



# Akıllı Ev Bileşenlerinde Kullanılan Farklı Kablosuz İletişim Standartları için Makine Öğrenmesi Tabanlı Öneri Sistemi

## *Machine Learning-Based Recommendation System for Different Wireless Communications Standards Used in Smart Home Components*

Ahmet Yazar<sup>1\*</sup>, Ahmet Ata Şentürk<sup>2</sup>, Şulenur Çörez<sup>2</sup>, Olçan Satır<sup>2</sup>, Burak Kosova<sup>2</sup>

<sup>1</sup>Eskişehir Osmangazi Üniversitesi, Mühendislik-Mimarlık Fakültesi, Yazılım Mühendisliği Bölümü, Eskişehir, Türkiye

<sup>2</sup>Eskişehir Osmangazi Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Eskişehir, Türkiye

### Öz

Akıllı ev sistemlerinin giderek yaygınlaştığı son yıllarda bu sistemlere ait kablosuz iletişim altyapısı da daha çok önem kazanmıştır. Birbirlerine karşı farklı üstünlükleri olan kablosuz iletişim standartlarının bir akıllı ev sistemi için ne tür ihtiyaçlar ve hangi şartlar altında daha kullanılabilir olduğunun kestirilmesi yeni bir problem haline gelmiştir. Bu çalışmada, yeni nesil akıllı ev bileşenlerinde kullanılan farklı kablosuz iletişim standartları için makine öğrenmesi tabanlı özgün öneri yöntemleri geliştirilmiştir. Ayrıca bu amaca yönelik olarak ortamsal ve çevresel farkındalığı yükseltecek düzeyde bilgi girdilerinden yararlanılmıştır. Makine öğrenmesi uygulamasına yönelik yeni bir yapay veri kümesi oluşturulmuştur. Alınan sonuçlara bakıldığında, geliştirilen özgün çözümlerin akıllı ev tasarımlarına fayda getireceği görülmüştür.

**Anahtar Kelimeler:** 5G, akıllı evler, kablosuz iletişim, makine öğrenmesi, öneri sistemi

### Abstract

In recent years, as smart home systems have become increasingly widespread, the wireless communication infrastructure associated with these systems has gained more importance. Assessing the needs and determining the conditions under which different wireless communication standards, each with its own advantages, can be more suitable for a smart home system has become a new challenge. In this study, a machine learning-based recommendation methods have been developed for various wireless communication standards used in next-generation smart home components. Additionally, a level of ambient and environmental awareness has been utilized to enhance the information inputs for this purpose. A new artificial dataset has been created for the machine learning application. When examining the results, it can be observed that the proposed novel solution would be beneficial in smart home designs.

**Keywords:** 5G, smart homes, wireless communications, machine learning, recommendation system

## 1. Giriş

Akıllı evler, insan faaliyetlerini taklit edebilen, belirli görevleri yerine getirebilen ve çeşitli cihazları uzaktan kontrol edebilen sistemlerdir. Bu sistemler, kullanıcıların konforu-

nu ve güvenliğini artırır, enerjiden tasarruf etmelerini sağlar (Stefanov vd. 2004). Gelişen teknolojiyle beraber insanların hayatını kolaylaştıracak teknolojik ürünlere ilgi günden güne artmaktadır. Akıllı evlerin de yıllara göre kullanımlarında önemli ölçüde artış görülmektedir. (Insight 2022)'de yapılan bir analiz çalışmasında, 2022 yılında 120 milyon civarı olan akıllı ev sayısının, 2026 yılı itibarıyla 200 milyona yaklaşacağı öngörülmektedir. Aynı doğrultuda akıllı ev pazarının gelişimi hızla devam etmektedir. Özellikle çevresel etkenleri algılama kabiliyeti yüksek akıllı evlerin sayısında önemli artış olmaktadır (Yazar vd. 2012, Yazar ve Çetin 2013).

Yaygınlaşmakta olan akıllı ev sistemleri için en kritik altyapılardan biri de iletişim alt sistemleridir. Akıllı evlerde kul-

\*Sorumlu yazarın e-posta adresi: [ahmtzyr@gmail.com](mailto:ahmtzyr@gmail.com)

Ahmet Yazar [orcid.org/0000-0001-9348-9092](https://orcid.org/0000-0001-9348-9092)

Ahmet Ata Şentürk [orcid.org/0009-0002-3292-9597](https://orcid.org/0009-0002-3292-9597)

Şulenur Çörez [orcid.org/0009-0004-0582-5869](https://orcid.org/0009-0004-0582-5869)

Olçan Satır [orcid.org/0009-0005-8828-3950](https://orcid.org/0009-0005-8828-3950)

Burak Kosova [orcid.org/0009-0005-5652-9020](https://orcid.org/0009-0005-5652-9020)



lanılan iletişim ağı teknolojileri, kablolu ve kablosuz olmak üzere iki ana sınıf altında değerlendirilebilmektedir. Kablosuz haberleşmenin kurulumunun ve bakımının kablolu haberleşmeye göre çok daha kolay ve düşük maliyetli olması sebebiyle kablosuz iletişim sistemlerinin akıllı evlerde kullanılması günümüzde giderek yaygınlaşmıştır. Aynı zamanda kablosuz iletişimde çoklu bağlantının kolay sağlanması ve taşınabilir olması avantajlıdır (Parikh vd. 2010). Özellikle 5. Nesil (5G) haberleşmesinin standartlaşması sonrasında kablosuz haberleşmenin akıllı ev gibi farklı senaryolarda daha da ön plana çıkması beklenmektedir (Dzogovic vd. 2019). 6. Nesil (6G) haberleşmesinin gelişim sürecinde ise akıllı ev sistemleri gibi dikey sektörlerin önemi giderek artmaktadır (Yazar vd. 2020, Yazar 2021).

Kablosuz iletişim sistemleri için kullanılan birbirinden farklı standartlar bulunmaktadır. Bu standartların birbirlerine karşı çeşitli üstünlük ya da zayıflıkları olabilmektedir. Örneğin bir kısmı çok yüksek veri hızlarını desteklemekte iken diğerleri çok düşük gecikme ya da çok yüksek güvenilirlik olacak şekilde veri iletimi sağlayabilmektedir. Mevcut kablosuz iletişim sistemleri arasında tüm farklı ölçütler açısından en iyi olan tek bir haberleşme standardı bulunmamaktadır (Horyachyy 2017). Kullanıcı sistemlerinin ve akıllı evlerdeki uygulamaların ihtiyaç duyduğu haberleşme gereksinimlerine göre uygun olacak iletişim standartları kullanılabilir. Ayrıca, değişen ortam koşullarına göre bu tercihler farklılaşmaktadır. Bu çalışmada, tüm bu değişen koşullar dikkate alınarak akıllı ev ihtiyaçlarına göre en uygun kablosuz haberleşme standardının belirlenmesine yönelik özgün yöntemler geliştirilmeye çalışılmıştır. Geliştirilen yaklaşımın ele aldığı problem tanımı Şekil 1 üzerinde özetlenmektedir.

Farklı kablosuz iletişim standartları için gruplamaların yapılması mümkün olmaktadır. Örneğin, geniş alan ağları



Şekil 1. Geliştirilen yaklaşım özelinde ele alınan problem tanımı özeti.

(wide area networks, WAN), yerel alan ağları (local area networks, LAN) ve düşük güçlü geniş alan ağları (low-power wide area networks, LPWAN) gibi gruplamalara literatürde rastlanmaktadır (Shilpa 2022). Söz konusu gruplamalar, ele alınan standartların genel karakteristikleri üzerinden oluşturulmaktadır. Bu çalışmada geliştirilen yöntem için WAN, LAN ve LPWAN gruplamaları esas alınarak makine öğrenmesi tabanlı bir öneri sistemi tasarlanmıştır. Güncel literatür incelendiğinde, akıllı evlerde kullanılan haberleşme standartları için daha önce karşılaştırma çalışmalarının yapıldığı görülmektedir (Horyachyy 2017). Fakat bu standartlar arasından grup bazlı olarak makine öğrenmesinden yararlanılarak seçim yaptıran bir yöntem yazarların bildiği kadarıyla literatürde henüz geliştirilmemiştir.

Bu çalışmanın literatüre olan temel katkısı, akıllı ev sistemlerinde yer alan alt bileşenler için kullanılabilen farklı kablosuz iletişim standartlarına yönelik özgün protokol öneri yöntemleri geliştirilmesidir. Verilen hedef doğrultusunda geliştirilen yaklaşımlar için makine öğrenmesi algoritmalarından yararlanılmıştır. Makine öğrenmesinin tek başına kullanılması haricinde, hibrit bir yöntem de önerilmiştir. Ayrıca ortamsal ve çevresel farkındalığı yükseltmek amacı ile farklı bilgilerden yararlanılmıştır. Bu bilgiler kullanılarak yeni bir yapay veri kümesi oluşturulmuştur. Geliştirilen konsept ve yöntemler, tasarlanacak olan akıllı evlerde en doğru kablosuz iletişim altyapısı tercihlerinin belirlenmesinde önemli bir fayda getirecektir.

Çalışmanın 2. bölümünde materyal ve yöntem başlığı altında geliştirilen tasarımların detayları verilmektedir. 3. bölümde ise makine öğrenmesi sonuçları ile ilgili bulgular ve tartışmalar sunulmaktadır. Son olarak 4. bölümde çıkarımlar verilmiş ve geleceğe yönelik yapılabilecek araştırma faaliyetleri örneklendirilmiştir.

## 2. Gereç ve Yöntem

Bu çalışmada makine öğrenmesi tabanlı bir yaklaşım geliştirilmesi sebebiyle veri kümesine ihtiyaç olmuştur. Literatürde uygun bir veri kümesi bulunmaması sebebiyle yeni bir tane oluşturulması yoluna gidilmiştir. Fakat, çalışmanın doğası itibarıyla birçok farklı bilgi kaynağından yararlanılması gerektiğinden dolayı gerçek dünya verisine bağlı bir veri kümesi oluşturulması mümkün olmamıştır. Bu noktada yapay bir veri kümesinin elde edilmesi sağlanmıştır. Simülasyona dayalı oluşturulan bu yapay veri kümesinde sınıf etiketi tabanlı üretilen öznitelikler kullanılmıştır. Son yıllardaki trendlere bakıldığında, yapay veri kümelerinin giderek yaygınlaştığı görülmektedir (Emam 2020, Nikolenko 2022).

Hızlı şekilde çok sayıda örneklemin üretilebilmesi ve gerçek dünya verisi olarak elde etmenin zor olduğu senaryoların simülasyonda gerçekleştirilebiliyor olması, yapay veri kümelerinin önemli avantajları arasında sayılmaktadır.

Veri kümesinin üretilmesi sırasında sınıf etiketleri ve öznitelikler arasında kablosuz haberleşme kanalına etki eden faktörler üzerinden bir ilişkilendirme yapılmaya çalışılmıştır. Bu ilişkilere temel oluşturan kablosuz haberleşme kanalı ile ilgili bazı temel bilgiler aşağıdaki alt başlıkta anlatılmaktadır. Sonrasında veri kümesi üretimi detayları ayrı bir alt başlıkta sunulmaktadır. En son başlıkta ise makine öğrenmesi tabanlı yöntemlerin detayları aktarılmaktadır.

### 2.1. Kablosuz İletişim Kanalı

Kablosuz iletişim sistemleri için kritik bir yere sahip olan haberleşme kanalı birçok rastgelelik içeren doğası sebebi ile ilgili sistemler açısından önemli problemler doğurmaktadır. Yol kaybı ve çoklu yol etkileri kaynaklı bu problemler kablosuz iletişimin çeşitli yayılım ve sönümlenme özellikleri ile ilişkili oluşmaktadır. Değişen şartlar ve çevre koşulları ile kanalı etkilerinin genel hatları farklılaşmaktadır. Literatürde geçmişten günümüze kablosuz iletişim kanalları ile ilgili modelleme, dengeleme ve faydalanma üzerine birçok çalışma yapılmıştır. Bu çalışmada, yapay veri kümesi üretimi öncesinde kablosuz iletişim kanalı ve çevre koşullarının ilişkileri incelenmiştir. Hem yol kaybı (Kihero vd. 2021), hem de çoklu yol etkileri (Yarkan ve Serkan 2008) ile ilgili olarak kanal, çevre koşullarına bağlı olarak önemli ölçüde değişebilmektedir.

Bina içinde ve bina dışında bulunması kablosuz iletişim kanalı açısından önemli farklılıklar getirmektedir. Özellikle hücreli iletişim sistemlerinde baz istasyonu noktaları sokaklarda olduğundan dolayı, bina içi ile baz istasyonu noktası arasında oluşan haberleşme kanalı zorlu etkiler meydana getirebilmektedir. Bu örnekte görüldüğü üzere, kullanılan kablosuz iletişim sistemi ve standardı kablosuz iletişim kanalı açısından önemli sayılabilecek bir etkiye sebep olmaktadır. Bu çalışma kapsamında akıllı evler incelendiğinden dolayı daha çok bina içi kablosuz iletişim kanalları temel alınarak ilgili geliştirmeler yapılmıştır. Bununla beraber, her ne kadar bina içi haberleşme kanalları dikkate alınsa da, iletim noktalarının bina dışında yer alabileceği durumlar düşünülerek, bina mimarisi haricinde coğrafi yapı (Yarkan ve Serkan, 2008) ve yerleşim planlaması (Kihero vd. 2021) bileşenleri göz önünde bulundurulmuştur.

### 2.2. Veri Kümesi Üretimi

Bu çalışmada kullanılan, kablosuz iletişim kanalı özellikleri

ile olan ilişkilere dayalı yapay veri kümesi üretimi yöntemi daha önce literatürdeki farklı çalışmalarda ele alınmıştır. Uygun dalga şekli seçtirilmesine yönelik bir veri kümesi (Hançer ve Yazar 2023a, Hançer ve Yazar 2023b), uygun araçtan her şeye haberleşme protokolü seçtirilmesine yönelik bir veri kümesi (Eren vd. 2023) ve numeroloji kararlarına yönelik bir veri kümesi (Sazak ve Yazar 2023; Altunan vd. 2023) literatürde yer alan çalışmalarda geliştirilen yaklaşımlara dahil edilmiştir. Bahsi geçen mevcut çalışmalardaki problem tanımları ve uygulama senaryolarının farklı olması sebebiyle öznitelikler ve sınıf etiketleri değişiklik göstermiştir. Dolayısıyla bu çalışmada da farklı öznitelikler ve sınıf etiketleri kullanılarak yapay veri kümesi oluşturulmuştur.

Geliştirilen yaklaşıma yönelik oluşturulan yapay veri kümesinde üç sınıf etiketi ve dokuz öznitelik bulunmaktadır. Yapay veri kümesi oluşturulurken öncelikle sınıf etiketi oluşturulmuş, sonrasında bu sınıf etiketine bağlı olarak tanımlanmış rastgelelik değerlerine göre öznitelikler oluşturulmuştur. Bu rastgelelik değerlerinin tanımlanması sırasında normal dağılım kullanılmıştır. Ayrıca, üretilen öznitelik değerleri 1-10 arasında olacak şekilde normalize edilme varsayımı ile elde edilmiştir. Sınıf etiketlerine bağlı olarak özniteliklerin üretimi sırasında MATLAB ile hazırlanan bir simülasyon komut dizisinden yararlanılmıştır.

Sınıf etiketleri arasında kablosuz iletişim standartları gruplarından WAN, LAN ve LPWAN yer almaktadır. Öznitelikler arasında ise Çizelge 1 ile verildiği gibi bir akıllı ev ve çevresi ile ilgili coğrafi yapı, yerleşim planlaması, bina mimarisi, canlı sayısı, yaş ortalaması, kameralı sistem sayısı, sensörlü sistem sayısı, kritik sensör kullanımı ve veri iletim sıklığı bulunmaktadır.

Belirlenen öznitelikler arasından coğrafi yapı, yerleşim planlaması ve bina mimarisi coğrafi bilgi sistemleri (CBS) üzerinden elde edilebilmektedir. Şöyle ki, CBS ile konum bazlı olarak çevrenin coğrafi özellikleri ve yerleşim planlaması ile ilgili bilgiler çekilebilmektedir. CBS üzerinde tanımlanmış olarak bina mimarisi bilgileri de benzer şekilde alınabilmektedir. Bu çalışmada tasarlanan konsept ve yöntemlerin uygulamaya geçirilmesinde CBS uygulamalarının kullanılabilmesi düşünülmüştür. Ayrıca bu bilgiler kablosuz iletişim kanalı karakteristiği ile yakın ilişkilidir. Diğer öznitelikler arasından canlı sayısı ve yaş ortalaması kişi bilgileri ile ilişkili olmaktadır. Dolayısıyla, akıllı ev içerisinde yaşayacak kişilerin bilgilerinin girilmesi sonrası bu özniteliklerin çıkarılabilmesi sağlanacaktır. Kalan son dört öznitelik ise akıllı evde bulunacak bileşenler için sistem bilgilerini içermektedir. Kameralı sistem sayısı, sensörlü sistem sayısı, kritik sensör

**Çizelge 1:** Öznitelikler ile kablosuz iletişim kanalı ve haberleşme gereksinimi ilişkileri.

No	Öznitelik	Kablosuz İletişim Kanalı ve Haberleşme Gereksinimi İlişkisi	Normalize Değer Aralığı
1	Coğrafi Yapı	- Zorlu ortamlarda çoklu yol etkileri artış gösterir.	Zorlu (1) – Basit (10)
2	Yerleşim Planlaması	- Kentsel senaryolarda çoklu yol etkileri artış gösterir. - Yol kaybı karakteristiği planlamaya göre değişim gösterir.	Kentsel (1) – Kırsal (10)
3	Bina Mimarisi	- Zorlu mimarilerde çoklu yol etkileri artış gösterir. - Yol kaybı karakteristiği planlamaya göre değişim gösterir.	Zorlu (1) – Basit (10)
4	Canlı Sayısı	- Sayı arttıkça hareketliliğe bağlı kanal etkileri değişim gösterir.	Çok (1) – Az (10)
5	Yaş Ortalaması	- Ortalama değiştikçe uygulama kullanımları farklılaşacaktır.	Çok (1) – Az (10)
6	Kameralı Sistem Sayısı	- Sayı arttıkça veri iletim yoğunluğu ve veri hacmi artış gösterir.	Çok (1) – Az (10)
7	Sensörlü Sistem Sayısı	- Nesnelerin İnterneti tabanlı bileşen sayısına karşılık gelir.	Çok (1) – Az (10)
8	Kritik Sensör Kullanımı	- Kullanım söz konusu ise güvenilirlik gereksinimi önem kazanır.	Var (1) – Yok (10)
9	Veri İletim Sıklığı	- Sıklık arttıkça veri iletim yoğunluğu ve veri hacmi yükselir.	Sürekli (1) – Aralıklı (10)

**Çizelge 2:** Kullanıcı girdileri üzerinden öznitelik çıkarımı sırasında kullanılabilen soru listesi.

No	Uygulamada Kullanıcıya Yönelilecek Sorular	İlişkili Öznitelik
1	Binanın bulunduğu bölgenin dağlık/tepelik arazi yoğunluğu nasıldır?	Coğrafi Yapı
2	Bina bir ovada mı konumlanıyor?	
3	Bina ormana yakın mı?	
4	Binanın suya (deniz, nehir, vb.) yakınlığı nedir?	
5	Binanın bulunduğu bölgede yağış miktarını nasıl tanımlarsınız?	Yerleşim Planlaması
6	Binanın bulunduğu bölge şehir merkezinde veya kırsalda mı bulunuyor?	
7	Binanın bulunduğu bölgedeki binaların genel yüksekliği nasıl?	
8	Binanın bulunduğu bölgedeki binaların sıklığı nasıl?	Bina Mimarisi
9	Binanın yapı malzemesi nedir?	
10	Binanın cam oranı nasıldır?	
11	Evde kaç oda bulunuyor?	
12	Eviniz kaç metrekare?	Canlı Sayısı
13	Evde kaç kişi yaşıyor?	
14	Evde 50 yaş ve üzerinde kaç kişi var?	
15	Evde bulunan evcil hayvan sayısı kaçtır?	Yaş Ortalaması
16	Evde yaşayan insanların yaş bilgilerini girer misiniz?	Kameralı Sistem Sayısı
17	Evde kamera sistemi var mı?	
18	Evde kaç adet kamera var?	Sensörlü Sistem Sayısı Kritik Sensör Kullanımı Veri İletim Sıklığı
19	Akıllı evde aşağıdakilerden hangileri kullanılacak? - Ev aydınlatma kontrol sistemleri - Güvenlik sistemleri - Hareketli aydınlatma kontrolü sensörleri - Termostatlar - Akıllı fişler - Akıllı anahtarlı uzatma kabloları - Fırın, ocak uzaktan kontrol - Bahçe uzaktan kontrol sulama sistemleri - Gaz kaçağı, yangın vs. anlarında telefona anlık bildirim gelmesi	

kullanımı ve veri iletim sıklığı akıllı evin tasarımı sürecinde karar verilecek bilgileri oluşturmaktadır. CBS bilgileri, kişi bilgileri ve sistem bilgileri olmak üzere üç grup öznitelik çeşidinden yapay veri kümesi üretimi sırasında yararlanılmıştır. Son aşamada toplam dokuz öznitelik bu üç grup üzerinden gerekli bilgilerin toplanması ile temin edilmiştir.

Özniteliklerin çıkarımı noktasında gerçek bir uygulamada Çizelge 2 üzerinde verilen soruların kullanılabilmesi düşünülmüştür. Kullanıcılardan bu sorulara cevaplar alınarak öznitelik çıkarılması sağlanabilecektir. Söz konusu sorulara verilebilecek cevaplar özniteliklerin alacağı normalize değer aralıklarına haritalandırılabilir.

Çizelge 1 üzerinde verilen öznitelikler ile kablosuz iletişim kanalı ve haberleşme gereksinimi ilişkilerine daha detaylı şekilde bakılacak olursa; akıllı ev ve çevresi ile ilgili olarak coğrafi yapı, yerleşim planlaması, bina mimarisi ve canlı sayısı kablosuz iletişim kanalını değiştirmektedir. Yaş ortalaması, kameralı sistem sayısı, sensörlü sistem sayısı, kritik sensör kullanımı ve veri iletim sıklığı ise haberleşme gereksinimlerine yoğun şekilde etki etmektedir.

Coğrafi yapının zorlaştığı, örneğin dağlık ve ormanlık arazinin yaygın olduğu bölgelerde kablosuz iletişim kanalı açısından çoklu yol etkileri artış göstermektedir. Bu tür durumlarda WAN grubu yerine diğer standartların seçimi daha makul hale gelmektedir. Yerleşim planlaması açısından ise, kentsel senaryolarda yine çoklu yol etkilerinde artış oluşmaktadır. Dolayısıyla kentsel senaryolardaki yapılaşmanın yoğunluğuna bağlı olarak yine WAN grubu yerine diğer kablosuz haberleşme standartlarının seçtirilmesi daha tercih edilir olmaktadır. Bir benzer durum da bina mimarisi özniteliği için gerçekleşmektedir. Bina içi ve dışı arasındaki kablosuz iletişimin zorlaşacağı senaryo durumları için yine WAN grubu kablosuz iletişim standartları problem çıkarabilmektedir. Coğrafi yapı, yerleşim planlaması ve bina mimarisi öznitelikleri için aksi durumlarda diğer özniteliklerin önemi daha fazla olmaktadır.

Diğer özniteliklere bakıldığında, ortamdaki canlı sayısının fazla olması, doğal olarak hareketlilik miktarının yükselmesini beraberinde getirecektir. Bu noktada hareketliliğe bağlı kablosuz iletişim kanalı karakteristikleri değişim göstermeye başlayacaktır. Örnek olarak yüksek hareketlilik içeren senaryolarda WAN grubu haberleşme standartları daha etkin çözüm sunmaktadır. Beşinci öznitelik olarak, akıllı ev içerisinde yaşayacak kişilerin yaş ortalaması tercih edilecek uygulamalar açısından farklılık oluşturmaktadır. Genel olarak, yaş ortalaması arttıkça daha yoğun bir veri iletimi gereksini-

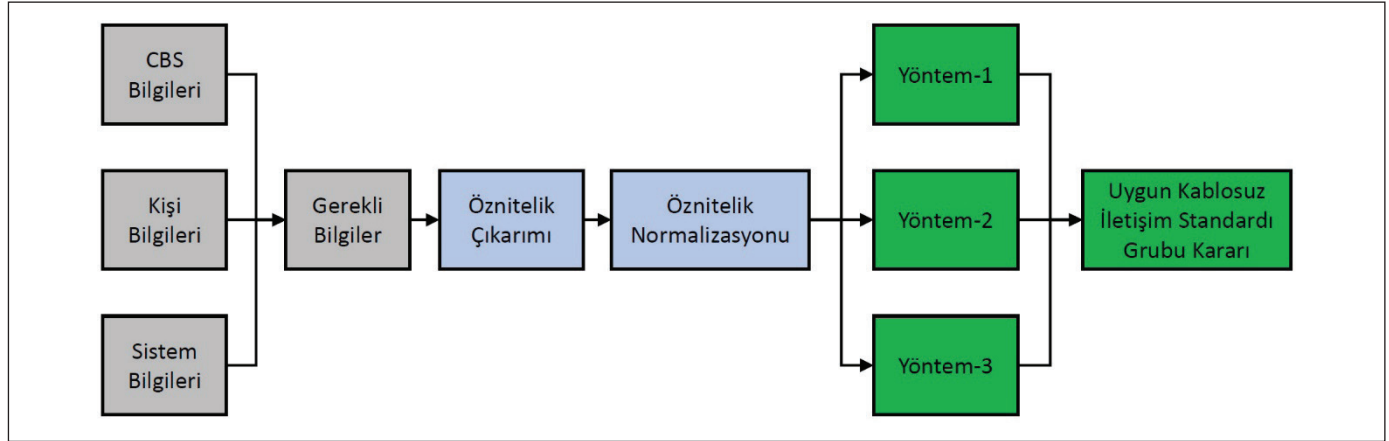
mi doğabilmekte, bu sebeple LPWAN standart grubu ihtiyacı karşılama noktasında zayıf kalabilmektedir.

Yaş ortalaması özniteliğindeki bir mantıkla, altıncı öznitelik olarak, kameralı sistem sayısının azlık ya da çokluğunda LPWAN ve diğer iletişim standardı grupları arasında bir tercih yapılması söz konusu olabilmektedir. Sensörlü sistem sayısı özniteliği için ise bu sayıda bir artış olursa Nesnelerin İnterneti tabanlı bileşen sayısının artması söz konusudur. Bu sebeple LPWAN standart grubu ön plana çıkmaktadır. Diğer yandan, kritik sensör kullanımının varlığı söz konusu olduğunda güvenilirlik ölçütü önem kazanmaktadır. Bu konuda farklı standartlar arasından 5G haberleşmesini içeren WAN standart grubu güvenilirlik ihtiyacını daha iyi karşılayabilmektedir. Son olarak, veri iletim sıklığı özniteliği veri iletim yoğunluğunu göstermekte ve yoğun bir iletim durumunda LAN standart grubu önemli olabilmektedir.

Görüldüğü üzere, farklı öznitelikler ile farklı sınıf etiketleri arasında değişen miktarlarda ilişkiler söz konusudur. Dolayısıyla, öznitelikler arasındaki ideal ilişkilerin yakalanması ve bu ilişkilerin tamamı göz önünde bulundurularak sınıf etiketleri arasından bir seçim yapılması için özel yöntemlerin geliştirilmesine ihtiyaç bulunmaktadır. Bu türde özniteliklerin bir arada olduğu ve öznitelik ilişkilerinin çıkarılmasında zorlanılacak durumlarda makine öğrenmesi hızlı bir çözüm imkanı sunmaktadır. Makine öğrenmesi ile farklı öznitelikler arasındaki ilişkilerin sınıf etiketleri arasından seçim yaptırma amacıyla hızlı şekilde çıkarılabilmesi sağlanmaktadır. Aynı zamanda sınıflar arası ayırıştırma adil bir denge kurma noktasında makine öğrenmesi teknikleri bu tür çok öznitelikli veri kümeleri açısından önemli bir fayda getirmektedir.

### 2.3. Geliştirilen Yaklaşım

Veri kümesi üretimi detaylarında anlatıldığı üzere farklı kaynaklardan (CBS, kişi ve sistem bilgileri) bilgiler toplanarak bu gerekli bilgilerden öznitelik çıkarımı yapılmaktadır. Öznitelik çıkarımı için kablosuz iletişim kanalı ve haberleşme gereksinimleri ile olan ilişkiler temel alınmaktadır. Şekil 2 üzerinde gösterilen blok diyagramda olduğu gibi öznitelik çıkarımı sonrasında öznitelik değerleri üzerinde bir normalizasyon işlemi yaptırılarak değerler 1-10 arasına çekilmektedir. Sonrasında bu normalize değerler, geliştirilen farklı yöntemlere girdi olarak verilmektedir. Yöntemlerin çıktısı olarak, mevcut şartlar açısından en uygun kablosuz iletişim standardı grubu kararına ulaşılmaktadır. Tavsiye kararı niteliğinde olan bu sonuca bakılarak bir akıllı ev sisteminde ne tür bir kablosuz iletişim standardının kullanılmasının daha



Şekil 2. Geliştirilen yaklaşımlar için kullanılan blok diyagram gösterimi.

etkin çözüm sağlayacağı belirlenebilecektir. Geliştirilen yaklaşım ve yöntemler özetle akıllı ev sistemi geliştiricilerini ve kullanıcılarını ilgilendirmektedir.

Şekil 2 üzerinde gösterilmiş olan, bu çalışmada geliştirilen üç farklı yöntemin ana özellikleri aşağıda özetle sunulmaktadır. Sonraki başlıkta bu yöntemlere ait sonuçlar verilerek birbirleriyle karşılaştırılmış ve makine öğrenmesine ne yönde ihtiyaçların olduğu yorumlanmıştır.

**Yöntem-1:** Bu yöntemde sadece makine öğrenmesi algoritmaları kullanılmaktadır. Normalize edilmiş özniteliklerin tamamı daha önceden eğitilmiş makine öğrenmesi modelini beslemekte, model çıktısı olarak da uygun kablosuz iletişim standardı grubu kararı verdirilmektedir. Bu kapsamda çoklu-sınıf sınıflandırma problemine çözüm aranmaktadır.

**Yöntem-2:** Bu yöntem iki aşamalı olarak uygulanmaktadır. İlk aşamada Sınıf-1 (WAN) öncelikle diğer iki sınıftan makine öğrenmesi kullanılmadan ayrıştırılmaktadır. Sonrasında ise ikinci aşamada ayrıca eğitilen makine öğrenmesi modeli Sınıf-2 (LAN) ve Sınıf-3 (LPWAN) ayrıştırması için görev almaktadır. Bu şekilde bir hibrit yaklaşım uygulanmaktadır. İlk aşamadaki Sınıf-1 ayrıştırmasında coğrafya, canlı sayısı, yaş ortalaması (yüksek ağırlıklı), kameralı sistem sayısı, kritik sensör kullanımı (yüksek ağırlıklı) ve veri iletim sıklığı öznitelikleri kullanılmıştır. Makine öğrenmesi için ise tüm öznitelikler girdi olarak verilmiştir.

**Yöntem-3:** Bu yöntem de iki aşamalı uygulanmaktadır. Fakat her iki aşamada da makine öğrenmesi kullanılmamıştır. İlk aşama olarak Yöntem-2 için kullanılan ilk aşamanın aynısı kullanılmıştır. İkinci aşamada ise Sınıf-2 ve Sınıf-3 arasında ayrıştırma yapmak için sensörlü sistem sayısı özneliğinden yararlanılmıştır.

Hem Yöntem-2 hem de Yöntem-3 için hangi özniteliklerin

kullanılacağına karar verilirken özniteliklerin sınıf tabanlı olarak sayısal dağılım grafikleri incelenmiş, makine öğrenmesi kullanılmayan yöntem aşamaları bu şekilde belirlenmiştir. Ayrıca, sayısal dağılım grafiklerine ek olarak sonraki bölümde ele alınan hata analizi sırasında karmaşıklık matrislerine bakılarak birbirlerine daha yakın ve daha uzak olan sınıf etiketlerinin belirlenmesi sağlanmıştır. Böylece Yöntem-2 ve Yöntem-3 için ilk etapta hangi sınıf etiketinin diğerlerinden ayrıştırılabileceğine karar verilebilmiştir. Bu noktada Sınıf-1 diğer iki sınıftan daha kolay ayrıştırılabilmektedir.

### 3. Bulgular ve Tartışma

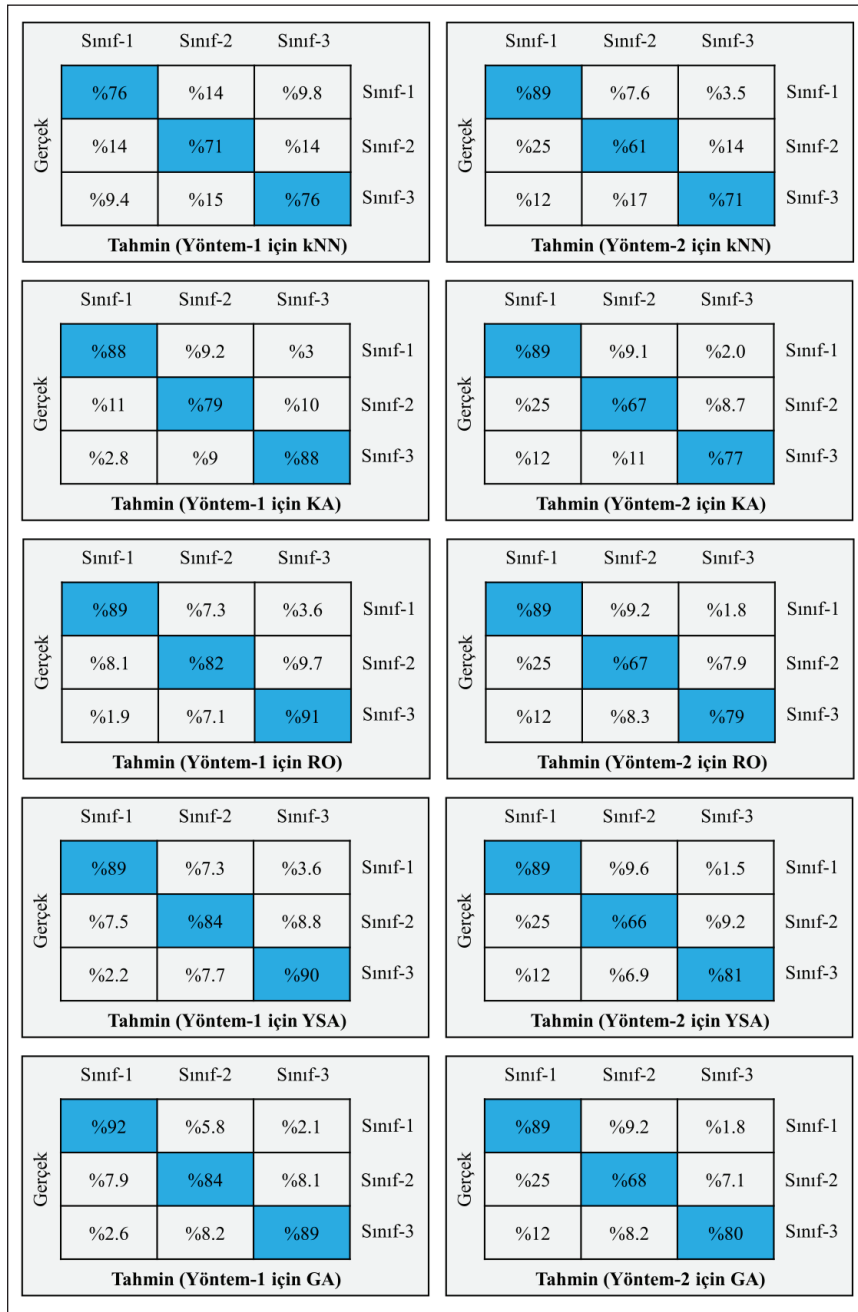
Bu bölümde, farklı makine öğrenmesi modellerinin üretilen yapay veri kümesi üzerindeki başarıları karşılaştırılmış ve hangi makine öğrenmesi algoritmalarının bu veri kümesi için daha başarılı sonuç verdiği anlaşılmaya çalışılmıştır. Ayrıca geliştirilen farklı yöntemlerin sonuçları birbirleriyle kıyaslanarak birbirlerine karşı üstünlükleri ele alınmış ve yorumlama yapılmıştır.

MATLAB platformu ile üretilen yapay veri kümesi için 10.000 örneklem kullanılmıştır. Herbir örneklem sınıf etiketi ile birlikte dokuz öznitelik bulundurmaktadır. Makine öğrenmesi kullanılan yöntem aşamalarında yapay veri kümesi üzerinde 5-katlamalı çapraz doğrulama yapılarak modeller eğitilmiştir. Farklı sınıflandırma algoritmalarına yönelik hiperparametre optimizasyonları öncesinde deneme yanılma yöntemi ile yapılmıştır (Yang ve Shami 2020). Sonrasında ise, Python için scikit-learn kütüphanesinden yararlanılmış ve GridSearchCV aracı ile farklı sınıflandırma algoritmaları için hiperparametreler belirlenmiştir (Pedregosa vd. 2011). Nihai hiperparametreler kullanılarak alınmış sonuçlar aşağıdaki alt başlıklarda sunulmaktadır.

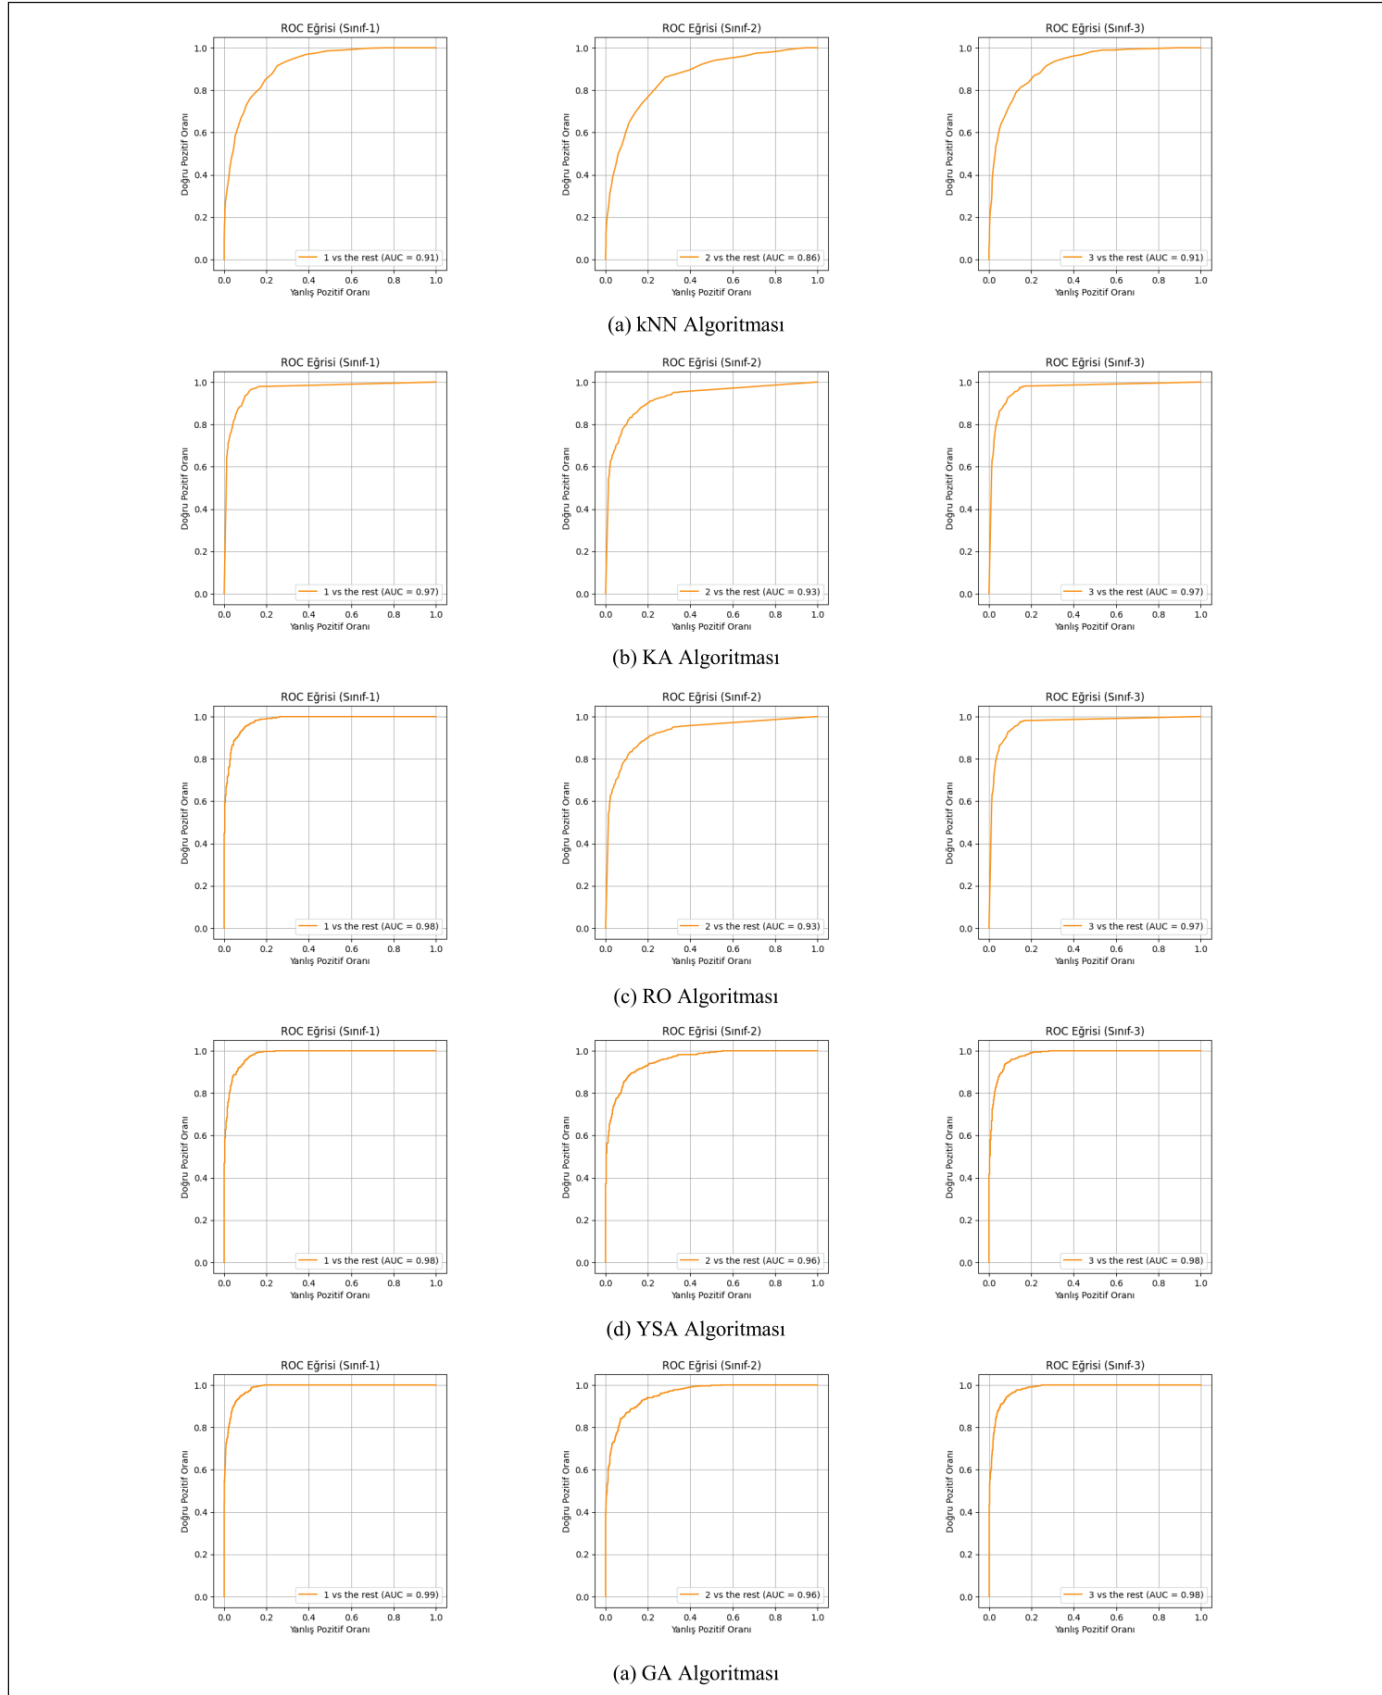
### 3.1. Yöntem-1 Sonuçları

Yöntem-1 kapsamında tüm öznitelikler kullanılarak tek bir aşamada makine öğrenmesinden yararlanılmıştır. Bu kapsamda k-En Yakın Komşu (kNN), Karar Ağacı (KA), Rastgele Orman (RO), Yapay Sinir Ağları (YSA) ve Gradyan Artırma (GA) sınıflandırma algoritmalarından yararlanılmıştır. RO ve GA topluluk öğrenmesi algoritmalarının özellikle YSA tabanlı algoritmalara karşı tablosal veri kümeleri üzerindeki olası üstünlüğünün araştırılabilmesi için bu sınıflandırma algoritmaları tercih edilmiştir. Literatürde bu

yönde araştırmalar yapılmaktadır (Shwartz-Ziv ve Armon 2022). KA algoritması ise RO algoritması ile karşılaştırılabilmek için çalışmaya dahil edilmiştir. Son olarak, klasik bir makine öğrenmesi algoritması olarak kNN algoritmasına da karşılaştırmalarda yer verilmiştir. Farklı algoritmalar için optimize edilmiş hiperparametreler ile alınan en iyi başarı sonuçları Çizelge 3 kapsamında sunulmuştur. Ayrıca bu sonuçlara karşılık gelen karmaşıklık matrisleri ve sınıf tabanlı ROC eğrileri sırasıyla Şekil 3 ve Şekil 4 üzerinde gösterilmiştir.



Şekil 3. Farklı sınıflandırıcı algoritmaları için alınmış karmaşıklık matrisleri.



Şekil 4. Farklı sınıflandırıcı algoritmalar için alınmış sınıf tabanlı ROC eğrileri.



**Çizelge 3.** Farklı algoritmalar için en iyi başarı sonuçları ve ilgili hiperparametreler.

Kullanılan Algoritma	Hiperparametre Seçimleri	Başarı Değerleri (Yöntem-1)	Başarı Değerleri (Yöntem-2)
kNN	Komşu Sayısı: 40	Doğruluk: %74.2 F1 skoru: 0.7425	Doğruluk: %72.7 F1 skoru: 0.7265
KA	Yapraktaki Min. Veri: 9 Bölmedeki Min. Veri: 8 Maks. Derinlik: 9	Doğruluk: %84.8 F1 skoru: 0.8475	Doğruluk: %76.8 F1 skoru: 0.7675
RO	Kestiri Sayısı: 200 Yapraktaki Min. Veri: 1 Bölmedeki Min. Veri: 5 Maks. Derinlik: 5	Doğruluk: %87.3 F1 skoru: 0.8725	Doğruluk: %77.9 F1 skoru: 0.7785
YSA	Gizli Katman: 20 Aktivasyon: Tanh Çözücü: Adam Maks. Tekrar: 1000	Doğruluk: %87.5 F1 skoru: 0.8750	Doğruluk: %77.8 F1 skoru: 0.7780
GA	Kestiri Sayısı: 500 Öğrenme Oranı: 0.1 Yapraktaki Min. Veri: 1 Bölmedeki Min. Veri: 2	Doğruluk: %88.3 F1 skoru: 0.8825	Doğruluk: %78.2 F1 skoru: 0.7820

**kNN Algoritması:** Bu algoritmada eğitilen modele test verileri verildiğinde en yakın komşusuna göre sınıflandırma işlemi yapılmaktadır. Optimize edilmeye çalışılan hiperparametre olarak da komşu sayısı ele alınmıştır. Komşu sayısı 40 olarak alındığında en yüksek doğruluk oranı olan %74.2 değerine ulaşılmıştır. Bu değer için alınan sonuçlar kapsamında karmaşıklık matrisi Şekil 3 üzerinde verilmektedir. Sınıf-1 ve Sınıf-3 için doğruluk oranları Sınıf-2'ye kıyasla daha yüksek olarak alınmıştır.

**KA Algoritması:** Bu algoritma kullanılarak yapraktaki minimum veri sayısı, bölmedeki minimum veri sayısı ve maksimum derinlik parametrelerine göre optimizasyon yapılmıştır. Son aşamada bu parametreler sırasıyla 9, 8 ve 9 olarak seçtirilmiştir. En yüksek doğruluk oranı olarak %84.8 değerine ulaşılmıştır. Karmaşıklık matrisinde Sınıf-1 ve Sınıf-3 için doğruluk oranları Sınıf-2'ye kıyasla daha yüksek olarak alınmıştır.

**RO Algoritması:** Hiperparametre olarak kestiri sayısı, yapraktaki minimum veri sayısı, bölmedeki minimum veri sayısı ve maksimum derinlik dikkate alınmıştır. Son aşamada bu parametreler sırasıyla 200, 1, 5 ve 5 olarak seçtirilmiştir. En yüksek doğruluk oranı olarak %87.3 değerine ulaşılmıştır. Karmaşıklık matrisinde Sınıf-3 için doğruluk oranı Sınıf-1 ve Sınıf-2'ye kıyasla daha yüksek olarak alınmıştır.

**YSA Algoritması:** Hiperparametre olarak gizli katman sayısı, aktivasyon fonksiyonu, çözücü algoritma ve maksimum tekrar sayısı dikkate alınmıştır. Son aşamada bu parametreler sırasıyla 20, Tanh, Adam ve 1000 olarak seçtirilmiştir. En yüksek doğruluk oranı olarak %87.5 değerine ulaşılmıştır. Karmaşıklık matrisinde Sınıf-3 için doğruluk oranı Sınıf-1 ve Sınıf-2'ye kıyasla daha yüksek olarak alınmıştır.

**GA Algoritması:** Hiperparametre olarak kestiri sayısı, öğrenme oranı, yapraktaki minimum veri sayısı ve bölmedeki minimum veri sayısı dikkate alınmıştır. Son aşamada bu parametreler sırasıyla 500, 0.1, 1 ve 2 olarak seçtirilmiştir. En yüksek doğruluk oranı olarak %88.3 değerine ulaşılmıştır. Karmaşıklık matrisinde Sınıf-1 için doğruluk oranı Sınıf-2 ve Sınıf-3'e kıyasla daha yüksek olarak alınmıştır.

Kullanılan sınıflandırma modellerine bakıldığında tüm sınıflar birlikte ele alındığında en yüksek doğruluk oranına ulaşan algoritmanın GA olduğu görülmektedir. Bununla birlikte Sınıf-1 için en başarılı algoritma GA; Sınıf-2 için en başarılı algoritma YSA ve GA; Sınıf-3 için en başarılı algoritma ise RO olarak karşımıza çıkmaktadır. Genel olarak topluluk öğrenmesi algoritmalarının kullanılan tablosal veri kümesi üzerinde daha başarılı olduğu anlaşılmıştır. (Shwartz-Ziv ve Armon 2022).

### 3.2. Yöntem-2 Sonuçları

Yöntem-2 ile ilgili sonuçlar yine aynı şekilde Çizelge 3 ve Şekil 3 üzerinde verilmiştir. İlk yöntemden farklı olarak iki aşamalı hibrit bir çözümün sunulduğu bu yöntemde öncelikle makine öğrenmesi kullanılmadan Sınıf-1 ayrıştırılmıştır. Sonrasında ise geriye kalan iki sınıf etiketi üzerinde yeni bir makine öğrenmesi modeli çalıştırılmıştır. Bu hibrit yöntemin başarı sonuçları genel olarak Sınıf-1 için daha iyi oluşsa da, yanlış negatif oranı açısından Yöntem-1 sonuçlarına kıyasla daha başarısız olmuştur. Genel doğruluk oranları %72.7 ile %78.2 arasında değişim göstermiştir. Kullanılan algoritmaların sıralaması açısından Yöntem-1 sonuçları ile farklılık olarak RO algoritması YSA algoritmasından çok az daha iyi sonuç vermiştir. Dolayısıyla topluluk öğrenmesi algoritmaları Yöntem-2'nin son aşaması kapsamında daha başarılı olmuştur. Bir diğer yorum olarak, her ne kadar Yöntem-2 yaklaşımı Sınıf-1 için Yöntem-1'e karşı üstünlük oluştursa da, GA algoritması Yöntem-1 ile Sınıf-1 açısından da daha iyi başarı göstermiştir. Bunun haricinde Sınıf-2 için en iyi sonucu GA ve Sınıf-3 için en iyi sonucu YSA vermiştir.

### 3.3. Yöntem-3 Sonuçları

İlk iki yöntemden farklı olarak makine öğrenmesinin hiç kullanılmadığı bir yöntem olarak, Yöntem-3 kapsamında ilk aşamada Yöntem-2 ile aynı yol izlenmiş, son aşamada ise Sınıf-2 ve Sınıf-3 arasında ayrıştırma sensörlü sistem sayısı özneliği kullanılarak yapılmıştır. Yöntem-3 için doğruluk oranı %73.1 olarak elde edilmiştir. Bu kapsamda Yöntem-3, kNN algoritmalarının kullanıldığı durumlarla benzer sonuçlar oluşturmuş, fakat ilk iki yöntemde diğer sınıflandırma algoritmalarının kullanıldığı durumlardan daha iyi bir sonuç vermemiştir.

Farklı tipte özneliklerin olduğu ve bu öznelikler arasında ilişki kurmanın zorlaştığı durumlar için yeni nesil makine öğrenmesi teknikleri pratik başarılı sonuçlar oluşturabilmektedir. Ele alınan özneliklerin herbirinin sınıf etiketlerine farklı yönlerden etki oluşturması sınıflandırma problemi zorlaştırmaktadır. Bununla birlikte, kNN algoritması gibi klasik makine öğrenmesi teknikleri bu çalışmadaki gibi veri kümeleri için zayıf kalabilmektedir.

### 3.4. Makine Öğrenmesi Algoritmalarında Eğitim ve Test Süreleri

Yöntem-1 ve Yöntem-2 için kullanılan makine öğrenmesi algoritmalarının eğitim ve test süreleri elde edilerek Çizelge 4 üzerinde sunulmuştur. Bu süreler bakıldığında, kNN ve KA algoritmalarının eğitim sürelerinin daha kısa olduğu gö-

rülmektedir. Gerçek zamanlı bir uygulama için daha kritik olan test sürelerinde ise KA ve YSA algoritmaları ön plana çıkmıştır. GA algoritması ise üçüncü sıradadır.

Çizelge 4. Farklı algoritmalar için alınan eğitim ve test süreleri.

Makine Öğrenmesi Algoritması	Eğitim Süresi (saniye)	Test Süresi (saniye)
kNN	0.104	2.687
KA	0.922	0.001
RO	3.589	0.491
YSA	38.357	0.038
GA	26.451	0.244

Çizelge 5. Kullanılan öznelikler için hesaplatılan bilgi kazancı ve reliefF değeri.

No	Öznelik	Bilgi Kazancı (Information Gain)	reliefF Değeri
1	Coğrafi Yapı	0.065	0.048
2	Yerleşim Planlaması	0.011	0.008
3	Bina Mimarisi	0.005	0.003
4	Canlı Sayısı	0.025	0.011
5	Yaş Ortalaması	0.067	0.024
6	Kameralı Sistem Sayısı	0.059	0.031
7	Sensörlü Sistem Sayısı	0.098	0.048
8	Kritik Sensör Kullanımı	0.033	0.013
9	Veri İletim Sıklığı	0.022	0.005

### 3.5. Hata Analizi

Yöntem-1 için alınan LogLoss (çapraz entropi kaybı) değerlerine göre, kararlılık açısından en iyi sonucu 0.310 ile yapay sinir ağları algoritması göstermiştir. En kötü sonuç ise karar ağacı algoritması ile 0.817 ile alınmıştır. Bu kapsamda, doğruluk oranları haricinde yapılan tahmin hatalarının gerçek değerden ne kadar uzak düştüğü incelenmiştir. Diğer algoritmaların LogLoss değerleri 0.310 ve 0.817 arasında değişiklik göstermiştir.

Çizelge 5 üzerinde, bu çalışmada kullanılan için hesaplatılan bilgi kazancı ve reliefF değerleri sunulmuştur. Bilgi kazancı, bir öznelik ve sınıf etiketleri düşünüldüğünde, beklenen bilgi miktarının hesaplanması şeklinde özetlenebilir ve ent-

ropinin azalma miktarı ile ilişkilidir. reliefF değeri ise, bir özneteliğin benzer veri örnekleri üzerinde sınıfları ayırt etme yeteneği olarak açıklanabilir. Bu kapsamda bilgi kazancı olarak, veri kümesindeki en değerli öznetelikler sensörlü sistem sayısı, yaş ortalaması, coğrafi yapı ve kameralı sistem sayısı olarak karşımıza çıkmıştır. Eğer öznetelik seçimi yapılmak istenseydi, bina mimarisi ve yerleşim planlaması öznetelikleri veri kümesine dahil edilmeyebilirdi. reliefF değeri açısından ise bina mimarisi ve yerleşim planlamasına ek olarak veri iletim sıklığı ve canlı sayısı da sınıflandırma için ayırt etme noktasında çok büyük bir etki oluşturamayabilmektedir. Fakat yine de küçük miktar da olsa tüm bu öznetelikler sınıflandırma başarısının artmasında rol oynamaktadır.

Son olarak, karmaşıklık matrisleri ve ROC eğrileri beraber değerlendirildiğinde, yanlış pozitif ve yanlış negatif değerleri açısından ardışık gelen sınıflar arasında daha yüksek oran olduğu, Sınıf-1 ve Sınıf-3 arasında ayrıştırma yapmanın daha kolay gerçekleştiği görülmektedir.

#### 4. Sonuç ve Öneriler

Yapılan çalışmanın sonuçlarına bakıldığında, geliştirilen makine öğrenmesi tabanlı yaklaşımın umut vaadedici olduğu görülmektedir. Tablosal veri kümeleri açısından topluluk öğrenmesi algoritmaları başarılı olabilmektedir. Akıllı ev sistemlerine yönelik olarak hangi kablosuz iletişim standartlarından yararlanılması gerektiğinin kararının tavsiye şeklinde verilmesi hususunda geliştirilen yaklaşımdan faydalanılabilecektir. Hem akıllı ev sistemlerinin tasarımcıları, hem de kullanıcıları bu geliştirilen yaklaşımdan yararlanabileceklerdir.

Gelecek çalışmalarda, kablosuz iletişim standartlarının gruplarından ziyade daha spesifik standartların bu tür bir çalışma ile belirlenebilmesi sağlanabilecektir. Dolayısıyla daha fazla sınıf etiketi arasından seçim yaptırılması söz konusu olacaktır. Bu durumda problem zorlaşabilecek, daha fazla özneteliğe ihtiyaç duyulabilecektir. Öznetelik sayısının artışına paralel olarak öznetelik indirgeme tekniklerinden yararlanılması gerekebilecektir. Yine sonraki çalışmalarda, geliştirilen yaklaşım için uygulamaya yönelik şekilde bir geliştirme yapılması söz konusu olacaktır. Bu noktada gerçek bir uygulama için farklı sistemlerden bilgi çekimi sürecinde çeşitli zorluklar yaşanabilecektir.

**Yazar katkısı:** Ahmet Yazar makalenin başlıca yazarıdır. Diğer yazarlar literatür taraması ve simülasyonlar için katkı vermiştir.

#### 5. Kaynaklar

- Altunan, U., Sazak, H., Yazar, A. 2023.** ML-Based Service Type Priority Decision Method Using Ambient Information for 5G. International Conference on Smart Applications, Communications and Networking (SmartNets), Istanbul, Turkey.
- Dzogovic, B., Santos, B., Noll, J., Do, VT., Feng, B., Do, TV. 2019.** Enabling Smart Home with 5G Network Slicing. IEEE 4th International Conference on Computer and Communication Systems (ICCCS), s.543, Singapore.
- Emam, KE. 2020.** Accelerating AI with Synthetic Data. O'Reilly Media, Inc.
- Eren, HA., Adar, N., Yazar, A. 2023.** Vehicle-to-Everything Communications Standard Selection Under Different Intelligent Transportation Scenarios with Artificial Learning. Journal of Intelligent Systems: Theory and Applications, 6(1):67-74.
- Hançer, A., Yazar, A. 2023a.** Waveform Decision Method with Machine Learning for 5G Uplink Communications. International Journal of Engineering Research and Development, 15(2):820-827.
- Hançer, A., Yazar, A. 2023b.** Multi-Carrier and Single-Carrier Waveform Decision Method in Non-Terrestrial Networks. 31st Signal Processing and Communications Applications Conference (SIU), Istanbul, Turkey.
- Horyachyy, O. 2017.** Comparison of Wireless Communication Technologies used in a Smart Home. MS Thesis, Blekinge Institute of Technology.
- Insight, B. 2022.** Smart Homes and Home Automation. Technical Report (9th Ed.).
- Kihero, AB., Tusha, A., Arslan, H. 2021.** Wireless Channel and Interference. Wireless Communication Signals: A Laboratory-based Approach. Wiley, ch. 10, s.267.
- Nikolenko, SI. 2022.** Synthetic Data for Deep Learning. Springer Cham.
- Parikh, PP., Kanabar, MG., Sidhu, TS. 2010.** Opportunities and challenges of wireless communication technologies for smart grid applications. IEEE PES General Meeting, USA.
- Pedregosa, F., vd. 2011.** Scikit-learn: Machine Learning in Python. Journal of Machine Learning Research, 12:2825-2830.
- Shilpa, B., Radha, R., Movva, P. 2022.** Comparative Analysis of Wireless Communication Technologies for IoT Applications. Artificial Intelligence and Technologies. Lecture Notes in Electrical Engineering, vol 806. Springer, Singapore.
- Sazak, H., Yazar, A. 2023.** Ambient Aware User-Numerology Association for 5G and Beyond. Signal Processing and Communications Applications Conference (SIU), Turkey.

- Stefanov, DH., Bien, Z., Bang, WC. 2004.** The smart house for older persons and persons with physical disabilities: structure, technology arrangements, and perspectives. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 12(2):228-250.
- Shwartz-Ziv, R., Armon, A. 2022.** Tabular Data: Deep Learning is Not All You Need. *Information Fusion*, 81:84-90.
- Yang, L., Shami, A. 2020.** On hyperparameter optimization of machine learning algorithms: Theory and practice. *Neurocomputing*, 415(1):295-316.
- Yarkan, S., Arslan, H. 2008.** Exploiting Location Awareness toward Improved Wireless System Design in Cognitive Radio. *IEEE Communications Magazine*, 46(1):128-136.
- Yazar, A., Çetin, AE., Töreyn, BU. 2012.** Human activity classification using vibration and PIR sensors. 20th Signal Processing and Communications Applications Conference (SIU), Mugla, Turkey.
- Yazar, A., Çetin, AE. 2013.** Ambient assisted smart home design using vibration and PIR sensors. 21st Signal Processing and Communications Applications Conference (SIU), Girne.
- Yazar, A., Dogan-Tusha, S., Arslan, H. 2020.** 6G Vision: An Ultra-Flexible Perspective. *ITU Journal on Future and Evolving Technologies – Volume 2020*, Article 9, 1(1):1-20.
- Yazar, A. 2021.** Requirement Analysis and Clustering Study for Possible Service Types in 6G Communications. 29th Signal Processing and Communications Applications Conference (SIU), Istanbul, Turkey.