

Kablosuz Ağlarda Farklı Gölgeleyen Kanallar Üzerinden Enerji-Verimli Veri İletimi için Makine Öğrenmesi-temelli Su-Doldurma Algoritması

Performance of Machine Learning-based Water-Filling Algorithm for Energy Efficient Data Transmission over Different Fading Channels in Wireless Networks

 Ömer Melih Gül

Bilgisayar Mühendisliği Bölümü
Bahçeşehir Üniversitesi, İstanbul, Türkiye
Email: omermelih.gul@bau.edu.tr

Özetçe—Bu çalışmada, kablosuz ağlarda çoklu gölgeleyen kanallar üzerinden bir kaynak tahsisi problemi ele alınmaktadır. Bu çalışmada önceki çalışmalardan farklı olarak, anlık veri iletim hızı sadece ayrık bir kümedeki veri iletim hızı değerlerinden birini alabilir. Bu probleme makine öğrenmesi-temelli çevrimiçi su doldurma algoritmaları önerilmiştir. Çevrimiçi ve en iyi çevrimdışı politikaların görece performansı, çeşitli tiplerde (Rayleigh, Rician, Nakagami, Weibull) gölgeleyen kanallar için çeşitli zaman ufuklarında değerlendirilmektedir. Sayısal sonuçlar, özellikle daha uzun zaman ufukları için bu çevrim içi su doldurma algoritmalarının çevrim dışı su doldurma algoritmalarına yakın performansı olduğunu göstermektedir.

Anahtar Kelimeler — Su-Doldurma, Makine Öğrenmesi, Çoklu Erişim Haberleşmesi, Çevrimiçi Politika

Abstract—In this paper, we tackle a resource allocation problem over multiple fading channels in wireless networks. Differing from previous studies, the data transmission rate can take a value out of a discrete set of data transmission rates in this work. We propose machine-learning-based online waterfilling algorithms for this problem. The relative performance of the online and optimal offline policies are evaluated for various types of fading channels (Rayleigh, Rician, Nakagami, Weibull) over various time horizons. The numerical results demonstrate these online waterfilling algorithms shows close performance to offline waterfilling algorithms especially for longer time horizons.

Keywords — Water-Filling, Machine Learning, Multi-access Communications, Online Policy

I. GİRİŞ

Bu kısımda, öncelikle incelenen problemin güdülenmesi verilmektedir. Sonraki alt kısımda, problemin ilgili literatüründeki yakın çalışmalardan bahsedilmiştir. Daha sonraki alt kısımda, bu makalede literatüre yapılan ana katkılar özetlenmiştir. Son alt kısımda, makalenin geriye kalan kısmının teşkili verilmiştir.

A. Güdüleme

Sıfır gecikme süresi, daha yüksek güvenilirlik ve yüksek hızlara sahip olacak beşinci nesil iletişimin (5G) bir sonucu olarak gezici ekosistemlerin yeni yollarla genişleyeceği tahmin edilmektedir. Qualcomm'un internet sitesine [1] göre 5G, sayısallaştırılmış lojistik, uzaktan sağlık, hassas tarım ve daha güvenli ulaşım sağladığı için neredeyse tüm işletmeleri etkileyecektir. Doğrudan iletişim, 5G teknolojisinin önemli bir bileşeni olacaktır. Gezici stratejiler düşünüldüğünde, gelişen dönem ulaşımı ve yaygınlaşan gezici hizmetler, önemli miktarda enerji kullanımına yol açmakta ve bu da cihazdan cihaza iletişimin gerçekleşmesini engellemektedir. Sınırlı menzili nedeniyle veri aktarımı, yeni gezici uygulamalar ve iş modellerine olanak sağlayacaktır [2].

Haberleşme sistemlerinde veri iletiminin verimliliğini en yükseltmek için su doldurma algoritmaları mutlak bir gerekliliktir. Bu algoritmalar, diğer şeylerin yanı sıra kablosuz haberleşme sistemlerinin tasarımını, ağ eniyileştirmesini ve kaynak tahsisini etkiler [3], [4], [5], [6], [7], [8], [9], [10], [11]. Bunlar, genellikle çok boyutlu haberleşme sistemlerinde kaynakların tahsisi süreci için gereklidir. Son on yılda kablosuz sistemlerin gelişmesiyle birlikte farklı fiziksel sınırlamalar ve performans ihtiyaçları ortaya çıkmıştır. Bu durum, tek su seviyeli çözümlerden çoklu su seviyeli çözümlere ve ideal kanal durum bilgisi (KDB)-tabanlı çözümlerden gürbüz çözümlere kadar çeşitli su doldurma politikalarına yol açmaktadır [12].

B. İlgili Literatür

Bu alt kısımda benzer problemlere su-doldurma algoritmaları öneren, kullanan çalışmalar sunulmaktadır.

[13]'teki makale, dikey frekans bölmeli çoklama (DFBC) tabanlı bilişsel radyo sistemlerinde güç tahsisi için düşük karmaşıklıkta bir su doldurma algoritması sunmaktadır. Bilişsel radyo ile ortaya çıkan bu güç sınırlamalarının üstesinden gelmek için anlık güç artırma

veya güç azaltma su doldurma işlemi kullanılarak yapılabilir. Bu güç sınırlamaları, geleneksel su doldurma algoritmaları ile çözülememektedir. Sayısal sonuçlar, bu makalede önerilen su doldurma algoritmasının gücü en iyi şekilde yeniden dağıtabildiklerini ve bunu yinelemeli su doldurma algoritmalarından daha uygun bir şekilde yaptığını göstermektedir.

[14]'te bu problemleri Karush-Kuhn-Tucker koşullarına dayalı doğrusal olmayan bir sistem çözülerek bir yaklaşım önerilmiş ve bu önerilen su doldurma algoritmasının en iyiliği gösterilmiştir. Sayısal sonuçlar, önerilen yöntemin sağlam, ileri görüşlü ve düşük karmaşıklıkta olduğunu göstermektedir.

[15]'te benzetim ortamında DFBC tabanlı bir bilişsel radyo sisteminde kullanılmak üzere tekdüze, su doldurma, yetersiz ve en iyi algoritmalar gibi çeşitli güç dağıtım algoritmaları incelemektedir. Sayısal bulgular, önerilen algoritmaların geleneksel su doldurma algoritmalarına ve tekdüze su doldurma algoritmalarına göre daha yüksek iletim sağlama yeteneğine sahip olduğunu göstermektedir.

[16]'da Devasa Çok Girdili Çok Çıktılı (ÇGÇÇ) için mümkün olan en yüksek enerji verimliliği seviyesine ulaşmasını sağlayacak bir güç tahsisi yöntemi önerilmiştir. Bu basitleştirilmiş ifadeye dayalı olan en iyi güç tahsisi stratejisini geliştirmek için yeni bir yöntem sağlamakta ve sonra bu yöntemi geleneksel yöntemle karşılaştırmaktadır. Hem enerji hem de çalışma (spektral) bant genişliği açısından mümkün olan en büyük tasarrufu elde etmek için, bu çalışmanın yazarları gelişmiş bir su doldurma tekniği önermekte ve güç tahsisi algoritmasına dahil etmektedir. Benzetimin sonuçları, inen bağlantı iletiminin enerji verimliliğinin ve spektrum verimliliğinin, geleneksel yöntemlerle karşılaştırıldığında önemli ölçüde arttığını ortaya koymaktadır.

[17]'teki çalışma, bir geliştirilmiş güç tahsisi su doldurma politikası önermektedir. Bu politika, geleneksel su doldurma politikasının gerektirdiği yinelemeli hesaplamalara olan ihtiyacı ortadan kaldırmaktadır. Ek olarak, bu politika, hesaplama sayısını azaltan politikayı etkili bir şekilde sadeleştirir. DFBC'ye dayalı bir güç tahsisi stratejisi [18]'deki çalışmada önerilmiştir. Sonra, bilişsel radyo ağındaki sönmülenen (gölgelenen) kanallar boyunca su akışı olarak bilinen bir mekanizma kullanılmaktadır. Bu politika, ağır kanal performansını önemli ölçüde iyileştirme potansiyeline sahiptir. Ek olarak, [19]'daki çalışmada belirtildiği gibi, çok taşıyıcı çıkkan-bağlantı dikey-olmayan çoklu erişim (DOÇE) ağlarında kaynak tahsisi probleminin çözümü için su doldurma stratejisi kullanılabilir. [20]'de makalede [21]'de makalede önerilen MAPEL yöntemi ile çözülebilecek yüksek karmaşıklıkta ağırlıklı verihacmi enyükseltmesi problemi ele alınmaktadır. MAPEL hesaplamaları için gereken süreyi azaltmak için, en önemlisi en iyileştirme probleminde en az veri hızı gerekliliğini dikkate alarak, bir dizi farklı yöntemlerden yararlanmaktadır. Ayrıca ilave kaynak blokları üzerinden

tahsisat yapılması gerektiğinde her kullanıcı için en fazla güç kullanılabilir; bu güç miktarı gözetilerek su doldurma prensibi eniyileştirme sürecine dahil edilmiştir.

[22]'de bu yöntem, dışbükey bir eniyileştirme problemi oluşturarak gerçekleştirilir. Elde edilen kelimelerin ortalama karesel hatasının sınırlarına bağlı olarak hızı maksimize etme, enerjiyi minimuma indirme ve enerji-gecikme ürününü eniyileştirme kriterlerini dikkate alır. Bu çalışmada ele alınan eniyileştirme problemleri sırasıyla geleneksel su doldurma problemleri, zemin düzleştirme ve su doldurma problemleri ve kum dökme ve su doldurma problemleri olarak kabul edilebilir. Buna göre, açgözlü algoritmalar, en iyi şekilde ayrı salınımlar elde etmek için bir yöntem olarak sunulmuştur.

[23]'te sıfır zorlama, en büyük olabilirlik ve minimum karesel ortalama hatası eşitleme teknikleriyle su doldurma algoritmaları uygulayıp ÇGÇÇ sistemlerinin uzay-zaman blok kodu (UZBK), Dikey-UZBK ve kanal kapasitesi geliştirme çerçevelerinin bit hata oranını inceler. Bu çalışmanın sonuçları bir tablo şeklinde sunulmuştur.

[24]'teki makalede geliştirilmiş bir su doldurma tekniği önerilmiştir. Bu algoritma, iletim enterferansının (girişiminin) sıcaklık sınırını en iyileştirmek için signum işlevini kullanmaktadır. Bu, hem kanal taramanın esnekliğini geliştirmekte, hem de iletişim ağının sığasını (kapasitesini) da etkili bir şekilde en iyileştirmektedir.

[25]'de yapılan çalışmada, birçok sönmüleme kanalı içeren kablolu ağlarda bir kaynak tahsisi probleminin çözümü üzerine çalışılmaktadır. Burada veri iletim hızının sürekli bir değer alabileceği kabul edilmektedir. Ele alınan probleme önce çevrimdışı bir yaklaşım uygulanmaktadır ve sorunu tüm farklı sönmüleme kanallarında bir bütün olarak değerlendirilip çevrimdışı bir su doldurma tekniğini uygulanarak, tüm sönmüleme kanalları üzerinden bu soruna en uygun çözüm önerilmesi hedeflenmiştir. Sonra birçok sönen kanalın olduğu durumu çevrimiçi olarak ele alınıp geçmişe dayalı bir su doldurma politikası önerilmiştir.


İlgili araştırmalarda, bu politikaların genellikle yüksek düzeyde hesaplama karmaşıklığına sahip olmasına rağmen, çeşitli sistemlerde meydana gelen çeşitli problemler için çok sayıda farklı su doldurma politikası sunulmaktadır. Sonuç olarak, bu sorunu ele almak için, özellikle hem pratik hem de daha güvenilir ve etkili su doldurma algoritmaları gerekir. Ayrık veri hızı kümesi düşünülerek bu problemde veri iletimi için gelecekteki su seviyesine karar vermek için makine öğrenmesi kullanmanın etkisi, bildiğimiz kadarıyla araştırılmamıştır.

C. Önemli Katkıları

Bu makalenin literatüre ana katkıları şu şekildedir:

- Bu çalışmada, birçok sönmüleme kanalı içeren kablolu ağlarda bir kaynak tahsisi probleminin çözümü üzerine çalışılmaktadır. Bu problem, farklı sönmüleme kanallarında bir bütün olarak ele alınıp incelenmektedir.

Şekil 1'de, X, Y(Bölümlenmiş) ve Y(Yığılanmış) değişkenleri, sırasıyla zamanın geçişi, kanal kazancı miktarını ve ayrılan iletim gücünün kanal kazancıyla çarpımını göstermektedir. İletim olmadığında zaman dilimi 10'daki Y(Yığılanmış) değeri, Şekil 2'de gösterildiği gibi Y(Bölümlenmiş) değeri ile aynıdır.



Şekil 2. $T=10$ zaman diliminde $E=20$ 'yle su doldurma

IV. ÖNERİLEN SU DOLDURMA POLİTİKASI

Bu bölümde, ilgili literatür ve önceki çalışmamız [25]'ten farklı olarak (sürekli yerine) ayrık bir veri iletim hızı setini düşünerek eldeki probleme Makine Öğrenmesine dayalı çevrimiçi bir çözüm önerilmektedir.

Bu yönetime göre önce ayrık veri iletim hızı kümesini ve sürekli bir kümeden değer alan kanal kazançlarını düşünerek bir makine öğrenmesi algoritması olan k-means kümeleme ve sınıflandırma algoritmasını uygulanır. Burada kanal kazançlarının her birini bir değere eşlenir. Sonra geçmişin bir bölümüne dayalı bir su doldurma seviyesi oluşturmak için geçmişten yararlanır. Zamanla algoritma dinamik biçimde öğrenip güncel su seviyesini ne kadar verinin iletilmesi gerektiğini hesaplar. Bu çevrimiçi politikanın amacı, önceki zaman dilimlerinde kanalın özelliklerinden sonuçlar çıkararak veri iletimini en iyi politika kadar verimli hale getirmektir.

Bu makalede makine öğrenmesi uygulayarak sürekli (sonsuz sayıda değer alabilen) veri iletim hızı seti yerine birkaç veri iletim hızı seti ile pratik bir yaklaşım sergileyen bir su-doldurma algoritması önerilmektedir. K-means burada sürekli bir veri iletim hızı kümesi seçmek yerine ayrık bir veri iletim hızı kümesini en iyi şekilde seçmeye yaramaktadır. Aslında bir bakıma ayrıklaştırma yapmamızı sağlamaktadır. Bu ayrık veri iletim hızı kümesini seçmeyi düşündüğümüzde sürekli veri iletim hızı kümesine göre performans kaybı beklenmektedir. Burada en iyi ayrık veri iletim hızı kümesini seçerek sürekli veri iletim hızı kümesine göre oluşan fazladan enerji tüketiminin en aza indirilmesi hedeflenmektedir.

Bu makalede aynı zaman diliminde aynı enerji ile ne kadar fazla veri yollanabileceği problemini değil aynı zamanda aynı miktarda veriyi ne kadar az enerji ile yollanabileceği ele alınmaktadır. Bunun üzerine Şekil 3'teki Makine Öğrenmesi Tabanlı Su-Doldurma Algoritma önerilmiştir.

Algorithm 1 Makine Öğrenmesi Tabanlı Su-Doldurma Politikası

Girdiler: $D(K, T)$, T zaman dilimlik zaman ufku boyunca K kanalı boyunca iletilecek veri miktarıdır. $h_k[n]$, n . zaman dilimi içindeki k . kanal kazancıdır.
Baslangıç: WFL_{max} , WFL_{min} , ϵ , sırasıyla maksimum su-doldurma seviyesi, minimum su doldurma seviyesi ve toleransdır.
 1) $K \times M$ Su-doldurma seviyesi matrisi WFL , şöyle baslatılmaktadır:
 $WFL \leftarrow \left(\frac{WFL_{max} + WFL_{min}}{2} \right)$
 2) $K \times T$ kanal kazancı matrisi G , su şekilde baslatılmaktadır:
 $G(k, n) = \frac{h_k[n]}{|h_k[n]|^2} \forall k \in \{1, \dots, K\}, \forall n \in \{1, \dots, T\}$
 3) Kanal sığası (kapasitesi) teoreminden $K \times T$ veri hızı matrisi, su şekilde tanımlanmaktadır: $C(K, T) \triangleq B \cdot \log_2(1 + 10^{(WFL - G)})$
Prosedür:
 Ayrık veri iletim hızı kümesini düşünülerek k-means makine öğrenmesi algoritması uygulanmaktadır. Burada kanal kazançlarının herbiri bir değere eşlenmektedir (mapping). Buna göre su-doldurma seviyesi algoritmasını takip eden şekilde uygulanmaktadır.
 # Yorum: Bu dongu, sadece kanal kapasitesi ve iletilecek veri miktarı arasındaki fark çok az (ϵ 'dan az) olunca sonlanmaktadır.
 Suresince $(|C(K, M) - D(K, T)| * \frac{M}{T} > \epsilon)$ yap
 eger $C(K, M) < D(K, T) * \frac{M}{T}$ ise
 $WFL_{min} \leftarrow \frac{WFL_{max} + WFL_{min}}{2}$
 degilse
 $WFL_{max} \leftarrow \frac{WFL_{max} + WFL_{min}}{2}$
 son eger
 $WFL \leftarrow \left(\frac{WFL_{max} + WFL_{min}}{2} \right)$
 # Yorum: Su doldurma seviyesi ve kanal kazancı arasındaki farkın pozitif olup olmadığını kontrol ederek her bir zaman diliminde her kanal kazancı değeri için kanal kapasitesi hesaplanmaktadır.
 $C(K, M) \leftarrow B \cdot \log_2(1 + 10^{\min(WFL - G, 0)})$
 son suresince
 # Yorum: Pratik bir algoritma için M ($M \leq T$) zaman dilimlik bir geçmiş ele alınabilir. Böylece, elde edilen su doldurma seviyelerini (ve buna göre tüm kanallardaki tüm anlık veri iletim güçlerini) içeren WFL daha rahat uygulanabilir.
Çıktı: Geri Dondur WFL

Şekil 3. Makine Öğrenmesi (MÖ) Tabanlı Çevrimiçi Su Doldurma Algoritması.

Bu algoritmanın çıktısı su doldurma seviyesine bağlı tüm kanallarda tüm anlık iletim güçlerini içeren bir matristir. Böylece zaman ufku boyunca tüm kanallarda veri iletimi için harcanan toplam enerjiyi enazaltmak amaçlanır.

V. SAYISAL SONUÇLAR

Bu çalışmada, bir iletişim sistemi içindeki bir dizi sönümlenme kanalı aracılığıyla verileri enerji verimli bir şekilde iletmenin zorluğu araştırılmaktadır [7]. Bu bölümde, makine öğrenmesine dayalı çevrimiçi su doldurma politikasının performansını çevrimdışı doldurma politikasının performansıyla iki farklı şekilde karşılaştırılmaktadır: 1) Özellikle 1000 ve 10000 zaman dilimli zaman ufukları. 2) $k=2$ ile Rayleigh sönümlenme, Nakagami sönümlenme, Rician sönümlenme, $m=2$ ile Weibull sönümlenme olarak çeşitli sönümlenme kanalları. Farklı kanal tiplerinin (kanal sönümlenme modellerinin) farklı olasılıksal dağılımı vardır. Bu da farklı sönümlenme altında farklı kanal kazançlarının olduğunu gösterir ki bu da algoritmanın performansını etkilemektedir.

Makine öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikası tarafından kullanılan toplam iletim enerjisi, En İyi Çevrimdışı Su Doldurma Politikası tarafından kullanılan enerji miktarıyla karşılaştırılmaktadır.


Çevrimiçi Su Doldurma Politikasının gelişimi, her biri zaman ufkunun %10'a eşit bir oranını gösteren bir dizi zaman bölümü olarak sunulur. Örneğin, $T=1000$ zaman dilimiye, 4 zaman bölümü için geçmişin uzunluğu 4 çarpı 1000 zaman diliminin %10'udur, bu da 400 zaman dilimine eşittir. Ancak, $T=10000$ zaman dilimine eşitse, 4 zaman bölümü için geçmişin uzunluğu 4 çarpı 10000 zaman diliminin %10'udur, 4000 zaman dilimine eşittir.

A. Zaman Ufku

Çevrimiçi ve en iyi çevrimdışı stratejilerin görelî performansı, 1000 ve 10000 zaman dilimi zaman ufku boyunca çeşitli sönümlenme kanalları için bu altbölümde incelenir.

1. Rayleigh Sönümlenen Kanal

Rayleigh sönümlenen kanallar için çevrimiçi ve çevrimdışı politikaların görelî performansı 1000 ve 10000 zaman diliminde zaman ufuklarında incelenmektedir. Tablo I, Rayleigh sönümlenme kanalı için Makine Öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikasına göre toplam iletim enerjisinin En iyi Çevrimdışı Su Doldurma Politikasına oranının genel eğilimlerini gösteren Şekil 4'ten daha kesin (hassas) sonuçlar göstermektedir. Şekil 4, Makine Öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikasına göre toplam iletim enerjisi oranının genel eğilimlerini göstermektedir.



Şekil 4. Rayleigh Sönümlenen Kanal'da Makine Öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikası tarafından sağlanan toplam iletim enerjisinin Çevrimdışı Su Doldurma Politikası tarafından sağlanana oranı.

Şekil 4'e bakıldığında, çevrimdışı doldurma politikası ile Makine Öğrenmesine tabanlı çevrimiçi doldurma politikası arasındaki toplam enerji kullanımındaki farkın, 1000 zaman dilimi durumunda, 10000 zaman dilimi durumunda yaklaşık 3 kat daha fazla olduğu açıktır.

TABLO I. BU TABLO, MAKİNE ÖĞRENMESİNE DAYALI ÇEVİRİMİÇİ SU DOLDURMA POLİTİKASI TARAFINDAN ÜRETİLEN RAYLEİGH SÖNÜMLENEN KANAL İÇİN TOPLAM İLETİM ENERJİSİNİN EN İYİ ÇEVİRİMİÇİ SU DOLDURMA POLİTİKASI TARAFINDAN ÜRETİLENE ORANINI GÖSTERMEKTEDİR. $M=1$, MAKİNE ÖĞRENME TABANLI ALGORİTMANIN $T=1000$ ZAMAN DİLİMİ ZAMAN UFKUNDAKİ PERFORMANSINI GÖSTERİRKEN $M=2$, $T=10000$ ZAMAN DİLİMİ ZAMAN UFKUNDAKİ PERFORMANSINI GÖSTERİR.

C	0.1T	0.2T	0.3T	0.4T	0.5T	0.6T	0.7T	0.8T	0.9T	1.0T
M1	1.35	1.25	1.20	1.17	1.14	1.13	1.13	1.12	1.12	1.11
M2	1.11	1.09	1.08	1.07	1.06	1.06	1.06	1.05	1.05	1.04

Tablo I'e göre, toplam zaman ufkunun (veya 0,1 T) %10'unu temsil eden yalnızca bir zaman diliminin geçmişi düşünüldüğünde, çevrimiçi politika, 10000 zaman dilimindeki çevrimdışı politikadan %35 daha fazla enerji

kullanır, çevrimdışı yöntemle göre %11 daha fazla enerji kullanır.

5 zaman bölümü geçmişi kullanıldığında (zaman ufkunun yarısı veya 0,5 T), çevrimiçi politika 500 zaman dilimindeki çevrimdışı politikadan %14 daha fazla enerji kullanır, ancak 5000 zaman dilimindeki çevrimdışı algoritmadan yalnızca %6 daha fazla enerji kullanır. Bu fark, çevrimiçi algoritmanın 0,5 T kullanması ile açıklanabilir.


Altıdan fazla farklı zaman dilimini içeren bir geçmişi kullanmak, çevrimiçi veya çevrimdışı politikalar için önemli bir etki (yaklaşık %2) oluşturmaz.

2. Nakagami Sönümlenen Kanal

Nakagami sönümlenen kanallar için çevrimiçi ve çevrimdışı politikaların görelî performansı 1000 ve 10000 zaman dilimi zaman ufuklarında incelenmektedir.

Şekil 5, Makine Öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikası tarafından sağlanan toplam iletim enerjisinin, Nakagami sönümlenme kanalı için En iyi Çevrimdışı Su Doldurma Politikası tarafından sağlanan oranın genel eğilimini gösterir. Tablo II, Şekil 7'den daha kesin sonuçlar sağlar.

Şekil 5'e bakıldığında, çevrimdışı doldurma politikası ile Makine Öğrenmesine dayalı çevrimiçi doldurma politikası arasındaki toplam enerji kullanımındaki eşitsizliğin, 1000 zaman dilimi durumunda, 10000 zaman dilimi durumunda olduğundan yaklaşık 3 kat daha fazla olduğu açıktır.



Şekil 5. Makine Öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikasına göre toplam iletim enerjisinin, $k=2$ ile Nakagami Sönümlenen Kanal için Çevrimdışı Su Doldurma Politikasına oranına oranı.

Tablo II'ye göre, zaman ufkunun %10'unu (veya 0,1 T) temsil eden yalnızca bir zaman diliminin geçmişi düşünüldüğünde, çevrimiçi politika 100 zaman diliminde çevrimdışı politikadan %15 daha fazla enerji kullanır, ancak çevrimiçi algoritma yalnızca 1000 zaman diliminde çevrimdışı politikadan %6 fazla enerji kullanmaktadır.

TABLO II. BU TABLO, MAKİNE ÖĞRENMESİNE DAYALI ÇEVİRİMİÇİ SU DOLDURMA POLİTİKASININ ÜRETTİĞİ $K=2$ İLE NAKAGAMI SÖNÜMLENEN KANAL İÇİN TOPLAM İLETİM ENERJİSİNİN EN İYİ ÇEVİRİMİÇİ SU DOLDURMA POLİTİKASI TARAFINDAN ÜRETİLENE ORANINI GÖSTERMEKTEDİR. $M=1$, MAKİNE ÖĞRENMESİ TABANLI ALGORİTMANIN $T=1000$ ZAMAN DİLİMİ ZAMAN UFKUNDAKİ PERFORMANSINI GÖSTERİRKEN $M=2$, $T=10000$ ZAMAN DİLİMİ ZAMAN UFKUNDAKİ PERFORMANSINI GÖSTERİR.

C	0.1T	0.2T	0.3T	0.4T	0.5T	0.6T	0.7T	0.8T	0.9T	1.0T
M1	1.15	1.11	1.09	1.08	1.07	1.07	1.06	1.06	1.05	1.04
M2	1.06	1.05	1.04	1.03	1.03	1.03	1.03	1.02	1.02	1.02


Beş zaman dilimi geçmişi kullanıldığında (zaman ufkunun yarısı veya $0,5 T$), çevrimiçi politika 500 zaman diliminde çevrimdışı politikadan %7 daha fazla enerji kullanırken, 5000 zaman diliminde çevrimdışı algoritmadan yalnızca %3 daha fazla enerji kullanır. Bu fark, çevrimiçi algoritmanın beş zaman dilimi geçmişi kullanması ile açıklanabilir.

Altıdan fazla farklı zaman dilimini içeren bir geçmişi kullanmak, çevrimiçi veya çevrimdışı politikalar için önemli bir etki (yaklaşık %3) oluşturmaz.

3. Rician Sönümlenen Kanal

Rician sönümlenen kanallar için çevrimiçi ve çevrimdışı politikaların görece performansı 1000 ve 10000 zaman dilimi zaman ufuklarında incelenmektedir.

Şekil 6, Makine Öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikası tarafından sağlanan toplam iletim enerjisinin Rician sönümleme kanalları için En iyi Çevrimdışı Su Doldurma Politikası tarafından sağlanana karşılaştırmasının genel eğilimlerini göstermektedir. Tablo III, Şekil 6'dan daha kesin sonuçlar vermektedir.



Şekil 6. Rician Sönümlenen Kanal'da Makine Öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikası tarafından yönetilen toplam iletim enerjisi miktarının, Çevrimdışı Su Doldurma Politikası tarafından yönetilen ile karşılaştırılması

Şekil 6'dan, Makine Öğrenmesine dayalı çevrimiçi su doldurma politikası ile çevrimdışı doldurma politikası arasındaki toplam enerji tüketimi farkının 1000 zaman dilimi durumunda 10000 zaman dilimi durumunda olduğundan yaklaşık 3 kat daha fazla olduğu sonucuna varmak mümkündür.

TABLO III. AŞAĞIDAKİ TABLO, MAKİNE ÖĞRENMESİNE DAYALI ÇEVİRİMİÇİ SU DOLDURMA POLİTİKASI TARAFINDAN OLUŞTURULAN RİCIAN SÖNÜMLENEN KANAL İÇİN TOPLAM İLETİM ENERJİSİNİN EN İYİ ÇEVİRİMİÇİ SU DOLDURMA POLİTİKASI TARAFINDAN OLUŞTURULANA ORANINI KARŞILAŞTIRMAKTADIR. $M=1$, MAKİNE ÖĞRENMESİ TABANLI ALGORİTMANIN $T=1000$ ZAMAN DİLİMİ ZAMAN UFKUNDAKİ PERFORMANSINI GÖSTERİRKEN $M=2$, $T=10000$ ZAMAN DİLİMİ ZAMAN UFKUNDAKİ PERFORMANSINI GÖSTERİR.

C	0.1T	0.2T	0.3T	0.4T	0.5T	0.6T	0.7T	0.8T	0.9T	1.0T
M1	1.36	1.30	1.29	1.26	1.25	1.23	1.23	1.22	1.22	1.21
M2	1.18	1.15	1.15	1.14	1.13	1.13	1.12	1.12	1.11	1.11

Tablo III'e göre, tüm zaman ufkunun %10'una (veya $0,1 T$ 'ye) tekabül eden yalnızca bir zaman diliminin geçmişi düşünülünce, çevrimiçi politika, 100 zaman diliminde çevrimdışı politikadan %36 daha fazla enerji kullanırken, 10000 zaman diliminde çevrimdışı yöntemle göre %18 fazla enerji kullanır.


5 zaman bölümü geçmişi kullanıldığında (zaman ufkunun yarısı veya $0,5 T$), çevrimiçi politika 500 zaman diliminde çevrimdışı politikadan %25 daha fazla enerji kullanır, ancak 5000 zaman diliminde çevrimdışı algoritmadan yalnızca %13 daha fazla enerji kullanır. Bu fark, çevrimiçi algoritmanın $0,5 T$ kullanması ile açıklanabilir.

6'dan fazla farklı zaman bölümünü içeren bir geçmişi kullanmak, çevrimiçi veya çevrimdışı politikalar için önemli bir etki (yaklaşık %2) oluşturmaz.

4. Weibull Sönümlenen Kanal

Weibull sönümlenen kanallar için çevrimiçi ve çevrimdışı politikaların görece performansı 1000 ve 10000 zaman dilimi zaman ufuklarında incelenir.

Şekil 7, Makine Öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikası tarafından sağlanan toplam iletim enerjisinin Rayleigh sönümleme kanalı için En iyi Çevrimdışı Su Doldurma Politikası tarafından sağlanana oranının genel eğilimlerini göstermektedir. Sonuçlar, Şekil 7'de daha genel sunulurken Tablo IV'te daha kesin bir şekilde sunulmaktadır.



Şekil 7. $m=2$ ile Weibull Sönümlenen Kanal'da Makine Öğrenmesine Dayalı Çevrimiçi Su Doldurma Politikası tarafından yönetilen toplam iletim enerjisinin, Çevrimdışı Su Doldurma Politikası tarafından yönetilen toplam iletim enerjisine oranı.

Şekil 7'ye bakıldığında, Makine Öğrenmesine dayalı çevrimiçi su doldurma politikası ile çevrimdışı su doldurma stratejisi arasındaki toplam enerji tüketimindeki farkın, 1000 zaman dilimi durumunda 10000 zaman dilimi durumunda olduğundan yaklaşık 2 kat daha fazla olduğu açıktır.

TABLO IV. BU TABLO, MAKİNE ÖĞRENMESİNE DAYALI ÇEVİRİMİÇİ SU DOLDURMA POLİTİKASI TARAFINDAN ÜRETİLEN $M=2$ İLE WEIBULL SÖNÜMLENEN KANAL İÇİN TOPLAM İLETİM ENERJİSİNİN EN İYİ ÇEVİRİMİÇİ SU DOLDURMA POLİTİKASI TARAFINDAN ÜRETİLENE ORANINI GÖSTERMEKTEDİR. $M=1$, MAKİNE ÖĞRENMESİ TABANLI ALGORİTMANIN $T=1000$ ZAMAN DİLİMİ ZAMAN UFKUNDAKİ PERFORMANSINI GÖSTERİRKEN $M=2$, $T=10000$ ZAMAN DİLİMİ ZAMAN UFKUNDAKİ PERFORMANSINI GÖSTERİR.

C	0.1T	0.2T	0.3T	0.4T	0.5T	0.6T	0.7T	0.8T	0.9T	1.0T
M1	1.11	1.09	1.08	1.07	1.06	1.05	1.05	1.04	1.04	1.04
M2	1.05	1.04	1.04	1.04	1.04	1.03	1.03	1.02	1.02	1.02

Tablo IV'e göre, zaman ufkunun %10'u veya 0,1 T tek bir zaman bölümü geçmiş olarak kullanıldığında, çevrimiçi politika 100 zaman diliminde çevrimdışı politikadan %11 daha fazla enerji kullanırken, 1000 zaman diliminde sadece %5 fazla enerji kullanmaktadır.

Bazen zaman ufkunun yarısı veya 0,5 T olarak bilinen 5 zaman bölümü geçmişle çevrimiçi politika, 1000 zaman dilimindeki çevrimdışı politikadan %4 daha fazla enerji tüketmektedir, ama çevrimiçi politika çevrimdışına göre yalnızca %2 daha fazla enerji harcamaktadır.

6'dan fazla zaman bölümünü (0.6T) içeren bir geçmişli kullanmak, çevrimiçi ve çevrimdışı politikaların performansı için önemli bir fark oluşturmaz (sadece %1).

B. Diğer Açıklamalar

Bu alt bölümde, Şekil 4-7 ve Tablo I-IV kullanılarak çevrimiçi politikanın görece performansı, bir dizi farklı sönümlenme kanalı altında 1000 zaman dilimi ve 10000 zaman dilimi zaman ufkuları üzerinden incelenmektedir. Bu sönümlenme kanalları Rayleigh sönümlenme, Nakagami sönümlenme, Rician sönümlenme ve Weibull sönümlenme ile içermektedir.

1000 zaman dilimli zaman ufkunda, Makine Öğrenmesine dayalı bir çevrimiçi su doldurma politikası ile bir çevrimdışı su doldurma politikası arasındaki toplam enerji tüketimindeki eşitsizliğin, $k=2$ ile Nakagami ve $m=2$ ile Weibull altında sifira yaklaştığını çıkarmak mümkündür. Çevrimdışı su doldurma politikasının toplam enerji tüketiminin %6'sine eşit olan 0,1-T geçmişsel senaryosu dışında, fark %5'den küçüktür. Geçmişin uzunluğu 0.4T=400 zaman diliminden az ise, çevrim içi politika ile çevrim dışı politika arasındaki (yaklaşık %25 oranında) farkın bir sonucu olarak tüketilen enerji miktarında farkı nedeniyle Weibull sönümlenme Nakagami sönümlenmesine tercih edilir. Hem $k=2$ olan Nakagami modeli hem de $m=2$ olan Weibull modeli, $T=1000$ zaman dilimi geçmişli olduğunda, çevrim içi politika ile çevrim dışı politika arasındaki farkın %5'e eşit olacağını öngörmektedir. Rayleigh ve Rician sönümlenme kanalları altında, 0,1 T=100 zaman dilimi (zaman ufkunun %10'u)

geçmişine sahip bir Çevrim içi Su Doldurma Politikası, en iyi çevrim dışı politikadan %35 daha fazla enerji tüketimi ile aynı performansı elde etmektedir. Diğer yandan, geçmişin uzunluğu 0,5T=500 zaman diliminden (zaman ufkunun yarısından) büyükse, bir çevrim içi politika ile çevrim dışı bir politika tarafından tüketilen enerji miktarı arasındaki fark, Rayleigh sönümlenmesi altında Rician sönümlenmesine kıyasla yaklaşık 40% oranında azaltılır.

10000 zaman dilimi zaman ufkunda, Nakagami modelinde $k=2$ ve Weibull modelinde $m=2$ olduğunda, Makine Öğrenmesine dayalı bir çevrim içi su doldurma politikası ile çevrim dışı bir su doldurma politikası arasındaki toplam enerji tüketimindeki eşitsizliğin sifira yaklaştığını Tablo I, II, III, IV'ten çıkarmak mümkündür. Aralarındaki fark, %0.2'den daha azdır ve bu, çevrim dışı su doldurma politikasının toplam enerji tüketiminin %1'ine eşittir. Geçmişin uzunluğu 0,4T=4000 zaman diliminden az veya 0,7 T=7000 zaman diliminden büyükse, çevrim içi politika tarafından tüketilen enerji miktarı ile çevrim dışı politika tarafından tüketilen enerji arasındaki fark, hem Weibull sönümlenmesi hem de Nakagami sönümlenmesi altında aynıdır. Hem $k=2$ olan Nakagami modeli hem de $m=2$ olan Weibull modeli, geçmiş 0,8T=8000 zaman diliminden uzun olduğunda, çevrimiçi politika ile çevrimdışı politika arasındaki farkın yaklaşık birbirine eşit olması tahmin edilebilir (%2 fark). Rayleigh sönümlenme ile çevrimiçi su doldurma politikası ile en iyi çevrim dışı politika arasında tüketilen enerji farkı, Rician sönümlenmesine göre yaklaşık iki kat azalır.

$m=2$ ile Weibull sönümlenmesi altında, çevrim içi su doldurma politikasının performansı, en iyi çevrim dışı politikanınkinden çok yaklaşmıştır. $k=2$ ile Nakagami sönümlenme modeli altında, çevrimiçi politika genel olarak en iyi ikinci performansa ulaşır. Rician sönümlenme gerçekleştiğinde, çevrim içi politika ile çevrim dışı politika arasındaki enerji farkı en yüksek seviyededir. Performanstaki fark, öncelikle çeşitli sönümlenme modellerinin olasılıksal (stokastik) dağılımlarındaki farklılıkları nedeniyle ortaya çıkabilir.

Başka bir gözlemse, aynı oranda (örneğin, 0,1 T) geçmişin uzunluğunun zaman ufkunun uzunluğuyla orantılı olarak genişlemesidir. Geçmiş uzunluğunun zaman ufkunun uzunluğuna oranı aynı kalsa bile (örneğin, zaman ufkunun %10'u 0,1 T), çevrim içi politika daha uzun zaman ufkuları için daha iyi performans elde edebilir.

VI. SONUÇLAR VE SONRAKİ ARAŞTIRMA ÖNERİLERİ

Bu makalede, çoklu sönümlenme kanalları arasında kaynak tahsisini içeren bir problem araştırılmaktadır. Bu problem tüm çoklu sönümlenme kanallarında çevrimdışı bir şekilde bir bütün olarak ele alınmaktadır. Bu problem tüm çeşitli sönümlenme kanallarında aynı anda çevrimiçi bir şekilde ele alınmaktadır. Bu probleme tüm sönümlenme kanallarını düşünerek en iyi bir çözüm aranmaktadır. Bundan sonra, bu probleme makine öğrenmesine dayalı bir çevrimiçi su doldurma algoritması sunulmaktadır.

Su doldurma algoritmasının bilgi kuramında da verilen genel mantığına göre sürekli veri iletim hızı kümesi ile en iyi enerji yakalanabilir. Ayrık veri iletim hızı kümesi ise sürekli veri iletim hızı kümesi yakalanabilecek su doldurma seviyesinin ya üstünde ya da altında tercih yapacaktır; bu da sürekli veri kümesi kabulü altında bir tane en iyi çözümü olan problemin aslında en iyi-altı çözümünü elde edebileceğini gösterir ki bu da ayrık veri kümesi ile en iyi çözümdür. Bu makalede ayrık veri kümesi altında en iyi çözümün sürekli veri kümesi altındaki en iyi çözüme göre performansını incelenmekte ve genel olarak farkın az olmasından dolayı bu makalede önerilen algoritma başarılı bulunmaktadır.

Sayısal sonuçlara göre, makine öğrenmesine dayalı çevrimiçi su doldurma algoritmasının performansı, özellikle uzun zaman ufuklarında çevrimdışı su doldurma algoritmasının performansına yakın performans gösterir.

İleride yapılacak çalışmalarda gecikme, seçirme gibi çeşitli kısıtlar eklenerek bu problemin farklı durumları incelenebilir. Etkili ve güvenilir bir çözüm üretmek için farklı bakış açıları gerekir, problemin her bir durum için yenilikçi ve pratik stratejilerin kullanılması gerekecektir.

KAYNAKLAR

- [1]Qualcomm. Everything you need to know about 5G. Available at <https://www.qualcomm.com/5g/what-is-5g>
- [2]Nazir, M., Sabah, A., Sarwar, S. et al. (2021). Power and Resource Allocation in Wireless Communication Network. *Wireless Pers Commun* 119, 3529-3552.
- [3]Boyd, S. and Vandenberghe, L. (2004). *Convex Optimization*. Cambridge University Press.
- [4]Cover, T. and Thomas, J. (2006). *Elements of Information Theory*, 2nd Edition. Wiley&Sons.
- [5]Dai, M., Zhang S., Chen, B., Lin, X., &Wang, H. (2014). A refined convergence condition for iterative waterfilling algorithm. *IEEE Communications Letters*, 18(2), 269-272.
- [6]Gai, Y.& Krishnamachari, B. (2012). Online Learning Algorithms for Stochastic Water-Filling. *IEEE Information Theory and Applications Workshop (ITA)*, 1-6.
- [7]Goldsmith, A. (2005). *Wireless Communications*. Cambridge University Press.
- [8]Goldsmith, A., &Varaiya, P. P. (1996). Capacity, mutual information, and coding for finite-state Markov channels. *IEEE Transactions on Information Theory*, 42 (3), 868-886.
- [9]Tse, D. & Viswanath, P. (2005). *Fundamentals of Wireless Communication*. Cambridge University Press.
- [10] Teletar, E. (1995). Capacity of multi-antenna Gaussian channels. AT&T Bell Labs Internal Tech. Memo.
- [11] Yang, J. and Roy, S. (1994). On joint transmitter and receiver optimization for multiple-input-multiple-output (MIMO) transmission systems. *IEEE Transactions on Communications*, 42(12), pp. 3221-3231.
- [12] Xing, C., Jing, Y., Wang, S., Ma, S. & Poor, H. V. (2020). New Viewpoint and Algorithms for Water-Filling Solutions in Wireless Communications. in *IEEE Transactions on Signal Processing*, 68, 1618-1634.
- [13] Ajitsinh. N., Jadhav1 and Sakib. R. Mujawar. (2017). Different power loading allocation schemes for ZF based cognitive radio system. *International Journal of Latest Trends in Engineering and Technology*, 8 (1), 350-359.
- [14] Qi Q, Minturn A., and Yang Y. L. (2012). An Efficient Water-Filling Algorithm for Power Allocation in OFDM-Based Cognitive Radio Systems. *2012 International Conference on Systems and Informatics*, 2069-2073.
- [15] P. He, L. Zhao, S. Zhou, Z. Niu, (2013). Water-Filling: A Geometric Approach and its Application to Solve Generalized Radio Resource Allocation Problems. *IEEE Transactions on Wireless Communications*, 12 (7), 3637-3647.
- [16] Noor Shahida M. K, Nordin R. and Ismail. M. (2017). Improved Water-Filling Power Allocation for Energy-Efficient Massive MIMO Downlink Transmissions. *Intl Journal of Electronics& Telecommunications*, vol. 63, no. 1, pp. 79-84.
- [17] Yu S., Daoxing G., Lu L., and Xiaopei D., "A modified water-filling algorithm of power allocation," in *Information Technology, Networking, Electronic &Automation Control Conf.*, IEEE, 2016.
- [18] Wael C. B. A, Armi N., Miftahushudr M. T., Muliawarda D., and Sugandi G., "Power Allocation in OFDM-Based Cognitive Radio Networks for Fading Channel," in *2017 International Conference on Radar, Antenna, Microwave, Electronics, and Telecommunications (ICRAMET)*, 2017.
- [19] Zeng M., Nguyen N. P., Dobre O. A., Ding Z., and Poor H. V., "Spectral- and Energy-Efficient Resource Allocation for Multi-Carrier Uplink NOMA Systems," *Vehicular Technology, IEEE Transactions on*, 2019.
- [20] Elgarhy O. and Reggiani L., "Application of the Water Filling Algorithm to the Sum Rate Problem with Minimum Rate and Power Constraint," *2018 Advances in Wireless and Optical Communications (RTUWO)*, 2018, pp. 12-16.
- [21] Qian L. P., Zhang Y. J., and Huang J., "MAPEL: Achieving global optimality for a non-convex wireless power control problem," *IEEE Trans. on Wireless Communications*, vol. 8, no. 3, pp. 1553-1563, Mar. 2009.
- [22] Kim Y.; Kang M.; Varshney L. R.; Shanbhag N. R., (2018). Generalized Water-Filling for Source-Aware Energy-Efficient SRAMs. *IEEE Trans. on Communications*, 66 (10), 4826-4841.
- [23] Gurdasani H., Ananth, A. G., Thangadurai N. (2021). Channel Capacity Enhancement of MIMO System using Water-Filling Algorithm. *Turkish Journal of Computer and Mathematics Education*.12 (12), 192-201.
- [24] Wei S., Zheng Z. and Wu, C., Channel Power Allocation Optimization Based on Water-filling Algorithm in 5G. *J. Phys.: Conf. Ser.* 1871 012082.
- [25] Gul, O. M. (2022). Performance of History-based Water-Filling Algorithm for Energy-Efficient Data Transmission over Different Fading Channels . *Avrupa Bilim ve Teknoloji Dergisi*, (41) , 118-125 . DOI: 10.31590/ejosat.1112389.

Özgeçmiş



Ömer Melih Gül (S'17, M'21), Orta Doğu Teknik Üniversitesi (ODTÜ) Elektrik ve Elektronik Mühendisliği Bölümü'nden lisans, yüksek lisans ve doktora derecelerini sırasıyla 2012, 2014 ve 2020 yıllarında aldı. Bu esnada aynı bölümde araştırma görevlisi olarak da görev yaptı. Uluslararası yayınları 11 dergi makalesi, 16 konferans bildirisi ve 4 kitap bölümünü kapsarken ulusal yayınları 3 dergi makalesi ve 3 konferans bildirisini kapsamaktadır.

IEEE Computer Society tarafından 2019 Lance Stafford Larson Üstün Öğrenci Makale Ödülü'nde (2019 Lance Stafford Larson Outstanding Student Paper Award) üçüncülük ödülüne layık görülmüştür. 2021 IEEE Rising Stars Global Konferansı'nda poster yarışmasında üçüncülük ödülüne layık görülmüştür. 2022 yılında Kanada'da Ottawa Üniversitesi Elektrik Mühendisliği ve Bilgisayar Bilimleri Okulu'nda doktora sonrası araştırmacı olarak çalıştı. 2022 yılında 48. Kablosuz Dünya Araştırma Forumu'nda (WWRF) en iyi konferans bildirisi ödülünü aldı. Mevcut durumda, İstanbul'da Bahçeşehir Üniversitesi Bilgisayar Mühendisliği Bölümü'nde Dr. Öğr. Üyesi olarak görev yapmaktadır.

2021'den bu yana IEEE Computer Society'de Region 8 (Avrupa, Orta Doğu ve Afrika Bölgesi) Koordinatörü olarak görev yapmaktadır. Nisan 2023'ten beri IEEE Computer Society Member&Geographic Activities (MGA) Board'da Özel Üye (Member-at-Large) olarak görev yapmaktadır. 2022 IEEE MGA Genç Profesyoneller Başarı Ödülü'ne (2022 IEEE MGA Young Professionals Achievement Award) layık görülmüştür. 2020-2021 yıllarında başkanlığını yaptığı IEEE Türkiye Genç Profesyonel Grup ile 2021 IEEE Region 8 Outstanding Young Professionals Affinity Group Award ve 2022 IEEE MGA Young Professionals Hall of Fame Honorable Mention ödülleri kazanmıştır.