

# Makine Öğrenmesi ile Kablosuz Örgü Ağlarda Akıllı Bağlantı Yönlendirme

## Smart Steering with Machine Learning for Wireless Mesh Networks

Bulut Kuşkonmaz

Mühendislik ve Doğa Bilimleri Fakültesi Mühendislik ve Doğa Bilimleri Fakültesi  
Sabancı Üniversitesi  
İstanbul, Türkiye  
kuskonmazbulut@sabanciuniv.edu

Hüseyin Özkan

Mühendislik ve Doğa Bilimleri Fakültesi Mühendislik ve Doğa Bilimleri Fakültesi  
Sabancı Üniversitesi  
İstanbul, Türkiye  
hozkan@sabanciuniv.edu

Özgür Gürbüz

Mühendislik ve Doğa Bilimleri Fakültesi Mühendislik ve Doğa Bilimleri Fakültesi  
Sabancı Üniversitesi  
İstanbul, Türkiye  
ogurbuz@sabanciuniv.edu

**Özetçe**—Kablosuz ağların daha verimli kullanılması ve daha kaliteli, yüksek hızlı internet erişimi için, kullanıcıların bağlı oldukları erişim noktalarını (EN) değiştirmelerine bağlantı değiştirme ya da bağlantı yönlendirme (steering) eylemi denir. Ancak, hedeflenen bağlantı değiştirme/yönlendirme eylemi her zaman istenen sonucu vermeyebilir ve kullanıcı eski erişim noktasına bağlı kalır. Ağ ve bağlantı kalitesinin iyileştirilemediği bu durum, yapışkan kullanıcı problemi olarak tanımlanır. Bu çalışmada, bu soruna çözüm olabilecek bütüncül işlemeli Destek Vektör Makinesi (DVM) ve çevrimiçi işlemeli çekirdek perceptron farklı ağ özelliklerini kavrayacak biçimde uygulanmıştır. Bağlantı yönlendirme eylemlerinin başarı oranını maksimize edecek şekilde, doğru kararlarla sonuçlanan bağlantı yönlendirmeleri doğrusal olmayan sınıflandırıcılarla öğrenilmiştir. Özellikle, çözümümüzde uyguladığımız çevrimiçi perceptron buluttan gelen birçok ağa ait verileri kullanarak sıralı öğrenme sağlamakta, erişim noktasında çalışarak bağlantı yönlendirmesini gerçekleştirmekte ve her iki işlemi de gerçek zamanda çalıştırmaktadır. Önerdiğimiz algoritma veri tabanlı olarak değişik durumlara uyumlanabilmekte ve gerçek zamanlı olarak optimum bağlantı yönlendirmesi çözümlerini bulabilmektedir. Gözlemediğimiz deneylerde, bütüncül işlemeli algoritmamız başarılı bağlantı yönlendirme koşullarını %95 doğrulukla belirlemiştir. Hesaplama karmaşıklığı çok daha düşük ve gerçek zamanlı bağlantı yönlendirmeye uygun olan çevrimiçi algoritmamız ise aynı sınıflandırma doğruluk payına küçük bir farkla ulaşabilmiştir.<sup>12</sup>

**Anahtar Kelimeler**—Kablosuz örgü ağlar, bağlantı yönlendirme, sınıflandırıcı, bütüncül, çevrimiçi, çekirdek, perceptron

**Abstract**—In wireless networks, clients can be steered from one access point (AP) to another for a better internet connection. Although this client steering has large potential to improve overall network service and the user experience, such steering actions may not always yield the desired result and the client may remain persistently connected to its current AP. This issue is referred to as the sticky client problem, which prevents the intended improvement in the network. In this work, in order to address the sticky client problem, Support Vector Machine (SVM) as a batch method and kernel perceptron as an online method are examined based on various network features. Nonlinear classifiers

of correct steering actions have been trained to maximize the accuracy of steering actions. In particular, the online kernel perceptron performs sequential learning at APs using the cloud data to decide about steering actions in real time. This algorithm is data-driven, and able to provide optimum steering in real-time. In our experiments, we observed that our batch approach identifies successful steering actions with %95 accuracy. On the other hand, our online algorithm is able to approximate the batch performance by a small margin while allowing real time steering with significantly lower computational complexity.

**Index Keys**—Wireless mesh networks, client steering, classifier, batch, online, kernel, perceptron

### I. GİRİŞ

Günlük yaşamlarımızın vazgeçilmez bir parçası olan akıllı telefonların ve ona bağlı uygulamaların sayısının artması, mobil veri trafiğinin de çok artmasına sebep olmuştur. Bu veri trafiğine yön veren sistemlerden birisi de Wi-Fi teknolojisidir [1]. IEEE 802.11 Wi-Fi, kablosuz teknolojiler arasında en yaygın olarak kullanılmaktadır. IEEE 802.11n'deki MIMO teknolojisinin ve IEEE 802.11ac'deki çift bantlı (2,4 GHz ve 5,8 GHz) erişimin katkılarıyla beraber Wi-Fi bağlantı hızları Gbps seviyelerine ulaşmıştır [2]. Öte yandan, kapalı alanlardaki tek erişim noktalı (EN) Wi-Fi ağlarında duvarların ve katların sinyal gücünde neden olduğu düşüşler, vadedilen bağlantı hızlarına ulaşılmasında bir engel olarak karşımıza çıkmaktadır. Bununla birlikte, Wi-Fi örgü ağları ile, EN'lerin dinamik konfigürasyonu ve EN'ler arası örgü sekme yönlendirmeleri mümkün kılınarak tek EN'li Wi-Fi ağların verimi ve kapsamı önemli derecede artırılabilir [3], [4].

Wi-Fi örgü ağları, giriş noktası olan geçit (gateway) EN ile ona ve birbirine bağlı diğer ENler, ve kullanıcı kablosuz cihazlardan yani istemcilerden oluşmaktadır. Geçit EN'si internet bağlantısı olan EN'dir ve diğer EN'lere internet akışını sağlar. İstemciler de bu ağda bulunan herhangi bir EN üzerinden internet'e bağlanabilir. Wi-Fi örgü ağlarında istemciler, EN'lere adil olmayan bir şekilde dağıtılıp bant aralığı ve erişim problemlerine neden olabilir. Bazı durumlarda ise istemcilerin konumlarına göre farklı bir EN'ye geçiş yapması gerekebilir. Bu geçişin kararı, bağlantılar arası hesaplanan

<sup>1</sup>Bu çalışma Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 118E268 sözleşme numaralı araştırma projesi kapsamında desteklenmektedir.

<sup>2</sup> 978-1-7281-7206-4/20/\$31.00 ©2020 IEEE

bir maliyet fonksiyonuna göre belirlenir. İstemciler ile geçit EN'si arasındaki bu maliyet, istemcinin başka bir EN'ye geçip geçmemesinde önemli rol oynar. Her hattın maliyeti, alınan sinyal gücü ve bağlantı hızı gibi hattın kalitesi ile ilgili ölçütler ile hesaplanır. Bazı durumlarda (örneğin, maliyet metriklerinin istemciye yanlış/eksik bildirilmesi) istemciler daha iyi internet bağlantısı sağlayacak EN'lere (bulunduğu konuma göre toplam maliyeti en az olan EN'lere) bağlanamayabilirler. Buna Yapışkan İstemci Problemi (Sticky Client Problem) denir [5], [6]. Sinyal gücü ve bağlantı hızı kaynaklı EN veya kullanıcı odaklı bazı problemler, birtakım bütüncül ve çevrimiçi işlemeli makine öğrenme algoritmaları yardımı ile incelenmiştir [6].

Bu makalede, kablosuz örgü ağlardaki yapışkan istemci ve benzeri bağlantı problemlerini çözmek için, istemcilerde çalışan bağlantı yönlendirme birimleri veri tabanlı makine öğrenmesi teknikleri ile incelenmiştir. Çalışmamızda, gerçek bir ağ üzerinden bulutta toplanan veriler makine öğrenmesi yaklaşımı ile işlenmiş ve farklı ağ öznitelikleri ikili sınıflandırma teknikleri ile irdelenerek, başarılı bağlantı yönlendirmelerin tespiti ve iyi bir akıllı bağlantı yönlendirme çözümünün bulunması hedeflenmiştir. Sonuçta iki adet akıllı bağlantı yönlendirme yöntemi sunulmuştur.

- Bağlı olunan mevcut EN'den ölçülen sinyal gücü, mevcut maliyet, ve yeni bağlantı noktası olarak değerlendirilen hedef EN'den ölçülen sinyal gücü, hedef maliyet gibi ağ öznitelikleri, başarılı bağlantı yönlendirmelerini belirlemek için incelenmiştir.
- Sunulan ilk akıllı bağlantı yönlendirme makine öğrenmesi yöntemi için bütüncül işlemeli destek vektör makinesi (DVM) kullanılmıştır.
- Sunulan ikinci akıllı bağlantı yönlendirme yöntemi için veriye gerçek zamanlı uyarlanabilen ve çevrimiçi bir makine öğrenmesi yöntemi olarak çekirdek perceptron kullanılmıştır.
- Sonuçlarımıza göre bütüncül işlemeli makine öğrenmesi yöntemi DVM öznitelik uzayındaki başarılı bağlantı yönlendirme sınırlarını %95 doğruluk payı ile belirleyebilmiştir. Çevrimiçi makine öğrenmesi yöntemi (çekirdek perceptron) ise DVM'nin doğruluğuna oldukça yaklaşırken gerçek zamanlı çalışabilmesi sebebiyle avantajlıdır. Bunun sebebi DVM'nin bütüncül işleminin büyük veriye uygulanmasındaki hesapsal zorluktur. Çevrimiçi çekirdek perceptron yöntemi ise oldukça verimli ve ölçeklenebilirdir.

## II. PROBLEM TANIMI

Bir evdeki kullanıcıların bağlantı yönlendirme verileri bulutta toplanmaktadır. Bağlantı yönlendirme kararları için ise istemcide çalışan bir program (Steering Daemon) kullanılmaktadır [5]. Toplanan bulut verileri, istemcilerin kendilerine gönderilen EN geçişi veya bulunduğu EN'de kalma komutları göz önünde bulundurularak başarılı veya başarısız olarak etiketlenmiştir. Veriler, eğer bir istemci kendisine daha iyi internet sağlayan bir EN'ye veya frekans bandına (2.4 GHz ya da 5 GHz) geçtiğinde veya bağlı bulunduğu EN veya frekans bandı ona en iyi interneti sağlayan bu EN veya frekans bandında bağlı kalmaya devam ettiğinde başarılı (1) olarak,

diğer durumlarda ise başarısız (-1) olarak etiketlenmiştir. (BuArada,  $Y$ : etiket,  $N$ : veri sayısıdır;  $Y \in \{-1, 1\}^{N \times 1}$ ).

Veri özniteliklerinden sinyal gücü bağlantı kalitesini, maliyet ise istemcinin bağlı bulunduğu EN ve geçit EN'si arasındaki uçtan uca bağlantının metrik hesabını belirtmektedir [5]. Sinyal gücü istemcinin konumuna bağlı olduğu için zaman içinde değişebilmektedir. Bu yüzden EN'lerde sürekli bir maliyet hesabı söz konusudur. Her bir bağlantı için maliyet hesabının formülü şu şekildedir:  $\frac{50000}{(\lfloor \frac{R}{20} \rfloor + 1)}$  Burada,  $R$ : fiziksel katmanın bağlantı hızıdır [5].

Mevcut/hedef sinyal gücü, mevcut/hedef maliyet ile birlikte dört öznitelik üzerinden veriler dört boyutlu bir öznitelik vektörü ile şu şekilde temsil edilmiştir: veriler:  $X \in R^{N \times 4}$ , etiketleri:  $Y \in \{-1, 1\}^{N \times 1}$ . Bizim yaklaşımımız elde bulunan verileri kullanarak bir sınıflandırıcı eğitmek ve yeni veri etiketlerini tahmin edebilen bir  $f(x) \in \{-1, 1\}$  modelini oluşturmaktır. Sonuçta bu model öznitelik uzayı içerisinde başarılı yönlendirmeleri sağlayan bölgeyi verdiği göre, herhangi bir ağ kullanıcısı sadece bu bölgeye girdiğinde yönlendirme (EN değişikliği) kararı verilir. Bu sayede yüksek ihtimalle başarılı makine öğrenmesi tabanlı veriye uyarlanabilen akıllı bir gerçek zamanlı yönlendirme sağlanmış olur.

Bütüncül işlemeli makine öğrenmesi yöntemi olarak DVM iyi bir performans sağlayabilir fakat büyük veriye ve büyük ağlara ölçeklenebilirlik açısından problemlidir. Çevrimiçi makine öğrenmesi yöntemi çekirdek perceptron ise bütüncül işleme performansını neredeyse ihmal edilebilecek düzeyde bir hesapsal karmaşıklık ile yakalayabilmektedir. Çekirdek perceptron çevrimiçi yönteminde veriler zamanda sıralı olarak sınıflandırmaya girmektedir. Anlık gelen verinin etiket tercihi belirlenmekte ve bu verinin işi bittiğinde depolama alanından çıkarılmaktadır. Bu yüzden bu yöntemin hesapsal karmaşıklığı doğrusal, depolama karmaşıklığı ise ihmal edilir düzeydedir. Dolayısıyla bu yöntem büyük veriye ve büyük ölçekli ağlarda yüksek performans sağlayabilir. Bu şekilde veri odaklı, gerçek zamanlı ve akıllı bir bağlantı yönlendirme birimi kablosuz örgü ağlara yenilikçi bir bakış açısı kazandırabilir.

## III. AKILLI BAĞLANTI YÖNLENDİRME İÇİN SUNULAN SINIFLANDIRMA

Destek Vektör Makinesi (DVM) [7], etiketlenmiş verileri kullanarak ikili doğrusal bir sınıflandırma yapan bir makine öğrenmesi yöntemidir. DVM esasında öznitelik uzayında verileri sınıflarına göre ayıran bir çok boyutlu bir düzlem öğrenmeye dayanır. Sınıflandırma işlemini de bu düzleme göre yapar. Doğrusal olmayan karar sınırlarını öğrenmek için DVM uygun bir çekirdek ile kullanılır. DVM bütüncül işlemeli bir algoritma olup hesapsal maliyeti görece yüksektir.

Çekirdek perceptron algoritması ise doğrusal veya doğrusal olmayan tüm sınıflandırmaları çevrimiçi olarak yapabilir. Çekirdek perceptronun sınıflandırma yapılabilmesi için kullandığı verilerin boyutlarını dönüştürmesi gerekir. Bu dönüştürme işlemi için Bochner Teoremi [8], [9], rbf çekirdeği ile birlikte kullanılmıştır. Seçilen "rbf" çekirdeğinde,  $k(x_i, x_j) = \exp(-g||x_i - x_j||^2)$ ,  $k(\cdot, \cdot)$  çekirdek fonksiyonunu ve  $g$  bant genişliğini (ters orantılı olarak) ifade eder. Kullanılan dönüştürme yöntemi Mercer

koşulunu sağlayan kaymalara duyarız diğer tüm çekirdeklere de uygulanabilir [8], [9]. Çekirdek, veri akışından gelen her bir örneği çoklu boyuta dönüştürür. Kullanılan dönüştürme  $x_i \rightarrow z_i$  sonucunda, çekirdek değerleri içsel çarpım olarak yaklaşık bir şekilde elde edilebilir:  $k(x_i, x_j) \simeq z_i^T z_j$ . Rbf çekirdeği öteleme ile değişmez ve simetrik (  $k(x_i, x_j) = k(0, x_i - x_j) \triangleq \bar{k}(x_i - x_j) = \bar{k}(-x_i + x_j)$  ). Bu örneklerin çoklu boyuttaki iç çarpımları, orjinal boyuttaki çekirdek değerine benzerdir. Böylece, kendisi çevrimiçi bir algoritma olan perceptron [7] çok boyutta doğrusal olarak uygulandığında normal boyutta doğrusal olmayan yine çevrimiçi bir sınıflandırma sağlar. Bu sonuç Bochner Teoremine dayanmaktadır:

$$\begin{aligned} \bar{k}(x_i - x_j) &= \int_{R^{d \times 1}} p(\alpha) \exp(j\alpha^T(x_i - x_j)) d\alpha \\ &= \int_{R^{d \times 1}} p(\alpha) (\cos(\alpha^T(x_i - x_j)) + j \sin(\alpha^T(x_i - x_j))) d\alpha \\ &\text{(Euler Özdeşliği)} \\ &= \int_{R^{d \times 1}} p(\alpha) \cos(\alpha^T(x_i - x_j)) d\alpha \\ &\text{(} k(x_i, x_j) \text{ gerçek ve simetrik)} \\ &= E_\alpha[\cos(\alpha^T(x_i - x_j))] = E_\alpha[r_\alpha(x_i)r_\alpha^T(x_j)] \simeq z_i^T z_j, \end{aligned}$$

burada,  $r_\alpha(x) = [\cos(\alpha^T x), \sin(\alpha^T x)]$  IV-C bölümünde de bahsettiğimiz Fourier özniteliklerini,  $p(\alpha)$  bir olasılık dağılımı olarak kullanılan çekirdeğin Fourier transformunu,  $E_\alpha(\cdot)$  ise ortalaması  $\mu = 0$  olan ve kovaryansı ise  $\Sigma = 2gI$  olan ( $I$  özdeşlik matrisi) olan çok-değişkenli Gauss yoğunluğunun,  $p(\alpha) = N(\alpha; \mu, \Sigma)$ , beklentisini belirtir. Sonuçta Fourier öznitelikleri rasgele seçilerek aşağıdaki dönüşüme göre veriler yüksek boyuta aktarılır,

$$z_i = \frac{1}{\sqrt{D}} [r_{\alpha_1}(x_i), r_{\alpha_2}(x_i), \dots, r_{\alpha_{D-1}}(x_i), r_{\alpha_D}(x_i)]^T \in R^{2D \times 1}$$

ve sonrasında ise perceptron ile sınıflandırılır.

Perceptron hesaplama karmaşıklığı DVM'ye göre daha az olup çevrimiçidir. Bu yüzden, örgü Wi-Fi ağlarında çekirdek perceptron gerçek zamanda çalışabilen bir yöntemdir. DVM, örgü Wi-Fi ağı bulunan bir evin verilerini bütüncül işleyip bağlantı yönlendirme sınıflandırması ile akıllı bağlantı yönlendirme mekanizması oluşturabilir. Çevrimiçi işlerlik gerekli olduğunda ise (gerçek zamanda çalışabilmesi için) çekirdek perceptron ile istenen akıllı bağlantı yönlendirme sağlanabilir.

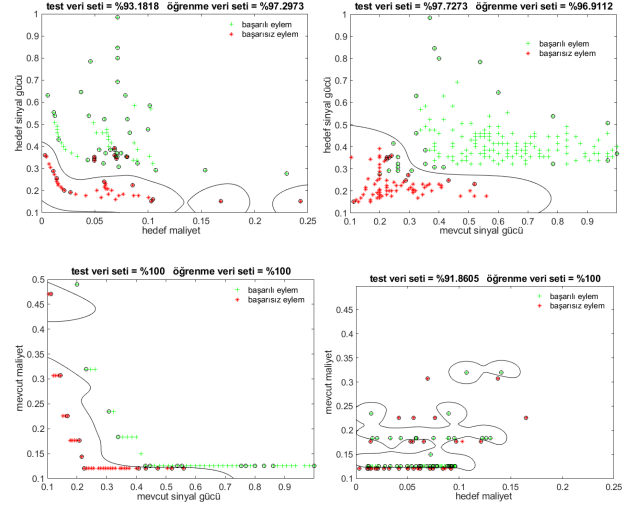
#### IV. DENEY SONUÇLARI

Bu bölümde, örgü Wi-Fi ağlarında akıllı bağlantı yönlendirmesi için bütüncül işlemeli DVM ve çevrimiçi çekirdek perceptron yöntemlerinin sınıflandırma sonuçları karşılaştırmalı olarak verilmektedir.

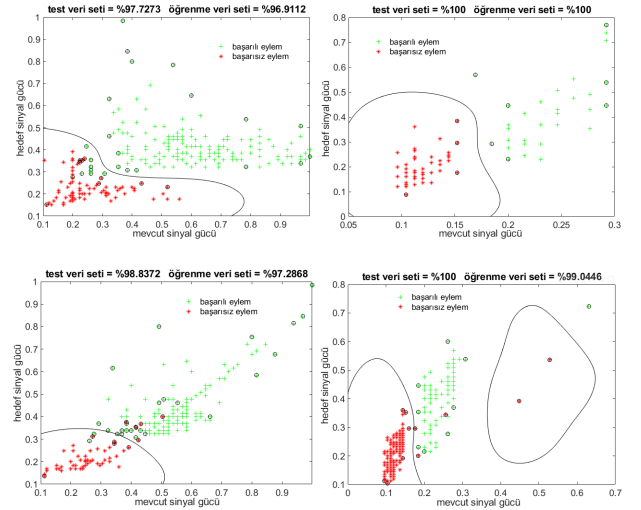
##### A. Bütüncül İşlemeli DVM Sonuçları

Örgü ağlardan gelen bağlantı yönlendirme verilerinin DVM ile kullanıp başarılı bağlantı yönlendirme sınırlarının elde edilmesi için, her bir veri setinin 75%'i eğitim, kalanı ise test için kullanılmıştır. Eğitim seti içinde 5-katlı çapraz doğrulama ile parametre eniyilemesi yapılmıştır. Kullandığımız verilerin başarı-başarısız sınıfları doğrusal bir şekilde ayrıldığı için

doğrusal olmayan rbf çekirdekli DVM kullanılmıştır. Ayrıca sonuçları 2 boyutlu grafikte gösterebilmek, hem de en iyi öznitelikleri bulabilmek için veri setleri ikili öznitelikler şeklinde seçilmiştir.



Şekil 1: Sol üstte hedef maliyet-hedef sinyal gücü, sağ üstte mevcut sinyal gücü-hedef sinyal gücü, sol altta mevcut sinyal gücü-mevcut maliyet ve sağ altta ise hedef maliyet-mevcut maliyet ikilisinin 2.4 GHz'den 5 GHz'e geçiş sınıflandırma sonuçları bulunur.




Şekil 2: Sol üstte farklı EN'lerde 2.4 GHz'ten 5 GHz'e, sağ üstte farklı EN'lerde 5 GHz'ten 2.4 GHz'e, sol altta aynı EN'de 2.4 GHz'ten 5 GHz'e ve sağ altta ise aynı EN'de 5 GHz'ten 2.4 GHz'e geçişin sonuçları bulunur.

Şekil 1'de tek bir geçişin doğrusal olmayan DVM tarafından oluşturulan sınıflandırmaları gösterilmektedir. Bu sonuçlara göre, mevcut sinyal gücü ve maliyet ikilisinin en iyi sınıflandırmayı, ve mevcut ve hedef sinyal gücü ikilisinin ise en iyi ikinci sınıflandırmayı verdiği gözlenmektedir. Şekil 2'de mevcut ve hedef sinyal güçleri ikilisinin farklı geçişlerinin DVM sınıflandırmaları gösterilmektedir (farklı geçişlerde

farklı veri noktaları olduğu için bu ikili kullanılmıştır). Bu sonuçlara göre, farklı EN'ler arasında 5 GHz'ten 2.4 GHz'e geçiş veri seti 100%lük doğruluk oranı ile en iyi sınıflandırmayı bize sunuyor. Şekil 3 ve Şekil 4 karşılaştırıldığında, mevcut ve hedef sinyal güçlerinin tüm senaryolarda iyi bir performans sağladığı sonucu çıkmaktadır.

### B. Çevrimiçi Çekirdek Perceptron Sonuçları

Burada ise çevrimiçi yaklaşımımız çekirdek perceptronun sonuçlarını sunmaktayız. Çekirdek perceptron yöntemi hesapsal olarak verimli, büyük veriye gerçek zamanlı ölçeklenebilir ve kesintisiz veri işleme kabiliyetleri yönleriyle avantajlıdır. Dolayısıyla sonuçlarımız bu hesapsal avantaj ile elde edilen performans analize odaklanmaktadır.




Şekil 3: Mevcut sinyal gücü-hedef sinyal gücü ikilisinin (solda) ve mevcut maliyet-mevcut sinyal gücü ikilisinin (sağda) örgü ağda 2.4 GHz'den 5 GHz'e geçiş verilerinin çevrimiçi çekirdek perceptron sınıflandırma sonuçları.

Şekil 3'te, dönüştürülme yapılmadan uygulanan perceptron ve  $D \in \{1, 2, 4, 6, 8, 10\}$  dönüştürme boyutları için çekirdek perceptron algoritmasının kullanılan veri setleri üzerinde sonuçları sunulmuştur. Görüldüğü gibi,  $D$  arttıkça hata oranı azalmaktadır, fakat  $D$  boyutu olabildiğince küçük tutulmak istendiğinden (hesapsal verimlilik için) ve  $D = 6$  boyutundan sonra hata oranı neredeyse aynı kaldığından  $D = 6$  yeterli sınıflandırmayı sağlamaktadır. DVM ile karşılaştırılacak olursak, DVM'in sınıflandırma performansı, çekirdek perceptron'un sınıflandırma performansından yaklaşık olarak % 5 ila % 10 daha iyidir. Ancak, DVM verileri toplu halde kullanırken, çekirdek perceptron verileri sıralı işleyebilir. Çekirdek perceptron gerçek zamanda çalışabilen bir algoritmadır ve hesaplama karmaşıklığı DVM'e oranla daha azdır. Bunlar büyük veriye ve büyük ağlara gerçek zamanlı ölçeklenebilirlik açısından çekirdek perceptrona çok büyük avantajlar sağlamaktadır.

### C. Çekirdek Perceptron İçin Fourier Özniteliklerinin Seçimi

Çekirdek perceptron Fourier özniteliklerini kullanan bir algoritmadır. En iyi sınıflandırmayı sağlayabilmek için de en iyi Fourier öznitelikleri seçilmelidir. Bunun için, öncelikle rasgele bin adet Fourier öznitelik seçildi. Daha sonra, bu rasgele seçilen Fourier öznitelikler arasından perceptronun en iyi çalıştığı ilk Fourier öznitelik seçilmiştir. Sonrasında ise ilk seçilen Fourier öznitelik ile beraber en iyi çalışan ikinci Fourier öznitelik seçilmiştir. Bu işlem,  $D$  kadar Fourier öznitelik seçilene kadar devam etmiştir. Her bir veri seti için bu işlem gerçekleştirilmiştir.



Şekil 4: Mevcut sinyal gücü-hedef sinyal gücü ikilisinin farklı EN'de 2.4 GHz'den 5 GHz'e geçişi (solda) ve aynı EN'de 5 GHz'den 2.4 GHz'e geçiş verilerinin seçmeli ve rastgele çevrimiçi çekirdek perceptron sınıflandırma sonuçları.

Şekil 4'te belirtilen geçişlere göre perceptron sınıflandırılması uygulanmıştır. Düz çizgiler rasgele Fourier öznitelikleri ile yapılan, kesikli çizgiler ise bilinçli seçilen Fourier öznitelikleri ile perceptron hata oranlarını temsil etmektedir. Her iki şekilde de görüldüğü gibi, bilinçli seçilen Fourier öznitelikleri ile sınıflandırma yapıldığında rasgele olarak seçilenlere göre daha iyi sonuçlara ulaşılmıştır. Ayrıca, seçilen Fourier öznitelikleri ile yapılan sınıflandırmada daha küçük  $D$  değerleri aynı hata oranını verebilmektedir. Bu yüzden,  $D$ 'yi daha küçük seçip uygun sınıflandırma sağlanabilir, hesapsal karmaşıklık daha da düşürülebilir.

## V. SONUÇ

Bu çalışmada, örgü ağ sistemlerinde oluşan istemci bağlantı yönlendirme sorunlarına çözüm olarak veri odaklı makine öğrenmesi yöntemleri ele alınmıştır. Sınıflandırma için genel bir izlenim almak için DVM algoritması kullanılmıştır. Akıllı bağlantı yönlendirme için ise çekirdek perceptron kullanılmış daha iyi performans için ise çekirdek perceptron'un en iyi Fourier öznitelikleri seçilmiştir. Çevrimiçi doğrusal olmayan yöntemlerin akıllı yönlendirmenin gerçek zamanlı uygulanabilmesi için daha uygun olduğu, öte yandan, sınıflandırmayı gözlemlemek için bütüncül yöntemlerin de kullanılabileceği sonucu elde edilmiştir.

## REFERENCES

- [1] C. V. N. Index, Global mobile data traffic forecast update, 2016-2021 white paper.
- [2] E. Perahia, R. Stacey, Next generation wireless LANs: 802.11 n and 802.11 ac, Cambridge university press, 2013.
- [3] I. F. Akyildiz, X. Wang, W. Wang, Wireless mesh networks: a survey, Computer networks 47 (4) (2005) 445-487.
- [4] X. Wang, A. O. Lim, Ieee 802.11s wireless mesh networks: Framework and challenges, Ad Hoc Networks 6 (6) (2008) 970-984.
- [5] S. M. Gokturk, A. Akcan, M. I. Taskin, Client steering, US Patent App. 15/534,772 (Dec. 28 2017).
- [6] B. Kusonmaz, H. Ozkan, O. Gurbuz, Machine learning based smart steering for wireless mesh networks, Ad Hoc Networks 88 (2019) 98-111.
- [7] R. O. Duda, P. E. Hart, D. G. Stork, Pattern classification, John Wiley & Sons, 2012.
- [8] A. Rahimi, B. Recht, Random features for large-scale kernel machines, in: Advances in neural information processing systems, 2008, pp. 1177-1184.
- [9] F. Porikli, H. Ozkan, Data driven frequency mapping for computationally scalable object detection, in: 2011 8th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS), IEEE, 2011, pp. 30-35.