iki bağımsız değişken arasında anlamlı bir bağ olup olmadığının tespitini yapan bir yöntemdir [12]. Aralarında anlamlı bir bağ olmayan değişkenlerin elenmesi ile özellik çıkarım uygulamalarında sıkça kullanılır. Bilgi Kazancı (Information Gain); veriyi temsil eden özellikleri 0 ve 1 arasındaki değerler ile ifade eder. Bunun için özelliklerin her bir sınıf kümesi için ne kadar farklı değer aldığını göz önüne alarak bir ağırlık değeri(bilgi kazanım

değeri) elde edilir. En yüksek ağırlık değerine sahip olan özellikler, veri seti için en anlamlı özelliklerdir. Bilgi kazanım değerlerine göre en anlamlı özelliklerin seçilmesi veri seti boyutunun küçültülmesini sağlar [13]. Literatürde bahsi geçen çalışmaların, bu çalışmayla olan karşılaştırmalı sonuçları Bölüm 4’de verilmiştir.

3. MALZEME VE YÖNTEM (MATERIAL AND METHOD)

3.1. Kullanılan Kablosuz Sinyal Haritası (Used Wireless Signal Map)

İç mekân konum tespiti, Şekil 1’de görüldüğü gibi çevrimiçi ve çevrimdışı olmak üzere iki aşamadan oluşur. Sinyal haritası çevrimdışı aşamada elde edilir. Öncelikle bina içerisinde ölçüm yapılacak referans noktaları belirlenir. Bu noktalarda mobil cihazın mevcut KEN’lerden aldığı sinyal gücü seviyesi tespit edilir. Bunun için genellikle Android işletim sistemi tabanlı programlar geliştirilir. Bu programlar istenilen bir t anında RSSI bilgilerini kullanıcılara sunar. Bu bilgilere; referans noktasının bulunduğu bina, kat ve oda numarası bilgileri de eklenerek sinyal haritası elde edilir.

Çevrimiçi aşamada ise sinyal haritası ve bir dizi makine öğrenme yöntemi kullanılarak merkezi sunucuda bir konumlandırma modeli oluşturulur. Gerçek zamanlı uygulamalar için oldukça uygun olan bu yöntemde; kullanıcıların konumları belirlenirken mobil cihazlarında kurulu olan bir uygulama, anlık olarak topladığı RSSI bilgilerini merkezi sunucuya iletir. Sunucu, gelen bilgiyi konumlandırma modelinde işler ve kullanıcının bulunduğu konumu tahmin eder.

Bu çalışmada, literatürde bulunan kullanıma açık en büyük sinyal haritalarından biri olması aynı zamanda içerisinde çok fazla erişim noktası barındırması nedeniyle UJIndoorLoc veri kümesi kullanılmıştır [9]. Veri kümesi, bir üniversite kampüsü içerisindeki dört veya beş katlı üç farklı binada bulunan toplam 520 adet KEN’den toplanan 21048 adet ölçümden oluşmaktadır. Veri kümesinde bulunan *BuildingID*, *Floor* ve *SpaceID* alanları her ölçümün sırasıyla hangi binada, kaçınca katta ve hangi odada yapıldığını

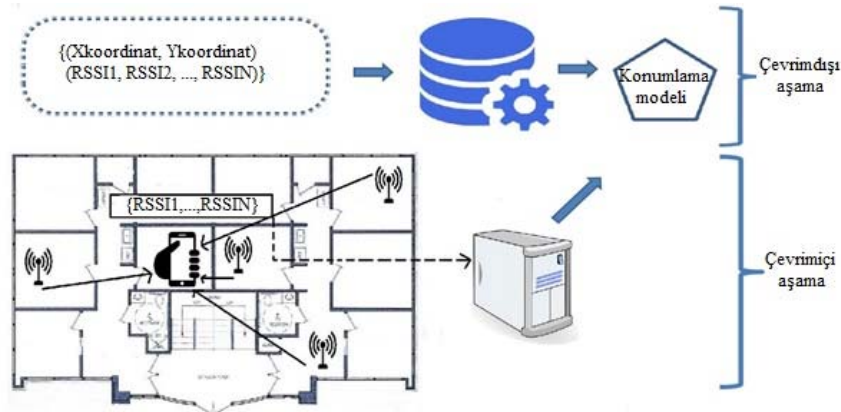
göstermektedir. Her ölçüm için ayrıca enlem ve boylam bilgileri de kayıt edilmiştir. Şekil 2’de veri kümesindeki enlem, boylam ve kat bilgilerinden faydalanılarak oluşturulmuş üç boyutlu harita görülmektedir. Bina içinde seçilen referans noktalarındaki ölçümler için katılımcıların bilgileri gizli tutulmuştur. Kendilerine birer ID değeri ve kullanıcı adı atanmıştır. Katılımcıların boy ortalaması 172.7 cm’dir. Verilerin toplanma aşamasında gerçek zamanlı uygulamalara uygun heterojen bir yapı elde edebilmek için farklı model mobil cihazlar kullanılmıştır. Her bir cihazın ölçüm anında elde ettiği RSSI değeri bir diğerinden farklı olabilir. Gerçek zamanlı bir uygulamada kullanıcıların mobil cihazlarının birbirinden farklı olduğu düşünülürse, ölçüm cihazlarının farklı çeşitte olması daha gerçekçi bir veri kümesi elde edilmesini sağlamıştır. Kullanılan cihazların marka, model ve işletim sistemi bilgisi Tablo 1’de görülmektedir. Bazı cihazlar aynı marka ve modelde olmasına rağmen farklı işletim sistemlerine sahiptirler.

3.2. Konumlandırma Modeli İçin Kullanılan Yöntemler (Methods for Localization Model)

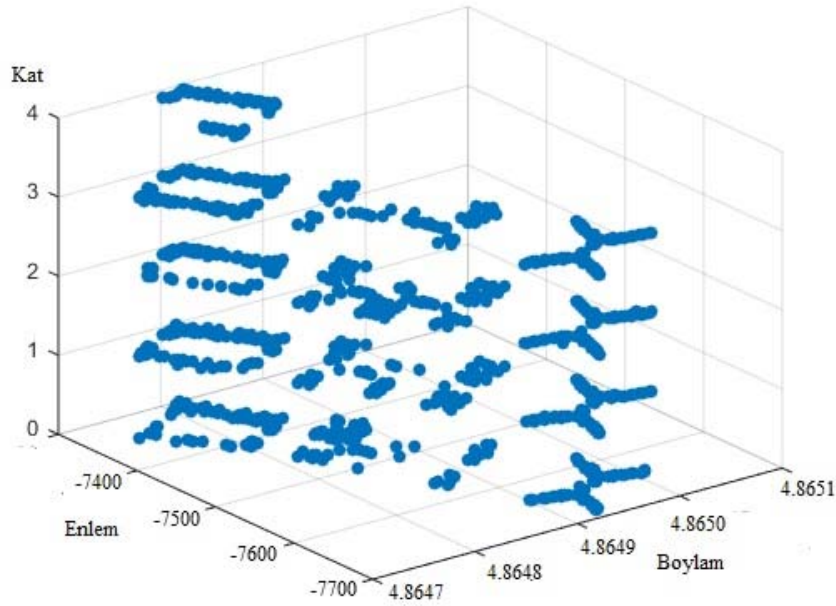
Bu çalışmada harita boyutunu küçültmek ve kullanılan özelliklerin sayısını azaltmak amacıyla Temel Bileşen Analizi, sınıflandırma işleminde ise En Yakın Komşuluk (EYK), Destek Vektör Makineleri (DVM) ve Doğrusal Ayırtaç Analizi (DAA) yöntemleri kullanılmıştır.

3.2.1. Temel bileşen analizi (Principal component analysis)

Temel bileşen analizi, veride boyut (öznelik) azaltımı ve buna bağlı olarak iki ya da üç boyutlu uzayda verinin dağılımının izlenmesi için kullanılan istatistiksel bir yöntemdir [14]. Yöntemin ana amacı, veri kümesini oluşturan örneklerden farklı grupta olanları birbirinden daha iyi ayırabilecek baz vektörlerine (temel bileşenlere) sahip yeni bir veri uzayı bulmak ve bu vektörler aracılığıyla veriyi yeni uzaya taşımak, bir diğer deyişle iz düşürmektir. Verinin iz düşürüldüğü yeni uzayın her temel bileşenindeki değişinti(varyans) miktarının en büyük olması hedeflenir. Örnek olarak, S uzayındaki N adet örnek içeren D boyutlu veri kümemizdeki ($X = [x_1, x_2, \dots, x_N]$) örneklerin tek



Şekil 1. İç mekân konum tespitinin çevrimiçi ve çevrimdışı aşamaları
(Online and offline steps for determining indoor location)



Şekil 2. UJIndoorLoc veri kümesinin enlem, boylam ve kat bilgisiyle oluşturulmuş 3B haritası (3D map of UJIndoorLoc dataset using latitude, longitude, and floor information)

Tablo 1. Ölçümde kullanılan mobil cihaz bilgileri (Mobile device information used in measurement)

Telefon ID	Cihaz Marka/Model	Android İşletim Sistemi Versiyonu
0	Celkon A27	4.0.4 (6577)
1	GT-I8160	2.3.6
2	GT-I8160	4.1.2
3	GT-I9100	4.0.4
4	GT-I9300	4.1.2
5	GT-I9505	4.2.2
6	GT-S5360	2.3.6
7	GT-S6500	2.3.6
8	Galaxy Nexus	4.2.2
9	Galaxy Nexus	4.3
10	HTC Desire HD	2.3.5
11	HTC One	4.1.2
12	HTC One	4.2.2
13	HTC Wildfire	2.3.5
14	LT22i	4.0.4
15	LT22i	4.1.2
16	LT26i	4.0.4
17	M1005D	4.0.4
18	MT11i	2.3.4
19	Nexus 4	4.2.2
20	Nexus 4	4.3
21	Nexus S	4.1.2
22	Orange Monte Carlo	2.3.5
23	Transformer TF101	4.0.3
24	bq Curie	4.1.1

boyutlu S' uzayına v_l temel bileşeni aracılığıyla $v_l^T X$ şeklinde taşındığını/iz düşürüldüğünü kabul edelim. S' uzayına taşınan verinin değişintisi Eş. 1'deki gibi elde edilir. Burada C , X verisinin S uzayındaki özdeğişinti matrisi, \bar{X} ise ortalamasıdır.

$$\frac{1}{N} \sum_{i=1}^N \{v_l^T x_i - v_l^T \bar{X}\} = v_l^T C v_l \quad (1)$$

Eş. 1'den de görüleceği üzere S uzayındaki özdeğişinti bilgisi, v_l temel bileşeni yardımıyla S' uzayındaki değişinti

miktarmı bulmak için kullanılabilir. Amaç, bu değeri en büyük kılacak en uygun v_l bileşenini elde etmektir. Ancak bunu sağlarken de v_l bileşeninin uzunluğunun (normunun) tam 1 birim olması gerekmektedir. Bu kısıtın λ_l gibi bir Lagrange çarpanı yardımıyla Eş. 1'e eklenmesiyle Eş. 2 elde edilir [15].

$$v_l^T C_v^{-1} + \lambda_l (1 - v_l^T) v_l \quad (2)$$

Bulunan ifadenin v_l 'e göre türevinin sıfıra eşitlenmesiyle eniyileme problemimiz, $C v_l = \lambda_l v_l$ şeklinde bir özdeğer-özvektör problemine dönüşür. Bu problemin çözümüyle elde edilen λ_l özdeğeri, v_l temel bileşeniyle S' uzayına taşınan verinin bu yeni uzaydaki değışinti miktarıdır.

3.2.2. Doğrusal ayırtaç analizi (Linear discriminant analysis)

Temel bileşen analizi yöntemi (TBA) verideki değışintinin en büyük olmasını hedefleyerek farklı gruplara ait örneklerin birbirlerinden daha belirgin bir şekilde ayırt edilmesini hedefleyen bir yöntem olmasına karşın, örneklerin sınıf etiketlerini hesaba katmadığından bu amacı garantileyememektedir. Buna karşılık Doğrusal Ayırtaç Analizi yöntemi örnekleri sınıf etiketlerine göre gruplandırmakta ve iki ana amaca yönelik olarak TBA yöntemine benzer şekilde verinin taşınacağı/iz düşürüleceği yeni uzayın temel bileşenlerini bulmayı hedeflemektedir [16]. Yeni veri uzayındaki örnekler için bu iki amaç; *i.* Farklı grupların merkezlerinin değışintisini en büyük kılmak, *ii.* Her grubun kendi içindeki değışintiye en küçük kılmak şeklindedir. Böylelikle grupların birbirlerine mümkün olduğunca uzak ve kendi içlerinde de mümkün olduğunca toplu olması sağlanır. Örneklerin yeni uzaya taşınması/iz düşürülmesi için kullanılan temel bileşen w_l vektörüyle, orijinal veri uzayındaki grupların merkezlerinin değışintisi S_B , ve grupların kendi içlerindeki değışinti de S_W özdeğışinti matrisleriyle ifade edilmek üzere, Eş. 3'deki ifade en büyük kılınmalıdır [17].

$$v_l^T S_B w_l / v_l^T S_W w_l \quad (3)$$

Bu ifadenin w_l 'e göre türevinin sıfıra eşitlenmesiyle en iyileme problemi $S_W^{-1} S_B w_l = \varphi_l w_l$ şeklindeki özdeğer-özvektör problemine dönüşür. Bu problemin çözümüyle elde edilen w_l temel bileşeni, hedeflenen iki amacı en iyi şekilde sağlayan ayırtaç olarak isimlendirilir.

3.2.3. Destek vektör makineleri (Support vector machines)

Doğrusal sınıflandırma problemi için önerilen yaklaşımlardan biri kenar payı (marjin) sınıflandırıcılar olup bu sınıflandırıcıların en popülerleri Destek Vektör Makineleri (DVM) sınıflandırıcısıdır. DVM yaklaşımında, söz gelimi iki boyutlu bir S uzayındaki pozitif ve negatif sınıftan örnekleri birbirinden ayıran ve Eş. 4'de görülen bir doğrunun var olduğu kabul edilir.

$$f(x) = w_1 x_1 + w_2 x_2 + k = w^T x + k = 0 \quad (4)$$

$f(x)$ doğrusu, w ağırlık vektörü ve k öteleme miktarı ile tanımlanır. x , S uzayındaki bir örnek olup, $f(x) \geq 1$ olması durumunda bu örneğin pozitif sınıftan, $f(x) \leq -1$ olması durumunda da negatif sınıftan olduğu kabul edilir. Bu durum Eş. 5'deki genel ifadeyle gösterilebilir. Burada c , x örneğinin sınıf etiketini göstermektedir (x , pozitif sınıftansa $c = +1$, negatif sınıftansa $c = -1$).

$$c(w^T x + k) \geq +1 \quad (5)$$

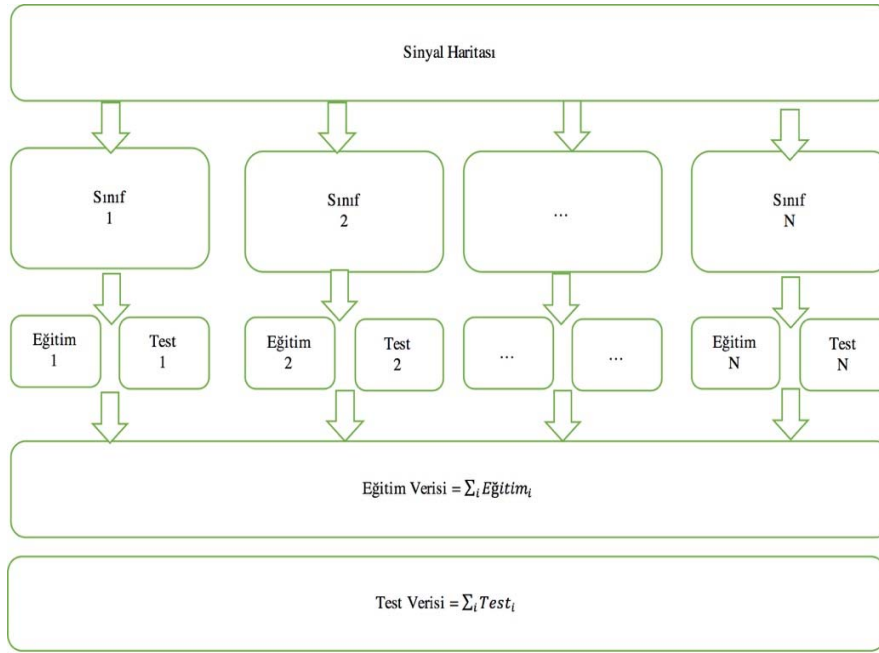
DVM yönteminin amacı, S uzayındaki bütün örnekler için Eş. 5'deki ifadeyi sağlayan yeni bir S' veri uzayının w ağırlık katsayılarını bulmaktır. Yöntem, kuadratik bir eniyileme probleminin çözümüyle bu yeni veri uzayının temel bileşenlerini bulmakta ve orijinal veri uzayında birbirinden doğrusal olarak ayrılamayan örnekleri yeni veri uzayında doğrusal olarak ayırabilmektedir. Klasik DVM yönteminin bir dezavantajı yöntemin iki sınıflı problemler için tasarlanmış olmasıdır. Bu nedenle, bu çalışmada ikiden fazla sınıf içeren problemlerde çalışabilen LibSVM kütüphanesinden faydalanılmıştır [18].

4. UYGULAMA VE TEST SONUÇLARI (APPLICATION AND TEST RESULTS)

UJIndoorLoc veri kümesindeki ölçümler negatif değerler içermektedir. Ancak, oluşturulan konumlandırma modelindeki sınıflandırıcılarda kullanılan verinin pozitif değerler içermesi gerektiğinden öncelikle veri kümesindeki değerler Eş. 6'dan faydalanarak negatif olmayan sayılara dönüştürülmüştür [19]. Dönüştürme işleminden sonra yüksek değerler güçlü sinyal şiddetini, düşük değerler ise zayıf sinyal şiddetini göstermektedir.

$$\text{Pozitif}_i = \begin{cases} (RSS_i - \min), & \text{Eğer sinyal gücü } (RSS_i) \geq \tau \\ 0, & \text{diğer durumlarda} \end{cases} \quad (6)$$

Dönüştürme işleminde kullanılan RSS_i , i . ölçümün RSS değerini; \min ise veri kümesindeki en küçük RSS değerini temsil etmektedir. UJIndoorLoc veri kümesi için \min değeri -104 dbm'dir. Eşik değeri, τ , -100 dbm olarak kabul edilmiştir. Bölüm 3.1'de belirtildiği gibi UJIndoorLoc veri kümesi 520 KEN'den (öznitelikler) alınan 21048 adet ölçüm (örnekler) içermektedir. Ancak bu çalışmada sadece oda içinden yapılan 3329 adet ölçüm kullanılmıştır. Kullanılan ölçümler *BuildingID*, *Floor* ve *SpaceID* bilgisine göre yeniden etiketlenilerek toplamda 174 sınıfa dağıtılmıştır. Veri kümesi için herhangi bir konumlandırma modeli oluşturmadan/eğitmeden önce kümeyi oluşturan örneklerin "eğitim" ve "test" alt kümelerine ayrılması gerekir. Bu amaçla, örneklerin kullanıcı tarafından belirlenen bir yüzdeliği eğitim kümesi, kalan kısmı ise test kümesi olarak ayrılır. Ancak bu ayırım örnek bazında rastgele seçim yerine sınıf bazında rastgele seçim ile gerçekleştirilir. Böylece herhangi bir sınıf için; eğitim kümesine dahil edilen örneklerin sayısının, o sınıfın tüm örneklerinin sayısına oranı her sınıf için eşit olmaktadır. Eğitim ve test kümelerinin oluşturulması işlemi Şekil 3'de görülmektedir.



Şekil 3. Eğitim ve test kümelerinin oluşturulması (Forming training and test sets)

Şekil 3’de görüldüğü üzere veri kümesindeki (sinyal haritası) tüm örnekler *SpaceID* değerlerine göre gruplanmıştır. *Sınıf_i*, *SpaceID* değeri *i* olan örneklerin oluşturduğu kümedir. Bu kümenin içindeki örneklerin sırası rastgele bir dizilime göre yeniden sıralanmakta ve kullanıcı tarafından belirlenen bir orana (*eğitim_oranı*) göre *Eğitim_i* ve *Test_i* şeklinde iki parçaya bölünmektedir. Tüm eğitim kümelerinin bir araya gelmesi ile eğitim verisi, test kümelerinin bir araya getirilmesi ile de test verisi oluşturulmuştur. Oluşturulan eğitim kümesi; (i) Sinyal haritasının küçültülmesi (KEN sayısının azaltılması), (ii) Küçültülmüş sinyal haritası ile konumlandırma modelinin oluşturulması amaçlarıyla kullanılmaktadır.

Birinci aşama sinyal haritasının küçültülmesi aşaması olup öncelikle eğitim kümesi, Bölüm 3.2.1’de değinilen TBA yöntemi kullanılarak 520 boyutlu (KEN sayısı kadar) orijinal eğitim uzayından yine 520 boyutlu yeni bir eğitim uzayına transfer edilir. Buradaki amaç; örneklerin izdüşümlerinin değişimlerinin en büyük olduğu, bir diğer deyişle örneklerin, ortalamasının mümkün olduğunca uzağına dağıldığı yeni veri boyutları bulmaktır. Yeni eğitim uzayını oluşturan bu yeni veri boyutlarında, eğitim kümesi örnekleri orijinal eğitim uzayındakine nazaran birbirlerinden daha iyi ayrılır. Bunu sağlayan en önemli faktör yeni veri boyutlarını oluşturmak için kullanılan özvektörler’dir. Her özvektör temelde bir ağırlık vektörü olup oluşturduğu yeni veri boyutu için orijinal veri uzayındaki 520 veri boyutunun (520 KEN) her birinin pozitif/negatif ağırlığını (etkisini) barındırır. Özvektördeki mutlak ağırlığı büyük olan orijinal veri boyutunun (KEN), örneklerin birbirinden ayrılması hususundaki katkısı da büyüktür. Ancak bunu sadece bir özvektöre bakarak söylemek doğru olmaz. Bu nedenle kullanıcı tarafından seçilen ve kendisine ait özdeğeri en büyük olan ilk *m* adet özvektörün mutlak ağırlıkları eleman

eleman çarpılarak çarpım vektörü, *S*, bulunur. *S* vektörünün elemanlarından en büyük *r* adedine karşılık gelen KEN’ler küçültülmüş sinyal haritasını meydana getirir. İkinci aşamada, birinci aşamada kullanılan eğitim kümesi ve kullanıcı tarafından belirlenen makine öğrenme algoritmalarından (K-EYK, DVM veya DAA) herhangi biri kullanılarak konumlandırma modeli oluşturulur/egitilir. Konumlandırma modelinin başarısı test kümesindeki örneklerin konumlarının doğru/yanlış tahmin sonuçlarıyla değerlendirilir. Bu çalışmada hem eğitim hem de test aşamaları çevrimdışı olarak gerçekleştirilmiş olup oluşturulan konumlandırma modeline çevrimiçi aşamaya toplanan yeni test örnekleri de verilerek kişinin konum tespiti yapılabilir. Sinyal haritasının küçültülmesi ve küçültülmüş sinyal haritası ile konumlandırma modelinin oluşturulması sürecine dair sözde kod Şekil 4’de görülmektedir. Şekil 4’de verilen algoritma, istatistiksel doğruluk için 100 kez tekrarlanmaktadır. Her kümeye ait verilerin kendi içerisinde karıştırılarak rastgele seçilip ayrılması, döngünün her iterasyonunda farklı bir doğruluk oranı elde edilmesine neden olacaktır. Bu nedenle ortalama doğruluk değeri göz önüne alınır. Küçültülmüş harita üzerinde konumlandırma işlemi için üç farklı makine öğrenme yöntemi kullanılmıştır. K-EYK için *K* değeri 1 olarak seçilmiş ve mesafe metriği olarak Öklid uzaklığı kullanılmıştır. DVM yönteminde doğrusal çekirdek fonksiyonu kullanılmış ve penaltı değeri (*C*) 1 olarak seçilmiştir. DAA yöntemi ise sözde doğrusal (pseudolinear) analiz türü kullanılmıştır. Bu uygulamada, *eğitim_oranı* değeri ise %70 olarak seçilmiştir. Şekil 5 (a-c)’de sırasıyla K-EYK, DVM ve DAA makine öğrenme yöntemleriyle oluşturulan konumlandırma modellerinin test sonuçları (doğruluk değerleri) verilmiştir. Her üç şekilde de görüleceği üzere KEN sayısı (*r*) arttıkça doğruluk oranı artmaktadır. Ancak kullanılan özvektör sayısının (*m*) etkisinin çok düşük

```

haritaküçült_modeloluştur(n, m, r, Sınıf, eğitim_oranı, KEN_sayısı)
//n: Sınıf Sayısı
//m: Kullanılacak özvektör sayısı
//r: Kullanılacak KEN sayısı
//sınıf: Her sınıfın ölçümlerini tutan {sınıf1, sınıf2, ..., sınıfn} kümesi
//eğitim_oranı: Herhangi bir sınıftaki eğitim örneklerinin tüm örneklere oranı
//KEN_sayısı: Sinyal haritasındaki toplam KEN sayısı

eğitim_kümesi ← {}
test_kümesi ← {}

Döngü i ← 1:n
Küme ← rastgelesıra( Sınıf[i] )
aynım ← eğitim_oranı x elemansayısı ( Küme )
eğitim_kümesi ← eğitim_kümesi ∪ Küme[1:aynım, SÜTUNLAR]
test_kümesi ← test_kümesi ∪ Küme[aynım+1 : elemansayısı( Küme), SÜTUNLAR]
Döngü Sonu

[özvektörler, özdeğerler] ← TBAuygula( eğitim_kümesi )
sıraliendisler1 ← sırala( özdeğerler, "azalansırada" )
özvektörler ← özvektörler[SATIRLAR, sıraliendisler1]

S[KEN_sayısı] ← [1,1, ..., 1] //KEN_sayısı kadar 1 içeren vektör

Döngü j ← 1:m
Döngü k ← 1:KEN_sayısı
S[k] ← S[k] x mutlakdeğer( özvektörler[k,j] )
Döngü Sonu
Döngü Sonu

sıraliendisler2 ← sırala(S, "azalansırada")
Kalan_KENLER ← sıraliendisler2[1 : r]

küçültülmüş_eğitim_kümesi ← eğitim_kümesi( SATIRLAR, kalan_KENLER )
küçültülmüş_test_kümesi ← test_kümesi( SATIRLAR, kalan_KENLER )

konumlandırma_modeli ← seçileneğitimalgoritması( küçültülmüş_eğitim_kümesi )

doğruluk ← seçileneğitimalgoritması( konumlandırma_modeli, küçültülmüş_test_kümesi )

```




Şekil 4. Geliştirilen sistemin algoritması (Algorithm of Developed System)

olduğu görülmüştür. Denemelerde; çarpım vektörünün (S) oluşturulması için 5 özvektörün, başarılı konumlandırma için ise en etkili 150 KEN'in seçilmesinin yeterli olduğu görülmüştür. Şekil 5'de görülen en yüksek doğruluk değerleri K-EYK için 0,91 (%91), DVM için 0,88 (%88) ve DAA için 0,72 (%72)'dir. Kullanılan özvektör sayısı ($m = 5$) için her üç yöntemle de elde edilen doğruluk değerleri Tablo 2'de görülmektedir. En yüksek doğruluk K-EYK yöntemiyle elde edilirken en düşük doğruluk DAA yöntemiyle elde edilmiştir. Sinyal haritasının küçültülmesi işleminde seçilen algoritma konumlandırma başarısını doğrudan etkilemektedir.

Şekil 5'de bu çalışma ile önerilen yaklaşımın Bölüm 2'de değinilen [11-13] diğer yaklaşımlarla karşılaştırılması görülmektedir. Her bir yaklaşım için %10 ila %90 arasında KEN azaltımı yapılmış ve azaltımdan önceki duruma göre EYK komşu algoritmasının 100 tekrarı sonucu elde edilen ortalama doğruluk değerleri sunulmuştur.

Tablo 2. Konumlandırma Modeli Test Sonuçları ($m = 5$)
(Test Results of Localization Model ($m = 5$))

KEN Sayısı	K-EYK	DVM	DAA
10	0,23	0,17	0,12
20	0,43	0,35	0,20
30	0,51	0,45	0,28
40	0,57	0,49	0,31
50	0,63	0,55	0,35
60	0,67	0,60	0,41
70	0,71	0,64	0,46
80	0,75	0,68	0,49
90	0,78	0,71	0,56
100	0,80	0,74	0,55
110	0,82	0,77	0,58
120	0,85	0,80	0,62
130	0,86	0,82	0,66
140	0,88	0,83	0,68
150	0,89	0,85	0,71
520	0,93	0,90	0,87



Şekil 5. Konumlandırma Modeli Test Sonuçları a) K-EYK b) DVM c) DAA)
(Test Results of Localization Model a) KNN b) SVM c) LDA)

Tablo 3. Önerilen konumlandırma modelinin mevcut yöntemlerle karşılaştırılması
(Comparison of proposed localization model with existing methods)

<i>KEN Azaltma Oran</i>	<i>KEN Sayısı</i>	<i>Fisher Değeri</i>	<i>Ki-Kare Testi</i>	<i>Bilgi Kazancı</i>	<i>Önerilen</i>
90	52	36.5697	64.5967	70.8426	72.1664
80	104	75.3688	79.8591	87.7799	87.5946
70	156	88.3538	89.9745	91.1171	91.2429
60	208	92.4123	92.5352	92.4723	92.6987
50	260	93.023	92.6372	92.6912	92.9130
40	312	93.0105	92.8456	92.9685	93.0975
30	364	92.8366	92.9475	92.9145	93.1754
20	416	92.964	92.8726	93.0315	93.1124
10	468	93.069	93.042	93.0465	93.0270
0	520	93.1759	93.1759	93.1759	93.1759

Fisher Değeri yaklaşımında; KEN sayısının %70 azaltılması doğruluk oranında çok büyük bir düşüşe neden olurken; eşik değeri olarak kabul edilebilecek bu negatif etki Ki-Kare testi için %70, Bilgi kazancı ve Önerilen yaklaşımında %80 olarak hesaplanmıştır. Önerilen TBA boyut küçültme yaklaşımında $m=50$ değeri seçilmiştir.

KEN sayısındaki azaltım %50'den fazla olduğunda bu çalışma ile önerilen yaklaşımın diğer yaklaşımlara göre daha düşük bir hata artış oranına sahip olduğu yani KEN sayısından çok daha az etkilendiği, dolayısıyla alt yapısı zayıf mekânlarda bile yüksek doğruluk sağlayabileceği görülmektedir.

Sinyal haritasının küçültülmesi, konumlandırma modelinin iş yükünü azaltmakta ve çalışma hızına olumlu yönde etki etmektedir. Tablo 4, kullanılan her üç makine öğrenmesi yöntemleri ile iç mekân konumlandırma modelinin farklı KEN sayıları ile eğitilmesi için harcanan işlem zamanını, Tablo 5 ise oluşturulmuş olan bu modelin test aşamasında harcanan işlem zamanını göstermektedir. Bu çalışmada yapılan denemelerde 17 3.40 GHz işlemci ve 8 GB RAM'e sahip bir platform kullanılmıştır.

Tablo 4. Kullanılan KEN sayısının model eğitimi süresine(saniye) etkisi
(Effect of number of WAPs on training model time)

<i>KEN Sayısı</i>	<i>K-EYK</i>	<i>DVM</i>	<i>DAA</i>
10	0,0146	0,2436	12,4453
20	0,0112	0,2168	12,4667
30	0,0118	0,2333	12,5297
40	0,0122	0,2549	12,5425
50	0,0124	0,2797	12,6758
60	0,0123	0,2926	12,7459
70	0,0130	0,3098	12,9346
80	0,0133	0,3202	13,0584
90	0,0131	0,3336	13,1682
100	0,0127	0,3476	14,6366
110	0,0137	0,3510	14,7889
120	0,0124	0,3588	14,9988
130	0,0125	0,3650	15,3125
140	0,0126	0,3732	15,4528
150	0,0126	0,3794	15,6107
520	0,0255	0,4788	102,81

Tablo 5. Kullanılan KEN sayısının test süresine (saniye) etkisi

(Effect of number of WAPs on testing model time (second))

<i>KEN Sayısı</i>	<i>K-EYK</i>	<i>DVM</i>	<i>DAA</i>
10	0,031	0,697	0,026
20	0,048	0,726	0,034
30	0,072	0,760	0,046
40	0,092	0,808	0,056
50	0,113	0,841	0,066
60	0,131	0,871	0,074
70	0,155	0,900	0,105
80	0,175	0,913	0,120
90	0,200	0,928	0,135
100	0,222	0,954	0,145
110	0,244	0,967	0,172
120	0,240	0,981	0,178
130	0,263	0,998	0,231
140	0,284	1,014	0,362
150	0,304	1,033	0,390
520	1,165	1,429	5,378

Tablo 4 'de görüleceği üzere KEN sayısında yapılan %71 azaltım konumlandırma modelinin eğitim aşamasını tüm algoritmalar için olumlu etkilemiştir. Veri setinde bulunan 520 KEN önerilen yöntem ile analiz edilip en etkili 150 adet KEN seçildiğinde konum sınıflandırma modelinin eğitimini KNN için %52, DVM için %21 ve LDA için %85 kat hızlandırmıştır. Elde edilen hızlandırma modelin test aşamasını da olumlu etkilemiştir. Konumlandırma modelinin eğitiminde toplam 2330, test aşamasında ise 999 örnek kullanılmıştır. KEN sayısının azaltım yapılmamış durumuna göre kullanıcının konumu Tablo 4 de görüldüğü gibi KNN için %75, DVM için %28 ve LDA için %93 daha hızlı yapılabilmektedir. Kalabalık mekânlarda gerçek zamanlı konum tespit uygulaması gerçekleştirilebilmesi için oluşturulacak olan sistemin hızlı sonuç vermesi oldukça önemlidir.

5. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)

Popüler bir araştırma alanı olan iç mekân konumlandırma konusunda farklı yaklaşımlar kullanılmaktadır. Bu yaklaşımlardan en yaygın olanı IEEE 802.11 WLAN

standartıyla belirlenmiş Kablosuz Erişim Noktalarından (KEN) elde edilen sinyal ölçümlerinden faydalanarak parmak izi olarak da bilinen sinyal haritası oluşturularak kişinin konumunun tespit edilmesidir. KEN tabanlı yaklaşımda mekânda kör nokta bırakmayacak şekilde kapsama alanını oluşturmak için fazla sayıda cihaz kullanılabilir. Konumlandırma aşamasında tüm cihazların kullanımı parmak izinin boyutunu büyüttüğü gibi fazladan gürlütle oluşturularak başarıyı da olumsuz etkileyebilmektedir. Bu çalışma ile parmak izinin küçültülmesine yönelik bir yöntem önerilmiştir. Buna göre; her bir KEN'in konumlandırma üzerindeki etkisini ölçmek amacıyla Temel Bileşen Analizi (TBA) yöntemiyle oluşturulmuş yeni parmak izi uzayının özvektörlerinden faydalanılmıştır. En yüksek özdeğere sahip ilk m adet özvektörün içerdiği KEN ağırlıklarının değerlendirilmesi ile KEN'ler, ölçümleri birbirinden ayırma güçlerine göre sıralanmış ve bu sıralama üzerinden kullanıcının istediği ölçüde küçültme yapılmıştır. Ancak TBA yöntemiyle yapılan küçültmenin ne kadar başarılı/etkili olduğu konumlandırma modeli oluşturulup testler yapılmadan değerlendirilemez. Bu amaçla, küçültülmüş sinyal haritasının eğitim örnekleri üzerinde K-En Yakın Komşuluk (K-EYK), Destek Vektör Makineleri (DVM) ve Doğrusal Ayırtaç Analizi (DAA) makine öğrenme yöntemleri çalıştırılarak farklı konumlandırma modelleri oluşturulmuş, test örnekleri üzerinde yapılan konum tahminleri ile bu modellerin karşılaştırmalı doğruluk değerlendirmesi yapılmıştır. Farklı sınıflandırıcılarla oluşturulan konumlandırma modelleri üzerinde yapılan testlerde K-EYK yönteminin, sadece $m = 5$ özvektör kullanılarak yapılan %70'lik (150 KEN'e indirgenmiş) küçültme işleminden sonra dahi K-EYK ile yapılan konumlandırma doğruluğu %89 gibi yüksek bir değere sahip olduğu görülmüştür. Daha büyük m değerleriyle oluşturulmuş ve yine %70'lik küçültme oranına sahip sinyal haritası üzerinde K-EYK kullanıldığında ise bu oran %91'e ulaşabilmiştir. Sinyal haritasında hiç küçültme yapılmadığında K-EYK ile yapılan konumlandırma doğruluğunu %93 olduğu düşünüldüğünde, haritada yapılan bu denli büyük bir küçültme işleminden sonra konumlandırma doğruluğundaki %2'lik azalmanın askeri ve savunma gibi hayati riskler taşımayan uygulama alanları için ihmal edilebilir bir düzeyde olduğu düşünülmektedir. Dolayısıyla alt yapısı zayıf mekânlarda bile yüksek doğruluk sağlayabileceği görülmektedir.

Konumlandırma modelinde kullanılacak diğer iki makine öğrenme yönteminden DVM yönteminin K-EYK yöntemine çok yakın bir başarısının olduğu, ancak DAA yöntemi ile yeterince yüksek sonuçlar elde edilemeyeceği değerlendirilmiştir.

Parmak izi küçültme için literatürde önerilen diğer yöntemler ele alındığında bu çalışma ile önerilen TBA temelli yaklaşıma en yakın konumlandırma performansının Bilgi Kazancı yöntemiyle yapılan küçültme ile elde edildiği görülmüştür. Her iki yaklaşımla yapılan %80'lik küçültme sonucunda, küçültme yapılmadan önceki duruma yakın doğruluk oranlarının elde edildiği görülürken, %80'den daha

büyük küçültme oranları için, önerilen TBA temelli yaklaşımla oluşturulan modelin konumlandırma doğruluğundan daha az taviz verdiği görülmektedir (Tablo 3). Ki-Kare testi ve Fisher değeri benzer performans göstermekte ve veri setinin boyutunu azaltılırken doğruluk değerine olan negatif etkisi önerilen yaklaşımdan oldukça yüksektir. Konumlandırma modellerinde performans ölçütü olarak hız diğer önemli bir etkidir. Kullanıcının yerinin anlık belirlenebilmesi için; modelin hesaplama konum tahminini çok hızlı yapması gerekmektedir. Konumlandırma modelinin matematiksel işlemlerinin karmaşıklığı ve kullandığı verinin büyük olması hızı azaltacaktır. Veri setinin büyüklüğü konumlandırma modelinin eğitim süresini artırmakta (Tablo 4) ve dolaylı olarak kullanıcının bina içerisindeki anlık konum tespit hızını (Tablo 5) azaltmaktadır. Bu çalışma ile önerilen model doğrultusunda geliştirilen konumlandırma sistemlerinde; kullanıcıların konum tespiti KNN için %75, DVM %28 ve DAA için %93 kat daha hızlı yapılabildiği gösterilmiştir.

TEŞEKKÜR (ACKNOWLEDGEMENT)

Bu çalışma İstanbul Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından 37102 proje numarası ile desteklenmiştir. Bu çalışma aynı zamanda İstanbul Üniversitesi, Fen Bilimleri Enstitüsü "Yeni Nesil Kablosuz Ağlar İçin Etkin Bir Kullanıcı Konumlandırma Sistemi Tasarımı" doktora tezinin bir parçasıdır.

KAYNAKLAR (REFERENCES)

1. Paramvir B., Padmanabhan V.N., RADAR: An in-building RF-based user location and tracking system, INFOCOM 2000. Nineteenth Annual Joint Conference of the IEEE Computer and Communications Societies, Proceedings. 2, 777-784, 2000.
2. Technavio. Top 33 Indoor Location-Based Services (LBS) Companies in the US. <https://www.technavio.com/blog/top-33-indoor-location-based-services-lbs-companies-in-the-us>, Yayın Tarihi 19 Haziran 2014, Erişim Tarihi 10.06.2016.
3. Ekahau. Wi-Fi Site Surveys: Passive, Active, RTLS, <https://www.ekahau.com/blog/2010/04/27/wi-fi-site-surveys-passive-active-rtls>. Yayın Tarihi 27 Nisan 2010. Erişim Tarihi 10.06.2016.
4. AeroScout Company. RTLS (Real Time Location Systems) Solutions: <http://www.aeroscout.com/> Yayınlanma Tarihi 10. Ocak. 2011, Erişim Tarihi 10.06.2016.
5. Carlson J.D., Mittek M., Parkison S.A., Sathler P., Bayne D., Psota E.T., Bonasera S.J. Smart watch RSSI localization and refinement for behavioral classification using laser-SLAM for mapping and fingerprinting, Engineering in Medicine and Biology Society (EMBC), 2014 36th Annual International Conference of the IEEE, 2173-2176, August, 2014.
6. Tatar Y., Yıldırım G., A dynamic location estimation technique based on fingerprint using a reduced radio map in wireless sensor networks, Journal of the Faculty

- of Engineering and Architecture of Gazi University, 29 (2), 217-226 2014.
7. Cherntanomwong, P., Suroso D.J., Indoor localization system using wireless sensor networks for stationary and moving target, Information in Communications and Signal Processing (ICICS) 8th International Conference of IEEE, 1-5 December 2011.
 8. Zhang A., Yuan Y., Wu Q., Zhu S., Deng J., Wireless localization based on RSSI fingerprint feature vector, International Journal of Distributed Sensor Networks 11 (11), 2015.
 9. Torres-Sospedra J., Montoliu R., Martínez-Usó, A., Avariento J.P., Arnau, T.J., Benedito-Bordonau M., Huerta J., Ujiindoorloc: A new multi-building and multi-floor database for wlan fingerprint-based indoor localization problems. In Indoor Positioning and Indoor Navigation (IPIN) 2014 International Conference of IEEE, 61-270, October, 2014.
 10. Chen G., Meng X., Wang Y., Zhang Y., Tian P., Yang H., Integrated WiFi/PDR/Smartphone using an unscented kalman filter algorithm for 3D indoor localization, Sensors, 15 (9), 24595-24614, 2015.
 11. Gu Q., Li Z., Han J., Generalized fisher score for feature selection. arXiv preprint arXiv, 1202-3725, 2012.
 12. Liu H., Setiono R., Chi2: Feature selection and discretization of numeric attributes. Tools with artificial intelligence, Seventh international conference on IEEE, 388-391, November, 1995.
 13. Mitchell Tom M., Machine Learning.,The Mc-Graw-Hill Companies, Inc, 0070428077, 997, 1997.
 14. Hotelling H., Analysis of a complex of statistical variables into principal components, Journal of Educational Psychology, 24 (6), 417-441, 1933.
 15. Vapnyarskii I.B., Lagrange multipliers, Encyclopedia of Mathematics, 978, 1-55, 2001.
 16. McLachlan G.J., Discriminant Analysis and Statistical Pattern Recognition. Wiley Interscience, 544, 2004.
 17. Alpaydin E., Yapay Öğrenme, Boğaziçi Üniversitesi Yayinevi, 2013.
 18. Chang C.C., Lin C.J., LIBSVM: A library for support vector machines, ACM Transactions on Intelligent Systems and Technology, 2:3, 27, 2011.
 19. Torres-Sospedra J., Montoliu R., Trilles S., Belmonte Ó., Huerta J., Comprehensive analysis of distance and similarity measures for Wi-Fi fingerprinting indoor positioning systems, Expert Systems with Applications, 42 (23), 9263-9278, 2015.

