

PAPER DETAILS

TITLE: 5G Yukari Link Haberlesmesinde Makine Öğrenmesi ile Dalga Sekli Karar Yöntemi

AUTHORS: Ayça HANÇER,Ahmet YAZAR

PAGES: 820-827

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/3148290>



5G Yukarı Link Haberleşmesinde Makine Öğrenmesi ile Dalga Şekli Karar Yöntemi

Waveform Decision Method with Machine Learning for 5G Uplink Communications

Ayça Hançer¹ , Ahmet Yazar^{2*}

¹Eskişehir Osmangazi Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, 26040 Eskişehir, TÜRKİYE

²Eskişehir Osmangazi Üniversitesi, Mühendislik-Mimarlık Fakültesi, Yazılım Mühendisliği Bölümü, 26040 Eskişehir, TÜRKİYE

Başvuru/Received: 17/05/2023

Kabul / Accepted: 30/06/2023

Çevrimiçi Basım / Published Online: 11/07/2023

Son Versiyon/Final Version: 14/07/2023

Öz

5. Nesil (5G) iletişim sistemleri öncesinde hücresel haberleşme yukarı linkinde sadece tek bir dalga şekli kullanılmaktaydı. İlk kez 2018 yılında standartları yayımlanmaya başlayan 5G iletişim sistemlerinde ise yukarı link için iki farklı dalga şekli kullanılabilmesi esnekliği getirilmiştir. Bununla beraber, bu esnekliğin yönetimini sağlayacak metotlar standartlarda geliştiriciye bırakılmıştır. Bu çalışmada, 5G iletişim sistemlerindeki yukarı link dalga şeklinin seçtirilmesine yönelik makine öğrenmesi tabanlı özgün bir metot geliştirilmiştir. Geliştirilen bu metot, çevresel farkındalığı yüksek seviyede olacak şekilde tasarlanmıştır.

Anahtar Kelimeler

“5G, Çevresel farkındalık, Dalga şekli, Makine öğrenmesi, Yukarı link haberleşmesi.”

Abstract

Prior to 5th generation (5G) communications systems, only a single waveform was used in the cellular communications uplink. In 5G communications systems, the standards of which were released for the first time in 2018, the flexibility of using two different waveforms for the uplink has been introduced. However, the methods to ensure the management of this flexibility are left to the designer in the standards. In this study, a novel machine learning-based method is developed for uplink waveform selection in 5G communications systems. The proposed method is designed to have a high level of environmental awareness.

Key Words

“5G, Environment awareness, Waveform, Machine learning, Uplink communications.”


1. Giriş

Gelişen teknoloji ile birlikte mobil iletişim altyapılarına ihtiyaç duyan uygulamaların çeşitliliğinin giderek daha fazla arttığı görülmektedir (Yazar, 2021). 5. Nesil (5G) ile beraber ilk defa birden fazla uygulama grubu tanımlanarak gelişmiş mobil genişbant (eMBB), ultra güvenilir ultra düşük gecikmeli haberleşme (URLLC) ve çok sayıda makine tipi haberleşme (mMTC) olmak üzere üç grup yeni iletişim teknolojilerinin geliştirilmesine temel olarak kullanılmaya başlanmıştır (ITU, 2015). Bu uygulama çeşitliliğine cevap verebilmek adına 5G iletişim sistemleri ile beraber alt teknolojilerde esnek tasarımların kullanılması önem kazanmıştır (Yazar vd., 2020). 5G sonrasında ise daha fazla uygulama çeşitliliği ve bunun sonucu olarak daha fazla esnek tasarımlı teknolojilerin görüleceği öngörülmektedir (Yazar vd., 2020). Literatürde uygulama çeşitliliklerine yönelik araştırmalar yapılarak 6. Nesil (6G) için farklı uygulama gruplarının tanımlanması amacıyla ön çalışmalar sürdürülmektedir (Dang vd., 2020; Saad vd., 2020; Zhang vd., 2019; Zong vd., 2019). Bunun haricinde, geliştirilmeye çalışılan esnek teknoloji konularından önemli bir tanesi de dalga şekli tasarımlarıdır.

Dalga şekli tasarımları, kablosuz iletişimde kritik öneme sahip alt sistemler olarak geçmektedir. Vericiden gönderilecek kiplenmiş sinyallerin, kablosuz haberleşme kanalına karşı dayanıklı hale getirecek şekilde paketlenmesi ve diğer yandan radyo spektrumunun en verimli şekilde kullanılması dalga şekli teknikleri ile tasarlanmaktadır (Yazar ve Arslan, 2020b). Bu kapsamda, 5G haberleşmesinin standartlaştırma çalışmaları öncesinde farklı dalga şekillerinin karşılaştırılmasına yönelik birçok çalışma yapılmıştır (Yazar vd., 2016). Bu çalışmalarda farklı dalga şekillerinin üstünlükleri incelenerek en uygun 5G dalga şekli belirlenmeye çalışılmıştır (Femenias vd., 2017). Standartlaştırma sürecinde ise, 5G haberleşmesinde kullanılan dalga şekli tekniklerine yönelik özellik tanımlamaları 3GPP TR 38.211 standart dokümanı altında yapılmıştır (3GPP, 2022). Aşağı link iletişimde ön ekli dikgen frekans bölme (CP-OFDM) dalga şekli ve ilişkili numerolojileri tercih edilmiştir. Yukarı link iletişimde ise CP-OFDM haricinde tek taşıyıcı frekans bölme (SC-FDM) dalga şekli de kullanılabilir. Görüldüğü üzere, 5G yukarı link iletişimde iki farklı dalga şeklinin kullanılabilirliği mümkündür. Daha önceki hücresel haberleşme standartlarında yukarı link iletişimde tek tip bir dalga şekli tercih edilerek kullanılmaktaydı. Bu kapsamda 5G ile beraber yeni bir esneklik boyutu kazandırıldığı görülmektedir (Yazar vd., 2020).

Bahsedilen esnek alt teknoloji tasarımları çerçevesinde, 5G haberleşmesinde aşağı link için dalga şeklinin farklı parametreleri aynı kapsama alanı altında farklı kullanıcılara atanabilmektedir (3GPP, 2022). Bu noktada farklı dalga şekli parametreleri anlamına gelen numeroloji gruplarının kullanıcılara atanması sırasında optimizasyon yapılmasına yönelik literatürde çalışmalar bulunmaktadır (Yazar ve Arslan, 2018; Marijanovic vd., 2018; Correia vd., 2021; Kotagiri vd., 2022). Bunlar arasında, kullanılan numeroloji çeşitliliğinin ne kadar sayıyla sınırlandırılması gerektiğine yönelik olarak bir optimizasyon çalışması yapılmıştır (Yazar ve Arslan, 2018). Diğer bir çalışmada numeroloji seçimleri kaynak tahsisi optimizasyonu ile beraber yaptırılmak istenmiştir (Marijanovic vd., 2018). Farklı bir optimizasyon çalışması olarak, veri tabanlı olarak numeroloji tahsisi yapılan çalışmalar da bulunmaktadır (Correia vd., 2021; Kotagiri vd., 2022). Ayrıca bu çalışmalara ek olarak makine öğrenmesi kullanılan numeroloji tahsis yöntemleri de mevcuttur (Yazar ve Arslan, 2019; Lee vd., 2019; Yazar ve Arslan, 2020a). Makine öğrenmesinden yararlanmak için bu çalışmalarda ölçülen kanal bilgisi genelde doğrudan veri kümesi olarak ele alınmıştır. Her ne kadar dalga şekli ile yoğun şekilde ilgili olmasa da, literatürde yukarı link için radyo kaynaklarının dinamik yönetimine dair farklı çalışmalar da bulunmaktadır (Mathur vd., 2017; Tang vd. 2020).

5G yukarı link iletişimi için SC-FDM ve CP-OFDM tekniklerinin beraber kullanılabilirliği, 3GPP organizasyonunun standart dokümanlarında belirtilmiştir (3GPP, 2022). Fakat literatür incelendiğinde, değişen şartlar altında bu dalga şekilleri arasından seçim yaptırıcı yönde optimizasyon yöntemlerinin henüz geliştirilmediği görülmektedir. Bu çalışmada bahsi geçen problem tanımı Şekil 1'de özet olarak verildiği üzere ele alınarak özgün bir yöntem geliştirilmiştir. Problem tanımlaması kapsamında, mevcut bölge şartlarında 5G yukarı link iletişimde hangi dalga şekli daha uygundur sorusuna cevap aranmaktadır.



Şekil 1. Geliştirilen yöntem için problem tanımı özeti

Bu çalışma ile literatüre yapılan özgün katkılar şunlardır:

1. 5G yukarı link iletişimde dalga şekli seçtirilmesine yönelik özgün bir yöntem geliştirilmiştir.
2. Çevre farkındalığı yüksek öznetelikler barındıran yeni bir yapay veri kümesi oluşturulmuştur.
3. Geliştirilen özgün yöntem kapsamında makine öğrenmesi tekniklerinden yararlanılmış, bu kapsamda kablosuz haberleşme sistemleri açısından örnek bir makine öğrenmesi uygulaması geliştirilmiştir.

Makalenin kalan kısımlarında incelenen konular şu şekildedir: 2. Bölüm kapsamında geliştirilen yöntemle dair detaylar ve yapay veri kümesinin üretim süreci açıklanmıştır. Makine öğrenmesi sonuçları 3. Bölüm içerisinde verilmiştir. Son olarak, 4. Bölüm kapsamında yapılan çıkarımlar sunulmuştur.


2. Materyal ve Metot

2.1. Dalga şekli karar yöntemi

Tek taşıyıcılı ve çok taşıyıcılı dalga şekillerinin birbirlerine karşı farklı üstünlükleri olabilmektedir. Tek taşıyıcılı dalga şekillerinin tepe güç ortalama güç oranı (PAPR) performanslarının daha iyi olması ve daha az hesaplama karmaşıklığı gerektirmesi sebebi ile yukarı link haberleşmede genelde tek taşıyıcılı dalga şekilleri tercih edilmektedir. 5G öncesinde 4. Nesil (4G, LTE) haberleşme sistemlerinin yukarı linki için bu sebeple tek taşıyıcılı bir dalga şekli olan SC-FDM kullanılmıştır. 5G iletişim ağlarında ise her ne kadar PAPR ve hesaplama karmaşıklığı açısından olumsuzlukları varsa da, ikinci bir yukarı link dalga şekli olarak CP-OFDM de kullanılması mümkün olmuştur. Çok taşıyıcılı bir dalga şekli olan CP-OFDM ile daha yüksek veri hızlarına çıkılabilmektedir. Dolayısıyla 5G yukarı link iletişimde hem tek taşıyıcılı hem de çok taşıyıcılı dalga şekli kullanma esnekliği bulunmaktadır. Bir başka deyişle, bu çalışmada geliştirilen dalga şekli seçim karar yöntemi, aynı zamanda tek taşıyıcılı ve çok taşıyıcılı dalga şekilleri arasında seçim yapılabilmesini sağlamaktadır.

Geliştirilen yöntemin blok diyagramı Şekil 2 üzerinde sunulmaktadır. Öncelikle çevresel bilgilerin toplanarak kaydedilmesi sağlanmaktadır. Çevresel bilgiler kapsamında bir bölgeye ait coğrafi karakteristik, yerleşim planlaması, açık-kapalı (indoor-outdoor) mekan yoğunluğu, küçük hücre yoğunluğu, nüfus yoğunluğu ve hareketlilik ortalaması gibi özet bilgiler değerlendirmeye alınmaktadır. Bu bilgilerin akıllı şehir ağları üzerinden otomatik olarak toplandığı varsayımı kabul edilmiştir.

Kablosuz haberleşme kanalı ilişkilerinden yararlanılarak çevresel bilgiler üzerinden öznetelik çıkarımı yapılmaktadır. Dolayısıyla, çevresel etkiler, kablosuz haberleşme kanalı ve sınıf etiketi olan dalga şekli seçenekleri (CP-OFDM/Sınıf 1 ve SC-FDM/Sınıf 2) arasında ilişkiler kurulmaktadır. Bu çalışmada iki farklı sınıf etiketi kullanılmıştır. Önerilen yöntem bu sınıflardan bir tanesini seçerek bir kapsama bölgesinde yukarı link iletişimi için dalga şekli kararı almaktadır.



Şekil 2. Geliştirilen yöntem için blok diyagram

2.2. Yapay veri kümesi üretimi

Dalga şekli karar yönteminin güdümlü öğrenme tabanlı uygulanabilmesi için bir veri kümesine ihtiyaç olmuş, bu kapsamda yapay bir veri kümesi üretilmiştir. Literatürdeki mevcut veri kümeleri incelendiğinde bu çalışmanın ele aldığı konuya yönelik örnek bir veri kümesine rastlanılamamıştır. Gerçek dünya verisine dayalı bir veri kümesi oluşturulmamasının sebebi ise, yapay veri kümelerinin hem daha hızlı ve az iş gücü ile üretilebilmesi, hem de yapay veri kümelerinde gerçek dünyada az rastlanan senaryo durumlarının istenildiği kadar oluşturulabilmesi sebebiyle daha dengeli bir veri kümesi üretilebilmesidir. Literatürde özellikle son yıllarda yapay veri kümeleri öne çıkmaktadır (Emam, 2020; Nikolenko, 2021).

Yapay veri kümesi oluşturulması sırasında ilk öncelikle her örneklem için sınıf etiketi oluşturulmaktadır. Bu sınıf etiketi üretildikten sonra özniteliklerin oluşturulması sağlanmaktadır. Özniteliklerin 1-10 arasında normalize edilmiş değerleri şu üç etkene bağlı şekilde elde edilmektedir: 1) Öznitelik karakteristiği, 2) kablosuz haberleşme kanalı ilişkisi, 3) sınıf etiketi ilişkisi. Öznitelik karakteristikleri ve kablosuz haberleşme kanalı ilişkileri Tablo 1 üzerinde özet olarak sunulmaktadır. Aynı tabloda ayrıca öznitelikler için normalize değer aralıkları ve bilgi kazanımı değerleri verilmektedir. Aşağıda ise detay açıklamalar yapılmıştır.

Tablo 1. Öznitelik Tanımları ve Kablosuz Haberleşme Kanalı İlişkileri

Öznitelik No	Öznitelik Tanımı	Temel Kablosuz Haberleşme Kanalı İlişkisi	Normalize Değer Aralığı	Bilgi Kazanımı
1	Coğrafi Karakteristik	Zorlu çevre koşullarında zengin çoklu yol etkileri ortaya çıkmaktadır	Basit (1) – Zorlu (10)	0.146
2	Yerleşim Planlaması	- Kentsel senaryolarda zengin çoklu yol etkilerinin oluşma ihtimali artmaktadır. - Yol kaybı karakteristiği çokça değişim göstermektedir.	Kırsal (1) – Kentsel (10)	0.138
3	Açık-Kapalı Mekan Yoğunluğu	- Yol kaybı karakteristiği çokça değişim göstermektedir. - Yüksek girişim ihtimali artmaktadır.	Açık (1) – Kapalı (10)	0.153
4	Küçük Hücre Yoğunluğu	- Yol kaybı karakteristiği çokça değişim göstermektedir. - Yüksek girişim ihtimali artmaktadır.	Seyrek (1) – Yoğun (10)	0.149
5	Nüfus Yoğunluğu	- Spektral verimlilik önemli bir kriter olmaktadır. - eMBB hizmet sınıfı ile yakın ilişkili olmaktadır. - Kanal kapasitesinin artırılmasını gerektirmektedir.	Seyrek (1) – Yoğun (10)	0.144
6	Hareketlilik Ortalaması	- Yüksek hareketlilik Doppler yayılımı oluşturmaktadır. - URLLC hizmet sınıfı ile yakın ilişkili olmaktadır. - URLLC gereksinimlerinin karşılanabilmesi için, daha az gecikme yayılımı ve Doppler yayılımı olmalıdır.	Yavaş (1) – Hızlı (10)	0.152

*eMBB : gelişmiş mobil genişbant, URLLC: ultra güvenilir ultra düşük gecikmeli haberleşme

İlk öznitelikler olarak coğrafi karakteristik ve yerleşim planlaması ele alınmaktadır. Bir bölgenin coğrafi karakteristiklerinin değişimi kablosuz haberleşme kanalına doğrudan etki eden faktörlerden önemli bir tanesidir. Zorlu coğrafya şartları genelde zengin çoklu yol (multipath) etkilerini beraberinde getirmektedir. Dağlık arazi, ormanlık bölge, deniz ya da büyük bir göle yakınlık gibi coğrafi özellikler haberleşme kanalına etki edebilmektedir (Yarkan ve Arslan, 2008). Benzer şekilde bir bölgedeki yerleşim planlamasının da çoklu yol etkileri açısından ilişkilendirilmesi gerekmektedir. Kentsel bir yerleşim planlamasında çoklu yol etkileri kırsal alan yerleşim planlamasına kıyasla daha fazla olmaktadır (Yarkan ve Arslan, 2008). Buna ek olarak, yerleşim planlamasının yapısına göre yol kaybı karakteristiği de değişim göstermektedir. İlk iki öznitelik için görüldüğü üzere çoklu yol ve yol kaybı etkileri ile yakın bir ilişki bulunmakta, sonuç olarak da zorlu coğrafya şartlarında ve kentsel yerleşim planlamalarında yukarı link iletişimde CP-OFDM (Sınıf 1) dalga şeklinin kullanımı tercih edilebilmektedir. Normalize edilmiş öznitelik değerleri Tablo 1 üzerinde verilen sınır değerleri çerçevesinde 1-10 değerleri arasında değişecek şekilde yapay veriler üretilmiştir.


Bir bölgedeki açık-kapalı mekan yoğunluğu diğer bir öznitelik olarak veri kümesi üretimine dahil edilmiştir. Çarşı, pazar, yollar ve stadyum gibi yerlerde açık mekan yoğunluğu daha fazlayken, yüksek sayıda yerleşim olan bölgelerde kapalı mekan yoğunluğu daha fazla olabilmektedir. Bu yoğunluk dağılımına göre yol kaybı karakteristiği de oldukça değişmektedir. Kapalı mekan yoğunluğunun yüksek olduğu bölgelerde yol kayıpları daha fazla olacak şekilde bir ilişki ortaya çıkmaktadır. Dolayısıyla, kapalı mekan yoğunluğu olan bölgelerde SC-FDM (Sınıf 2) dalga şekli daha ön planda olacak şekilde tercihlerin yapılması makuldur.

Diğer bir öznitelik olarak, bir bölge kapsamında küçük hücre yoğunluğu yukarı linkte dalga şekli seçimine etki edebilecektir. Bu yoğunluk yüksek olduğunda girişim olasılıkları daha fazla ortaya çıkacaktır. Bununla beraber, küçük hücre yapıları ile daha uyumlu olarak kullanılabilecek milimetre dalga frekansları için yol kaybı etkileri büyük önem taşımaktadır. Yüksek frekanslarda doğal olarak

yol kaybı etkilerinde artış gerçekleşmektedir. Bu sebeple küçük hücre iletim noktalarının yaygın olduğu bölgelerde milimetre dalga iletişiminin daha etkin olacağı temel alındığında, SC-FDM (Sınıf 2) dalga şeklinin tercih edilmesi mümkündür.

Beşinci öznelik olarak, bir bölgedeki nüfus yoğunluğu bilgisi ise spektrum verimliliği ve iletişim kapasitesi üzerinden kablosuz haberleşme kanalı ile ilişkilendirilebilmektedir. Yoğun nüfuslu bölgelerde çok taşıyıcı dalga şekillerinden yararlanmak daha uygun görülmekte, CP-OFDM (Sınıf 1) bu anlamda öne çıkmaktadır. Çok taşıyıcı dalga şekillerinin ölçeklenebilir yapısı sayesinde daha fazla kişiye daha yüksek kapasitede hizmet sunulabilmektedir. Ek olarak, eMBB uygulamaları da yoğun nüfusta daha fazla rol oynayacaktır.

Son öznelik, bir bölgedeki genel hareketlilik ortalaması bilgisi olarak ele alınmıştır. Hareketliliğin yüksek olması mobil haberleşme kanalı açısından Doppler yayılımı olarak karşımıza çıkabilmektedir. Dolayısıyla haberleşme kanalı üzerinden genel hareketlilik ortalamasının önemli bir yeri vardır. Bu öznelik ile ilgili olarak SC-FDM (Sınıf 2) dalga şekli tercih edilebilecektir.



Şekil 3. Kullanılan özneliklerin sınıf etiketleri için dağılım çizimleri

3. Bulgular ve Tartışma

Veri kümesi önceki bölümde anlatıldığı şekilde MATLAB platformu kullanılarak 20000 örneklem ile oluşturulmuştur. Bu veri kümesine yönelik olarak, kullanılan özneliklerden her biri için sınıf etiketi baz alınarak oluşturulan sıklık dağılım grafikleri Şekil 3'te verilmiştir. Görüldüğü gibi bu çalışmada tek bir öznelik dikkate alınarak bir sınıflandırma yapılması çok mümkün değildir. Başarı oranını artırmak için özneliklerin çoğunun kullanılması ve dengeli bir dağılım yapılması gerekmektedir. Tablo 1 ile verilen bilgi kazancı değerleri üzerinden de bu yönde bir değerlendirme yapmak mümkündür.

Tablo 2. En iyi Hiperparametreler ve Karşılık Gelen Başarı Oranları

Sınıflandırma Modeli	Hiperparametreler	Başarı Oranı	F1 Değeri
Sinir Ağları	En Fazla Döngü Sayısı = 200 Gizli Katman Sinir Sayısı = 10	0.886	0.886
k-En Yakın Komşu	Komşu Sayısı = 20	0.883	0.883
Gradyan Artırma	Ağaç Sayısı = 100 Öğrenme Oranı = 0.1	0.882	0.882
Rastgele Orman	Ağaç Sayısı = 15	0.869	0.869

Veri kümesi üzerinde herhangi bir öznitelik seçimi ya da öznitelik indirgeme işlemi yapılmadan, özniteliklerin hepsi dahil edilerek makine öğrenmesi yöntemleri kullanılmış, bu kapsamda Sinir Ağları, k-En Yakın Komşu, Gradyan Artırma ve Rastgele Orman modelleri tercih edilmiştir. Bu modellerin eğitimi sırasında 5-katlamalı çapraz doğrulama yöntemi kullanılmış ve sonrasında elde edilen sonuçlar dikkate alınarak hiperparametre optimizasyonu gerçekleştirilmiştir. Bu süreçte en iyi hiperparametreler deneme yanılma yoluyla belirlenmiştir (Yang ve Shami, 2020; Yu ve Zhu, 2020). Bu kapsamda her bir öğrenme modeli için en iyi sonucu veren hiperparametreler ve karşılık gelen başarı sonuçları Tablo 2’de gösterilmiştir.

Sinir Ağları modeli için en fazla döngü sayısı 200 ve gizli katman sayısı 10 seçildiğinde %89, k-En Yakın Komşu modeli için komşu sayısı 20 seçildiğinde %88, Gradyan Artırma modelinde ağaç sayısı 100 ve öğrenme oranı 0,1 seçildiğinde %88, Rastgele Orman modeli için ağaç sayısı 15 seçildiğinde %87 oranında başarı sağlanmıştır. Yapay veri kümesi üzerinden çalışıldığından ve bu sebeple veri kümesi üzerinde daha homojen bir dağılımın oluşması sebebiyle F1 değerleri başarı yüzdeleri ile benzer oluşmuştur. Tüm bu sonuçlara beraber bakıldığında, her model için uygun hiperparametreler seçildiğinde birbirine yakın başarı oranları elde edilmiştir. Bununla beraber, Sinir Ağları daha iyi sonuç veren bir makine öğrenmesi modeli olmuştur.

Şekil 4, Kullanılan makine öğrenmesi modelleri için elde edilen karmaşıklık matrislerini göstermektedir. Sinir Ağları (Şekil 4-a) modelinde 20000 tahmin içerisinde 1. sınıf etiketi (CP-OFDM) için %89.0, 2. sınıf etiketi (SC-FDM) için %88.1’lik doğruluk oranı hesaplanırken sırasıyla; k-En Yakın Komşu (Şekil4-b) modelinde 1. sınıf etiketi için %89.8, 2. sınıf etiketi için %86.8; Gradyan Artırma (Şekil4-c) modelinde 1. sınıf etiketi için %88.4, 2. sınıf etiketi için %88.0; Rastgele Orman (Şekil4-d) modelinde 1. sınıf etiketi için %87.2, 2. sınıf etiketi için %86.7’lik doğruluk oranı hesaplanmıştır. Yapay sinir ağlarının diğer algoritmalarla göre daha iyi performans göstermesinin nedeni, lineer olmayan ilişkileri modelleyebilmesi, veriler arasındaki kompleks ilişkileri yakalayabilmesi ve yeterli genişlikteki veri kümeleri üzerinde yüksek performans gösterebilmesidir (Abd El-Hamid vd., 2019). Bununla beraber, diğer makine öğrenmesi algoritmaları da uygun hiperparametreler kullanıldığında Sinir Ağları ile alınan sonuçlara yaklaşabilmiştir. Klasik bir makine öğrenmesi tekniği olmasına karşılık, k-En Yakın Komşu algoritması 1. sınıf etiketi için en iyi doğruluk oranı performansını göstermiş, fakat 2. sınıf etiketi için bu kadar başarılı olamamıştır.

Tahmin

1

2

Σ

Gerçek

1

%89.0

%11.0

10112

2

%11.9

%88.1

9888

Σ

10176

9824

20000

a) Sinir Ağları

Başarı Oranı = %89

Tahmin

1

2

Σ

Gerçek

1

%89.8

%10.2

10112

2

%13.2

%86.8

9888

Σ

10377

9623

20000

b) k-En Yakın Komşu

Başarı Oranı = %88

Tahmin

1

2

Σ

Gerçek

1

%88.4

%11.6

10112

2

%12.0

%88.0

9888

Σ

10121

9879

20000

c) Gradyan Artırma

Başarı Oranı = %88

Tahmin

1

2

Σ

Gerçek

1

%87.2

%12.8

10112

2

%13.3

%86.7

9888

Σ

10129

9871

20000

d) Rastgele Orman

Başarı Oranı = %87

Şekil 4. Karmaşıklık matrisleri

4. Sonuç

Yapılan çalışmanın sonuçlarına bakıldığında, 5G hücresel iletişim sistemlerinin yukarı linklerinde kullanılan farklı dalga şekilleri arasında otomatik seçim yaptırılabilmesini sağlayan işlevsel bir yöntemin geliştirildiği görülmektedir. Bu kapsamda makine öğrenmesinin kullanılması, farklı bilgi kaynaklarından gelen verilerin ortak analiz edilmesi sebebiyle anlamlı olmuştur.

6G haberleşmesinde daha fazla sayıda dalga şeklinin beraber çalışabilmesi öngörüsü ele alındığında, gelecek çalışmalarda ikiden daha fazla dalga şekli arasında seçim yaptırılabilmesine olanak tanıyan yöntemlerin geliştirilmesi söz konusu olabilecektir. Bununla beraber bu çalışmada kullanılan bilgi kaynaklarına kıyasla daha fazlasının girdi olarak sisteme dahil edilmesi sonrasında yeni yöntemlerin tasarlanması gerekebilecektir. Dolayısıyla, makine öğrenmesi açısından hem daha çok öznelite, hem de daha çok sınıf etiketi ortaya çıkacaktır. Gelecek çalışmaların bu öngörü çerçevesinde şekillenmesinin faydalı olacağı değerlendirilmektedir.

Teşekkür

Bu çalışma 122E400 no'lu Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) projesi kapsamında desteklenmiştir.

Referanslar

3GPP. 2022. "NR; Physical channels and modulation", Teknik Rapor, TR 38.211.

Abd El-Hamid, H. E. M. A. A., Khalifa, W., Roushdy, M. I., Salem, A. M. 2019. "Machine Learning Techniques for Credit Card Fraud Detection", Future Computing and Informatics Journal, 4(2), 98-112.

Correia, N., Al-Tam, F., Rodriguez, J. 2021. "Optimization of Mixed Numerology Profiles for 5G Wireless Communication Scenarios", Sensors, 21(4), 1-22.

Dang, S., Amin, O., Shihada, B., Alouini, M. 2020. "What should 6G be?", Nature Electronics, 3(1), 20–29.

El Emam, K. 2020. Accelerating AI with Synthetic Data (1. Basım). ABD: O'Reilly Media.

Femenias, G., Riera-Palou, F., Mestre, X., Olmos, J.J. 2017. "Downlink scheduling and resource allocation for 5G MIMO-multicarrier: OFDM vs FBMC/OQAM", IEEE Access, 5(1), 13770–13786.

International Telecommunication Union (ITU). 2015. "IMT Vision – Framework and Overall Objectives of the Future Development of IMT for 2020 and Beyond", ITU Publications, M.2083-0.

Kotagiri, D., vd. 2022 "Context-based Mixed-Numerology Profile Selection for 5G and Beyond", IEEE 19th Annual Consumer Communications & Networking Conference (CCNC), 611-616.

Lee, H., Vahid, S., Moessner, K. 2019. "Machine Learning Based RATs Selection Supporting Multi-connectivity for Reliability", International Conference on Cognitive Radio Oriented Wireless Networks, 31-41.

Marijanovic, L., Schwarz, S., Rupp, M. 2018. "Optimal Numerology in OFDM Systems Based on Imperfect Channel Knowledge", IEEE 87th Vehicular Technology Conference (VTC Spring), 1-5.

Mathur, R.P., Pratap, A., Misra, R. 2017. "Distributed algorithm for resource allocation in uplink 5G networks", MobiMWareHN, Mobility, Interf. Middlew. Manag. HetNets, 1–6.

Nikolenko, S. I. 2021. Synthetic Data for Deep Learning (1. Basım). Springer.

Saad, W., Bennis, M., Chen, M. 2020. "A Vision of 6G Wireless Systems: Applications, Trends, Technologies, and Open Research Problems", IEEE Network, 34(3), 134-142.

Tang, F., Zhou, Y., Kato, N. 2020. "Deep Reinforcement Learning for Dynamic Uplink/Downlink Resource Allocation in High Mobility 5G HetNet", IEEE J. Sel. Areas Commun., 38(12), 2773-2782.

Yang, L., Shami, A. 2020. "On Hyperparameter Optimization of Machine Learning Algorithms: Theory and Practice", arXiv:2007.15745 [cs.LG].

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., Onat, F. A., Arslan, H. 2016. "New Generation Waveform Approaches for 5G and Beyond", IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU).
- Yazar, A., Arslan, H. 2018. "A Flexibility Metric and Optimization Methods for Mixed Numerologies in 5G and Beyond", IEEE Access, 6(1), 3755-3764.
- Yazar, A., Arslan, H. 2019. "Selection of Waveform Parameters Using Machine Learning for 5G and Beyond", IEEE International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC), 1-6.
- 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., Arslan, A. 2020a. "A Waveform Parameter Assignment Framework for 6G With the Role of Machine Learning", IEEE Open Journal of Vehicular Technology, 1(1), 156-172.
- Yazar, A., Arslan, H. 2020b. "Introduction to Waveform Design", Flexible and Cognitive Radio Access Technologies for 5G and Beyond, The Institution of Engineering and Technology (IET), 3-27.
- Yazar, A. 2021. "Requirement Analysis and Clustering Study for Possible Service Types in 6G Communications", IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU).
- Yu, T., Zhu., H. 2020. "Hyper-Parameter Optimization: A Review of Algorithms and Applications", arXiv:2003.05689 [cs.LG].
- Zhang, Z., vd. 2019. "6G Wireless Networks: Vision, Requirements, Architecture, and Key Technologies", IEEE Vehicular Technology Magazine, 14(3), 28-41.
- Zong, B., Fan, C., Wang, X., Duan, X., Wang, B., Wang, J. 2019. "6G Technologies: Key Drivers, Core Requirements, System Architectures, and Enabling Technologies", IEEE Vehicular Technology Magazine, 14(3), 18-27.