

## Intelligent Resource Allocation in Wireless Communication Systems Based on deep Neural Networks

S. Hadis Hayatolghheybi<sup>1</sup>, Ali Kuhestani<sup>2</sup>, Mohammadreza Keshavarzi<sup>3</sup>

<sup>1</sup> MSc. Student, Department of Electrical and Computer Engineering, Qom University of Technology, Tehran, Iran.

[hayatolghheybhadi@yahoo.com](mailto:hayatolghheybhadi@yahoo.com)

<sup>2</sup> Associate Professor, Department of Electrical and Computer Engineering, Qom University of Technology, Qom, Iran.

[Kuhestani@qut.ac.ir](mailto:Kuhestani@qut.ac.ir)

<sup>3</sup> Assistant Professor, ICT Research Institute, Iran Telecommunication Research Center (ITRC), Tehran, Iran  
[mrkeshavarzi@itrc.ac.ir](mailto:mrkeshavarzi@itrc.ac.ir)

### Abstract:

5G networks are designed to provide higher data rates, lower energy consumption and very short latency. Resource allocation (RA) in wireless communication systems is an intelligent process to allocate the limited resources available in different blocks of these systems in order to meet the needs of end users. In contrast to traditional approaches in which the optimal strategy for RA is determined based on analytical models and using a set of assumptions, the method based on deep neural networks can rely on its ability to adapt to the environment directly from real channel data to achieve use the optimal strategy and provide superior performance in practice. In this paper, an intelligent scheme based on deep neural networks is presented for RA in 5G networks, which includes user-to-base station (CUE) cellular communication and D2D communication between users. In this plan, by considering the non-ideal system model, we achieve the dedicated resources (Maximum Production Efficiency (Max SE), Energy Efficiency (Max EE) and Minimum Transmission Power Min PW)) with interference constraints, QoS and minimum transmission power. Uses non-ideal.

**Keywords:** Wireless communication systems (WCS), Resource allocation (RA), Deep neural networks (DNN), D'enoising auto encryption network (DAE).

**Article Type:** Research

**Received:** 05. 04. 2024

**Revised:** 08. 07. 2025

**Accepted:** 07. 12. 2025

**Corresponding author:** A. Kuhestani

**Corresponding author's address:** Khoda Karam Ave. Elec. And Comp. Eng. Dep., Qom Uni. Of Tech. Qom , Iran



## 1. Motivation of the work

The motivation of this work is to design a practical, robust, and intelligent resource allocation framework for 5G networks that overcomes the limitations of traditional analytical methods by leveraging deep learning, while explicitly accounting for non-ideal channel conditions and imperfect CSI. By incorporating denoising autoencoders, the proposed approach improves spectral efficiency, energy efficiency, and power minimization in realistic CUE–D2D coexistence scenarios.

## 2. Contributions

The main contribution of this paper is the proposal of a robust and practical deep learning–based resource allocation framework for 5G networks that jointly supports cellular users and D2D communications under non-ideal channel conditions. Unlike most existing studies that rely on perfect or noise-free CSI, this work adopts a realistic system model with channel estimation errors, making the proposed approach closer to real 5G deployments. By leveraging deep neural networks, the complex RA problem is solved without relying on restrictive analytical assumptions, while satisfying interference constraints, QoS requirements, and minimum transmission power limits. To mitigate the adverse impact of imperfect and noisy channel information, an automatic denoising autoencoder (DAE) is integrated into the framework to clean the input CSI before decision making, significantly improving robustness and accuracy. The proposed scheme simultaneously addresses maximum spectral efficiency, maximum energy efficiency, and minimum transmission power as design objectives.

## 3. Procedures

In this work, first, channel state information is collected for both cellular users and D2D pairs, where the CSI is assumed to be imperfect and contaminated by noise and estimation errors. This raw CSI is then preprocessed and fed into a denoising autoencoder (DAE), which is trained to reconstruct clean channel representations by suppressing unwanted noise and inaccuracies in the input data. The denoised CSI is subsequently provided to a deep neural network–based resource allocation module, which learns the mapping between channel conditions and optimal resource allocation decisions. During training, the RA network is optimized under practical constraints, including interference limits, QoS requirements, and minimum transmission power, while jointly targeting the objectives of maximum spectral efficiency, maximum energy efficiency, and minimum transmission power. After training is completed offline, the learned model is deployed for real-time operation, where it rapidly generates resource allocation decisions for new channel realizations. Finally, the performance of the proposed framework is evaluated through simulations, comparing the achieved SE, EE, and

transmit power with benchmark and conventional methods to verify the effectiveness and robustness of the proposed approach under non-ideal channel conditions.

## 4. Findings

The findings demonstrate that DL–based resource allocation can effectively and robustly optimize 5G network performance under realistic, non-ideal conditions. The simulation results show that incorporating a denoising autoencoder significantly improves the quality of channel state information, which directly leads to more accurate and stable resource allocation decisions in the presence of noisy and imperfect CSI. As a result, the proposed framework achieves higher spectral efficiency and energy efficiency, while simultaneously reducing the required transmission power, compared with conventional optimization-based and learning-based schemes that do not account for channel noise. The findings further indicate that the performance gains are more pronounced in dense CUE–D2D coexistence scenarios, where interference and CSI uncertainty are severe.

## 5. Conclusion

This paper presented an intelligent deep learning–based resource allocation framework for 5G networks that jointly supports cellular users and D2D communications under non-ideal and noisy channel conditions. By moving beyond traditional analytical approaches and idealized assumptions, the proposed method leverages deep neural networks to effectively learn optimal resource allocation strategies directly from channel data while satisfying interference, QoS, and minimum power constraints. The integration of a denoising autoencoder proved crucial in mitigating the impact of imperfect and erroneous CSI, leading to more reliable and robust decision making. Simulation results demonstrated that the proposed framework consistently outperforms conventional schemes in terms of spectral efficiency, energy efficiency, and transmission power minimization, particularly in interference-limited and noisy environments. These findings highlight the importance of combining realistic system modeling with denoising-aware learning techniques and confirm that the proposed approach constitutes a practical and effective solution for resource allocation in future 5G.

## تخصیص منابع هوشمند در سیستم‌های مخابراتی بی‌سیم مبتنی بر شبکه‌های عصبی عمیق

سیده حدیث حبوت‌الغیبی<sup>۱</sup>، علی کوهستانی<sup>۲</sup>، محمدرضا کشاورزی<sup>۳</sup>

۱- دانشجوی کارشناسی ارشد- دانشکده مهندسی برق و کامپیوتر- دانشگاه صنعتی قم- قم- ایران

[hayatolgheybhadis@yahoo.com](mailto:hayatolgheybhadis@yahoo.com)

۲- دانشیار- دانشکده مهندسی برق و کامپیوتر- دانشگاه صنعتی قم- قم- ایران

[Kuhestani@qut.ac.ir](mailto:Kuhestani@qut.ac.ir)

۳- استادیار- پژوهشکده فناوری ارتباطات، پژوهشگاه ارتباطات و فناوری اطلاعات - تهران - ایران

[mrkeshavarzi@itrc.ac.ir](mailto:mrkeshavarzi@itrc.ac.ir)

**چکیده:** شبکه موبایل نسل پنجم (5G) با هدف ارائه نرخ داده بالاتر، مصرف انرژی کمتر و تأخیر بسیار کوتاه طراحی شده است. با افزایش تقاضا برای خدمات سلولی و محدودیت منابع موجود برای ارائه آن، مدیریت کارآمد ترافیک و عملیات شبکه به چالش توزیع منابع، تبدیل شده است. تخصیص منابع (RA) در سیستم‌های مخابراتی بی‌سیم، فرآیندی هوشمندانه با هدف برآوردن نیازهای کاربران نهایی است. در مقابل رویکردهای سنتی که در آنها استراتژی بهینه برای RA بر اساس مدل‌های تحلیلی و با استفاده از مجموعه‌ای از مفروضات تعیین می‌شود، روش مبتنی بر شبکه‌های عصبی عمیق می‌تواند با اتکا به توانایی تطبیق‌پذیری آن با محیط، به طور مستقیم از داده‌های واقعی کانال برای دستیابی به استراتژی مطلوب استفاده کند و عملکردی برتر ارائه دهد. در این مقاله، طرحی هوشمند مبتنی بر شبکه‌های عصبی عمیق برای RA در شبکه‌های 5G ارائه می‌شود که شامل مخابره سلولی کاربر (CUE) با ایستگاه پایه و ارتباط D2D بین کاربران است. در این مقاله، با در نظر گرفتن مدل سیستم غیرایده‌آل، تخصیص منابع با اهداف حداکثر بهره‌وری طیفی (Max SE)، حداکثر کارایی انرژی (Max EE) و حداقل توان انتقالی (Min PW) با در نظر گرفتن محدودیت‌های تداخل، کیفیت خدمات (QoS) و حداقل توان انتقالی، ارائه می‌گردد. این مدل سیستم در مقایسه با مدل‌های ایده‌آل و بدون نویز در مطالعات گذشته، به مدل سیستم واقعی نزدیک‌تر است. در سیستم مدل غیرایده‌آل، نقیصه‌های سخت‌افزاری در گره‌های فرستنده و گیرنده (DUE و UE) در نظر گرفته شده و همچنین پس از پردازش داده‌های ورودی در شبکه عصبی عمیق (DNN)، جهت رفع خطاهای موجود در داده‌های ورودی به دلیل خطا در تخمین اطلاعات کانال، از شبکه خودرمن‌نگار خودکار حذف نویز (DAE) استفاده می‌شود. نتایج شبیه‌سازی نشان‌دهنده دستیابی به نتایج بهتر برای Max SE، Max EE و Min PW با حذف نویزهای ناخواسته کانال برای این مدل سیستم است.

**کلمات کلیدی:** سیستم‌های مخابراتی بی‌سیم، تخصیص منابع، شبکه‌های عصبی عمیق، شبکه‌ی خودرمن‌نگار حذف نویز

### نوع مقاله: پژوهشی

دریافت: ۱۴۰۳/۰۳/۱۹

بازنگری: ۱۴۰۴/۰۵/۲۵

پذیرش: ۱۴۰۴/۰۹/۱۵

نام نویسنده‌ی مسئول: دکتر علی کوهستانی

نشانی نویسنده‌ی مسئول: ایران - قم - بلوار شهید خدایار - دانشگاه صنعتی قم - دانشکده‌ی مهندسی برق و کامپیوتر

## ۱- مقدمه

فناوری مخابراتی نسل پنجم<sup>۱</sup> (5G) یک مدل چند لایه می‌باشد که ضرورت مدیریت تداخل و تخصیص منابع<sup>۲</sup> (RA) در آن اهمیت بسیاری دارد. با نیاز روزافزون به خدمات سلولی و در ضمن داشتن منابع محدود، مدیریت کارآمد ترافیک و عملیات شبکه به مشکل توزیع منابع تبدیل شده است [۱]. هدف از RA در سیستم‌های مخابراتی بی‌سیم، تخصیص هوشمندانه منابع محدود به بلوک‌های مختلف سیستم‌های مخابراتی بی‌سیم<sup>۴</sup> (WCS) می‌باشد تا نیازهای کاربران برآورده گردد. با تکامل سریع شبکه‌های مخابراتی، تخصیص منابع همچنان یکی از چالش اساسی است؛ زیرا با افزایش تقاضا برای خدمات و نیز جهت ارائه خدمات با کیفیت بهتر، پهنای باند مورد نیاز افزایش می‌یابد. در سال‌های اخیر، ابزارهای زیادی از جمله بهینه‌سازی و نظریه کنترل برای حل انواع مسائل تخصیص منابع عملی به کار گرفته شده‌اند. بنابراین، تخصیص منابع در شبکه‌های مخابراتی یک موضوع تحقیقاتی ضروری محسوب می‌شود و توسعه تکنیک‌های RA پیشرفته برای اطمینان از عملکرد بهینه شبکه‌ها ضروری است [۲].

یادگیری عمیق<sup>۵</sup> (DL) یک تکنیک مبتنی بر شبکه‌های عصبی عمیق<sup>۶</sup> (DNNs) است که به فعالیت نورون‌ها در مغز مربوط می‌شود و اخیراً مورد توجه قرار گرفته است. اشتیاق به DL عمدتاً به دلیل مزایای قابل توجه آن از نظر عملکرد بهتر نسبت به طرح‌های معمولی است [۳]، [۴] [۵]. برای مثال، طرح‌های طبقه‌بندی تصویر مبتنی بر DL می‌توانند به دقت بسیار بیشتری نسبت به طرح‌های معمولی مبتنی بر مدل‌های تحلیلی دست یابند و حتی در برخی موارد از عملکرد سطح انسانی نیز پیشی گرفته‌اند. استفاده از DL به طبقه‌بندی ساده محدود نمی‌شود؛ بلکه عملکردهای قابل توجهی را در کارهای پیچیده‌تر، مانند درک صحنه‌های معنایی نشان می‌دهد [۵]. ظهور DL می‌تواند باعث تغییر در الگوی تحقیق شود؛ سوئیچ از طراحی طرح‌ها با مهندسی دقیق (مبتنی بر مدل‌های ریاضی) به رویکردی مبتنی بر یادگیری (با مشاهده مقادیر زیادی از داده‌ها). نوع دیگر شبکه‌های DNN، شبکه‌های خود-رمزنگار حذف نویز<sup>۷</sup> (DAE) هستند که خطاهای موجود در داده ورودی را بر اساس الگوی تعریف شده، حذف می‌کنند [۶].

در سیستم‌های مخابراتی، فرستنده و گیرنده‌ها دارای نقیصه‌های سخت‌افزاری هستند که اعوجاج‌هایی را ایجاد می‌کنند و در نتیجه عملکرد سیستم‌های مخابراتی را کاهش می‌دهد. در غالب تحقیقات صورت گرفته شده، نقیصه‌های سخت‌افزاری نادیده گرفته می‌شود و بنابراین، سخت‌افزار را ایده‌آل فرض می‌کنند. چنین تقریب‌هایی در سیستم‌های با نرخ پایین منطقی است، اما می‌تواند منجر به نتایج بسیار گمراه‌کننده در هنگام تحلیل سیستم‌های با نرخ بالا شود. این موضوع نشان‌دهنده اهمیت در نظر گرفتن نقیصه‌های سخت‌افزاری در مدل سیستم است. مدل سیستم مورد مطالعه در [۳]، شامل فرستنده، گیرنده و رله می‌باشد که در آن، تمام عناصر مخابراتی از نقیصه‌های سخت‌افزاری

رنج می‌برند. نتایج نشان می‌دهد که برخلاف حالت ایده‌آل، در حالت غیرایده‌آل نرخ قابل حصول به یک مقدار سقف محدود می‌شود. برخلاف رویکردهای مرسوم که در آنها رویکرد بهینه برای RA از تحلیل مدل سیستم با استفاده از مجموعه‌ای از مفروضات مشتق می‌شود، در رویکرد مبتنی بر DL به لطف توانایی آن در انطباق با محیط، مستقیماً از داده‌های کانال واقعی استفاده می‌شود [۷]. در یک رویکرد مبتنی بر DL، RA بهینه را می‌توان از بهره کانال [۷]، [۸] استخراج کرد. در [۷]، [۸] توان ارسالی به منظور به حداکثر رساندن بازدهی طیفی<sup>۹</sup> (SE) یا بازدهی انرژی<sup>۱۰</sup> (EE) بهینه شد که در آن رویکرد بهینه برای کنترل توان از طریق DL و بدون نیاز به استخراج یک فرمول ریاضی صریح به دست آمده است. نویسندگان در [۹] از یک DNN بر اساس میانگین وزنی حداقل مربعات خطا<sup>۸</sup> (WMMSE) به منظور حل مشکلات مرتبط با زمان محاسبات بالای آن استفاده کرده‌اند. در [۹]، مطالعه جامعی در خصوص استفاده از الگوریتم‌های یادگیری ماشین<sup>۱۱</sup> (ML) برای مدیریت موثر منابع در شبکه‌های سلولی بی‌سیم نسل پنجم و فراتر از آن (5G/B5G) ارائه شده است. در این مرجع، از ML و محاسبات لبه متحرک یک چارچوب نوین برای ارایه QoS بهبود یافته برای کاربران نهایی استفاده شده است؛ زیرا آن‌ها می‌توانند بار محاسباتی مرتبط با مدیریت منابع رادیویی را کاهش دهند. محققین در مرجع [۳]، از بهره کانال به عنوان ورودی یک شبکه عصبی به منظور دستیابی به اهداف تخصیص منابع، افزایش راندمان طیفی و بازده انرژی و نیز کاهش توان ارسالی استفاده کردند. همچنین

نویسندگان در کار تحقیقاتی [۱۰]، از یک رویکرد یادگیری عمیق برای انجام یک مطالعه اساسی و نیز تخصیص منابع هوشمند در شبکه‌های مخابراتی بی‌سیم استفاده می‌کنند. در این مقاله، از شبکه حافظه کوتاه مدت طولانی<sup>۱۲</sup> (LSTM) برای پیش‌بینی موقعیت موبایل کاربران مورد استفاده قرار می‌گیرد. کار پژوهشی [۱۱] بر تخصیص منابع انرژی به صورت کارآمد در سیستم‌های مخابراتی چند ورودی-تک خروجی به کمک سطح هوشمند قابل پیکربندی مجدد (RIS)<sup>۱۳</sup> تمرکز دارد. در هر بار تکرار بهینه‌سازی متناوب<sup>۱۴</sup> (AO) پیشنهادی، بهینه‌سازی فاز RIS با استفاده از روش گرادیان به‌دست می‌آید که البته همگرایی را تضمین نمی‌کند. توجه شود که مدل سیستم در نظر گرفته شده در تمام مقالات بالا ایده‌آل بوده و الگوریتمی برای حذف نویزهای کانال در نظر گرفته نشده است.


این مقاله به موضوع RA هوشمند با استفاده از DL در یک سیستم مخابراتی بی‌سیم می‌پردازد. مدل سیستم مورد مطالعه، برخلاف مقالات گذشته، به عنوان نوآوری، مدل سیستم غیرایده‌آل می‌باشد. همچنین به منظور رفع خطاهای موجود در داده‌های ورودی شبکه DNN به علت خطا در اطلاعات کانال از شبکه‌ی خودرمزنگار خودکار حذف نویز استفاده می‌شود. برای این منظور، ابتدا شبکه 5G و ضرورت تخصیص منابع در آن شرح داده می‌شود. سپس، معماری DNN مورد بحث قرار می‌گیرد که می‌توان از آن به عنوان یک رویکرد کلی برای RA با هدف

همچنین در [۱۷]، نویسندگان یک روش تخصیص منابع برای کاربران دستگاه به دستگاه<sup>۱۵</sup> (D2D) در ذیل ایستگاه پایه<sup>۱۶</sup> (BS) پیشنهاد دادند. طرح ارائه شده تا حد کمتری به BS متکی بود. بنابراین، بار کاری به BS و ضمناً زمان مورد نیاز برای اجرای فرآیند تخصیص منابع به حداقل رسید. به علاوه، نویسندگان در کار تحقیقاتی [۱۸]، تخصیص منبع را برای یک لینک D2D برای وضعیتی که BS سلولی از باند موج میلیمتری استفاده می‌کرد، ارایه دادند. نویسندگان بر تخصیص منصفانه منابع در یک سلول برای افزایش کارایی طیفی تمرکز کردند.

تفاوت این مقاله با مرجع [۱۹] این است که مقاله حاضر، نسخه کامل‌تر و دقیق‌تری از [۱۹] می‌باشد که به‌طور خاص، نقیصه‌های سخت‌افزاری در مقاله حاضر بررسی شده است. لذا این کار تحقیقاتی جامعیت بیشتری دارد. به علاوه مقاله حاضر، مسائل بهینه‌سازی بیشتر (با اهداف متعدد) مطرح کرده که متعاقباً کار را مفصل‌تر نموده است. در نهایت می‌توان گفت که مقاله حاضر در مقایسه با مقاله [۱۹]، شفاف‌تر با توضیحات کامل‌تر است.

### ۳- مدل سیستم

مطابق شکل (۱)، مدل سیستم مورد مطالعه متشکل از یک سیستم سلولی چند کاناله با یک ارتباط D2D زیرین می‌باشد که در آن تجهیزات کاربران D2D<sup>۱۷</sup> (DUEs) به تعداد  $N$  وجود داشته و  $K$  کانال در دسترس می‌باشد. فرض می‌شود کاربران به طور تصادفی در یک منطقه  $D * D$  توزیع شده‌اند. بهره کانال بین فرستنده  $i$  ام و گیرنده  $j$  ام برای کانال  $k$  به صورت  $h_{i,j}^k$  نشان داده می‌شود که در آن شاخص 0 به تجهیزات کاربر سلولی<sup>۱۸</sup> (CUE) و ایستگاه پایه اختصاص داده می‌شود.



شکل (۱): مدل سیستم

### ۴- مدل سیستم ایده‌آل و مسائل بهینه‌سازی مربوطه بدون در نظر گرفتن نقیصه‌های سخت‌افزاری

در این بخش، سیستم مدل را ایده‌آل و بدون حضور نقیصه‌های سخت‌افزاری و شبکه DAE در نظر می‌گیریم.

دستیابی به حداکثر رساندن SE و EE و نیز به حداقل رساندن توان ارسالی، ضمن برآورده کردن محدودیت‌های تداخل و کیفیت خدمات، آموزش داد. در ادامه مدل سیستم ایده‌آل و غیرایده‌آل بررسی می‌شود و سپس به تحلیل و مقایسه شبیه‌سازی‌ها می‌پردازیم و آنها را ارزیابی می‌کنیم. در نهایت، نتیجه‌گیری و پیشنهادهایی برای ادامه کار بیان می‌شود.

در جدول (۱) مروری بر برخی از کارهای گذشته قرار داده شده است.

جدول (۱): مروری بر برخی از کارهای گذشته

| مرجع     | تکنیک ها | اهداف                  | سیستم راه اندازی                          | سال  |
|----------|----------|------------------------|-------------------------------------------|------|
| [2]      | DNN      | Max SE,EE<br>Min PW    | Wireless Communications Systems-D2D       | ۲۰۲۰ |
| [9]      | DNN      | Max SE,EE              | 5G                                        | ۲۰۲۲ |
| [10]     | DL(LSTM) | Max SE                 | 5G                                        | ۲۰۲۱ |
| [11]     | RIS      | Max SE,EE              | MISO downlink                             | ۲۰۲۳ |
| این مرجع | DNN(DAE) | Max SE,EE<br>Min noise | Wireless Communications Systems-D2D in 5G | ۲۰۲۳ |

### ۲- شبکه 5G و ضرورت تخصیص منابع در آن

تعداد دستگاه‌های بی‌سیم با سرعت بسیار زیادی در حال افزایش است [12]. به‌زودی، جامعه‌ای پویاتر و مرتبط‌تر پدیدار خواهد شد که با افزایش گسترده اتصالات، حجم ترافیکی داده‌ها به طرز چشمگیری افزایش خواهد یافت. انتظار می‌رود بین سال‌های ۲۰۱۰ تا ۲۰۳۰، ترافیک داده در سراسر جهان بیش از ۲۰۰۰۰ برابر افزایش یابد. اگرچه پیش‌بینی می‌شود تلفن‌های هوشمند محبوب‌ترین دستگاه‌های شخصی باشند، انتظار می‌رود انواع دیگر دستگاه‌های هوشمند افزایش یابد. در نتیجه، سیستم ارتباطات سلولی 5G باید به طور گسترده معرفی شود تا نیازهای دائماً در حال تحولی را که نسل‌های قبلی قادر به برآوردن آن نبودند را برآورده کند [۱۳].

تخصیص منابع یکی از جنبه‌های مهم سیستم‌های ارتباطی بی‌سیم است [۱۴]. تخصیص منابع نقش مهمی در دسترسی به شبکه برای کاربران نهایی، شرکای تجاری و مشتریان شبکه سلولی ایفا می‌کند. عملکرد شبکه به سطح عادلانه تخصیص منابع شبکه بستگی دارد. بنابراین، تخصیص مؤثر منابع، موضوعی اساسی است که نیاز روزافزون به شبکه‌های سلولی 5G را به چالش می‌کشد. منابع یک شبکه مخابراتی بی‌سیم به طور خاص بر اساس توان، طیف و کیفیت کانال تعریف می‌شوند که باید بر اساس نیاز کاربر تخصیص داده شوند. یک شبکه تلفن همراه ممکن است از کمبود منابع طیفی به دلیل افزایش عظیم در تعداد کاربران و نیز تعداد دستگاه‌های متصل به شبکه رنج ببرد [۱۵]. بر این اساس، نویسندگان در مرجع [۱۶]، یک الگوریتم پیشرفته تخصیص منابع با پیچیدگی کم برای تخصیص توان و بهینه‌سازی گروه‌بندی کاربر ارایه کردند. مدل پیشنهادی برای بالا بردن ظرفیت سیستم طراحی شد.

نباید از حداکثر توان ارسال  $P_T$  (محدودیت توان ارسال) تجاوز کند. دوم، میزان تداخل ایجاد شده در انتقال سلولی باید کمتر از آستانه  $I_T$  (محدودیت تداخل) باشد. سوم، هر انتقال D2D باید حداقل نیاز QoS را برآورده کند، یعنی SE بدست آمده توسط هر DUE باید بیشتر از آستانه،  $R_T$  (محدودیت QoS) باشد.

بر این اساس، مسئله بهینه‌سازی برای به حداکثر رساندن SE با توجه به محدودیت‌های DUE ها به صورت (۳) فرموله می‌شود:

$$\begin{aligned} & \text{maximize } P_i^k: \\ & \sum_{i \in \pi} SE_i \\ & \sum_{k \leq K} P_i^k \leq P_T \quad \forall i \in \pi \\ & 0 \leq P_i^k \quad \forall i \in \pi, \forall k \leq K \\ & \sum_{i \in \pi} h_{i,0}^k P_i^k \leq I_T \quad \forall k \leq K \\ & SE_i \geq R_T \quad \forall i \in \pi \end{aligned} \quad (3)$$

به طور مشابه، مسئله بهینه‌سازی برای به حداکثر رساندن EE ها مرتبط با DUE ها به صورت (۴) فرموله می‌شود:

$$\begin{aligned} & \text{maximize } P_i^k: \\ & \sum_{i \in \pi} EE_i \\ & \sum_{k \leq K} P_i^k \leq P_T \quad \forall i \in \pi \\ & 0 \leq P_i^k \quad \forall i \in \pi, \forall k \leq K \\ & \sum_{i \in \pi} h_{i,0}^k P_i^k \leq I_T \quad \forall k \leq K \\ & SE_i \geq R_T \quad \forall i \in \pi \end{aligned} \quad (4)$$

در نهایت، مسئله بهینه‌سازی برای به حداقل رساندن توان ارسالی کل DUE ها را می‌توان به صورت (۵) فرموله کرد:

$$\begin{aligned} & \text{minimize } P_i^k: \\ & \sum_{i \in \pi} \sum_{k \leq K} P_i^k \\ & \sum_{k \leq K} P_i^k \leq P_T \quad \forall i \in \pi \\ & 0 \leq P_i^k \quad \forall i \in \pi, \forall k \leq K \\ & \sum_{i \in \pi} h_{i,0}^k P_i^k \leq I_T \quad \forall k \leq K \\ & SE_i \geq R_T \quad \forall i \in \pi \end{aligned} \quad (5)$$

مسائل بهینه‌سازی طرح شده در (۳) تا (۵) غیر محدب هستند، به طوری که حل آن‌ها به صورت تحلیلی با پیچیدگی محاسباتی کم، بسیار دشوار است. علاوه بر این، با توجه به اینکه راه‌حل‌های بهینه به بهره کانال  $(h_{i,j}^k)$  بستگی دارد، هر زمان که بهره کانال تغییر کرد، توان مورد نیاز باید دوباره استخراج شود. بر این اساس، راهکار هوشمندانه به‌کارگیری DNN برای یافتن توان ارسال بهینه می‌باشد که به موجب آن، مشکلات فوق‌الذکر با زمان محاسبات کم، حل می‌گردد [۲].

همان‌طوری که می‌دانیم در مخابرات 5G سه شاخص مهم برای شبکه عبارتند از: (۱) بهره‌وری طیفی (SE)، (۲) کارایی انرژی (EE) و (۳) توان انتقالی (PW) که انتخاب شاخص به کاربرد، محیط شبکه و سیاست اپراتور بستگی دارد. در ادامه، ضمن تشریح این شاخص‌ها، مسائل بهینه‌سازی مربوط به هر کدام را مطرح می‌کنیم:

۱. بهره‌وری طیفی (SE - Spectral Efficiency): اهمیت این شاخص در مناطق پرجمعیت، بالا است؛ چرا که در مراکز شهری یا رویدادهای بزرگ، با کمبود طیف مواجه هستیم. طیف یک منبع محدود و گران است؛ لذا SE بالا یعنی انتقال داده بیشتر در همان پهنای باند. توجه شود اگر فقط به SE حداکثری فکر کنیم، معمولاً توان بیشتری مصرف می‌شود و کارایی انرژی کاهش می‌یابد.

۲. کارایی انرژی (EE - Energy Efficiency): اهمیت این شاخص در 5G، به‌خصوص برای IoT و نیز سلول‌های کوچک که منابع انرژی محدود دارند و یا شبکه‌های روستایی، اهمیت حیاتی پیدا می‌کند. مصرف انرژی کمتر، هم به کاهش هزینه عملیاتی اپراتور و هم کاهش اثرات زیست‌محیطی کمک می‌کند. البته توجه شود که EE زیاد ممکن است با کم شدن نرخ داده یا ظرفیت شبکه همراه شود.

۳. توان انتقالی (PW): این شاخص بیشتر به‌عنوان یک شاخص محدودکننده مطرح است تا هدف نهایی. به دلیل مقررات (حداکثر توان مجاز فرستنده)، کاهش تداخل و ایمنی کاربران معمولاً این شاخص باید در نظر گرفته شود. در 5G، کاهش PW به بهبود EE کمک می‌کند، اما اگر بیش از حد کاهش یابد، پوشش‌دهی و SE ضربه می‌خورد.

توان ارسال DUE های تخصیص یافته به هر کانال با  $P_i^k$  نشان داده می‌شود که در آن  $k$  و  $i$  به ترتیب شاخص کانال و DUE هستند. فرض می‌کنیم که حداکثر توان انتقال DUE ها  $P_T$  است به طوری که  $\sum_{k \leq K} P_i^k \leq P_T$  برای همه  $i$  ها. علاوه بر این، فرض می‌کنیم که توان انتقال CUE،  $P_M$  است. پارامترهای  $W$  و  $N_0$  را به ترتیب به عنوان پهنای باند و چگالی طیفی نویز نشان می‌دهیم. بر این اساس، در مدل سیستم، بازده طیفی (SE) مرتبط با  $DUE_i$  را می‌توان به صورت زیر نوشت:

$$SE_i = \sum_{k \leq K} \log_2 \left( 1 + \frac{h_{i,t}^k P_i^k}{N_0 W + \sum_{l \in \pi(l)} h_{l,t}^k P_l^k + h_{0,t}^k P_M} \right) \quad (1)$$

علاوه بر این، بازده انرژی (EE) مرتبط با  $DUE_i$  به صورت زیر است:

$$EE_i = \frac{SE_i}{\sum_{k \leq K} P_i^k + P_C} \quad (2)$$

که در آن  $P_C$  توان مداری DUE است. بهینه‌سازی را با سه هدف مختلف در نظر می‌گیریم که عبارتند از: (۱) به حداکثر رساندن SE، (۲) به حداکثر رساندن EE، و (۳) به حداقل رساندن توان ارسالی کل. علاوه بر این، سه محدودیت را در نظر می‌گیریم. اول، توان ارسالی تخصیص یافته به هر کانال باید غیرمنفی باشد و مجموع توان ارسالی برای یک DUE منفرد

سپس، DNN را می‌توان بر اساس یک الگوریتم انتشار برگشتی آموزش داد، جایی که این نمونه‌های کانال به ورودی آموزش تبدیل می‌شوند. آموزش، برای دستیابی به اهداف در عین ارضای محدودیت‌ها، مجموع وزنی تابع هدف، یعنی کل SE، EE یا توان ارسال کل و توابع مربوط به محدودیت‌ها در نظر گرفته می‌شود. در تابع ضرر، وزن تابع هدف باید برای مسئله بیشینه‌سازی منفی باشد؛ زیرا مدل DNN برای به حداقل رساندن مقدار تابع تلفات آموزش داده شده است.


علاوه بر این، توابع مربوط به محدودیت‌ها باید تابع افزایش با توجه به نقض محدودیت‌ها باشد، به طوری که مقدار تابع ضرر برای مدل DNN با برآورده شدن محدودیت‌ها کاهش می‌یابد. بر این اساس، مدل DNN را برای دستیابی به هدف مورد نظر آموزش می‌بیند، به عنوان مثال، به حداکثر رساندن SE، در حالی که محدودیت‌ها، یعنی محدودیت تداخل و محدودیت QoS را تضمین می‌کند. پس از تعیین تابع تلفات مناسب، آموزش DNN را می‌توان با استفاده از الگوریتم‌های شیب نزولی تصادفی خارج از قفسه، به عنوان مثال، الگوریتم برآورد لحظه تطبیقی به طور موثر انجام داد. پس از آموزش، توان انتقال مناسب تخصیص یافته به هر کانال را می‌توان با تغذیه بهره کانال فعلی به DNN آموزش دیده تعیین کرد.

با توجه به اینکه RA در نظر گرفته شده به صورت یک مسئله غیرمحدب فرموله شده است، استخراج RA بهینه به صورت تحلیلی دشوار است. بنابراین، روش‌های تکراری مبتنی بر ساده سازی لاگرانژی در نظر گرفته شده است. این رویکرد به تعدادی محاسبات تکراری نیاز دارد که می‌تواند زمان محاسبات را افزایش دهد [۸]، به طوری که برای کاربردهای real-time ممکن است دشوار باشد. با این حال، در RA مبتنی بر DNN، فقط شامل عملیات ماتریسی ساده است، به طوری که RA مناسب را می‌توان برای هر شرایط کانال با پیچیدگی محاسباتی کم، یافت. همین‌جا خوب است ذکر شود که میزان دینامیک بودن طرح پیشنهادی در این مقاله بالا است. دلیل آنکه:

۱. **ورودی لحظه‌ای از محیط واقعی:** مدل DNN مستقیماً از اطلاعات لحظه‌ای کانال و شرایط کاربران استفاده می‌کند.

۲. **خروجی بلادرنگ:** دو شبکه جداگانه Tnet برای توان کل و Pnet برای توزیع توان بین کانال‌ها بعد از آموزش، در زمان اجرا، پاسخ را خیلی سریع تولید می‌کنند که در نتیجه مناسب شبکه‌های 5G با تغییرات سریع خواهد بود.

۳. **مقاوم در برابر تغییر شرایط:** قیود QoS، محدودیت تداخل و حتی نقیصه‌های سخت‌افزاری در آموزش لحاظ شده است؛ لذا سیستم در شرایط عملیاتی متغیر هم پایدار می‌ماند. بنابر توضیحات فوق، تکنیک تخصیص منبع پیشنهادی، یک تخصیص کاملاً دینامیک، بلادرنگ و تطبیق‌پذیر است که می‌تواند با تغییر سریع شرایط کانال، تعداد کاربران یا اهداف شبکه به سرعت واکنش نشان دهد. این سطح از دینامیک بودن، برای سناریوهای پویای 5G (مثل D2D در محیط‌های متحرک) بسیار مناسب است.



شکل (۲): تخصیص منابع مبتنی DNN در غیاب نقیصه‌های سخت‌افزاری

شکل (۲) نشان دهنده تخصیص منابع مبتنی بر DNN بدون در نظر گرفتن نقیصه‌های سخت‌افزاری و تحت مدل ایده‌آل می‌باشد. در مدل DNN، مجموع توان ارسالی هر DUE و نسبت توان تخصیص داده شده به هر کانال توسط DUE‌های جداگانه از بهره کانال  $h_{i,j}^k$ ، پیدا می‌شود، به طوری که بهره کانال به ورودی DNN داده می‌شود و توان ارسال و تخصیص توان به خروجی DNN داده می‌شود. دو ماژول DNN مجزا، یکی برای شبکه توان ارسال کل  $T_{net}$  و دیگری برای شبکه تخصیص توان  $P_{net}$  که به طور مشترک در مدل DNN در نظر گرفته می‌شوند. به منظور بهبود عملکرد آموزشی بهره کانال، از قبل پردازش شده و ضمناً میانگین صفر و واریانس واحد برای آن لحاظ می‌شود. بهره کانال به ورودی دو شبکه Tnet و Pnet تبدیل می‌شوند. Tnet و Pnet از ماژول‌های فرعی هستند که از یک لایه کاملاً متصل  $FC$  و یک ReLU که به عنوان یک تابع فعال‌سازی استفاده می‌شود، تشکیل شده‌اند. با توجه به اینکه هر خروجی Tnet باید کمتر از حداکثر توان ارسال  $P_T$  باشد، یک سیگموئید در مقدار  $P_T$  در انتهای ضرب می‌شود، جایی که خروجی سیگموئید بین ۰ و ۱ قرار دارد. از طرف دیگر، نسبت توان ارسالی که به هر کانال برای هر DUE اختصاص داده می‌شود، توسط Pnet تعیین می‌شود، به طوری که ما  $N$  ماژول softmax را به عنوان آخرین لایه Pnet در نظر می‌گیریم، جایی که هر ماژول softmax دارای خروجی  $K$  است. در نهایت با ضرب خروجی‌های Tnet و Pnet توان انتقال DUE‌های اختصاص داده شده به هر کانال پیدا می‌شود. یک ساختار DNN با مقادیر مختلف وزن و بایاس را می‌توان برای سه هدف در نظر گرفته شده مورد استفاده قرار داد، در نتیجه با توجه به استفاده مجدد از همان ساختار DNN، به اهداف در نظر گرفته شده دست می‌یابیم.

برای یافتن مجموعه بهینه وزن‌ها و سوگیری‌ها، ابتدا باید مدل DNN پیشنهادی آموزش داده شود. برای این منظور، ابتدا باید نمونه‌های کانال برای آموزش با اندازه‌گیری یا شبیه‌سازی با استفاده از مدل کانال شناخته شده جمع‌آوری شوند. برخلاف طرح مبتنی بر یادگیری SL، در این طرح، به دلیل استفاده از UL، به توان انتقال بهینه برای هر نمونه کانال برای آموزش نیازی نیست که می‌تواند هزینه‌های سربار در تهیه داده‌های آموزشی را تا حد زیادی کاهش دهد [۲].

$$SE_i = \sum_{k \leq K} \log_2 \left( 1 + \frac{(h_{i,i}^k + \eta_i) P_i^k}{N_0 W + \sum_{l \in \pi \setminus \{i\}} h_{l,i}^k P_l^k + h_{0,i}^k P_M} \right) \quad (10)$$

در این فرمول  $\eta_i$  نویز سخت‌افزاری می‌باشد که در گره‌های فرستنده و گیرنده اضافه شده است. EE مرتبط با  $DUE_i$  نیز به صورت زیر نوشته می‌شود:

$$EE_i = \frac{SE_i}{\sum_{k \leq K} P_i^k + P_C} \quad (11)$$

### ۵-۱- فرمول‌بندی ریاضی برای توابع ضرر

آموزش، برای دستیابی به هدف ضمن ارضای محدودیت‌ها، مجموع وزنی تابع هدف و توابع محدودیت‌ها در نظر گرفته می‌شود. بر این اساس، به منظور آموزش مدل DNN برای به حداکثر رساندن SE، تابع ضرر  $L_{SE}$  را می‌توان به صورت (۱۲) تنظیم کرد:

$$L_{SE}: -\sum SE_i + \lambda_1 \sum \tanh((I_{CUE}^k - I_T)^+) + \lambda_2 \sum \tanh((SE_i - R_T)^+) \quad (12)$$

که در آن  $\lambda_1$  و  $\lambda_2$  پارامترهای کنترل‌کننده هستند و  $I_{CUE}^k$  تداخل ایجاد شده در CUE در کانال  $k$  است.

همانطور که توسط فرمول نشان داده شده است، تابع ضرر با کاهش SE از DUE‌ها افزایش می‌یابد. همچنین زمانی که تداخل یا محدودیت‌های QoS برآورده نمی‌شوند، افزایش می‌یابد. با توجه به اینکه DNN برای کاهش تلفات آموزش دیده است، از طریق آموزش، DUE، SE‌ها افزایش می‌یابد و نقض ناشی از تداخل و محدودیت‌های QoS کاهش می‌یابد. توجه داشته باشید که  $\lambda_1$  و  $\lambda_2$  مجازات نقض محدودیت‌ها را تعیین می‌کنند. برای مثال وقتی مقدار  $\lambda_1$  کوچک است، محدودیت تداخل به سختی در تابع تلفات در نظر گرفته می‌شود، به طوری که توان انتقال بدون در نظر گرفتن تداخل ایجاد شده به CUE آموخته می‌شود. به طور مشابه، تابع ضرر برای به حداکثر رساندن EE،  $L_{EE}$  به صورت زیر نوشته می‌شود:

$$L_{EE}: -\sum EE_i + \lambda_1 \sum \tanh((I_{CUE}^k - I_T)^+) + \lambda_2 \sum \tanh((SE_i - R_T)^+) \quad (13)$$


که در آن EE از  $DUE_i$  به صورت  $\frac{SE_i}{\sum_{k \leq K} P_i^k + P_C}$  قابل نوشتن است و  $P_C$  توان مدار DUE است.

در نهایت، تابع تلفات برای به حداقل رساندن توان ارسال کل که با  $L_{PW}$  نشان می‌دهیم، به صورت (۱۴) نوشته می‌شود [۲]:

$$L_{PW}: \sum P_i^k + \lambda_1 \sum \tanh((I_{CUE}^k - I_T)^+) + \lambda_2 \sum \tanh((SE_i - R_T)^+) \quad (14)$$

## ۵- مدل سیستم با لحاظ کردن نقیصه‌های سخت‌افزاری

در این بخش، مدل سیستم برای سخت‌افزار غیرایده‌آل یعنی با لحاظ کردن نقیصه‌های سخت‌افزاری ترسیم می‌شود. در این سناریو  $\eta_r, \eta_t$  که نویزهای اعوجاج ناشی از نقیصه‌ها در فرستنده و گیرنده هستند، به سیگنال ارسالی و دریافتی اضافه می‌شوند. شکل (۳) تخصیص منبع مبتنی DNN با در نظر گرفتن نقیصه‌های سخت‌افزاری را نشان می‌دهد.



شکل (۳): تخصیص منبع مبتنی DNN تحت قید نقیصه‌های سخت‌افزاری

$\eta_i \sim CN(0, K_i^2 P_i)$  نویز اعوجاج معرفی شده در ابتدای فصل می‌باشد. نویز اعوجاج ناشی از نقیصه‌های سخت‌افزاری (پس از اعمال الگوریتم‌های جبران مرسوم) به عنوان یک سیگنال تداخلی ناشناخته عمل می‌کند که از همان کانال  $h_i$  به عنوان سیگنال مورد نظر می‌گذرد. نویز در گره‌های فرستنده و گیرنده اعمال می‌شود، که نویز فرستنده به صورت (۶) تعریف می‌شود:

$$\eta_t \sim CN(0, K_t^2 P) \quad (6)$$

$$P = E_s\{|s|^2\} \quad (7)$$

$P$  به صورت میانگین هر کدام از سیگنال‌های ارسالی تعریف می‌شود. نویز در گیرنده به صورت (۸) می‌باشد:

$$\eta_r \sim CN(0, K_r^2 P|h|^2) \quad (8)$$

$|h|$  بزرگی کانال است، که به صورت (۹) تعریف شده است:


$$|h| = D^{-n} * |\hat{h}| \quad (9)$$

$n$  مولفه تلف مسیر و  $D$  فاصله کاربرها می‌باشد. در ادامه، نویز سخت‌افزاری را به بهره کانال و در گره‌های فرستنده و گیرنده اضافه کرده‌ایم.

بر این اساس، در مدل سیستم غیرایده‌آل، در حضور نقیصه‌های سخت‌افزاری، بازده طیفی SE مربوط به  $DUE_i$  را می‌توان نوشت:


## ۶- استفاده از DAE

در شکل (۴) شبکه DAE نشان داده شده است که یک تکنیک امیدوارکننده برای بهبود عملکرد با حذف نویز داده‌ها بوده و از داده‌های اصلی و نویز تشکیل شده است. شبکه خود-رمزنگار حذف نویز یک مدل شبکه عصبی است که در برابر اضافه کردن نویز به نمونه‌های ورودی مقاوم می‌باشد. ویژگی DAE این است که بعد فضای پنهان کوچکتر از اندازه بردار ورودی است. این بدان معنی است که مدل شبکه عصبی قادر به رمزگذاری و رمزگشایی از طریق یک بُعد کوچکتر است که در آن داده‌ها می‌توانند نمایش داده شوند [۶].



شکل (۴): شبکه DAE

شکل (۵) مدل سیستم با DAE می‌باشد. در این مدل بعد از پردازش داده‌های کانال و قبل از DNN، شبکه DAE را قرار داده‌ایم که نویزهای ناخواسته کانال را قبل از ورود به DNN حذف می‌کند. بعد از اضافه کردن نویز به بهره کانال، بهره کانال از شبکه DAE به ورودی دو شبکه Tnet و Pnet تبدیل می‌شود.



شکل (۵): مدل سیستم با DAE

## ۷- نتایج شبیه‌سازی

در این قسمت به ارائه شبیه‌سازی‌هایی در خصوص سیستم‌های ایده‌آل و غیر ایده‌آل می‌پردازیم.


### ۷-۱- محیط آزمایش شبیه‌سازی

شبیه‌سازی‌ها در محیط پایتون انجام شده است. برای روش‌های DL از کتابخانه TensorFlow و keras استفاده کرده‌ایم. حداکثر توان انتقال CUE و توان مدار DUE روی 20 dBm تنظیم شده است. علاوه بر این، پهنای باند و چگالی طیفی نویز به ترتیب روی ۱۰ مگاهرتز و ۱۷۴ dBm/Hz تنظیم شده است. همچنین،  $IT = -50$  dBm و  $RT = 3$  bps/Hz می‌باشد. علاوه بر این، DUE و CUE ها به طور تصادفی در منطقه‌ای توزیع می‌شوند که در آن حداکثر فاصله


بین فرستنده و گیرنده (همان جفت DUE) ۱۵ متر تعیین شده است. در مدل تلف مسیر، ضریب افت مسیر ۳.۸ و توان تلف مسیر ۱۰۳.۴۵۳ در نظر گرفته شده است و ضمناً یک متغیر تصادفی گوسی برای محو شدن چند مسیر، با میانگین صفر و واریانس واحد استفاده می‌شود. فرض می‌کنیم که تعداد لایه‌ها در Tnet و Pnet، ۴ لایه و تعداد گره‌های پنهان در لایه FC برابر ۱۰۰ است. علاوه بر این، ۴۰۰۰۰ نمونه کانال با شبیه‌سازی تولید شده و برای آموزش استفاده می‌شود. میانگین SE، میانگین EE و توان ارسال کل هر DUE را برای مقادیر مختلف مساحت D، در نظر می‌گیریم.

### ۷-۲- نتایج برای سیستم ایده‌آل

در این بخش، برخی نتایج شبیه‌سازی برای تأیید کارایی روش DNN ارائه می‌شود. عملکرد سیستم ایده‌آل برای RA مبتنی بر DNN را با عملکرد بهینه مبتنی بر جستجوی جامع مقایسه می‌کنیم که در آن سطح توان ارسال DUE در هر کانال با مقادیر Q با فاصله مساوی قرار دارد. در شکل (۶-ا) راندمان طیفی نسبت به مساحت (D)، در شکل (۶-ب) بهره‌وری انرژی نسبت به مساحت (D) و در شکل (۶-ج) کل توان ارسالی نسبت به مساحت (D)، نشان داده شده است. در اینجا، ما RA مبتنی بر DNN ایده‌آل و بدون در نظر گرفتن نقیصه‌های سخت‌افزاری را بررسی می‌کنیم با اهداف به حداکثر رساندن SE، به حداکثر رساندن EE و به حداقل رساندن توان ارسال کل. علاوه بر این، ما همچنین SE را با  $Q=5$ ، DNN با SL را با [۸]، و نیز توان ارسالی به صورت تصادفی را جهت مقایسه بررسی می‌کنیم. فرض می‌کنیم  $N=K=3$  می‌باشد.




شکل (۶-ا): راندمان طیفی نسبت به مساحت (D)




شکل (۶-ب): بهره‌وری انرژی نسبت به مساحت (D)


حالت ایده آل می باشد (یعنی  $k=0$ ) با افزایش مساحت، SE و EE و توان ارسالی افزایش می یابد. اما با افزایش سطح نقیصه ها از  $k=0.05$  تا  $k=0.1$  مقادیر SE و EE و توان ارسالی، نسبت به حالت ایده آل کاهش می یابد. در این قسمت، مسئله را از نگاه شبیه سازی در نظر گرفتیم که با مطالعات گذشته [۳]، در رابطه با تاثیر نقیصه های سخت افزاری منطبق می باشد.



شکل ۸(a): کارایی طیفی نسبت به مساحت (D)




شکل ۸(b): بهره‌وری انرژی نسبت به مساحت (D)



شکل ۸(c): کل توان انتقالی نسبت به مساحت (D)


#### ۷-۴- نتایج هنگام استفاده از DAE

در این قسمت، نتایج شبیه سازی هنگام استفاده از DAE را بررسی می کنیم. در ساختار شبکه DAE، دولایه برای اینکدر و سه لایه برای دیکدر استفاده کرده ایم. نتایج به دست آمده به ازای تعداد کاربر و تعداد کانال برابر با 3 و سطح نقیصه های سخت افزاری  $k=0.05$  می باشد.



شکل ۶(c): کل توان انتقالی نسبت به مساحت (D)

همان طور که نتایج شبیه سازی نشان می دهد RA مبتنی بر DNN عملکردی نزدیک به بهینه دارد. برای مثال، ۹۶.۶ درصد از SE را در همه موارد به دست می آورد. همچنین می توان مشاهده کرد که SE و EE هر دو با افزایش مساحت افزایش می یابند؛ زیرا DUE ها پراکنده تر می شوند که این خود منجر به کاهش تداخل بین DUE ها می شود. این نتایج شبیه سازی کاربرد و مزایای RA مبتنی بر DNN را تأیید می کند، که ناشی از زمان محاسبات بسیار کمتر آن نسبت به طرح بهینه است. به طور خاص، RA مبتنی بر DNN برای بیشینه سازی SE بالاترین SE را نشان می دهد، RA مبتنی بر DNN برای بیشینه سازی EE بالاترین EE را نشان می دهد، و RA مبتنی بر DNN برای کمینه سازی توان ارسال، کمترین توان ارسال کل را نشان می دهد.



شکل ۷: نتایج به دست آمده نسبت به افزایش تعداد کاربران

در شکل ۷) نتایج به دست آمده نسبت به افزایش تعداد کاربران، یعنی  $N$  نشان داده شده است. علاوه بر این، همان طور که از نتایج شبیه سازی مشاهده می شود، میانگین SE و EE با افزایش تعداد DUE ها کاهش می یابد. زیرا تداخل بیشتری در بین DUE ها ایجاد می شود. علاوه بر این، دریافتیم که کل توان ارسال DNN با بیشینه سازی SE و بیشینه سازی EE با افزایش تعداد DUE کاهش می یابد.

#### ۷-۳- نتایج برای سیستم غیر ایده آل

در شکل ۸(a) تا شکل ۸(c)، سطح نقیصه ها از  $k=0$  تا  $k=0.1$  مقایسه شده است. همان طور که مشاهده می شود زمانی که سیستم در

مبتنی بر اولویت کیفیت سرویس برای سرویس‌های حساس به تأخیر در نظر گرفته شود.


**۳. ادغام هوش لبه و یادگیری فدرال:** حجم داده‌های 6G عظیم و انتقال همه داده‌ها به ابر غیرعملی است. پیشنهاد می‌شود که آموزش مدل DNN به صورت یادگیری فدرال<sup>۲۲</sup> روی گره‌های لبه صورت گیرد تا ضمن حفظ حریم خصوصی، کاهش بار بک‌هاول داشته باشیم. همچنین قابلیت یادگیری آنلاین اضافه گردد تا شبکه پویایی‌اش را با تغییرات محیط حفظ کند.

**۴. احتساب شبکه‌های بازپیکربندی‌شونده:** در 6G به شدت از RIS برای شکل‌دهی کانال استفاده می‌شود. لذا پیشنهاد می‌شود ماتریس فاز RIS به ورودی شبکه اضافه شود تا یادگیری هم‌زمان تنظیم فاز RIS و تخصیص توان حاصل گردد.

**۵. پشتیبانی از ارتباطات حسی-ادراکی<sup>۲۳</sup>:** شبکه 6G داده را فقط انتقال نمی‌دهد، بلکه معنای داده را نیز منتقل کرده و حس‌گرها را یکپارچه می‌کند. پیشنهاد می‌شود لایه‌ای در تابع هدف افزوده شود که داده‌ها را بر اساس ارزش معنایی اولویت دهد.

## مراجع

- [1] M. A. Kamal, and A. Sajak, "Resource allocation schemes for 5G network: A systematic review," *sensors*, vol. 19, no. 21, pp. 65-88, Oct. 2021.
- [2] W. Lee, O. Jo and M. Kim, "Intelligent resource allocation in wireless communications Systems," *IEEE Communications Magazine*, vol. 58, no. 1, pp. 100-105, Jan. 2020.
- [3] V. Shahiri, M. Forouzesh, H. Behroozi, A. Kuhestani and K. -K. Wong, "Deep learning aided secure transmission in wirelessly powered untrusted relaying in the face of hardware impairments," *IEEE Open Journal of the Communications Society*, vol. 5, pp. 2196-2210, Aug. 2024 .
- [4] L. Andrej Karpathy, "Deep visual-semantic alignments for generating image descriptions," in *Proc. IEEE CVPR*, June 2015.
- [5] Y. LeCun, "Deep learning nature," *Nature*, vol. 531, May 2015.
- [6] W. -H. Lee, M. Ozger, U. Challita and K. W. Sung, "Noise learning-based denoising autoencoder," *IEEE Communications Letters*, vol. 25, no. 9, pp. 2983-2987, Sept. 2021.
- [7] W. Lee, M. Kim and D. -H. Cho, "Deep power control: transmit power control scheme based on convolutional neural network," *IEEE Communications Letters*, vol. 22, no. 6, pp. 1276-1279, June 2018.
- [8] H. Sun, X. Chen, Q. Shi, M. Hong, X. Fu and N. D. Sidiropoulos, "Learning to optimize: training deep neural networks for interference management," *IEEE Transactions on Signal Processing*, vol. 66, no. 20, pp. 5438-5453, Oct. 2018.
- [9] I. A. Bartsiokas, P. K. Gkonis, D. I. Kaklamani and I. S. Venieris, "ML-based radio resource



شکل (۹): نتایج RA هنگام استفاده از DAE

در شکل (۹) مقایسه‌ای بین نتایج به دست آمده برای RA، هنگامی که سیستم ایده‌آل می‌باشد و هنگامی سیستم غیر ایده‌آل در نظر گرفته شده است، انجام داده‌ایم. با توجه به نتایج به دست آمده مشاهده می‌شود، هنگام غیر ایده‌آل بودن سیستم، با استفاده از DAE توانستیم نویز اضافه شده در دیتای ورودی DNN را حذف کنیم و به نتایج نزدیک به سیستم ایده‌آل و بدون نویز دست یابیم.

## ۸- نتیجه‌گیری

در این پژوهش، از DL به منظور تخصیص منابع در یک شبکه سلولی و در حضور جفت‌های D2D بهره برده‌ایم. تخصیص منابع با اهداف بیشینه‌سازی بهره‌وری طیفی، بیشینه‌سازی کارایی انرژی و کمینه‌سازی توان ارسالی با در نظر گرفتن محدودیت‌های تداخل، QoS و حداقل توان ارسالی انجام شد. متفاوت با کارهای پیشین، نقیصه‌های سخت‌افزاری در مدل سیستم لحاظ شده است تا به مدل واقعی در عملی نزدیک‌تر شود. برخلاف طرح‌های قبلی از شبکه DAE برای تخفیف خطاهای موجود در داده‌های ورودی شبکه DNN به علت خطا در تخمین اطلاعات کانال استفاده کردیم. در ارزیابی عملکرد تأیید شد که RA مبتنی بر DNN پیشنهادی، ضمن حذف خطاهای کانال به اهداف مختلف RA دست می‌یابد.

برای کارهای آینده و در راستای نسل آینده شبکه موبایل 6G، برخی ایده‌های کلیدی به شرح زیر است [۲۰]، [۲۱]:

**۱. افزودن بُعد فوق‌طیفی و فرکانس‌های تراهرتز:** 6G به باندهای بالاتر (mmWave پیشرفته و THz) و طیف‌های وسیع‌تر می‌رود. لذا در مدل سیستم، پارامترهای کانال برای THz و mmWave (شامل تلف مسیر شدید، نفوذ پایین و شکل‌دهی پرتوی باریک) اضافه می‌شود. در این حالت، Tnet/Pnet توان و نیز پرتودهی مشترکاً تخصیص داده می‌شود و نه فقط توان اسکالر.

**۲. پشتیبانی از ارتباطات فوق‌انبوه و فوق‌کم‌تأخیر:** 6G باید قابلیت اطمینان بسیار بالا به همراه تأخیر بسیار ناچیز و نیز اتصال میلیون‌ها دستگاه در هر  $\text{km}^2$  را پشتیبانی کند. پیشنهاد می‌شود مازول پیش‌بینی ترافیک کوتاه‌مدت (Short-term Traffic Prediction) با LSTM یا Transformer اضافه شود و نیز یک لایه تصمیم‌گیری

## زیر نویس ها

- <sup>1</sup> Fifth-generation
- <sup>2</sup> Quality-of-service
- <sup>3</sup> Resource Allocation
- <sup>4</sup> Wireless communications systems
- <sup>5</sup> Deep learning
- <sup>6</sup> Deep neural networks
- <sup>v</sup> Denoising Autoencoder
- <sup>^</sup> Weighted minimum mean square
- <sup>9</sup> Spectral efficiency
- <sup>10</sup> Energy efficiency
- <sup>11</sup> Machine learning
- <sup>12</sup> Long Short Term Memory
- <sup>13</sup> Reconfigurable intelligent surface
- <sup>14</sup> Alternating optimizations
- <sup>15</sup> Device to Device
- <sup>16</sup> Base station
- <sup>17</sup> D2D user equipments
- <sup>18</sup> Cellular user equipment
- <sup>19</sup> Total transmit power network
- <sup>20</sup> Power allocation network
- <sup>21</sup> Fully connected
- <sup>22</sup> Federated learning
- <sup>23</sup> Semantic and Sensing Communication

- management in 5G and beyond networks: a survey," IEEE Access, vol. 10, pp. 83507-83528, Jan. 2022.
- [10] H. Hui, "Intelligent resource allocation method for wireless communication networks based on deep learning techniques," Journal of Sensors, p. 12, Oct. 2021.
- [11] M. Samaneh Bidabadi, "Energy efficient resource allocation for re-configurable intelligent surface-assisted wireless networks," Wireless Communications and Networking, May 2023.
- [12] N. Ejaz, "A comprehensive survey on resource allocation for CRAN in 5G and beyond networks.," J. Netw. Comput, Apr. 2020.
- [13] X. Wei, "5G Mobile Communications," Springer: Cham, Switzerland, 2017.
- [14] L. Nguyen, "Resource allocation for energy efficiency in 5G wireless networks.," EAI Endorsed Trans. Ind. Netw. Intell. Syst. May 2018.
- [15] T. M. Shah, "Resource allocation in SDN based 5G cellular networks.," Peer-to-Peer Netw, Feb. 2019.
- [16] ] O. Saraereh, "An Efficient Resource Allocation Algorithm for OFDM-Based NOMA in 5G Systems," Engineering, Computer Science, Nov. 2019.
- [17] B. Pavan Kumar Mishra, "Device-centric resource allocation scheme for 5G networks," Physical Communication, pp. 175-184, Feb. 2018.
- [18] G. D. Swetha and G. R. Murthy, "Fair resource allocation for D2D communication in mmwave 5G networks," 2017 16th Annual Mediterranean Ad Hoc Networking Workshop (Med-Hoc-Net), Budva, Montenegro, 2017, pp. 1-6.
- [19] H. Heyveh Alghibi, A. Kouhestani, H. Ahmadi, and M. Eslami, "Resource Allocation in Wireless Communication Systems Using Deep Learning," in Proc. International Conference on Novel Achievements in Information Technology, Computer Science, Security, Networks and Artificial Intelligence, Mashhad, Iran, 2023.
- [20] R. Sun et al., "A comprehensive survey of knowledge-driven deep learning for intelligent wireless network optimization in 6G," IEEE Communications Surveys & Tutorials, May 2025.
- [21] H. Ahmadi, A. Kuhestani, M. R. Keshavarzi, L. Mesin, "Semantic-aware doppler shift estimation for low earth orbit satellite communications" Authorea Preprints, Aug. 2025.
- [22] Mobini Z, dezfoolizade S. Improving Security in Cooperative Communication Networks by Using UAV-assisted Proactive Eavesdropping. Journal of Iranian Association of Electrical and Electronics Engineers 2021; 18 (3) :143-151
- [23] Ragheb M, Kuhestani A, Safavi Hemami S M. Joint Beamforming and Artificial Noise Design in Secure Millimeter-wave Communications with the Aid of Intelligent Reflecting Surfaces. Journal of Iranian Association of Electrical and Electronics Engineers 2022; 19 (3) :55-62