


5G Sistemleri için DL Tabanlı Kanal Tahmini DL Based Channel Estimation for 5G Systems

Bircan Çalışır* ¹

¹ Elektrik - Elektronik Bölümü, Fırat Üniversitesi, Elazığ, Türkiye
(bkamislioglu@firat.edu.tr)

Received: Sep.08,2022

Accepted: Sep.16,2022

Published:Oct.10,2022

Özetçe— Bu çalışma, Derin Öğrenme ve 5G ile oluşturulan veriler kullanılarak kanal tahmini için bir evrimsel sinir ağının (CNN) nasıl eğitileceğini gösterir. Eğitilmiş CNN, fiziksel aşağı bağlantı paylaşılan kanal (PDSCH) demodülasyon referans sinyali (DM-RS) kullanarak tek girişli tek çıkışlı (SISO) modunda kanal tahmini gerçekleştirilmiştir. Kanal tahmini için genel yaklaşım, iletim kanalı içine değeri bilinen referans pilot sembolleri eklemek ve daha sonra bu pilot sembolleri kullanarak kanal yanıtının geri kalanını enterpolasyon yapmaktır. Kanal tahmini yapmak için derin öğrenme teknikleri de kullanılabilir. Örneğin, PDSCH kaynak ızgarasını 2 boyutlu bir görüntü olarak görüntüleyerek, kanal tahmini problemini, CNN'lerin etkili olduğu gürültü giderme veya süper çözünürlüğe benzer bir görüntü işleme problemine dönüştürebilir. Bu çalışma, bu tür eğitim verilerinin nasıl oluşturulacağını ve bir kanal tahmini uygulamasında CNN'nin nasıl eğitileceğini gösterir. Ayrıca, lineer enterpolasyon ile alınan pilot sembolleri içeren görüntüleri işlemek için CNN kanal tahmininin nasıl kullanılacağını gösterir. Bu çalışma, pratik ve mükemmel tahmin edicilere kıyasla sinir ağı kanal tahmincisinin sonuçlarını görselleştirerek sona ermektedir.

Anahtar Kelimeler : CNN, Derin öğrenme, 5G, Modülasyon.

Abstract—This work demonstrates training a convolutional neural network (CNN) for channel prediction utilizing data generated by Deep Learning and 5G. Channel estimation is performed in single input single output (SISO) method using the trained CNN, physical downlink shared channel (PDSCH) demodulation reference signal (DM-RS). The usual approximation for estimation of the channel is to attach referenced pilot symbols of known value into the transceiver channel and then add the remainder of the response of the channel utilizing the pilot symbols. Deep learning techniques can also be used to make channel predictions. For instance, by displaying the PDSCH source grid as a 2D image, it can transform the channel prediction problem into an image operating issue like noise removal where CNNs are efficient. This work demonstrates generating like trained data and training CNN in a channel prediction application. It also demonstrates using CNN channel prediction to commit images containing pilot symbols acquired by linear interpolation. This study comes to end by envisioning the conclusions of the neural network channel estimator compared to the practical and excellent predictors.

Keywords : CNN, Deep Learning, 5G, Modulation.

1. Giriş

Dikgen frekans bölmeli çoğullama (OFDM), kablosuz kanallarda frekans seçici sönümlenme ile mücadele etmek için kablosuz geniş bant sistemlerinde yaygın olarak benimsenen popüler bir modülasyon şemasıdır. Kanal durum bilgisi (CSI), OFDM sistemlerinde tutarlı algılama ve kod çözme için hayati öneme sahiptir. Genellikle, CSI, iletilen verilerin algılanmasından önce pilotlar aracılığıyla tahmin edilebilir. Tahmini CSI ile iletilen semboller alıcıda kurtarılabilir. Bir iletişim kanalında, alınan sinyal genellikle kanal özellikleri tarafından bozulur. İletilen sembolleri kurtarmak için, kanal etkisinin alıcıda tahmin edilmesi ve telafi edilmesi gerekir. Genellikle alıcı, zaman-frekanstaki konumları ve değerleri hem verici hem de alıcı tarafından bilinen pilotlar olarak adlandırılan bazı sembolleri kullanarak kanalı tahmin eder. Bu pilot düzenlemelere bağlı olarak üç farklı yapı düşünülebilir: blok tipi, tarak tipi ve kafes tipi [S. Coleri, M. Ergen, A. Puri, and A. Bahai, 2002]. Blok tipi düzenlemede, pilotlar bir OFDM bloğunun başlangıcında tüm alt taşıyıcılarda periyodik olarak iletilirken, tarak tipinde pilotlar birkaç OFDM sembolünden oluşan birkaç alt taşıyıcıda bulunur. Kafes tipi düzenlemede, pilotlar elmas şeklindeki bir takımıyla verilen periyotlarla hem zaman hem de frekans eksenleri boyunca yerleştirilir.

Son zamanlarda, Derin Öğrenme (DL) 5G iletişim sistemlerinde çok dikkat çekmiştir. DL tabanlı iletişim sistemlerinde, modülasyon tanıma [T. OShea and J. Hoydis, 2017], sinyal algılama [N. Samuel, T. Diskin, and A. Wiesel, 2017], kanal eşitleme [D. Erdogmus, D. Rende, J. C. Principe, and T. F. Wong, 2001], kanal durum bilgisi (CSI) geri bildirimi [C. Wen, W. Shih, and S. Jin, 2018] ve farklı geleneksel algoritmaların performansını artırmak için bazı yaklaşımlar önerilmiştir. Kanal tahmini [H. Ye, G. Y. Li, and B.-H. Juang, 2018], [H. He, C. Wen, S. Jin, and G. Y. Li, 2018]. [H. Ye, G. Y. Li, and B.-H. Juang, 2018]'de, iletişim sistemi bir kara kutu olarak kabul edilir ve sinyal iletimi/alımı için uçtan uca bir DL mimarisi kullanılır. Bir iletişim bağlantısının kodlama, kod çözme, kanal tahmini ve diğer tüm işlevleri, dolaylı olarak DL bloğuna gömülüdür. Daha spesifik olarak, bu yöntem, kanal zaman-frekans yanıtını açıkça bulamaz ve bu nedenle tam kanal yanıtına sahip olması gereken uygulamalar için etkili değildir. [H. He, C. Wen, S. Jin, and G. Y. Li, 2018]'da, kanal matrisi bir görüntü olarak kabul edilir ve daha sonra kanal tahmini için görüntü giderici bir ağ kullanılır. Bu çalışma, verici/alıcı anten alanı boyunca (çoklu anten senaryosunda) kanal matrisine odaklanır ve her Tx/Rx bağlantısının zaman-frekans yanıtını tartışmaz.

Bu çalışmada, kanal yanıtının zaman-frekans ızgarası, yalnızca pilot konumlarında bilinen bir 2D görüntü olarak modellenir.

2. CNN Yapısı

Sinir ağı eğitimi şu adımlardan oluşur: Veri üretme, üretilen veriyi eğitim ve doğrulama setlerine ayırma, CNN mimarisini tanımlama, eğitim seçeneklerini, optimize ediciyi ve öğrenme oranını belirleme, ağı eğitme. Veri üretimi, 256 eğitim örneği veya eğitim veri seti üretecek şekilde ayarlanmıştır. Bu veri miktarı, makul bir sürede bir CPU üzerinde işlevsel bir kanal tahmin ağını eğitmek için yeterlidir. Karşılaştırma için, önceden eğitilmiş model 16.384 eğitim örneğine dayanmaktadır. CNN modelinin eğitim verilerinin sabit bir boyutu vardır, ağ yalnızca $612 \times 14 \times 1$ ızgaraları, yani 612 alt taşıyıcıyı, 14 OFDM sembolünü ve 1 anteni kabul edebilir. Bu nedenle, model yalnızca sabit bir bant genişliği tahsisi, dögüsel örnek uzunluğu ve tek bir alıcı anten üzerinde çalışabilir. CNN, kaynak ızgaralarını 2 boyutlu görüntüler olarak ele alır, bu nedenle ızgaranın her bir elemanı gerçek bir sayı olmalıdır. Bir kanal tahmin senaryosunda, kaynak ızgaraları karmaşık verilere sahiptir. Bu nedenle, bu ızgaraların gerçek ve sanal kısımları ayrı ayrı CNN'ye girilir. Bu örnekte, eğitim verileri, karmaşık bir 612×14 lük matristen, gerçek değerli bir $612 \times 14 \times 2$ lik matrise dönüştürülür; burada üçüncü boyut, gerçek ve hayali bileşenleri gösterir. Tahminler yaparken gerçek ve hayali ızgaraları sinir ağına ayrı ayrı girmeniz gerektiğinden, örnek eğitim verilerini $612 \times 14 \times 1$ e 2N biçiminde 4 boyutlu dizilere dönüştürür, burada N eğitim örneklerinin sayısıdır. CNN'nin eğitim verilerine fazla uymamasını sağlamak için eğitim verileri doğrulama ve eğitim setlerine bölünür. Doğrulama kaybı iyileşmeyi bıraktığında eğitim durdurulur. CNN, farklı gecikme yayılımlarına, doppler kaymalarına ve 0 ile 10 dB arasındaki SNR aralıklarına dayalı olarak çeşitli kanal konfigürasyonları üzerinde eğitilir. Kullanılan model, 5 konvolüsyon katmanına sahiptir. Girdi katmanı 612×14 boyutunda matrisler bekler, burada 612 alt taşıyıcı sayısı ve 14 OFDM sembollerinin sayısıdır. Karmaşık ızgaraların gerçek ve sanal kısımları ayrı ayrı girildiğinden, her eleman bir gerçek sayıdır. Bu çalışmada kanalın gecikme yayılımı 3×10^{-7} seçilerek sonuçlar elde edilmiştir.

3. OFDM

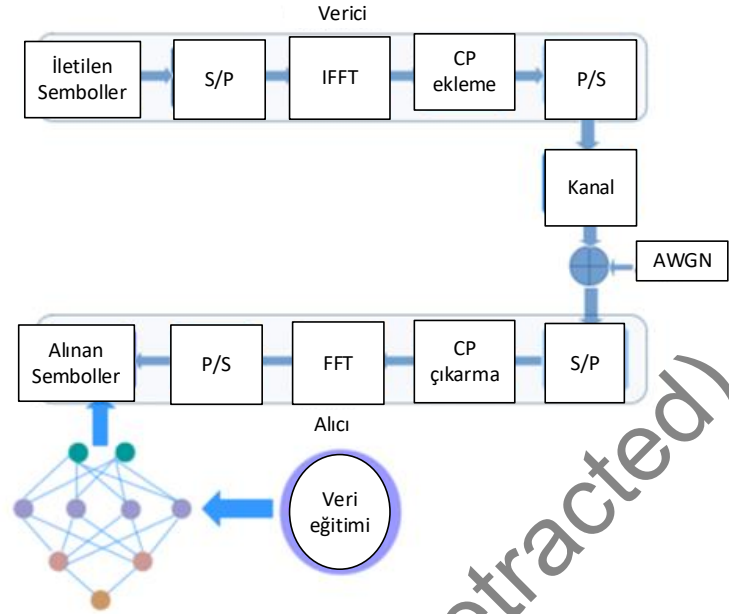
Derin öğrenme tabanlı kanal tahmini ve sinyal tespiti ile OFDM sisteminin mimarisi Şekil 1'de gösterilmektedir. Temel bant OFDM sistemi, geleneksel olanlarla aynıdır. Verici tarafında, pilotlarla eklenen iletilen semboller önce paralel bir veri akışına dönüştürülür, ardından sinyali frekans alanından zaman alanına dönüştürmek için ters ayrık Fourier dönüşümü (IDFT) kullanılır. Bundan sonra, semboller arası girişimi (ISI) azaltmak için dögüsel bir örnek (CP) eklenir. CP'nin uzunluğu, kanalın maksimum gecikme yayılımından daha kısa olmamalıdır.

Pilot sembollerin ilk OFDM bloğunda olduğunu, sonraki OFDM bloklarının ise iletilen verilerden oluştuğunu varsayarak birlikte bir çerçeve oluştururlar. Kanal, pilot blok ve veri blokları üzerinde sabit yayılma olarak ele alınabilir, ancak bir çerçeveden diğerine değişebilir. DNN modeli, ilk çalışmamızda bir pilot blok ve bir veri bloğundan oluşan alınan verileri girdi olarak alır ve iletilen verileri uçtan uca kurtarır. Şekil 1'de gösterildiği gibi, ortak kanal tahmini ve sembol tespiti için etkili bir DNN modeli elde etmek için iki aşama incelenmiştir. Çevrimdışı eğitim aşamasında, model, tipik kentsel veya engebeli arazi gecikme profili gibi belirli istatistiksel özelliklere sahip çeşitli bilgi dizileri ve çeşitli kanal koşulları altında oluşturularak alınan OFDM örnekleri ile eğitilir. Çevrimiçi dağıtım aşamasında, DNN modeli, kablosuz kanalı açıkça tahmin etmeden iletilen verileri kurtaran çıktıyı üretir.

Karmaşık rasgele değişkenler tarafından tanımlanan örnek aralıklı çok yollu bir kanalı ele alındığında alınan sinyal şu şekilde ifade edilebilir:

$$y(n) = x(n) \otimes h(n) + w(n) \quad (1)$$

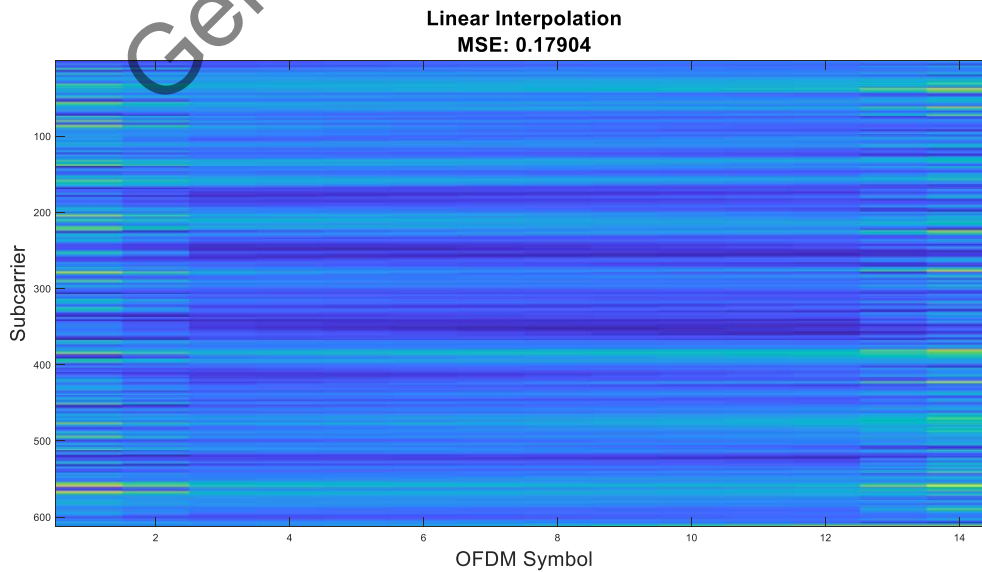
Denklem 1'de alınan sinyal y'dir, h kanalın kazanç matrisidir, modüle edilen sinyal x'tir ve w AWGN gürültüsüdür.



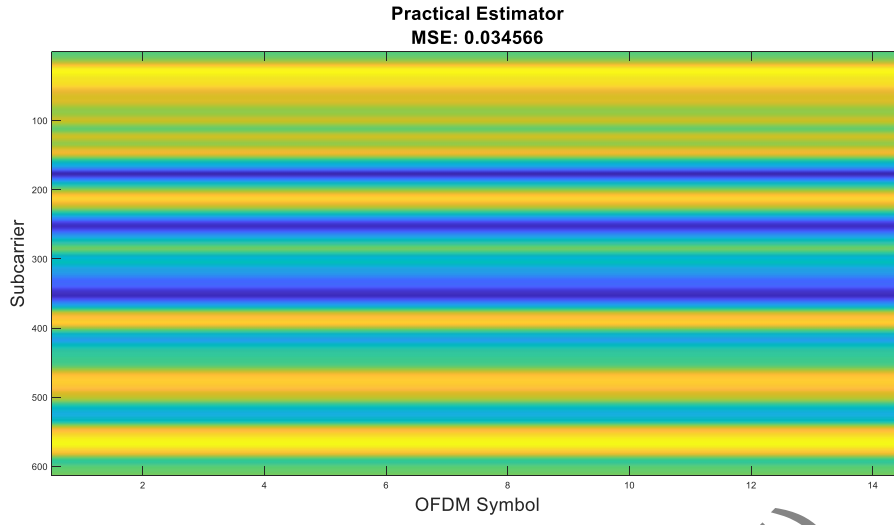
Şekil 1. Önerilen Sistem Yapısı

4. Simülasyon Sonuçları


OFDM 5G kablosuz iletişim sistemlerinde ortak kanal tahmini ve sembol tespiti için derin öğrenme yöntemlerinin performansını göstermek için bir uygulama gerçekleştirilmiştir. Şekil 2'de OFDM için lineer enterpolasyon ile kanal tahmini yapılmış MSE değeri 0.17904 elde edilmiştir. Şekil 3'te OFDM için pratik enterpolasyon ile kanal tahmini yapılmış ve MSE değeri 0.034566 olarak elde edilmiştir. Şekil 4'te OFDM için NN kullanılarak kanal tahmini yapılmış ve MSE değeri 0.019558 olarak elde edilmiştir. Son olarak Şekil 5'te gerçek kanal ile OFDM için kanal tahmini alt taşıyıcı ve OFDM sembollerine bağlı olarak çizdirilmiştir.



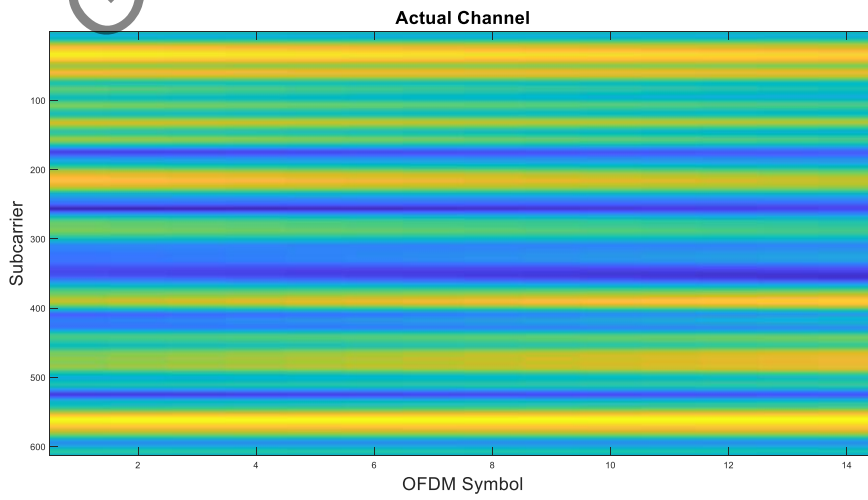
Şekil 2. Lineer Enterpolasyon ile OFDM için kanal tahmini



Şekil 3. Pratik Enterpolasyon ile OFDM için kanal tahmini

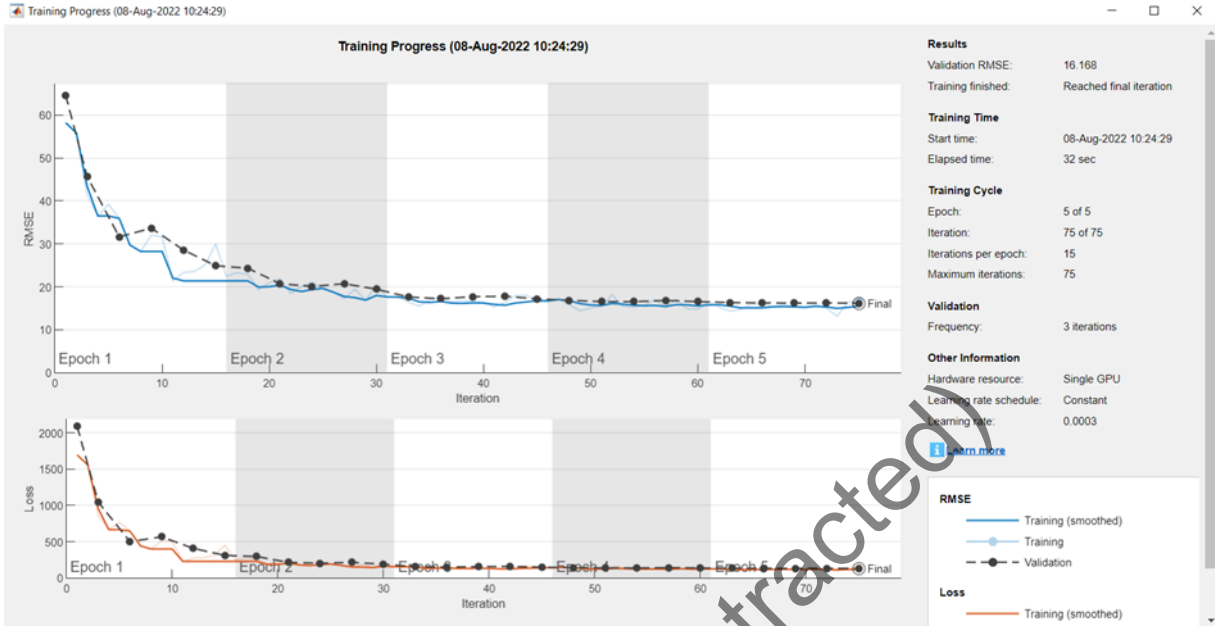


Şekil 4. NN ile OFDM için kanal tahmini



Şekil 5. Gerçek kanal ile OFDM için kanal tahmini

Eğitim işlem diyagramı Şekil 6 ile gösterilmektedir. Şekilden eğitim süresince RMSE ve kayıp eğrisi, 75 iterasyon için 32 saniyede 0.0003 öğrenme oranında elde edilmiştir.



Şekil 6. Eğitim diyagramı

Ayrıca bu eğitim diyagramında minibatchsize parametresi 32, max epochs parametresi 5 ve başlangıç öğrenme oranı parametresi $3e-4$ olarak seçilmiştir.

5. Sonuç

5G kablosuz iletişim sistemlerinde kullanılan OFDM kanal tahmini ve sembol tespiti işlemlerinde derin öğrenme yöntemlerinin performansını göstermek için bir uygulama gerçekleştirilmiştir. Bu çalışmada 256 eğitim örneği veya eğitim veri seti üretilecek şekilde ayarlanmıştır. Kullanılan veri miktarı, uygun bir sürede bir CPU üzerinde işlevsel bir kanal tahmin ağını eğitmek için yeterlidir. Karşılaştırma için, önceden eğitilmiş model 16.384 eğitim örneğine dayanmaktadır. CNN modelinde eğitim verilerinin sahip olduğu sabit bir boyut vardır, ağ yalnızca $612 \times 14 \times 1$ ızgaraları, yani 612 alt taşıyıcıyı, 14 OFDM sembolünü ve 1 anteni kabul edebilir. OFDM için lineer enterpolasyon ile kanal tahmini, pratik enterpolasyon ile kanal tahmini, NN kullanılarak kanal tahmini ve gerçek kanal için tahmin yapılmıştır. Gerçek, pratik, NN ve lineer enterpolasyon kullanılarak OFDM kanal tahmini yapılmış ayrıntılar alt taşıyıcı sayısı ve OFDM sembol sayısına bağlı olarak Şekil 2, Şekil 3, Şekil 4 ve Şekil 5 ile gösterilmiştir.

Kaynaklar

Coleri S, Ergen M, Puri A, Bahai A. (2002) Channel estimation techniques based on pilot arrangement in ofdm systems, IEEE Transactions on Broadcasting, vol. 48, pp. 223–229.

O'Shea T, Hoydis J. (2017) An introduction to deep learning for the physical layer. IEEE Transactions on Cognitive Communications and Networking, vol. 3, pp. 563–575.

Samuel N, Diskin T, Wiesel A. (2017) Deep mimo detection. IEEE 18th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC), pp. 1–5.

Erdogmus D, Rende D, Principe J, Wong C. T. F. (2001) Nonlinear channel equalization using multilayer perceptrons with informationtheoretic criterion. Neural Networks for Signal Processing XI: Proceedings of the 2001 IEEE Signal Processing Society Workshop (IEEE Cat. No.01TH8584), pp. 443–451.

Wen C, Shih W, Jin S. (2018) Deep learning for massive mimo csi feedback. IEEE Wireless Communications Letters, pp. 1–1.

Ye H, Li G. Y, Juang B.H. (2018) Power of deep learning for channel estimation and signal detection in ofdm systems. *IEEE Wireless Communications Letters*, vol. 7, no. 1, pp. 114–117.

He H, Wen C, Jin S, and Li G. Y. (2018) Deep learning-based channel estimation for beamspace mmwave massive mimo systems. *IEEE Wireless Communications Letters*, vol. 7, pp. 852–855.

Geri Çekildi (Retracted)