



AoI-Aware Optimization of Sub-Flow Scheduling for Multi-Path Transport Layer in Dual-Connectivity-Based Cellular Networks

¹ Seyyed Hamidreza Miryeganeh Langeroudi, ¹ Marzieh Sheikhi, ² Vesal Hakami*

¹ PhD Student, School of Computer Engineering, Iran University of Science and Technology, Tehran, Iran.
h_miryeganeh@comp.iust.ac.ir, marzieh_sheikhi@comp.iust.ac.ir

² Assistant Professor, School of Computer Engineering, Iran University of Science and Technology, Tehran, Iran.
vhakami@iust.ac.ir

Abstract

Emerging applications (e.g., Internet of Things) in new generation wireless networks have strict information freshness requirements. Recently, age of information (AoI) has been introduced as a new QoS metric which differs from conventional measures such as delay and throughput. AoI is defined as the elapsed time since the generation of the last received packet in the destination. Optimal configuration of the transport and physical layer protocols is key to AoI minimization. In this paper, we study the problem of scheduling multi-path TCP (MPTCP) sub-flows over a dual-connectivity-based physical transmission medium based on LTE and mmWave technologies. The synergy of a multi-path transport layer and a multi-connectivity-based physical layer gives rise to an efficient communication setup for AoI minimization. In order to optimize the scheduling of traffic sub-flows over the two available paths, we propose a model-free optimization algorithm using reinforcement learning. We aim at minimizing the long-run mean AoI for the data packets received by the destination. Simulation results showcase the superiority of the proposed algorithm in comparison with the default MPTCP scheduling algorithms, i.e., round-robin and lowest RTT.

Keywords: Traffic Scheduling, Internet of Things, Multi-Path Transport Layer, Dual-Connectivity, Age of Information, Reinforcement Learning.

بهینه‌سازی زمان‌بندی بار ترافیکی زیر-جریان‌های لایه حمل چندمسیری با آگاهی از دیرینگی اطلاعات در شبکه‌های سلولی مبتنی بر اتصال دوگانه

سید حمیدرضا میریگانه لنگرودی^۱، مرضیه شیخی^۱، وصال حکمی^{۲*}

^۱ دانشجوی دکتری، دانشکده مهندسی کامپیوتر، دانشگاه علم و صنعت ایران، تهران، ایران

h_miryeganeh@comp.iust.ac.ir, marzieh_sheikhi@comp.iust.ac.ir

^۲ استادیار گروه شبکه‌های کامپیوتری، دانشکده مهندسی کامپیوتر، دانشگاه علم و صنعت ایران، تهران، ایران

vhakami@iust.ac.ir

چکیده

در کاربردهای نوظهور بر بستر نسل جدید شبکه‌های بی‌سیم به ویژه در اینترنت اشیا، محدودیت‌های سخت‌گیرانه‌ای جهت تضمین تازگی اطلاعات وجود دارد. در همین راستا، اخیراً معیار جدیدی برای سنجش کیفیت سرویس شبکه به نام «دیرینگی اطلاعات» (AoI) مطرح شده که با معیارهای مرسوم مانند تاخیر و گذردهی متفاوت است و به عنوان زمان سپری شده از تولید آخرین بسته موفق دریافت شده در مقصد تعریف می‌شود. تضمین مقادیر پایین برای دیرینگی اطلاعات مستلزم پیگیری بهینه پروتکل‌های جدید انتقال اطلاعات در دو سطح لایه حمل و فیزیکی شبکه است. در این مقاله، ما مسأله زمان‌بندی بار ترافیکی پروتکل TCP چندمسیری (MPTCP) را بر بستر اتصال دوگانه فیزیکی مبتنی بر فناوری‌های LTE و mmWave مورد مطالعه قرار می‌دهیم. هم‌افزایی لایه حمل چندمسیری با لایه انتقال فیزیکی چندانکه، بستر ارتباطی کارآمدی را برای کاهش دیرینگی اطلاعات فراهم می‌نماید. برای بهینه‌سازی زمان‌بندی زیرجریان‌های ترافیکی روی دو مسیر ارتباطی، ما یک الگوریتم بهینه‌سازی فارغ از مدل مبتنی بر یادگیری تقویتی را پیشنهاد می‌کنیم که هدف آن دستیابی به یک سیاست بهینه است که میانگین بلندمدت AoI بسته‌های داده را در مقصد به حداقل برساند. نتایج شبیه‌سازی بیانگر برتری کارایی الگوریتم پیشنهادی نسبت به دو الگوریتم پیش‌فرض نوبت گردشی و کمترین میزان تاخیر رفت‌و برگشت می‌باشد.

کلمات کلیدی

زمان‌بندی بار ترافیکی، اینترنت اشیا، لایه حمل چندمسیری، اتصال دوگانه، دیرینگی اطلاعات، یادگیری تقویتی.

۱- مقدمه

اولین بار در نسخه ۱۲ پروژه مشارکت نسل سوم (3GPP)^۱ منتشر شد که هدف آن متصل کردن دستگاه به طور هم‌زمان به یک ایستگاه پایه ماکرو^۲ و کوچک^۳ می‌باشد. با استفاده از رویکرد اتصال دوگانه و اتصال هم‌زمان به ایستگاه‌های نسل چهارم^۴ (eNB) و پنجم^۵ (gNB) شبکه‌های تلفن همراه می‌توان از مسدود شدن کامل ارتباطات جلوگیری کرد. از این‌رو در چند سال اخیر مفهوم اتصال دوگانه توجه بسیاری از محققان را به خود جلب کرده است [1-3].

Wang و همکارانش در [4] یک الگوریتم کنترل جریان را بر اساس وضعیت پیوندها و تاخیر پیشنهاد می‌کنند. این مسأله به عنوان یک فرآیند تصمیم‌گیری مارکوف زمان گسسته مدل شده است و از الگوریتم برنامه‌نویسی پویا برای به دست آوردن راه حل بهینه استفاده می‌کند. Zaho و همکارانش در [5] به بررسی راه‌حل‌های یادگیری ماشین برای بهبود تصمیم‌گیری ارسال تکراری بسته‌ها و بهینه‌سازی تاخیر در یک شبکه سلولی 5G با اتصال

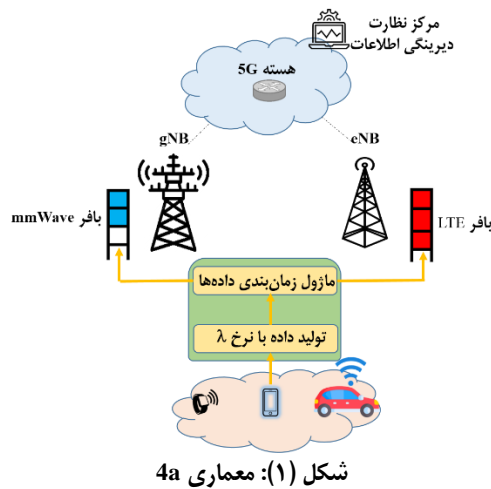
یکی از اهداف اصلی شبکه‌های تلفن همراه در نسل پنجم^۱، ارائه راه‌کاری برای مدیریت تعداد روز افزون کاربران و برآورده‌سازی الزاماتی مانند کاهش تاخیر، افزایش نرخ ارسال، ارتباط قابل اطمینان و دسترس‌پذیر بوده است که در کاربردهایی مانند حمل‌ونقل هوشمند، اینترنت اشیا، صنعتی، واقعیت افزوده، سلامت الکترونیک و سایر خدمات مبتنی بر شبکه‌های آینده مورد استفاده قرار می‌گیرد. ارتباطات امواج میلی‌متری^۲ به دلیل داشتن پتانسیل گردهمی چندگویی، یک فناوری امیدوارکننده برای شبکه‌های 5G به شمار می‌رود. با این حال این نوع از ارتباطات دارای دو مشکل اتلاف مسیر بالا و احتمال مسدود شدن در اثر برخورد با موانع هستند. با توجه به ایده استفاده از شبکه‌های ناهمگن با فناوری‌های رادیویی متفاوت در شبکه‌های 5G، مفهوم جدیدی به نام اتصال دوگانه^۳ بوجود آمد که برای

تصمیم‌گیری از هم جدا در نظر گرفته شده‌اند تا اطمینان حاصل شود که فرآیند یادگیری باعث ایجاد تاخیر و هزینه اضافی در تصمیم‌گیری نمی‌شود. در کاربردهای تعریف شده در شبکه‌های 5G و به ویژه در اینترنت اشیا، تنها در نظر داشتن تاخیر پایین و گذردهی بالا، کافی نیست. زیرا در بعضی از کاربردها به ویژه کاربردهای بلادرنگ و حساس به زمان، تازگی اطلاعات اهمیت بسیاری دارد. به همین منظور برای سنجش تازگی داده‌ها، از معیار جدیدی به نام دیرینگی اطلاعات (AoI) استفاده می‌شود که به عنوان زمان سپری شده از تولید آخرین بسته‌ی موفق دریافت شده در مقصد تعریف می‌شود و با معیارهای مرسوم کارایی مانند تاخیر و گذردهی متفاوت است. به طور مثال، در سیستم‌های صف‌بندی، به‌روزرسانی به موقع اطلاعات مبدا در مقصد لزوماً به معنای بیشینه‌سازی بهره‌وری شبکه یا حتی تضمین دریافت پیام‌ها با حداقل تاخیر نیست. در واقع، با وجود این که ارسال اطلاعات با نرخ بالا موجب بالا رفتن بهره‌وری سیستم می‌گردد، اما این استراتژی به علت انباشتن این اطلاعات در صف شبکه واسط، موجب می‌شود بسته‌ها با تاخیر در مقصد دریافت شوند. در چنین شرایطی، کاهش نرخ به‌روزرسانی به عنوان یک راه‌حل می‌تواند سبب بهبود دریافت به موقع اطلاعات جدید و به‌روز در گیرنده شود. اما از طرفی دیگر، جلوگیری از به‌روزرسانی موجب می‌گردد که گیرنده به علت عدم دریافت وضعیت به‌روز از مبدا، اطلاعات منسوخ داشته باشد و در صورت نیاز به کنترل تصمیم نادرستی را اتخاذ کند [15, 22].

در این مقاله ما از معماری 4a به کار رفته در [16] برای برقراری یک اتصال دوگانه استفاده کرده‌ایم که هسته آن را شبکه 5G تشکیل می‌دهد. این اتصال دوگانه بر روی دو پیوند LTE و mmWave، مبتنی بر پروتکل MPTCP شبیه‌سازی شده است که در آن ماژول زمان‌بندی باید تصمیم بگیرد که داده تولید شده را در کدام یک از صف‌های ارسال قرار دهد تا متوسط AoI به کمترین میزان خود برسد. از آنجا که شرایط کانال متغیر است و ما هیچ‌گونه اطلاعاتی از شرایط کانال و تغییرات آن نداریم، از یک راه‌کار فارغ از مدل مبتنی بر یادگیری تقویتی برای محاسبه سیاست بهینه جهت کمینه‌سازی متوسط AoI در بلندمدت استفاده می‌کنیم. همچنین مدل مسئله به کار رفته در این مقاله، به فناوری مورد استفاده در اتصالات وابسته نمی‌باشد. چون از دیدگاه لایه انتقال به مسئله نگاه می‌کنیم، فارغ از این که از چه فناوری‌ای برای ارسال داده استفاده شده است. مانند: Bluetooth, WiFi, LTE, mmWave و غیره، می‌توانیم الگوریتم مورد نظر خود را بدون وابستگی به لایه‌های دیگر به کار ببریم. این درحالی است که در کارهای پیشین اولاً زمان‌بندی MPTCP با محوریت AoI نبوده است و ثانیاً معماری اتصال دوگانه آن‌ها از نوع 4a نمی‌باشد. مشخصاً تنها کار پیشین که اتصال دوگانه LTE-mmWave را مبنا قرار داده است مرجع [23] می‌باشد که در آن برخلاف مدل ما هسته شبکه 4G در نظر گرفته شده است. تاکید روش [23] روی کنترل اندازه پنجره ازدحام زیر-جریان‌ها است در حالی که روش پیشنهادی ما انتخاب مسیر را مبنا قرار می‌دهد. همچنین در [23] یک الگوریتم برون خط برای زمان‌بندی پیشنهاد شده است که برای اجرا در محیط عملیاتی واقع‌بینانه نیست.

چندگانه پرداخته‌اند. در [5] طرح یادگیری تقویتی عمیق چندعاملی با مدل متوالی عملگر-تقاد برای بهبود تصمیم‌گیری در مورد ارسال تکراری بسته‌ها، با استفاده از مشاهدات محیط رادیویی مانند وضعیت کانال، ازدحام و بار ترافیکی ایجاد شده است. Pan و همکارانش در [6] یک طرح زمان‌بندی ترافیک برای پیوند فرسوسو برای ایستگاه پایه ماکرو پیشنهاد می‌کنند تا نرخ ارسال تقسیم بار ترافیکی به ایستگاه پایه کوچک تنظیم شود. در این کار، تابع هدف برابر با بیشینه‌سازی مقدار گذردهی، مقید به رعایت حد آستانه‌ای در نرخ ارسال است. این الگوریتم در ایستگاه پایه ماکرو برای هر کاربر، می‌تواند میانگین کیفیت کانال را محاسبه کند.

از سوی دیگر، با وجود واسط‌های مختلف در دستگاه‌ها مانند: WiFi, Bluetooth و فناوری‌های دسترسی سلولی در نسل‌های مختلف، پروتکل کنترل لایه حمل چندمسیری مطرح شد که نسخه توسعه‌یافته پروتکل TCP می‌باشد و اطلاعات را از چندین زیر-جریان به سمت گیرنده منتقل می‌کند [7, 8]. در MPTCP مشکلات رایج TCP مانند میسر نبودن تعویض زیر-جریان، عدم امکان توازن بار ترافیکی، داشتن اتصال واحد، دریافت خارج از ترتیب، انتظار برای رسیدن بسته‌های باقی‌مانده و غیره وجود ندارد [9]. به همین منظور، Zhang و همکارانش در [10] یک زمان‌بندی مبتنی بر یادگیری تقویتی برای MPTCP پیشنهاد می‌کنند. تابع پاداش به کار رفته در این پژوهش، گذردهی، تاخیر و اتلاف بسته را در زمان‌بندی در نظر می‌گیرد. همچنین، برای سرعت بخشیدن به فرآیند آموزش، یک الگوریتم یادگیری تقویتی عمیق ناهمگام را معرفی کرده‌اند که جمع‌آوری داده‌ها و آموزش مدل را جدا می‌کند تا امکان اجرای موازی زمان‌بندی بسته‌ها، جمع‌آوری داده‌ها و شبکه عصبی فراهم شود. Lee و همکارانش در [23] مسأله کنترل ازدحام MPTCP را بر بستر LTE-mmWave مورد بررسی قرار داده‌اند. Park و همکارانش در [11] با در نظر گرفتن MPTCP در شبکه‌های بی‌سیم ناهمگام WiFi و LTE، به مسأله کمینه‌سازی هزینه پرداختی کاربر به ازای دریافت اطلاعات با نرخ واحد، مقید به برآورده‌سازی تاخیر انتها به انتها را فرموله می‌کنند. Bai و همکارانش در [12] الگوریتم حریصانه‌ای پیشنهاد می‌کنند که در هر شکاف زمانی، ایستگاه با کم‌ترین میزان تاخیر را انتخاب می‌کند. در این الگوریتم تأثیر تاخیر صف لحاظ نشده است و فقط تاخیر لحظه‌ای ارسال، مبنای تصمیم‌گیری قرار داده شده است. همچنین، این الگوریتم نسبت به فرآیند ورود بسته‌ها و وضعیت پیوند mmWave هم سازگار نیست. Luo و همکارانش در [13] از یادگیری تقویتی برای زمان‌بندی و انتخاب مسیر استفاده می‌کنند و با انتخاب مسیر با پاداش بهتر، یک سیاست زمان‌بندی داده بهینه را بدست می‌آورند. راهکار پیشنهادی به این صورت است که با دریافت ACK از مسیر انتخاب‌شده، یک واحد به پاداش اضافه می‌شود و در صورت عدم دریافت ACK (به دلیل گم شدن ACK یا تمام شدن مهلت ارسال) یک واحد جریمه دریافت خواهد شد. Dong و همکارانش در [14] یک الگوریتم زمان‌بندی چندمسیری مبتنی بر یادگیری تقویتی برای تعیین مسیر بهینه برای زیر-جریان‌های مختلف پیشنهاد می‌کنند. در این الگوریتم فرآیندهای آموزش و



شکل (۱): معماری 4a

$$R_t^S = B_{LTE} * \log_2 \left(1 + \frac{g_{LTE}^t * P_{LTE}}{N_{0LTE}} \right) \quad (2)$$

۲-۱-۲- مدل کانال mmWave

در مدل سازی کانال mmWave، به علت اثر انسداد، سه حالت ممکن است رخ دهد: ۱- ایستگاه می تواند در مسیر دید دستگاه قرار داشته باشد که به آن حالت دید مستقیم (LoS) می گوئیم. ۲- دستگاه در مسیر دید ایستگاه نباشد که به آن حالت دید غیرمستقیم (NLoS) گفته می شود. ۳- پیوند بین ایستگاه و دستگاه به طور کامل قطع باشد (Outage). بنابراین وضعیت کانال به صورت طولانی مدت، به عنوان یک زنجیره مارکوف با تعداد وضعیت متناهی مدل شده است که وضعیت های آن از مجموعه $y_t \in Y = \{0(LoS), 1(NLoS), 2(Outage)\}$ مقدار می گیرد. وضعیت های این مدل بر اساس احتمال تعریف شده در ماتریس P_y در طول زمان تغییر می کند که در فرمول (۳) قابل مشاهده است [17]:

$$P_y = \begin{bmatrix} P_{LoS|LoS} & P_{LoS|NLoS} & P_{LoS|Out} \\ P_{NLoS|LoS} & P_{NLoS|NLoS} & P_{NLoS|Out} \\ P_{Out|LoS} & P_{Out|NLoS} & P_{Out|Out} \end{bmatrix} \quad (3)$$

همچنین مقدار افت مسیر از gNB تا دستگاه با فاصله d_{mmWave} از فرمول (۴) بدست می آید:

$$PL(d_{mmWave}) = \begin{cases} (1 - y_t) Q_L d_{mmWave}^{-\alpha_L} + y_t Q_N d_{mmWave}^{-\alpha_N} & y_t = 0 \text{ or } 1 \\ \infty & y_t = 2 \end{cases} \quad (4)$$

که Q_L و Q_N ثابت های وابسته به فرکانس حامل، α_L و α_N ضرایب افت مسیر در وضعیت های LoS و NLoS و d_{mmWave} فاصله کاربر از ایستگاه mmWave می باشد. قدرت توان دریافتی در گیرنده از رابطه (۵) بدست می آید که در آن بهره محوشدگی مقیاس کوچک، G_s^{max} بهره گوشه اصلی^{۱۲} دستگاه، G_b^{max} بهره گوشه اصلی gNB و P_{mmWave} توان

در ادامه، این مقاله به شرح زیر سازماندهی شده است: در بخش ۲ مدل سیستم و مفروضات معرفی شده اند. در بخش ۳ فرمول بندی مسأله در قالب یک مسأله بهینه سازی تصادفی بیان می شود. در بخش ۴ راه حلی مبتنی بر یادگیری تقویتی برای کمینه سازی میانگین بلندمدت AoI بسته های وضعیت در مقصد ارائه شده است که در بخش ۵ به بررسی و ارزیابی عملکرد راه حل پیشنهادی می پردازیم. در انتها، در بخش ۶ به نتیجه گیری از این مقاله اشاره خواهد شد.

۲- مدل سیستم و مفروضات

همان طور که در شکل (۱) مشاهده می شود از معماری 4a برای برقراری اتصال دوگانه در این مقاله استفاده شده است. در این معماری، یک اتصال به ایستگاه پایه ماکرو یا همان gNB و یک اتصال به ایستگاه کوچک یا eNB داریم که ایستگاه پایه ماکرو و هسته شبکه مربوط به شبکه 5G و ایستگاه پایه کوچک مربوط شبکه 4G می باشد. فضای حالت به کار رفته در این مسأله گسسته بوده و فرآیند تولید بسته به طور تصادفی صورت می گیرد که بعد از تولید بسته ها، ماژول زمان بندی داده ها تعیین می کند که بسته ها در کدام یک از دو صف کانال LTE و یا mmWave قرار بگیرند. بسته به ظرفیت کانال، نرخ خروج داده در هر شکاف زمانی متفاوت است و نرخ خروج ثابت نداریم.

۲-۱-۲- مدل کانال بی سیم

در ادامه، به نحوه چگونگی مدل کردن دو کانال LTE و mmWave خواهیم پرداخت.

۲-۱-۱-۲- مدل کانال LTE

کیفیت کانال LTE تحت تاثیر عوامل مختلف مانند: نویز، ائتلاف مسیر، محوشدگی، سایه شدگی و غیره متغیر است. از این رو برای در نظر گرفتن کیفیت متغیر کانال، فرض می کنیم که کیفیت آن در طول یک شکاف زمانی ثابت است؛ اما در بین شکاف ها امکان تغییر وجود دارد. بهره کانال بین دستگاه و ایستگاه ها به صورت فرمول (۱) بیان می شود که در آن h_t بیانگر ضریب کانال بین دستگاه و eNB بوده و متغیر d_{LTE} فاصله بین آن ها را نشان می دهد؛ همچنین α_{LTE} ضریب افت مسیر را مشخص می کند:

$$g_t^{LTE} = |h_t|^2 \times d_{LTE}^{-\alpha_{LTE}} \quad (1)$$

طبق فرمول (۱) بهره کانال از دو بخش قطعی (d_{LTE}) و غیرقطعی (h_t) تشکیل شده که یک متغیر تصادفی مستقل است که بر اساس پارامترهای کانال مانند محوشدگی تعیین می شود. طبق رابطه شانون، نرخ خروجی از صف LTE طبق فرمول (۲) قابل محاسبه است که در آن B_{LTE} بیانگر پهنای باند، P_{LTE} توان ارسال به ایستگاه و N_0^{LTE} نویز اضافی در کانال LTE می باشند:

نظارت باشد، AoI دستگاه در مرکز نظارت به عنوان یک فرآیند تصادفی به صورت فرمول (۱۱) تعریف می‌شود:

$$\varphi_t = t - u_t \quad (11)$$

نماد φ_t بیانگر میزان AoI در ابتدای قطعه زمانی t است که از مجموعه $\varphi \in \varphi = \{1, 2, \dots, \varphi_{max}\}$ مقدار می‌گیرد. حداکثر مقداری که AoI دستگاه می‌تواند بگیرد برابر با φ_{max} بوده و بنابراین، در طول زمان بر اساس فرمول (۱۲) به روزرسانی می‌شود:

$$\varphi_{t+1} = \min(t - u_t, \varphi_{max}) \quad (12)$$

نمادهای مهم مربوط به مدل سیستم در جدول (۱) قابل مشاهده است.

۳- فرمول‌بندی مسأله

در این قسمت ابتدا مسأله به فرم یک فرآیند تصمیم‌گیری مارکوف مدل گردیده و در ادامه معادلات بلمن مرتبط با بیان می‌شود.

۳-۱- مدل‌سازی مارکوف

از آنجایی که ترافیک تولیدی و همچنین AoI دارای ماهیت تصادفی هستند، ناگزیر هستیم که از یک روش بهینه‌سازی تصادفی با قابلیت تطبیق‌پذیری نسبت به وضعیت تصادفی سیستم ارائه دهیم. با توجه به مارکوفی بودن فرآیند تغییرات وضعیت سیستم، استفاده از فرآیند تصمیم‌گیری مارکوف گزینه مناسبی است. در این صورت مسأله به صورت چندتایی (φ, A, P, C) مدل می‌گردد که شامل فضای وضعیت، مجموعه اعمال کنترلی، احتمال گذار و تابع هزینه است. هر یک از عناصر این چندتایی به صورت زیر تعریف می‌شوند:

- **فضای وضعیت (φ) :** فضای وضعیت ما از فضای وضعیت AoI (φ) تشکیل می‌شود.

جدول (۱): نمادهای استفاده‌شده در مدل سیستم

نماد	توضیح	نماد	توضیح
g_t^{LTE}	بهره کانال LTE	I_t^S, I_t^M	تعداد بسته‌های ورودی به صف LTE و mmWave
B_{LTE}, B_{mmWave}	پهنای باند کانال LTE و mmWave	G_s^{max}, G_b^{max}	بهره گوشه اصلی دستگاه و gNB
R_t^S, R_t^M	نرخ خروجی از صف mmWave و LTE	O_t^S, O_t^M	تعداد بسته‌های خروجی صف LTE و mmWave
W_{t+1}^S, W_{t+1}^M	اندازه طول صف mmWave و LTE	φ_t	مقدار AoI
N_0^{LTE}, N_0^{mmWave}	نویز اضافی کانال mmWave و LTE	d_{LTE}, d_{mmWave}	فاصله بین دستگاه تا ایستگاه‌های پایه
Q_L, Q_N	ثابت‌های وابسته به فرکانس حامل	α_L, α_N	ضرایب افت مسیر در NLoS و LoS

ارسالی می‌باشد. بنابراین، توان دریافتی در gNB از فرمول (۵) محاسبه می‌گردد:

$$Z = |g_t^{mmWave}|^2 G_s^{max} G_b^{max} PL(d_{mmWave}) P_{mmWave} \quad (5)$$

همچنین، طبق رابطه شانون نرخ خروجی از صف mmWave از فرمول (۶) قابل محاسبه است که در آن B_{mmWave} بیانگر پهنای باند و N_0^{mmWave} نویز اضافی در کانال mmWave می‌باشند [18]:

$$R_t^M = B_{mmWave} * \log_2(1 + \frac{Z}{N_0^{mmWave}}) \quad (6)$$

۲-۲- مدل تولید ترافیک

تولید ترافیک در دستگاه از توزیع احتمال پواسون پیروی می‌کند و به صورت زمان گسسته با شکاف‌های زمانی مساوی به صورت $t = 0, 1, 2, \dots$ نمایه‌گذاری می‌شوند. به این معنا که در هر لحظه دسته‌ای از بسته تولید می‌شود و باید تصمیم بگیریم که این داده‌ها را در صف LTE یا mmWave قرار دهیم. یعنی بر اساس تصمیم اتخاذ شده، داده‌ها در یکی از این دو صف قرار می‌گیرند و طول صف در کانال LTE و mmWave به طور پویا تغییر خواهد کرد. همچنین، اگر K_n را تعداد بسته‌های تصادفی که در t امین شکاف زمانی از راه می‌رسند، در نظر بگیریم، این فرآیند ورود یک فرآیند توزیع پواسون با میانگین λ است. در شکاف‌های زمانی t اندازه طول صف LTE و mmWave از فرمول‌های (۷) و (۸) بدست می‌آیند:

$$W_{t+1}^M = I_t^M + W_t^M - O_t^M \quad (7)$$

$$W_{t+1}^S = I_t^S + W_t^S - O_t^S \quad (8)$$

که I_t^M بیانگر تعداد بسته‌های ورودی به صف mmWave، I_t^S بیانگر تعداد بسته‌های ورودی به صف LTE، W_t^M بیانگر تعداد بسته‌های موجود در صف mmWave، W_t^S بیانگر تعداد بسته‌های موجود در صف LTE، O_t^M بیانگر تعداد بسته‌های خروجی از صف mmWave و O_t^S بیانگر تعداد بسته‌های خروجی از صف LTE می‌باشد که از فرمول (۹) و (۱۰) بدست می‌آیند که L اندازه هر بسته و τ مدت زمان هر شکاف زمانی است:

$$O_t^M = \frac{R_n^M}{L} * \tau \quad (9)$$

$$O_t^S = \frac{R_n^S}{L} * \tau \quad (10)$$

۲-۳- مدل دیرینگی اطلاعات

برای سنجش تازگی داده‌ها در مرکز نظارت از معیار AoI استفاده شده است که به عنوان زمان گذشته از تولید آخرین بسته موفق دریافت شده در مقصد تعریف می‌شود. اگر u_t زمان تولید آخرین بسته موفق دریافت شده در مرکز

الگوریتم‌های یادگیری فارغ از مدل به کار می‌گیریم. بر طبق فرآیند تصادفی مارکوف تابع ارزش وضعیت-اقدام باید بر اساس معادلات بلمن مطابق با مسأله تعریف شود تا به سیاست بهینه دست یابیم. فرمول (۱۹) تابع ارزش وضعیت-اقدام مرتبط با فرمول (۱۸) را تعریف می‌کند:

$$Q^\pi(s, a) = [c(s, a) - \bar{c}^{\pi^*}] + \sum_{s' \in S} \mathbb{P}(s'|s, a) Q^\pi(s', a) \quad (19)$$

اگر دستگاه بر اساس سیاست بهینه π^* عمل خود را انتخاب کند، تابع ارزش وضعیت-اقدام بهینه به صورت فرمول (۲۰) بیان می‌شود:

$$Q^{\pi^*}(s, a) = [c(s, a) - \bar{c}^{\pi^*}] + \sum_{s' \in S} \mathbb{P}(s'|s, a) Q^{\pi^*}(s', a) \quad (20)$$

سیاست بهینه نیز از فرمول (۲۱) بدست می‌آید:

$$\pi^*(s) = \arg \min_{a \in A_s} Q^{\pi^*}(s, a) \quad (21)$$

۴- راه حل مبتنی بر یادگیری تقویتی

با توجه به عدم آگاهی از اطلاعات آماری تولید ترافیک و نیز تأخیر تصادفی کیفیت پیوندهای LTE و mmWave، نیازمند استفاده از الگوریتمی فارغ از مدل مانند یادگیری Q هستیم. برای استفاده از الگوریتم یادگیری Q در اولین شکاف زمانی، دستگاه تخمین‌های تمام توابع ارزش وضعیت-اقدام را با مقدار صفر جایگذاری می‌کند ($\hat{Q}(s, a) = 0, \forall s \in S, \forall a \in A$). در گام بعد، در هر مرحله تکرار از الگوریتم، دستگاه وضعیت فعلی s_t را مشاهده می‌کند و با اعمال رفتار اکتشافی حرصانه اِپسیلون یک عمل را انجام دهد. سپس دستگاه تابع هزینه آنی یعنی $c_t(s_t, a_t)$ را محاسبه کرده و حالت بعدی را مشاهده می‌کند. تابع ارزش وضعیت-اقدام بهینه برای حالت فعلی s_t و عمل اتخاذ شده a_t به صورت بازگشتی به صورت فرمول (۲۲) تخمین زده می‌شود:

$$\hat{Q}_{t+1}(s_t, a_t) \leftarrow (1 - \mu_t) \hat{Q}_t(s_t, a_t) + \mu_t (c(s_t, a_t) - \bar{c}^{\pi^*} + \min_{a_{t+1} \in A_{s_{t+1}}} \hat{Q}_t(s_{t+1}, a_{t+1})) \quad (22)$$

در رابطه (۲۲) مقدار \bar{c}^{π^*} که بیانگر مقدار متوسط هزینه بهینه برای هر مرحله است باید از قبل مشخص شود ولی این امر امکان پذیر نیست. بنابراین مقدار \bar{c}^{π^*} را با تخمینی از تابع ارزش برای برخی از دوتایی وضعیت-اقدام ثابت، جایگزین می‌کنیم. یعنی (s^*, a^*) به عنوان یک مرجع در نظر گرفته می‌شود و مقدار \bar{c}^{π^*} را می‌توان به صورت حدی $\lim_{t \rightarrow \infty} \hat{Q}_t(s_{t+1}, a_{t+1})$ تقریب زد. بنابراین، رابطه نهایی الگوریتم یادگیری Q به صورت فرمول (۲۳) قابل تبدیل است:

• **مجموعه اعمال کنترل (A):** $A = \{0, 1\}$ مجموعه اعمال کنترلی را نشان می‌دهد به طوری که $a_t = 0$ به معنای جایگذاری بسته‌های ترافیکی ورودی در صف ارسال مربوط به پیوند LTE و $a_t = 1$ به معنای جایگذاری بسته‌ها در صف نظیر پیوند mmWave است. با مشخص شدن مجموعه اعمال کنترلی، تعداد بسته‌های ورودی به صف که در رابطه (۷) و (۸) ذکر شد به صورت فرمول (۱۳) و (۱۴) به‌روزرسانی می‌شوند؛ چرا که از عوامل تأثیرگذار در تعداد بسته‌های ورودی به صف، یکی فرآیند تصادفی پواسون و دیگری عمل انتخاب شده می‌باشد:

$$W_{t+1}^M = a_t K_t + W_t^M - O_t^M \quad (13)$$

$$W_{t+1}^S = (1 - a_t) K_t + W_t^S - O_t^S \quad (14)$$

• **احتمال گذار (P):** در وضعیت s_t با اجرای عمل a_t وضعیت سیستم با احتمال $P(s_{t+1}|s_t, a_t)$ که در فرمول (۱۵) تعریف شده است به وضعیت جدید گذار می‌کند:

$$\mathbb{P}(s_{t+1}|s_t, a_t) = \mathbb{P}_\varphi(\varphi_{t+1}|\varphi_t, a_t) \quad (15)$$

• **تابع هزینه آنی (c):** تابع هزینه آنی $C_t(s_t, a_t)$ در وضعیت s_t و اتخاذ عمل a_t از فرمول (۱۶) محاسبه می‌گردد. در واقع هزینه‌ای است که با اتخاذ عمل در یک وضعیت می‌پردازیم، همان مقدار AoI است:

$$c_t(s_t, a_t) = \varphi_t \quad (16)$$

• **هدف بهینه‌سازی:** از آن‌جا که AoI فرآیندی تصادفی است، پس برای بهینه‌سازی باید متوسط کمینه آن را در بلند مدت محاسبه کرد که در فرمول (۱۷) نشان داده شده است:

$$\bar{c} = \lim_{n \rightarrow \infty} \frac{1}{n} E \sum_{t=1}^n c_t(s_t, a_t) \quad (17)$$


درواقع هدف دستگاه بدست آوردن سیاست بهینه π^* است که میانگین بلندمدت تابع هزینه را برای همه وضعیت‌ها بهینه کند. در ادامه، فرمول (۱۸) به این موضوع اشاره دارد:

$$\pi^* = \arg \min_{\pi} \bar{c}_\pi \quad (18)$$

برای محاسبه سیاست بهینه π^* باید با معادلات بلمن آشنا شویم که در ادامه به توضیح آن می‌پردازیم.

۳-۲- معادلات بلمن و برنامه‌ریزی پویا

معادلات بلمن استاندارد که مبتنی بر توابع ارزش وضعیت یا توابع ارزش وضعیت-اقدام هستند را به عنوان مبنایی برای برنامه‌ریزی پویا و طرح



شکل (۲) همگرایی تابع ارزش وضعیت-اقدام

جدول (۲): پارامترهای شبیه‌سازی

مقدار	پارامتر	مقدار	پارامتر
2.1 [24]	α_L	50 MHz [21]	B_{mmWave}
3.19 [24]	α_N	20 MHz	B_{LTE}
2	α_{LTE}	-50 dB	N_0^{LTE}
6 MB	L	$100 \leq d \text{ (m)} \leq 300$	d_{LTE}, d_{mmWave}
2 dB [25]	G_b^{max}	$30 \leq P \text{ (dB)} \leq 35$	P_{LTE}, P_{mmWave}
18 dB [25]	G_s^{max}	10 dB [26]	NF

پیشنهادی با دو الگوریتم نوبت گردشی^{۱۴} و کمترین میزان تاخیر رفت و برگشت^{۱۵} [20] مقایسه شده و نتایج حاصل از تاثیر پارامترهای محیطی بر عملکرد الگوریتم‌ها در قالب نمودار بیان شده است. همهی آزمایش‌ها با ۱۰۰ بار تکرار و فاصله اطمینان ۹۵ درصد محاسبه گردیده است.

شکل (۳) به بررسی تاثیر نرخ ورود بر روی متوسط AOI می‌پردازد. با افزایش λ از مقدار ۱ تا ۴ میزان تولید بسته افزایش پیدا می‌کند که نتیجه آن ازدحام بیشتر در صف کانال‌ها و افزایش متوسط AOI می‌باشد. روند متوسط AOI با افزایش نرخ ورود صعودی است که در بین الگوریتم‌ها، الگوریتم یادگیری Q عملکرد بهتری دارد.

شکل (۴) به بررسی اندازه تاثیر اندازه بسته بر روی متوسط AOI می‌پردازد. از آن‌جا که در یک شکاف زمانی نرخ ارسال ثابت است، با افزایش طول بسته از ۵ تا ۶ مگابایت، تعداد بسته‌های کمتری شانس خارج شدن از صف را دارند که نتیجه این امر افزایش متوسط AOI است.

شکل (۵) بیانگر تغییر توان از بازه ۳۰ dBm تا ۳۵ dBm و تاثیر آن بر روی متوسط AOI است. با افزایش توان، نرخ ارسال از صف کانال‌ها زیاد شده و بسته‌های بیشتری می‌توانند از صف‌ها خارج شوند که نتیجه این امر افزایش متوسط AOI است. به همین دلیل روند نمودارها نزولی می‌باشد که در بین سه الگوریتم، الگوریتم یادگیری Q عملکرد بهتری داشته است.

شکل (۶) به بررسی تاثیر فاصله بر روی متوسط AOI می‌پردازد. فاصله دستگاه تا ایستگاه‌ها از عوامل مهمی است که بر روی متوسط AOI تاثیر دارد. حداکثر فاصله در شبیه‌سازی مقدار ۳۰۰ متر در نظر گرفته شده است که هر چه از ایستگاه‌ها فاصله بگیریم، با توجه به احتمال قطع شدن پیوند در

$$\begin{aligned} \hat{Q}_{t+1}(s_t, a_t) \leftarrow & \\ & (1 - \mu_t) \hat{Q}_t(s_t, a_t) + \mu_t (c(s, a) \\ & - \hat{Q}_t(s^*, a^*)) \\ & + \min_{a_{t+1} \in A_{s_{t+1}}} \hat{Q}_t(s_{t+1}, a_{t+1}) \end{aligned} \quad (23)$$

در هر دو فرمول (۲۲) و (۲۳) منظور از μ_t نرخ کاهش یادگیری در الگوریتم یادگیری Q است که در واقع μ_t به صورت یک دنباله کاهشی برحسب زمان است. تابع μ_t باید طوری محاسبه شود که شرایط استاندارد تقریب تصادفی در فرمول (۲۴) را برآورده سازد:

$$\mu_t \rightarrow 0, \sum_t \mu_t = \infty, \sum_t (\mu_t)^2 < \infty \quad (24)$$

مقدار μ_t برای هر دوتایی (s, a) از فرمول (۲۵) بدست می‌آید که در آن $visit(s, a)$ برابر تعداد دفعاتی است که دوتایی (s, a) مشاهده و مقدار $Q(s, a)$ آن به‌روزرسانی می‌شود:

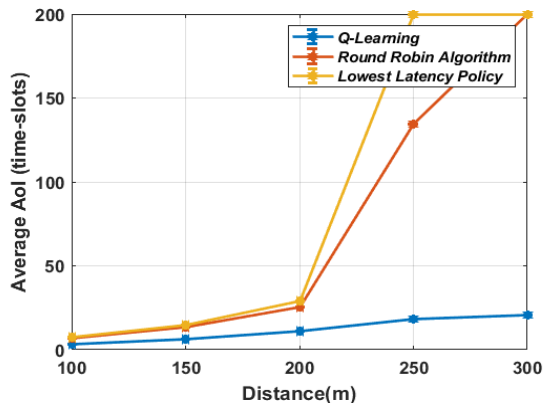
$$\mu_t = \frac{2.7}{1 + visit(s_t, a_t)} \quad (25)$$

۵- نتایج شبیه‌سازی

برای ارزیابی الگوریتم پیشنهادی، سناریوی مطرح‌شده در شکل (۱) را شبیه‌سازی می‌کنیم. همان‌طور که مشخص است دستگاه ما به دو ایستگاه eNB و gNB متصل است که فاصله دستگاه تا ایستگاه‌ها ۳۰۰ متر بوده و توان ارسال آن برابر ۳۰dBm است. محیط پیرامون دستگاه غیرقطعی است، به این معنا که بسته‌های تولید شده و همچنین کیفیت کانال نسبت به زمان متغیر است. در شبیه‌سازی محیط فرض بر این است که سیستم در شکاف‌های زمانی ثابت به مدت ۱ میلی‌ثانیه عمل می‌کند و در هر شکاف زمانی، بر اساس توزیع پواسون با میانگین ۱ بسته به اندازه ۶ مگابایت داده تولید می‌شود. در کانال LTE، ۱۰ کیفیت متفاوت برای ضریب بهره کانال داریم که به طور تصادفی تغییر می‌کنند و با زنجیره مارکوف مدل شده‌اند [19]. در کانال mmWave، سه وضعیت LoS، NLoS و Outage را در نظر گرفتیم که بر اساس ماتریس احتمال گذار مشخصی به صورت تصادفی تغییر می‌کنند [17]. پهنای باند کانال LTE برابر ۲۰ مگاهرتز و پهنای باند کانال mmWave برابر ۵۰ مگاهرتز است [21] و نرخ خروج داده در هر شکاف زمانی بسته به شرایط کانال متغیر است. مقدار نویز در کانال LTE برابر -۵۰dB و در کانال mmWave از فرمول (۲۶) بدست آید که در آن B_{mmWave} پهنای باند کانال mmWave و شکل نویز^{۱۲} می‌باشد که مقداری برابر ۱۰dB دارد [26]:

$$N_0^{mmWave} = -174 \frac{dBm}{Hz} + 10 \log_{10} B_{mmWave} + NF \quad (26)$$

پارامترهای شبیه‌سازی و مقادیر آن‌ها در جدول (۲) آورده شده است. در شکل (۲) همگرایی تابع ارزش وضعیت-اقدام آورده شده است که تعداد تکرار ۸۰۰۰۰۰ بار و با مقدار ۳.۹ همگرا شده است. در ادامه، روش



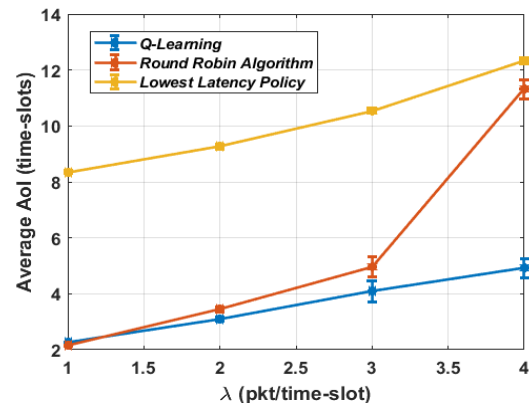
شکل (۲) متوسط AoI بر حسب تغییر اندازه فاصله

که یک سیاست بهینه برای زمان بندی بار ترافیکی بین دو مسیر موجود در اتصال دوگانه را ارائه داده و شرایط محیط و کانال را به صورت کاملا تصادفی در نظر می گیرد. در شبیه سازی، همگرایی الگوریتم پیشنهادی را مورد بررسی قرار داده و عملکرد آن را در مقایسه با دو الگوریتم RR و LL تحت تاثیر پارامترهای مختلف ارزیابی کردیم که نتایج آن در تمامی حالتها نشان می دهد الگوریتم پیشنهادی عملکرد بهتری نسبت به دیگر الگوریتمها داشته است.

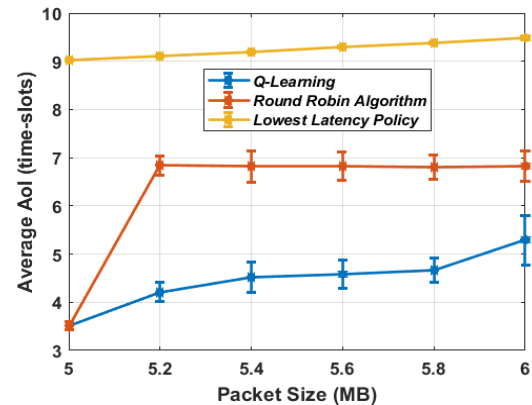
به عنوان کارهای آینده نیز می توان به بررسی تاثیر کنترل ازدحام، مدیریت مسیر در MPTCP، در نظر گرفتن اتصال چند کاربر به طور همزمان به ایستگاهها، متحرک در نظر گرفتن دستگاه، استفاده از سایر الگوریتمهای یادگیری مانند: یادگیری تقویتی عمیق و شبکه های عصبی عمیق اشاره کرد.

مراجع

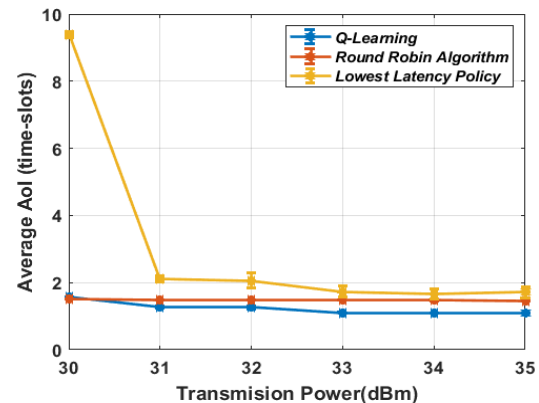
- [1] P. K. Taksande, A. Roy, and A. Karandikar, "Optimal traffic splitting policy in LTE-based heterogeneous network," in 2018 IEEE Wireless Communications and Networking Conference (WCNC), Apr. 2018, pp. 1–6.
- [2] P. Mishra, S. Kar, V. Bollapragada, and K.-C. Wang, "Multi-Connectivity using NR-DC for High Throughput and Ultra-reliable Low Latency Communication in 5G Networks," in 2021 IEEE 4th 5G World Forum (5GWF), Oct. 2021, pp. 36–40.
- [3] R. Odarchenko, R. Aguiar, B. Altman, and Y. Sulema, "Multilink Approach for the Content Delivery in 5G Networks," in 2018 International Scientific-Practical Conference Problems of Infocommunications. Science and Technology (PIC S&T), Oct. 2018, pp. 140–144.
- [4] Y. Wang, C. Sun, F. Jiang, and J. Jiang, "Blocking- and Delay-aware Flow Control Using Markov Decision Process," in 2020 IEEE/CIC International Conference on Communications in China (ICCC), Aug. 2020, pp. 905–910.
- [5] Q. Zhao, S. Paris, T. Vejalainen, and S. Ali, "Hierarchical Multi-Objective Deep Reinforcement Learning for Packet Duplication in Multi-Connectivity for URLLC," in 2021 Joint European Conference on Networks and Communications & 6G Summit (EuCNC/6G Summit),



شکل (۳) متوسط AoI بر حسب تغییر نرخ ورود



شکل (۴) متوسط AoI بر حسب تغییر اندازه بسته



شکل (۵) متوسط AoI بر حسب تغییر اندازه توان

شبکه های 5G و همچنین نیازمندی به توان ارسال بیشتر، میزان متوسط AoI نیز افزایش پیدا می کند و به همین خاطر روند نمودارها صعودی است که در این بین، الگوریتم یادگیری Q عملکرد بهتری دارد.

۶- نتیجه

در این مقاله مسأله زمان بندی ارسال بسته ها مبتنی بر اتصال دوگانه در شبکه های نسل چهارم و پنجم تلفن همراه تعریف شد که هدف آن کمینه کردن میانگین AoI به صورت بلندمدت در دستگاه مقصد می باشد. حل این مسأله با رویکرد فارغ از مدل، مبتنی بر یادگیری تقویتی بوده است

- [20] B. Y. L. Kimura, D. C. S. F. Lima, and A. A. F. Loureiro, "Packet Scheduling in Multipath TCP: Fundamentals, Lessons, and Opportunities," IEEE Syst. J., vol. 15, no. 1, pp. 1445–1457, Mar. 2021.
- [21] T. Specification and G. Services, "3gpp tr 21.915," vol. 0, no. Release 15, 2019.
- [22] N. Pappas, M. A. Abd-Elmagid, B. Zhou, W. Saad, and H. S. Dhillon, Eds., *Age of Information*. Cambridge University Press, 2023.
- [23] C. Lee, S. Song, H. Cho, G. Lim, and J. M. Chung, "Optimal multipath TCP offloading over 5G NR and LTE networks," IEEE Wirel. Commun. Lett., vol. 8, no. 1, pp. 293–296, 2019.
- [24] 3GPP, "Study on channel model for frequencies from 0.5 to 100 GHz, TR 38.901 v 17.0.0," 2022.
- [25] O. Onireti, A. Imran, and M. A. Imran, "Coverage, Capacity, and Energy Efficiency Analysis in the Uplink of mmWave Cellular Networks," IEEE Trans. Veh. Technol., vol. 67, no. 5, pp. 3982–3997, May 2018.
- [26] B. Maham and P. Popovski, "Capacity Analysis of Coordinated Multipoint Reception for mmWave Uplink With Blockages," IEEE Trans. Veh. Technol., vol. 69, no. 12, pp. 16299–16303, Dec. 2020.
- [6] M.-S. Pan, T.-M. Lin, C.-Y. Chiu, and C.-Y. Wang, "Downlink Traffic Scheduling for LTE-A Small Cell Networks With Dual Connectivity Enhancement," IEEE Commun. Lett., vol. 20, no. 4, pp. 796–799, Apr. 2016.
- [7] V. Adarsh, P. Schmitt, and E. Belding, "MPTCP Performance over Heterogenous Subpaths," in 2019 28th International Conference on Computer Communication and Networks (ICCCN), Jul. 2019, pp. 1–9.
- [8] M. Prakash and A. Abdrabou, "On the Fidelity of NS-3 Simulations of Wireless Multipath TCP Connections," Sensors, vol. 20, no. 24, p. 7289, Dec. 2020.
- [9] A. Jagetiya, C. Rama Krishna, and Y. Haider, "Survey of Transport Layer Multihoming Protocols and Performance Analysis of MPTCP," 2019, pp. 15–24.
- [10] H. Zhang, W. Li, S. Gao, X. Wang, and B. Ye, "ReLeS: A Neural Adaptive Multipath Scheduler based on Deep Reinforcement Learning," Proc. - IEEE INFOCOM, vol. 2019-April, pp. 1648–1656, 2019.
- [11] S.-Y. Park, C. Joo, Y. Park, and S. Bank, "Impact of traffic splitting on the delay performance of MPTCP," in 2014 IEEE International Conference on Communications (ICC), Jun. 2014, pp. 1204–1209.
- [12] J. Bai, S. Yeh, and S. Talwar, "Towards Delay-Optimal Multi-Connectivity Traffic Management for Edge Networks," in 2021 IEEE 94th Vehicular Technology Conference (VTC2021-Fall), Sep. 2021, pp. 1–6.
- [13] J. Luo, X. Su, and B. Liu, "A Reinforcement Learning Approach for Multipath TCP Data Scheduling," in 2019 IEEE 9th Annual Computing and Communication Workshop and Conference (CCWC), Jan. 2019, pp. 0276–0280.
- [14] P. Dong et al., "Multipath TCP Meets Reinforcement Learning: A Novel Energy-Efficient Scheduling Approach in Heterogeneous Wireless Networks," IEEE Wirel. Commun., pp. 1–9, 2022.
- [15] R. D. Yates, Y. Sun, D. R. Brown, S. K. Kaul, E. Modiano, and S. Ulukus, "Age of Information: An Introduction and Survey," IEEE J. Sel. Areas Commun., vol. 39, no. 5, pp. 1183–1210, May 2021.
- [16] M. Agiwal, H. Kwon, S. Park, and H. Jin, "A Survey on 4G-5G Dual Connectivity: Road to 5G Implementation," IEEE Access, vol. 9, pp. 16193–16210, 2021.
- [17] Y. Fan, Z. Zhang, and H. Li, "Message Passing Based Distributed Learning for Joint Resource Allocation in Millimeter Wave Heterogeneous Networks," IEEE Trans. Wirel. Commun., vol. 18, no. 5, pp. 2872–2885, May 2019.
- [18] D. Moltchanov, E. Sopin, V. Begishev, A. Samuylov, Y. Koucheryavy, and K. Samouylov, "A Tutorial on Mathematical Modeling of 5G/6G Millimeter Wave and Terahertz Cellular Systems," IEEE Commun. Surv. Tutorials, vol. 24, no. 2, pp. 1072–1116, 2022.
- [19] F. Namjoonia, M. Sheikhi, and V. Hakami, "Fast reinforcement learning algorithms for joint adaptive source coding and transmission control in IoT devices with renewable energy storage," Neural Comput. Appl., vol. 34, no. 5, pp. 3959–3979, Mar. 2022.

زیر نویس

-
- ¹ The 5th Generation Mobile Network (5G)
² Millimeter Wave (mmWave)
³ Dual Connectivity
⁴ The 3rd Generation Partnership Project
⁵ Macro Base Station
⁶ Small Base Station
⁷ The 4th Generation Mobile Network (4G)
⁸ Evolved Node Base (eNB)
⁹ Next Generation Node Base (gNB)
¹⁰ Line of Sight
¹¹ Non-Line of Sight
¹² Main Lobe
¹³ Noise Figure
¹⁴ Round Robin (RR)
¹⁵ Lowest Latency (LL)