Yapay Sinir Ağları ile WiFi Tabanlı İç Mekan Konumlandırma

Can Tunca[1], Edip Toplan[1], Sinan Işıka[2], Cem Ersoy[1]
1 Boğaziçi Üniversitesi, Bilgisayar Mühendisliği Bölümü, NETLAB, İstanbul
2 Boğaziçi Üniversitesi, Matematik Bölümü, İstanbul
can.tunca@boun.edu.tr , edip.toplan@boun.edu.tr , isiks@boun.edu.tr , ersoy@boun.edu.tr

Özet: GPS gibi uydu-tabanlı konumlandırma sistemleri navigasyon, sosyal konum hizmetleri, filo takibi gibi çeşitli uygulamaların önünü açmış ve hayatımızın vazgeçilmez bir parçası haline gelmiştir. Fakat, uydu-tabanlı konumlandırma sistemlerinin başarımı iç mekanlarda büyük ölçüde düşmekte veya tamamen etkisiz hale gelmekte ve bu durum alternatif sistemlerin gerekliliğini doğurmaktadır. Bu hususta, kurulum kolaylığı sebebiyle, halihazırda var olan altyapıları kullanan iç mekan konumlandırma sistemleri öne çıkmaktadır. Bu altyapılara örnek olarak WiFi erişim noktalarını verebiliriz. Özellikle son yıllarda, WiFi erişim noktalarının sayısındaki artış, iç mekanlarda çözünürlüğü yüksek ve mekan düzleminde hayli değişken telsiz haritaları sağlamakta ve etraftaki WiFi erişim noktalarının sinyal seviyelerini gözlemleyerek konumlandırma hizmeti sağlayan yöntemlerin önünü açmaktadır. Mobil iletişim aygıtlarının iç mekanlarda konumlandırılması ile ilgili araştırma/geliştirme faaliyetlerimiz için, başlangıç niteliğindeki bu çalışmada, Android tabanlı mobil telefonları konumlandırmak için yapay sinir ağlarının kullanıldığı bir algoritma geliştirildi. Tasarlanan algoritma, ofis ve ev ortamlarında test edilerek başarımı değerlendirildi.

Anahtar Sözcükler: İç Mekan Konumlandırma, WiFi Telsiz Ağları, Yapay Sinir Ağları, Makina Öğrenmesi.

WiFi Based Indoor Localization Using Artificial Neural Networks

Abstract: Satellite-based localization systems such as GPS have enabled various invaluable applications ranging from navigation, social location services and fleet tracking. However, the accuracy of satellite-based systems drops drastically or even disappears in indoor environments, which gives rise to the need of alternative systems. Systems utilizing existing infrastructure are preferable since they significantly ease the deployment process. Among such existing infrastructures, the WiFi access points stand out. The rapid growth in the number of deployed WiFi access points provides high resolution and spatially variable radio maps that enable localization systems based on observing the reception levels of the signals originating from these access points. In this paper, which is a preliminary work of our research/development activities related to the indoor localization of mobile communication devices, we developed a localization algorithm for positioning Android mobile phones using artificial neural networks. The developed algorithm is tested in office and home settings and its performance is evaluated.

Keywords: Indoor Localization, WiFi Radio Networks, Artificial Neural Networks, Machine Learning

1. Giriş

Uydu-tabanlı konumlandırma sistemleri (GPS, GLONASS, vb.), özellikle son yıllarda birçok yeni kullanım alanı doğurmuştur. Filo takibi, sosyal konum hizmetleri, navigasyon (araç veya yaya bazlı), kargo hizmetleri ve acil durum yönetimi bu uygulamalardan sadece bir-

kaçıdır. Ancak, uydu-tabanlı konumlandırma sistemleri, uydu sinyallerinin duvar gibi engelleyici yapılardan geçerken gücünü önemli ölçüde kaybetmesi sebebiyle, iç mekanlarda kullanılamamakta veya başarımları büyük ölçüde düşmektedir. Bu sebeple, başka teknolojilerden faydalanan alternatif iç mekan konumlandırma sistemlerinin gerekliliği doğmuştur.

İç mekan konumlandırma sistemleri birçok yeni kullanım alanı sunmaktadır. Örneğin, iç mekanlarda müşteri/personel takibine olanak sağlanmasıyla çeşitli müşteri istatistikleri toplanabilmekte, müşterilerin sık ziyaret ettiği mağazalar ve hatta bina içi ziyaretçi yoğunluk haritaları çıkarılarak çok ziyaret edilen kritik bölgeler belirlenebilmektedir. Bu bilgiler kullanılarak mağazalar müşterilerine çeşitli kampanyalar duyurabilmekte, ürün reyonlarını daha iyi düzenleyebilmekte, personellerini daha iyi yönetebilmektedir. Yönetimsel açıdan ise müşteri istatistikleri sayesinde ortak alanların çeşitli etkinliklerde kullanılması esnasında uygun fiyatlandırma politikalarını düzenlenebilmektedir.

Başka uygulamalara örnek olarak arkadaş takibi, sosyal buluşma planlama, bina içi ve katlar arası navigasyon, ebeveynler için çocuk takibi, konum tabanlı oyunlar, fabrika/mağaza içi ürün takibi gibi uygulamaları verebiliriz. İç mekan konumlandırma sistemlerinin gelecekte yaygınlaşmasıyla, şüphesiz ki bu kullanım alanlarına yenileri de eklenecektir.

Bir iç mekan konumlandırma sisteminin yaygınlaşabilmesi için kolay kurulum sağlaması esastır. Bu sebeple, ek donanıma ihtiyaç duymadan, halihazırda var olan altyapılardan faydalanan sistemler bir adım öne çıkmaktadır. Ancak, hedeflenen kullanım alanlarına da bağlı olarak, belirli bir hassasiyet hedefinin sağlanması da gerekmektedir.

Özellikle son yıllarda, WiFi erişim noktalarının her eve, mağazaya ve işyerine girmesiyle, bilhassa şehir içi bölgelerde birim alana düşen erişim noktası sayısında büyük bir artış olmuştur. Akıllı telefon gibi yaygın cihazlar sayesinde herhangi bir zamanda, herhangi bir konumda ve özellikle iç mekanlarda birden fazla erişim noktasından sinyal alınmaktadır. Bu sinyal çokluğu ve çeşitliliği, uzamsal alanda yüksek çözünürlüklü ve değişken bir telsiz haritası sağlamaktadır. Bu haritanın karakteristiğini öğrenebilecek bir yöntemle konumlandırma mümkün olmaktadır.

Apple, Samsung gibi büyük akıllı telefon üreticileri de var olan konum servislerinin hassasiyetini arttırmak için WiFi sinyallerinden faydalanmaktadır. Ancak iç mekanlar için tasarlanmış, salt WiFi tabanlı yaygın bir konumlandırma sistemi henüz yoktur.

Bir mekandaki WiFi sinyal haritasının öğrenilmesi, çeşitli cihazlar vasıtasıyla toplanan WiFi izleri (fingerprint) [1] sayesinde gerçekleştirilmektedir. Bu izler tipik olarak duyulan WiFi erişim noktaları hakkında MAC adresi, SSID gibi bilgiler ve her bir erişim noktasından gelen sinyalin sinyal-gürültü oranı gibi ölçütlerin toplamından oluşmaktadır.

Literatürde, WiFi izlerinden faydalanarak bir mekandaki radyo haritasını öğrenen ve bu bilgiye dayanarak konum tahmini yapan birçok yöntem önerilmiştir [2, 3]. Bu yöntemlerin çogunluğu ana konum belirleme şeması olarak iz eşleştirme yöntemini benimsemişlerdir. Bir aygıtın konumu anlık iz ölçümünün daha önceden veri tabanına toplanmış izlerle eşleştirilmesi yöntemiyle belirlenmektedir. Bu yöntem kalibrasyon, çevrim-dışı veya eğitim olarak adlandırılan ilk safhadan ve konumlandırma veya çevrim-içi olarak adlandırılan ikinci safhadan oluşmaktadır [3]. İz tabanlı yöntemlerin ana zorluğu, sinyal dağılımının değişken olmasına sebep olan hareket eden nesneler, kırınımlar ve yansımalardır [4]. Örüntü tanıma tekniklerini kullanan iz tabanlı konumlama algoritmaları belirlenimci ve rastgele, k-en yakın komşu (KNN) [5, 8], yapay sinir ağları [6], Bayes çıkarsama [7], karar destek makinesi (SVM) [8],

temel bileşen analizi (PCA) [9] veya bu tekniklerin bileşimleridir [10, 11].

Biz bu çalışmada bağlanım (regresyon) tabanlı, kullanıcının konumunu sürekli bir uzamsal alana (x ve y koordinat düzlemine) eşleştirebilen bir yöntem öneriyoruz. Bu çalışmada, nihai amacımız olan bina içi Wi-Fi tabanlı hassas konumlandırma sistemine başlangıç niteliğindeki oda içi konum belirleme prototip sistemini ve algoritmasını geliştirdik. Konumlandırma algoritmasında yapay sinir ağlarından faydalandık. Bu ağların bir alt türü olan çok katmanlı perseptronlar, çizgisel olmayan girdileri modelleyebilmekte ve uzamsal alandaki değişimlere adapte olabilmektedir. Bu özellikleriyle WiFi sinyal haritalarını yüksek başarımla öğrenebilmektedirler. Önerdiğimiz yöntemin başarımını değerlendirmek amacıyla ofis ve ev ortamlarında deneyler yaptık.

Bir sonraki bölümde önerdiğimiz sistemin tasarım detaylarını sunacağız. Üçüncü bölümde, sistemin başarım değerlendirmesi amacıyla yaptığımız deneylerin sonuçlarını paylaşacağız. Son olarak sistemin şu anki eksiklerine ve çözülmesi gereken zorluklara, gelecekte planlanan çalışmalara ve genel çıkarımlara yer vereceğiz.

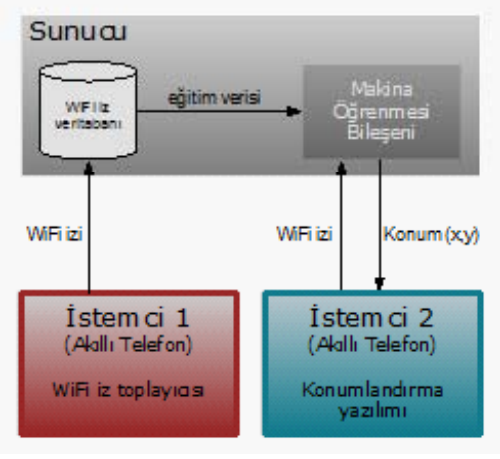

Şekil 1: Sistem genel mimarisi

2. Sistem Tasarımı

Bu çalışmada, son kullanıcının akıllı telefon kullanarak iç mekan konumlandırma hizmetinden faydalanacağı bir yapı tasarladık. Sunucu-istemci mimarisini benimsediğimiz bu sistem, çeşitli bileşenlerden oluşmaktadır. Makina öğrenmesinin esas olduğu sistemde, eğitme ve sonuç alma (konumlandırma) işlemlerini gerçekleştirecek bileşenler bulunmaktadır. Sistemin genel mimarisi Şekil 1'de gösterilmiştir.

2.1. Sunucu İstemci Yapısı

Sistem genel olarak bir sunucu ve iki ayrı istemci bileşeninden oluşmaktadır. Sunucu bileşeninde, toplanan WiFi radyo izlerinin saklandığı bir veritabanı ve makina öğrenmesi bileşeni mevcuttur.

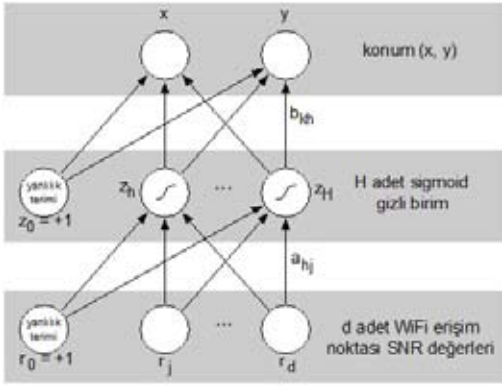

Şekil 2: Çok katmanlı perseptron yapısı

Sistemde, sunucuyla iletişim halinde olan iki farklı istemci bileşeni tasarladık. Bu istemcilerden biri makina öğrenmesi bileşeninin eğitilmesi için gerekli olan WiFi radyo izlerini toplayan bir akıllı telefon uygulamasıdır. Bu istemci, sistem yeni bir mekana kurulurken kullanılacaktır. Diğer istemci ise son kullanıcının sunucudaki makina öğrenmesi bileşeni vasıtasıyla konumlandırma hizmeti alacağı bir uygulamadır. Tüm istemci uygulamaları Android platformunda geliştirilmiştir.

2.2. Makina Öğrenmesi Bileşeni

Konumlandırma işlevini sağlamak amacıyla, yapay sinir ağlarının bir türü olan çok katmanlı perseptron yapısını kullandık. Tipik bir çok katmanlı perseptronda H adet gizli birim bulunmaktadır. Sigmoid fonksiyonunu gerçekleyen bu birimler çizgisel olmayan ayrıştırıcılar modellemektedir. Kullandığımız yapının detayları Şekil 2'de verilmiştir.

Sinir ağının işleyişi şu formüllerle belirtilir (değişken tanımları Tablo 1'de verilmiştir):

$$z_h = \text{sigmoid}(\boldsymbol{a}_h^T \boldsymbol{r}) = \frac{1}{1 + e^{-(\sum_{j=1}^{d} a_{hj} r_j + a_{h0})}}$$

$$y_k = \boldsymbol{b}_k^T \boldsymbol{z} = \sum_{h=1}^{H} b_{kh} z_h + b_{k0}$$

Tablo 1: Sinir ağı formülü değişken tanımları

Sembol	Tanımı
r	Girdi vektörü (WiFi erişim noktası SNR (sinyal/gürültü oranı) değerleri)
a_h	h gizli birimi için ilk katman ağırlıkları
b_k	k çıktısı için ikinci katman ağırlıkları
z_h	h gizli biriminin çıktısı
y_k	ikinci katman k çıktısı
x,y	çıktı koordinatları

Önerdiğimiz bağlanım (regresyon) tabanlı bu model, her girdi için, sürekli bir uzamsal alanda x ve y koordinatları üretmektedir. Bu koordinatlar kullanıcının iç mekandaki konumunun tahminini belirtmektedir. Girdiler ise duyulan erişim noktalarının SNR (sinyal/gürültü oranı) değerlerinden oluşmaktadır. Girdi vektörünün boyutu ortamda duyulma ihtimali olan erişim noktalarının toplam sayısına eşittir.

Çok katmanlı perseptron modelini eğitmek için geri-yayılım algoritması kullanılmakta-dır. Girdilerin hazır hale geldikçe gerçek zamanlı olarak modeli güncelleyebilmesi için çevrimiçi eğitme yöntemi benimsenmiştir. Bu yöntemde girdi örnekleri modele rastgele sırada birer birer verilmekte ve tüm girdi kümesi üzerinden geçilmektedir. Öğrenme katsayısı değişkeni her bir örneğin model parametrelerinin değişimine ne kadar katkı sağladığını belirlemektedir. Tüm girdi kümesinin üzerinden bir geçişe bir tekrar adı verilmekte ve tekrar sayısı değişkeni geçiş adetini belirlemektedir.

3. Başarım Değerlendirmesi

Önerdiğimiz sistemin başarımını değerlendirmek amacıyla ofis ve ev ortamlarında deneyler yaptık. Bir ofis odası ve bir ev salonunda eğitim verisi topladık ve tasarladığımız modeli eğittik. Eğitim ve test verisi olarak kullanılan WiFi izleri, Android işletim sistemini çalıştıran Samsung Galaxy Note II model akıllı telefonla toplanmıştır.

Başarım değerlendirmesi amaçlı kullandığımız çok katmanlı perseptron modelini MATLAB ortamında geliştirdik. Modeli eğitirken kullanılan geri-yayılım algoritmasının eğitim katsayısı 0.01, çevrimiçi eğitimin tekrar sayısı 100 olarak alınmıştır.

Her bir odada (ev salonu ve ofis odası) birer ızgara oluşturacak şekilde 9'ar noktada, her Her bir odada (ev salonu ve ofis odası) birer ızgara oluşturacak şekilde 9'ar noktada, her noktada 10'ar tane olacak şekilde WiFi izleri topladık (her oda için 90'ar iz).

Sistemin başarımını değerlendirmek amacıyla 10-katlı çapraz doğrulama yöntemini kullandık. Bu yöntemde toplanan iz örnekleri kümesi 10 eşit parçaya bölünmekte ve sırayla her bir parça sisteme test girdisi olarak verilirken geri kalan 9 parça ile sistem eğitilmektedir. Böylece toplanan tüm izler için birer tahmin yapılabilmekte ve bu tahminler gerçek konum bilgileriyle karşılaştırılarak sistemin hata ölçütleri belirlenebilmektedir.

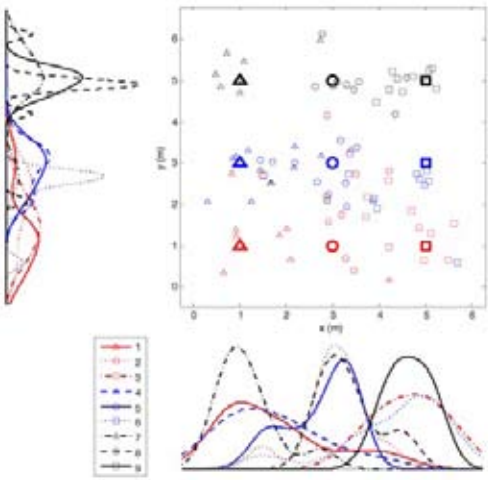

Şekil 3: Ofis deneyi (oda boyutu 6x6 m^2)

Şekil 3'te ofis deneyinin sonuçları verilmiştir. Deneyin yapıldığı oda 6x6 m2 boyutundadır. Görece büyük işaretler izlerin gerçek konumunu göstermekte, ilgili biçimde ve renkteki küçük işaretler ise ilgili izlere ait tahminleri göstermektedir. Odanın bazı bölümlerinde (özellikle binanın dış duvarlarından daha uzak olan noktalarda) tahmin başarımının daha yüksek olduğunu gözlemliyoruz. Bu deneydeki tahminlerin ortalama kare hatası (MSE) 1.76 m2 olarak hesaplanmıştır.

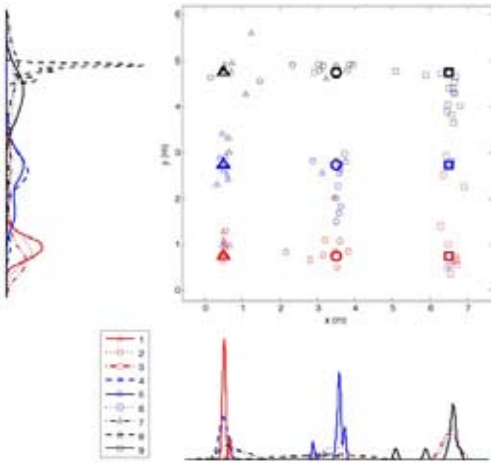

Şekil 4: Ev deneyi (oda boyutu 7x5.5)

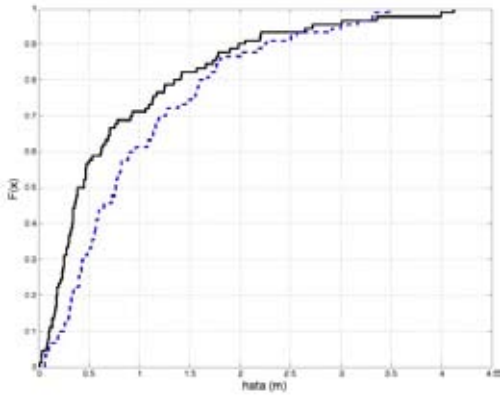

Şekil 5: Hata Birikimli Dağılım Fonksiyonu

Şekil 4'te ise ev deneyinin sonuçları verilmiştir. Deneyin yapıldığı oda 7x5.5 m2 boyutundadır. Sistemin ofis ortamına kıyasla ev ortamında daha yüksek başarımla çalıştığı gözlenmektedir. Bu deneydeki tahminlerin ortalama kare hatası 1.44 m2 olarak hesaplanmıştır.

Şekil 5'te her iki ortamda (ev ve ofis) yapılan tahmin hatalarının deneysel (ampirik) birikimli dağılım fonksiyonları verilmiştir. Bu fonksiyonlar sayesinde hata dağılımları net bir şekilde gözlemlenmektedir. Ofis ortamında tahminlerin %70'i 1.5 m ve altı hataya sahipken, ev ortamında 1 m ve altı hataya sahip tahminler bütün tahminlerin %70'ini oluşturmaktadır.

4. Gelecek Çalışmalar ve Sonuç

Daha kapsamlı bir sistemin ön çalışması niteliğinde olan bu çalışmada, yapay sinir ağı tabanlı, oda içi hassasiyetinde bir iç mekan konumlandırma sistemi önerdik. Gelecekte gerçekleştirmeyi planladığımız sistemin, sadece bir odada değil, tüm bir katta veya çok katlı bir binanın bütününde çalışması hedeflenmektedir.

Önerdiğimiz sistemin başarımını iki farklı mekanda (ev, ofis ortamları) yaptığımız deneylerle değerlendirdik. Bu aşamada sistemi sadece bir model telefonla test ettik. İleride başka modellerle de test ederek, gerekirse makina öğrenmesi modelinde ve WiFi izleri biçeminde gün-

cellemeler yaparak, istenen başarım seviyesini kullanılan cihazdan bağımsız olarak sağlayan bir sistem yaratmayı hedefliyoruz.

5. Kaynaklar

[1] P. Bahl and V. Padmanabhan, "RADAR: An in-building RF-Based user location and tracking system", INFOCOM, Tel Aviv, Israel, Jan 2000.

[2] Yanying Gu; Lo, A.; Niemegeers, I., "A survey of indoor positioning systems for wireless personal networks," IEEE Communications Surveys & Tutorials, Vol.11, No.1, pp. 13-32, 2009.

[3] Zahid Farid, Rosdiadee Nordin, and Mahamod Ismail, "Recent Advances in Wireless Indoor Localization Techniques and System," Journal of Computer Networks and Communications, Vol. 2013, Article ID 185138, 12 pages, 2013.

[4] R. Hansen, R. Wind, C. S. Jensen, and B. Thomsen, "Algorithmic strategies for adapting to environmental changes in 802.11 location fingerprinting," in Proceedings of the International Conference on Indoor Positioning and Indoor Navigation (IPIN '10), Zurich, Switzerland, September 2010.

[5] S. Khodayari, M. Maleki, and E. Hamedi, "A RSS-based fingerprinting method for positioning based on historical data," in Proceedings of the International Symposium on Performance Evaluation of Computer and Telecommunication Systems (SPECTS '2010), pp. 306–310, July 2010.

[6] Rey-Chue Hwang; Pu-Teng Hsu; Jay Cheng; Chih-Yung Chen; Chuo-Yean Chang; Huang-Chu Huang, "The indoor positioning technique based on neural networks" , IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC) , 14-16 Sept. 2011.

[7] A. S. Al-Ahmadi, A. I. Omer, M. R. Kamarudin, and T. A. Rahman, "Multi-floor indoor positioning system using bayesian graphical models," Progress In Electromagnetics Research B, vol. 25, pp. 241–259, 2010.

[8] P. Bolliger, "Redpin - Adaptive, zero-configuration indoor localization through user Collaboration", Workshop on Mobile Entity Localization and Tracking in GPS-less Environment Computing and Communication Systems (MELT), San Francisco, 2008.

[9] S.-H. Fang and T. Lin, "Principal component localization in indoor WLAN environments," IEEE Transactions on Mobile Computing, Vol. 11, No. 1, pp. 100–110, 2012.

[10] Abhishek Goswami, Luis E. Ortiz, and Samir R. Das. 2011. WiGEM: a learning-based approach for indoor localization. In Proceedings of the Seventh COnference on emerging Networking EXperiments and Technologies (CoNEXT '11). ACM, New York, NY, USA.

[11] Lathouwers Jef, Weyn Maarten, Vercauteren Charles, "User-trained, zero-configuration, self-adaptive opportunistic Wi-Fi localization for room-level accuracy", AMBIENT 2012 : The Second International Conference on Ambient Computing, Applications, Services and Technologies, 2012, pp. 64-70.