

Research Article

Improving the Handover Process Using Machine Learning Algorithms and Received Signal Strength Parameters

Babak Lotfi^{1*}  | Yaser Elmo Sola² 

¹Department of Computer Engineering and Information Technology, Islamic Azad University, Sabzevar Branch, Sabzevar, Iran, Babak.lotfi@iau.ac.ir

²Department of Computer Engineering and Information Technology, Islamic Azad University, Sabzevar Branch, Sabzevar, Iran, Yasser.elmi@iau.ac.ir

Corresponding Author

*Babak Lotfi, PhD Student Department of Computer Engineering and Information Technology, Islamic Azad University, Sabzevar Branch, Sabzevar, Iran, Babak.lotfi@iau.ac.ir

Main Subjects: Improving the HandOver in 5G Networks

Received: 24 March 2025

Revised: 9 April 2025

Accepted: 16 April 2025

Abstract

In 5G networks, the reduction in cell size has significantly increased the frequency of handover processes. Given the direct impact of this process on quality of service (QoS) and user experience, efficient handover management is of critical importance. This study focuses on improving the handover process using machine learning algorithms and a combination of three clustering methods: K-means, DBSCAN, and GMM. The proposed approach refines the features used in previous studies to optimize network performance and reduce unnecessary handovers. The K-means algorithm, known for its simplicity and efficiency, minimizes intra-cluster variance, yet it faces challenges such as sensitivity to noise and the need to predefine the number of clusters. In contrast, DBSCAN, which operates based on point density, does not require a predefined number of clusters and can effectively eliminate noisy data points. Additionally, GMM, through complex statistical modeling, provides more precise clustering and a better representation of data distribution. In this study, after preprocessing user location, received signal strength, and cell status, these three algorithms were integrated using parallel, sequential, and hybrid methods to enhance decision-making in the handover process. This adaptive approach not only reduces the number of handovers and their negative effects but

also enhances network efficiency and communication quality. The implementation results indicate that the proposed method can significantly improve user experience in dense 5G networks, making the handover process more reliable and efficient

<https://doi.org/10.82195/ntds.2025.1202659>

Keywords: Handover, 5G networks, Quality of Service (QoS), Machine Learning Algorithms, Received Signal Strength

بهبود فرایند انتقال بین سلول ها با استفاده از الگوریتم های یادگیری ماشین و پارامترهای قدرت سیگنال دریافتی

بابک لطفی* ¹ | یاسر علمی سولا ²

چکیده:

با گسترش روزافزون شبکه های نسل پنجم (5G) و افزایش تراکم ایستگاه های پایه، فرایند انتقال بین سلولی (Handover) به یکی از چالش های اساسی در تضمین کیفیت خدمات (QoS) و حفظ پایداری ارتباطات تبدیل شده است. در این پژوهش، باهدف بهبود مدیریت انتقال، رویکردی مبتنی بر یادگیری ماشین ارائه شده که با بهره گیری از سه الگوریتم خوشه بندی K-Means، DBSCAN و GMM در سه ساختار اجرایی متفاوت، شامل موازی، سری و ترکیبی (Ensemble)، پیاده سازی شده است. در این چارچوب، ویژگی های ورودی، شامل موقعیت مکانی کاربران، قدرت سیگنال دریافتی و وضعیت سلول ها، به دقت پیش پردازش شده و مدل های خوشه بندی، اصلاح و آموزش دیده اند. نتایج حاصل از پیاده سازی نشان می دهد که ساختار ترکیبی عملکرد بهتری نسبت به سایر روش ها داشته و بهبود معناداری در معیارهایی نظیر دقت پیش بینی (Precision) با مقدار ۹۱/۳ درصد و میانگین هارمونیک (F1 Score) با مقدار ۹۰/۲ درصد داشته اند. به منظور سنجش کارایی مدل، مقایسه ای نیز با نتایج دو روش شناخته شده، شامل روش مبتنی بر شبکه های عصبی بازگشتی (RNN) حافظه طولانی کوتاه مدت (LSTM) و روش مبتنی بر منطق فازی انجام شده است. مقایسه ها نشان می دهد که رویکرد پیشنهادی از نظر شاخص های عملکردی، از جمله دقت، نرخ انتقال و ثبات خوشه بندی، برتری محسوسی نسبت به این دو مدل دارد. همچنین تحلیل آماری با استفاده از آزمون ANOVA، تفاوت معنادار عملکرد میان روش ها را تأیید می نماید. در مجموع، نتایج این پژوهش حاکی از اثربخشی روش ترکیبی پیشنهادی در کاهش انتقال های غیرضروری، افزایش پایداری اتصال و بهبود کیفیت ارتباط در محیط های متراکم شبکه های نسل پنجم است.

^۱گروه مهندسی کامپیوتر و فناوری اطلاعات، واحد سبزوار،
دانشگاه آزاد اسلامی، سبزوار، ایران
Babak.lotfi@iau.ac.ir

^۲گروه مهندسی کامپیوتر و فناوری اطلاعات، واحد سبزوار،
دانشگاه آزاد اسلامی، سبزوار، ایران
Yasser.elmi@iau.ac.ir

نویسنده مسئول

*بابک لطفی، دانشجوی دکتری تخصصی مهندسی فناوری
اطلاعات، گروه مهندسی کامپیوتر و فناوری اطلاعات، واحد
سبزوار، دانشگاه آزاد اسلامی، سبزوار، ایران
Babak.lotfi@iau.ac.ir

عنوان اصلی: بهبود فرایند انتقال بین سلول ها در شبکه های
نسل پنجم
تاریخ دریافت: ۱۴۰۴/۰۱/۰۴
تاریخ بازنگری: ۱۴۰۴/۰۱/۲۰
تاریخ پذیرش: ۱۴۰۴/۰۱/۲۷

<https://doi.org/10.82195/ntds.2025.1202659>


کلیدواژه ها: الگوریتم های یادگیری ماشین، انتقال بین سلولی، خوشه بندی، شبکه های نسل پنجم، قدرت سیگنال دریافتی، کیفیت خدمات

۱. مقدمه

شبکه های نسل پنجم به عنوان یک فناوری پیشرفته ی ارتباطی، تحولی شگرف در سرعت و قابلیت های ارتباطاتی بی سیم، ایجاد کرده اند. این شبکه ها با ارائه ی پهنای باند وسیع تر، تأخیر کمتر و ظرفیت بالاتر، زمینه ساز توسعه و پیاده سازی برنامه های متنوعی از جمله اینترنت اشیا [۱]، خودروهای خودران [۲]، واقعیت افزوده و مجازی [۳] و خدمات پزشکی از راه دور [۴] هستند. با این حال، یکی از چالش های اصلی در شبکه های نسل پنجم، مدیریت مؤثر فرآیند انتقال [۵] بین سلول های مختلف شبکه است.

متراکم سازی شبکه، مکانیسمی بنیادی برای افزایش تراکم ایستگاه های پایه در یک منطقه خاص در جهت بالابردن ظرفیت شبکه دسترسی رادیویی است که انتظار می رود شبکه های نسل پنجم را قادر سازد تا افزایش ظرفیت مورد انتظار شبکه را برآورده کنند. ایده اصلی در متراکم سازی شبکه، استفاده مجدد از فرکانس نامیده می شود که در این رویکرد، سایر ایستگاه های پایه تا زمانی که تداخل متقابل وجود نداشته باشد مجاز به استفاده از طیف فرکانسی ایستگاه پایه هستند. به منظور محدود کردن مناطق همپوشانی، این اجتناب با کاهش قدرت انتقال انجام می شود [۶].

در شبکه های سلولی نسل پنجم، با افزایش پهنای باند، مدیریت انتقال بین سلولی به یک چالش جدی تبدیل شده است. مطابق با شکل (۱)، کاربران هنگام حرکت، به طور مداوم بین ایستگاه های پایه ی مختلف، جابه جا شده که می تواند باعث اختلال در اتصال، کاهش سرعت و افت کیفیت خدمات شود. با ظهور شبکه های متراکم و استفاده از امواج میلی متری [۷]، مشکل انتقال بین سلول ها تشدید شده است. زیرا فرکانس های بالاتر محدوده پوشش دهی کمتری دارند. به همین دلیل، برای پوشش بهتر، نیاز به نصب تعداد بیشتری ایستگاه پایه است. اما این افزایش پایه ها باعث افزایش تعداد انتقال بین سلولی شده و کیفیت خدمات به کاربران را کاهش می دهد. یکی از راه حل های ممکن، جهت افزایش کیفیت خدمات و بهبود مشکلات ناشی از افزایش تعداد انتقال بین سلول ها، استفاده از سلول های کوچک است [۸]. این سلول ها در نقاط پرتراکم نصب شده و با بهینه سازی پوشش و استفاده مجدد از فرکانس ها، امکان راه اندازی ایستگاه های پایه ی بیشتری را فراهم کرده که به کاهش تأثیرات منفی انتقال بین سلول ها، کمک می کند. علاوه بر این، امواج میلی متری، چالش های خاص خود را دارند. هرچه فرکانس بالاتر باشد، میزان افت سیگنال نیز بیشتر خواهد شد. یعنی سیگنال مسافت کوتاه تری را طی کرده و پوشش دهی ایستگاه های پایه، کاهش می یابد. همچنین، سیگنال هایی که پهنای باند بیشتری دارند، برد کوتاه تری خواهند داشت. این ویژگی ها باعث می شوند که ایستگاه های پایه با فاصله کمتری از هم نصب شده و ارتباطات پایدارتری را برای کاربران، فراهم کنند [۹].




شکل ۱: انتقال بین سلول ها در شبکه نسل پنجم

Figure 1: Transfer between cells in the fifth-generation network

مطابق با شکل (۲)، تأثیر افزایش فرکانس بر پوشش سلولی، نرخ فرآیند انتقال بین سلول‌ها و ظرفیت در شبکه‌های نسل پنجم و امواج میلیمتری را می‌توان دید. با افزایش فرکانس، شعاع پوشش سلولی به شدت کاهش یافته به طوری که در فرکانس‌های پایین مانند ۲ و ۳.۵ گیگاهرتز، پوشش‌دهی وسیع‌تر است اما در فرکانس‌های ۲۸ گیگاهرتز و بالاتر، برد سلول‌ها کاهش یافته و نیاز به افزایش ایستگاه‌های پایه، ایجاد می‌شود. نمودار میانی بیانگر نرخ فرآیند انتقال بین سلول‌ها بوده که با افزایش فرکانس، روندی صعودی را طی می‌کند. زیرا تعداد بیشتری ایستگاه‌های پایه، برای پوشش‌دهی مناسب در فرکانس‌های بالا مورد نیاز بوده که باعث افزایش نرخ جابه‌جایی کاربر بین سلول‌ها، می‌شود. در فرکانس‌های ۶۰ و ۱۰۰ گیگاهرتز، این مقدار به بیشینه‌ی خود رسیده و به‌طور قابل‌ملاحظه‌ای بر کیفیت تجربه‌ی کاربر، تأثیر منفی، می‌گذارد.

نمودار سمت راست، ظرفیت شبکه را بر حسب نرخ فرآیند انتقال بین سلول‌ها نشان می‌دهد. ظرفیت شبکه در فرکانس‌های بالاتر به‌رغم افزایش نرخ فرآیند انتقال بین سلول‌ها، در مقایسه با فرکانس‌های پایین، بیشتر است [۱۰]. این امر به دلیل پهنای باند وسیع‌تر در فرکانس‌های با امواج میلیمتری بوده که امکان انتقال داده‌ها با نرخ بالاتر را فراهم می‌کند. با این حال، افزایش نرخ فرآیند انتقال بین سلول‌ها در این باندها، چالشی جدی در حفظ پایداری اتصال محسوب می‌شود. نتایج این تحلیل تأکیدی بر ضرورت استفاده از تکنیک‌هایی نظیر سلول‌های پایه‌ی کوچک، تشکیل پرتو هوشمند [۱۱] و الگوریتم‌های یادگیری ماشین [۱۲]، جهت بهینه‌سازی فرآیند انتقال بین سلول‌ها در شبکه‌های نسل پنجم و فراتر از آن داشته تا ضمن افزایش ظرفیت شبکه، نرخ جابه‌جایی کاربران بین سلول‌ها، مدیریت شده و از تأثیرات منفی آنها، کاسته شود.



شکل ۲: تأثیر افزایش فرکانس بر پوشش سلولی

Figure 2: The effect of increasing frequency on cellular coverage

با افزایش تعداد ایستگاه‌های پایه در یک محیط معین، دستگاه‌های کاربر، ملزم به انجام انتقال بین سلولی بیشتری، می‌شوند. این افزایش، ناشی از کاهش اندازه سلول‌ها و افزایش تراکم ایستگاه‌های پایه بوده که باعث می‌شود، محدوده پوشش هر ایستگاه پایه، کوچک‌تر و دستگاه‌های کاربر، سریع‌تر از محدوده یک ایستگاه خارج شوند [۱۳]. در نتیجه، تعداد انتقال‌ها افزایش یافته که می‌تواند بر پایداری اتصال و کیفیت تجربه کاربر، تأثیر منفی بگذارد. از آنجایی که میانگین توان عملیاتی کاربر با تعداد انتقال‌ها، رابطه‌ی معکوس دارد، افزایش انتقال بین سلولی، منجر به کاهش کیفیت ارتباطات و افت سطح خدمات خواهد شد. علاوه بر این، قطع موقت سرویس در هنگام انتقال باعث کاهش رضایت کاربران شده و می‌تواند اهداف کلیدی شبکه‌های نسل پنجم از جمله پایداری اتصال، کاهش تأخیر و تجربه‌ی کاربری یکپارچه را تحت تأثیر قرار دهد [۱۴].

مواجه‌شدن با تعداد و هزینه‌ی انتقال‌های تحمیل شده در طول یک جلسه پیامدهای نامطلوبی دارد. به همین دلیل، عمده تحقیقات در مورد مدیریت انتقال بر دو موضوع کاهش تعداد و هزینه‌ی هر انتقال، متمرکز شده است. علی‌رغم این واقعیت و باتوجه‌به اطلاعات مربوطه به رشد ایستگاه‌های پایه، اینترنت اشیا و همچنین افزایش تقاضا برای خدمات داده‌محور، عمدتاً تاکنون، آمارها منفی گزارش شده است. اپراتورهای شبکه برای فعال‌کردن مدیریت مؤثرتر، ممکن است از حجم وسیعی از داده‌های ایجاد شده توسط شبکه‌های سلولی استفاده کرده که به‌طور قابل‌توجهی نیز در حال گسترش است. به عبارت دیگر، هرچه شبکه‌ها بزرگ‌تر و پیچیده‌تر شوند، همچنان حجم عظیمی از داده‌های تولید شده که توجه به کاهش این پیچیدگی‌ها، بسیار ضروری است. به همین دلیل، روش‌های یادگیری ماشین توجه زیادی را در حوزه ارتباطات بی‌سیم به خود جلب کرده

است. چرا که مقادیر زیادی از داده‌ها را می‌توان به طور مؤثر برای آموزش مدل‌های یادگیری ماشین مورد استفاده قرارداد که منجر به تصمیم‌گیری فعال‌تر و آگاهانه‌تر شود [۱۵].

هوش مصنوعی و یادگیری ماشین نقش محوری در شبکه‌های نسل ششم ایفا خواهند کرد، زیرا انتظار می‌رود این شبکه‌ها به صورت هوشمند مدیریت، کنترل و بهینه‌سازی شوند. در این راستا، مدیریت فرایند انتقال بین سلولی از اهمیت بالایی برخوردار بوده و نیازمند توسعه روش‌های کارآمد، مبتنی بر یادگیری ماشین است؛ بنابراین، بررسی پیشرفت‌های اخیر در مدیریت انتقال مبتنی بر یادگیری ماشین در شبکه‌های سلولی، به ویژه در نسل پنجم و ششم، همراه با تحلیل داده‌های مورد استفاده در این الگوریتم‌ها، ضرورتی اجتناب‌ناپذیر به شمار می‌رود [۱۲، ۱۶].

در عصر ارتباطات سیار، تداوم ارتباط با کیفیت یکی از عوامل کلیدی در شبکه‌های تلفن همراه محسوب می‌شود. فرایند انتقال بین سلولی به عنوان یک مؤلفه اساسی در شبکه‌های ارتباطی سلولی نسل جدید، چالش‌های متعددی را در کیفیت خدمات ایجاد می‌کند. این چالش‌ها شامل کاهش نرخ میانگین توان عملیاتی، افزایش تأخیر و اختلال در ارائه خدمات هستند. ظهور فناوری‌های توانمندساز در شبکه‌های نسل پنجم، از جمله اینترنت اشیاء، شبکه‌های فوق متراکم و ارتباطات مبتنی بر امواج میلی‌متری، منجر به افزایش چشمگیر تعداد ایستگاه‌های پایه و تراکم اتصال در واحد سطح شده است. این مسئله مدیریت کارآمد فرایند انتقال بین سلولی را پیچیده‌تر کرده و نیازمند روش‌های پیشرفته‌تر برای بهینه‌سازی این فرایند است. علاوه بر این، الزامات شبکه‌های نسل پنجم و ششم مانند کاهش تأخیر، افزایش پایداری ارتباطات و ارائه تجربه کاربری یکپارچه، این چالش‌ها را بیش از پیش برجسته کرده و ضرورت توسعه الگوریتم‌های بهینه‌سازی نوین را دوچندان ساخته است [۱۷].

به همین دلیل، این پژوهش بر تکنیک‌های بهینه‌سازی هوشمند فرایند انتقال مبتنی بر مدل‌های یادگیری ماشین متمرکز است که هدف آن بهبود مدیریت انتقال در شبکه‌های نسل پنجم و دستیابی به عملکردی پایدارتر و کارآمدتر در این شبکه‌ها است. تعدد فرایندهای انتقال بین سلولی می‌تواند منجر به کاهش کیفیت خدمات، افزایش تأخیر و ناپایداری ارتباطات شود که این مسئله در سناریوهای با تحرک بالا، نظیر وسایل نقلیه خودران و قطارهای پرسرعت، به طور چشمگیری برجسته‌تر است. بهینه‌سازی و مدیریت کارآمد فرایند انتقال در این شبکه‌ها نه تنها از اهمیت ویژه‌ای برخوردار است، بلکه می‌تواند به طور قابل توجهی کیفیت خدمات را ارتقا دهد. یکی از رویکردهای مؤثر در این زمینه، بهره‌گیری از الگوریتم‌های یادگیری ماشین و تکنیک‌های پیشرفته خوشه‌بندی است که قادر به تحلیل الگوهای حرکتی کاربران، بهینه‌سازی تصمیمات انتقال و کاهش اثرات منفی ناشی از انتقال‌های غیرضروری هستند. الگوریتم‌های مختلفی می‌توانند در افزایش دقت خوشه‌بندی و کاهش تعداد انتقال بین سلول‌ها نقش بسزایی ایفا کنند.

الگوریتم K-Means [۱۸]، به عنوان یکی از الگوریتم‌های خوشه‌بندی ساده و کارآمد بوده که با هدف کمینه کردن واریانس درون خوشه‌ها عمل می‌کند. با این حال، این الگوریتم با محدودیت‌هایی نظیر حساسیت به نویز، نقاط پرت و نیاز به تعیین تعداد خوشه‌ها پیش از اجرا، مواجه است. این الگوریتم بهینه‌سازی، فاصله اقلیدسی بین نقاط داده و مراکز خوشه را هدف قرار می‌دهد. مزایای این الگوریتم شامل سرعت بالا و سادگی است. در مقابل، الگوریتم DBSCAN [۱۹]، بر اساس چگالی نقاط عمل کرده و قادر است خوشه‌هایی با شکل‌های مختلف و پیچیده را شناسایی کند. این الگوریتم به تعداد خوشه‌ها حساس نبوده و می‌تواند نقاط نویز را نیز شناسایی و حذف کند. الگوریتم GMM [۲۰]، نیز با استفاده از مدل‌های آماری ترکیبی، خوشه‌بندی نقاط را انجام دهد و می‌تواند اطلاعات دقیق‌تری از توزیع داده‌ها فراهم کند. این الگوریتم قادر به مدل‌سازی خوشه‌هایی با توزیع‌های مختلف و پیچیده‌تر بوده و داده‌ها را به صورت ترکیبی از توزیع‌های گاوسی، مدل‌سازی کند. این الگوریتم از روش انتظار بیشینه‌سازی برای تعیین خوشه‌ها استفاده کرده که برای داده‌هایی با توزیع‌های پیچیده مناسب‌تر بوده اما نسبت به دیگر الگوریتم‌ها، پیچیدگی محاسباتی بیشتری دارد.

علاوه بر این، قدرت سیگنال دریافتی یکی از پارامترهای کلیدی در بهینه‌سازی فرایند انتقال بین سلولی محسوب می‌شود. این پارامتر به عنوان یک شاخص قابل اعتماد برای ارزیابی کیفیت ارتباط و پایداری لینک مخابراتی، نقش مهمی در تصمیم‌گیری‌های مرتبط با فرایند تحویل بین سلولی ایفا می‌کند. ترکیب الگوریتم‌های خوشه‌بندی پیشرفته با اطلاعات قدرت سیگنال دریافتی می‌تواند به بهبود دقت در انتخاب ایستگاه مقصد، کاهش تأخیر انتقال و افزایش پایداری ارتباطات منجر شود. این رویکرد، امکان

سازگاری هوشمند فرایند انتقال را در شرایط متغیر شبکه فراهم کرده و تأثیر عواملی مانند نویز، تداخل و تراکم کاربران را در تصمیم‌گیری‌های انتقال به حداقل می‌رساند [۲۱].

باتوجه به مباحث مطرح‌شده، این پژوهش بر دو نوآوری کلیدی ترکیب سه الگوریتم خوشه‌بندی برای بهینه‌سازی فرایند انتقال، با در نظر گرفتن ویژگی‌های ذاتی مسئله و بهره‌گیری از ترکیب جدیدی از ویژگی‌ها شامل موقعیت کاربران، قدرت سیگنال دریافتی و پارامترهای مربوط به وضعیت سلول‌ها متمرکز است. این دو رویکرد بهبود دقت تصمیم‌گیری در فرایند انتقال بین سلولی و افزایش کارایی شبکه را هدف قرار داده‌اند.

در ادامه، فصل دوم به بررسی مبانی نظری و پیشینه تحقیق اختصاص یافته و چالش‌های موجود در حل مسئله تحلیل شده است. فصل سوم روش پیشنهادی را به تفصیل تشریح می‌کند. در فصل چهارم نحوه پیاده‌سازی و تحلیل نتایج ارائه شده و در نهایت، فصل پنجم به جمع‌بندی و نتیجه‌گیری نهایی اختصاص یافته است.

۲. مروری بر ادبیات پژوهش

همان‌گونه که در بخش مقدمه گفته شد باتوجه به ویژگی‌های جدید شبکه‌های نسل پنجم و چالش‌های تحمیل شده به این شبکه‌ها، راه‌حل‌های مرسوم در مدیریت انتقال، قادر به مقابله با افزایش مشکلات و پیچیدگی‌هایی که استفاده از امواج میلی‌متری و باندهای فرکانسی بیشتر در شبکه‌های نسل پنجم برای مدیریت دست‌به‌دست شدن ایجاد می‌کند، نیستند. در شبکه‌های مخابرات سیار، فرایند انتقال بین سلول‌ها به فرآیندی اطلاق می‌شود که در آن، ارتباط فعال یک کاربر از یک ایستگاه پایه به ایستگاه پایه دیگری منتقل می‌شود تا پیوستگی خدمات و کیفیت ارتباط حفظ گردد. این مکانیزم به‌ویژه در شبکه‌های نسل پنجم با توجه به معماری فوق متراکم و تعداد بالای ایستگاه‌های پایه، اهمیت بیشتری یافته است. در این شبکه‌ها، مدیریت مؤثر فرایند انتقال بین سلول‌ها برای اطمینان از تأخیر کم، پایداری اتصال و تجربه کاربری بهینه ضروری است. تحقیقات نشان می‌دهد که استفاده از الگوریتم‌های یادگیری ماشین و روش‌های تحلیلی پیشرفته، می‌تواند به بهبود فرآیند فرایند انتقال بین سلول‌ها و کاهش نرخ شکست آن، کمک کند [۲۲]. در ابتدا، فاصله‌ی انتقال برای این محدوده فرکانسی به دلیل تضعیف شدید، محدود خواهد شد. در نتیجه، برای پوشش همان منطقه‌ای که از فرکانس‌های مایکروویو استفاده می‌کردند، ایستگاه‌های پایه اضافی باید ساخته شوند. این نشان می‌دهد که شبکه از نظر اندازه و پیچیدگی به طور قابل توجهی رشد خواهد کرد و کاربران انتقال‌های بین سلولی بیشتری را تجربه خواهند کرد، که به کیفیت خدمات آنها، به‌ویژه برای کاهش کیفیت و عملکرد ارتباط کاربران و برنامه‌های تلفن همراه منجر خواهد شد. ضمناً از آنجایی که شبکه‌های امواج میلی‌متری از پروتوکل‌های هدایت‌شده برای انتقال استفاده می‌کنند، موانع موجود در مسیر پرتو ارسالی ممکن است کاملاً مانع از اتصال کاربر به شبکه شده و یا تأثیر مخربی بر کیفیت سیگنال داشته باشد [۲۳]. بنابراین، کاربران در شبکه‌های ارتباطی موج میلی‌متری باید نه تنها بهترین ایستگاه پایه، بلکه بهترین پرتو را برای اتصال در هر زمان خاص انتخاب کنند تا کیفیت خدمات خود را به حداکثر برسانند. پس انتخاب پرتو بهینه به عامل دیگری تبدیل شده که باید در فرآیند مدیریت انتقال به دلیل تعداد زیاد پرتوهایی که کاربر باید در طول هر نمونه انتقال انتخاب کند، در نظر گرفته شود که این موضوع پیچیدگی بیشتری را به فرآیند مدیریت انتقال اضافه می‌کند [۲۴]. در نتیجه، بهینه‌سازی کارآمد انتقال، امکان شناسایی بهترین پرتو و ایستگاه پایه برای اتصال کاربر را فراهم کرده و قدرت و کیفیت اتصال کاربر را به حداکثر رسانده و همزمان انتقال‌های اضافی یا غیر ضروری را به حداقل رسانده و در نهایت، شناسایی و اجتناب از موانع را، تسهیل می‌کند. در مقایسه‌ی شبکه‌های ارتباطی موج میلی‌متری با نسل‌های قبلی شبکه سلولی، موارد ذکر شده تنها برخی از مشکلاتی هستند که مدیریت بهینه‌سازی انتقال را دشوارتر می‌کنند. علاوه بر این، اکثر روش‌های سنتی مدیریت فرآیند انتقال بین سلولی را بسیار دشوار می‌دانند، زیرا به چندین فاکتور شبکه نیاز داشته که باید در زمان واقعی در نظر گرفته شوند و برای فعال کردن انتقال بی‌عیب و نقص تنظیم شوند. یکی از مشکل تکنیک‌های سنتی مدیریت انتقال نیاز به قدرت پردازش زیادی در زمان اجرا، به‌ویژه در شبکه‌ها با ابعاد و اندازه‌ی بزرگ است [۲۴]. ضمناً این الگوریتم‌ها قادر به ثبت دقیق برخی از ویژگی‌های شبکه مانند وجود موانع در اندازه‌ها و انواع مختلف و الگوهای تقاضای ترافیک پویا که مشخصه شبکه‌های نسل پنجم بوده، نیستند. با این وجود، رویکردهای یادگیری ماشین ممکن است به هوشمندسازی و پشتیبانی از بهینه‌سازی شبکه‌ها کمک کنند [۲۵].

تکنیک‌های یادگیری ماشین ممکن است برای یادگیری ویژگی‌های مختلف شبکه از داده‌های تولید شده توسط شبکه به‌منظور بهینه‌سازی ویژگی‌های مختلف شبکه مورد استفاده قرار گیرند. این تکنیک‌ها می‌توانند الگوها و جزئیات پنهانی از شبکه را که روش‌های تحلیلی عادی قادر به استخراج آنها نیستند، کشف کنند. این الگوریتم‌ها می‌توانند خواسته‌های آتی کاربران یا شبکه را پیش‌بینی کرده و از قبل به چنین درخواست‌هایی واکنش نشان دهند.

این تکنیک‌ها، شبکه را قادر می‌سازند تا در صورت رخداد درخواست‌های پیش‌بینی‌شده کاربران، آماده رسیدگی به آنها بوده و می‌توانند به طور مستقل با تغییرات در محیط شبکه، تطبیق یابند [۲۶].

بخش آموزش الگوریتم‌های یادگیری ماشین که اغلب از نظر محاسباتی فشرده است به‌صورت آفلاین انجام شده و از نظر محاسباتی بخش اجرایی الگوریتم شبکه را می‌توان به طور کارآمدتری، طراحی کرد. سپس، مدل آموزش‌دیده ممکن است به‌صورت آنلاین برای بهینه‌سازی بلادرنگ مورد استفاده قرار گرفته و فقط در زمان مواجهه با داده‌های جدید، به‌روزرسانی شود [۲۷].

۱-۲. مقدمه‌ای بر روش‌های مبتنی بر الگوریتم برای مدیریت فرایند انتقال بین سلول‌ها

این بخش از مقاله به بررسی روش‌های مبتنی بر الگوریتم برای مدیریت فرایند انتقال بین سلول‌ها می‌پردازد. در این روش‌ها، داده‌های خاصی به‌عنوان ورودی سیستم دریافت می‌شوند تا پردازش و تصمیم‌گیری درباره اقدامات انجام شوند. سپس از یک پارامتر شبکه برای ارزیابی عملکرد شبکه بر اساس این تصمیمات استفاده می‌شود. از آنجاکه شبکه‌های نسل پنجم و فراتر از آن دارای پیچیدگی‌های بسیاری هستند، مدیریت و پیکربندی عملیاتی این شبکه‌ها نیازمند روش‌های پیشرفته‌ای همچون هوش مصنوعی است [۲۸].

امروزه با افزایش پیچیدگی شبکه‌های سلولی نسل پنجم و رشد فناوری‌هایی نظیر اینترنت اشیا، متراکم‌سازی شبکه و ارتباطات موج میلی‌متری، مدیریت فرایند انتقال بین سلول‌ها به چالشی اساسی تبدیل شده است. استفاده از هوش مصنوعی و یادگیری ماشین به‌عنوان یک راهکار نوین برای بهینه‌سازی فرایند انتقال بین سلولی و کاهش اختلالات خدماتی در این شبکه‌ها مورد توجه قرار گرفته است. این الگوریتم‌ها قادرند با تجزیه و تحلیل پارامترهای کلیدی شبکه، تصمیمات بهینه‌ای برای افزایش کیفیت خدمات و کاهش تأخیر اتخاذ کنند. با این حال، چالش‌های متعددی در پیاده‌سازی این روش‌ها وجود دارد. مشکلاتی نظیر نیاز به داده‌های گسترده برای آموزش مدل‌ها، عدم پایداری عملکرد در شرایط مختلف، محدودیت در قابلیت توضیح‌پذیری تصمیمات و دشواری در تعمیم‌پذیری مدل‌ها، از موانع اصلی پذیرش گسترده هوش مصنوعی در مدیریت انتقال بین سلولی هستند. علاوه بر این، سازگاری این الگوریتم‌ها با محیط‌های پویای شبکه نسل پنجم، یک چالش مهم محسوب می‌شود. روش‌های مختلفی از یادگیری ماشین برای بهینه‌سازی انتقال بین سلولی استفاده شده است. شبکه‌های عصبی مصنوعی و درخت‌های تصمیم نیز در پیش‌بینی نقاط بهینه انتقال بین سلول‌ها، به کار رفته‌اند. همچنین، الگوریتم‌های یادگیری عمیق، مانند شبکه‌های عصبی کانولوشنی و شبکه‌های بازگشتی، برای تجزیه و تحلیل الگوهای جابه‌جایی کاربران و بهینه‌سازی فرایند انتقال بین سلول‌های شبکه پیشنهاد شده‌اند. در این میان، مدل‌های یادگیری تقویتی مانند یادگیری تقویتی ارزش‌محور یادگیری تقویتی عمیق امکان تطبیق هوشمند با تغییرات شبکه را بدون نیاز به مدل‌های از پیش تعریف‌شده فراهم کرده‌اند. تحقیقات اخیر نشان می‌دهند که ترکیب الگوریتم‌های یادگیری ماشین در قالب یادگیری ترکیبی یا یادگیری تقویتی عمیق می‌تواند به کاهش تعداد انتقال‌های غیرضروری، بهینه‌سازی منابع شبکه و افزایش کارایی کلی سیستم‌های نسل پنجم، منجر شود [۲۹].

با پیچیده‌تر شدن شبکه‌های نسل چهارم و پنجم و افزایش تعداد ایستگاه‌های پایه و اتصالات کاربر، مدیریت کارآمد فرایند انتقال بین سلولی و تخصیص منابع شبکه به یک چالش اساسی تبدیل شده است. روش‌های سنتی مبتنی بر مدل‌های تصادفی به دلیل عدم توانایی در مدیریت پارامترهای متغیر شبکه، عملکرد مطلوبی ارائه نداده و در این راستا، مدل‌های یادگیری ماشین برای پیش‌بینی و بهینه‌سازی عملکرد شبکه‌های سلولی، معرفی شده‌اند. این مدل‌ها قادرند با تحلیل پارامترهای کلیدی مانند قدرت سیگنال دریافتی، نسبت سیگنال به نویز، شاخص قدرت سیگنال دریافتی و کیفیت سیگنال، تصمیمات هوشمندانه‌ای در زمینه پوشش بهینه شبکه، کاهش تأخیر، و افزایش نرخ فرایند انتقال بین سلول‌ها اتخاذ کنند. در چارچوب پیشنهادی، مدل‌های یادگیری ماشین برای پیش‌بینی پهنای باند آموزش‌داده‌شده که نتایج نشان می‌دهد، دقت پیش‌بینی این مدل‌ها برای

سه اپراتور مختلف بین ۸۹ تا ۹۶ درصد متغیر بوده است. این دقت بالا، بیانگر قابلیت اطمینان به مدل‌ها به جهت بهینه‌سازی فرآیند انتقال بین سلول‌ها، بهبود کیفیت خدمات و افزایش رضایت کاربران است.

باتوجه به توانایی این الگوریتم‌ها در یادگیری از داده‌های شبکه و تطبیق با شرایط پویای ارتباطی، به‌عنوان یکی از مؤثرترین راهکارها برای مدیریت هوشمند شبکه‌های متراکم نسل پنجم محسوب می‌شوند. مدل‌های یادگیری ماشین در بهینه‌سازی شبکه‌های سلولی، به‌ویژه در شبکه‌های نسل پنجم، مزایای قابل‌توجهی از جمله دقت بالا در پیش‌بینی پهنای باند و بهبود کیفیت خدمات با تحلیل پارامترهای کلیدی مانند قدرت سیگنال دریافتی و نسبت سیگنال به نویز دارند. این الگوریتم‌ها قادر به یادگیری از داده‌های شبکه و تطبیق با شرایط پویای ارتباطی بوده که به شبکه کمک کرده که به طور مؤثر با تغییرات محیطی سازگار شود. با این حال، نیاز به داده‌های حجیم و پردازش پیچیده، کمبود شفافیت در تصمیم‌گیری‌های مدل‌های پیچیده و نیاز به آموزش‌های زمان‌بر از معایب آن‌ها به شمار می‌رود. علاوه بر این، ممکن است این مدل‌ها در شبکه‌هایی با شرایط خاص عملکرد ضعیف‌تری داشته و نیاز به بازآموزی مستمر در محیط‌های پر تغییر داشته باشند [۳۰].

شبکه‌های عصبی مصنوعی، با الهام از عملکرد مغز انسان، یکی از روش‌های کارآمد یادگیری ماشین برای مدیریت انتقال بین سلولی در شبکه‌های نسل پنجم محسوب می‌شوند. این مدل‌ها با پردازش پارامترهای کلیدی شبکه مانند قدرت سیگنال دریافتی، نسبت سیگنال به نویز و کیفیت سیگنال به پیش‌بینی زمان و مکان بهینه انتقال بین سلولی کمک می‌کنند. به‌عنوان مثال، یک شبکه عصبی با دو زیر شبکه، برای تصمیم‌گیری در مورد زمان شروع انتقال بین سلولی طراحی شده که با تحلیل داده‌های کیفیت خدمات و کیفیت تجربه کاربر، تأخیر را کاهش داده و از قطع ناگهانی ارتباط جلوگیری می‌کند. استفاده از شبکه‌های عصبی عمیق و بازگشتی نیز در پیش‌بینی جابجایی کاربران و بهینه‌سازی فرایند انتقال بین سلولی مؤثر بوده است. با این حال، چالش‌هایی مانند نیاز به پردازش پر قدرت، تأخیر در استنتاج و دشواری در توضیح‌پذیری تصمیمات مدل‌های عصبی، پیاده‌سازی گسترده آن‌ها را محدود کرده است. به نظر می‌رسد، تحقیقات آینده بر بهینه‌سازی معماری شبکه‌های عصبی و کاهش پیچیدگی محاسباتی متمرکز خواهد بود. شبکه‌های عصبی در مدیریت انتقال بین سلول‌ها، دارای مزایای قابل‌توجهی مانند بهبود دقت پیش‌بینی زمان و مکان انتقال بین سلولی و افزایش پایداری ارتباطات در شبکه‌های نسل پنجم، هستند. این مدل‌ها با پردازش داده‌های مربوط به کیفیت خدمات و کیفیت تجربه کاربر، می‌توانند تأخیر را کاهش داده و از قطع ناگهانی ارتباط جلوگیری کنند. علاوه بر این، شبکه‌های عصبی عمیق و بازگشتی توانایی پیش‌بینی جابجایی کاربران و بهینه‌سازی فرایند انتقال بین سلول‌ها را دارند. با این حال، نیاز به توان پردازشی بالا و تأخیر در استنتاج مدل‌ها از معایب آن محسوب می‌شود. همچنین، شفافیت پایین در تصمیم‌گیری و پیچیدگی محاسباتی در پیاده‌سازی عملی این مدل‌ها، از چالش‌های مهمی است که نیاز به تحقیقات بیشتر دارد [۳۱].

یادگیری عمیق، به‌عنوان یکی از شاخه‌های یادگیری ماشین مبتنی بر شبکه‌های عصبی چندلایه‌ای، نقش مهمی در بهینه‌سازی فرایند انتقال بین سلولی در شبکه‌های نسل پنجم را دارد. این روش، قادر به شناسایی روابط پیچیده بین داده‌های ورودی و پیش‌بینی دقیق تغییرات شبکه است. برخلاف روش‌های سنتی که بر اساس مقایسه قدرت سیگنال و پارامترهای اولیه که بر اساس زمان فعال‌سازی انتقال و پدیده پسماند تصمیم‌گیری می‌کنند، مدل‌های یادگیری عمیق از داده‌های گسترده شبکه برای تحلیل الگوهای انتقال بین سلولی و اتخاذ تصمیمات بهینه، استفاده می‌کنند. مدل پیشنهادی در این زمینه، از شبکه‌های حافظه بلندمدت کوتاه‌مدت، برای پیش‌بینی قدرت سیگنال‌های منبع، بهره می‌برد. در مرحله بعد، خروجی این پیش‌بینی‌ها به یک الگوریتم طبقه‌بندی دودویی ارسال می‌شود تا تعیین کند که آیا این داده‌ها منجر به فعال‌سازی انتقال بین سلولی شدن خواهند شد یا خیر. این مدل، با دقت بیش از ۹۷ درصد، توانسته، لحظه دقیق فعال‌سازی انتقال بین سلولی را شناسایی کند. نتایج نشان می‌دهند که این رویکرد می‌تواند باعث کاهش قطعی‌های ناگهانی، بهینه‌سازی جابجایی کاربران و افزایش بهره‌وری در شبکه‌های نسل پنجم شود. علاوه بر این، پیاده‌سازی این مدل در معماری‌های شبکه‌های دسترسی رادیویی بازو محاسبات لبه چنددسترسی، امکان بهبود عملکرد شبکه را فراهم می‌کند. این روش برخلاف تکنیک‌های سنتی، به‌جای استفاده از پارامترهای اولیه ثابت، از داده‌های گسترده شبکه، برای تحلیل الگوهای جابجایی کاربران، استفاده می‌کند. مزیت کلیدی آن توانایی کاهش قطعی‌های ناگهانی، بهینه‌سازی جابجایی کاربران و افزایش بهره‌وری در نسل پنجم است. با این حال، نیاز به توان پردازشی بالا، پیچیدگی در پیاده‌سازی و نیاز به مدیریت منابع کارآمدتر از معایب آن محسوب می‌شود [۳۲].

با رشد شبکه‌های فوق متراکم در شبکه‌های نسل پنجم و افزایش تعداد ایستگاه‌های پایه، تجهیزات کاربری با تعداد زیادی فرایند انتقال بین سلولی مواجه شده که می‌تواند منجر به افزایش اثر پینگ‌پنگ و کاهش کیفیت خدمات شود. منطق فازی به‌عنوان یک روش انعطاف‌پذیر و تطبیق‌پذیر، برای مدیریت تصمیمات انتقال بین سلولی در شرایط نامشخص معرفی شده است. یک سیستم فرایند انتقال بین سلولی مبتنی بر منطق فازی شامل سه مرحله اصلی است. این مراحل به ترتیب، فازی‌سازی و تبدیل داده‌های عددی دقیق به مجموعه‌های فازی، موتور استنتاج به معنای، تحلیل داده‌ها با قوانین "اگر و آنگاه" و دیفازی‌سازی یعنی، تبدیل خروجی‌های فازی به مقادیر دقیق است. مدل تکنیک تصمیم‌گیری پویای تحویل مبتنی بر منطق فازی معرفی شده در این مقاله، به‌صورت پویا مقدار حاشیه تحویل مدیریت انتقال بین سلولی و زمان تا آستانه را تنظیم می‌کند. این مدل از نسبت سیگنال به نویز و سرعت حرکت کاربر به‌عنوان ورودی‌های کنترل‌کننده فازی بهره می‌برد. نتایج شبیه‌سازی با برنامه‌ی ns-3 نشان می‌دهد که این مدل نسبت به روش‌های سنتی، تعداد دست‌به‌دست شدن‌های غیرضروری را کاهش داده، اثر پینگ‌پنگ را کنترل کرده و توان عملیاتی کلی شبکه را بهبود می‌بخشد. این مدل به دلیل انعطاف‌پذیری در تنظیم آستانه‌ها، کارایی بهتری در مدیریت فرایند انتقال بین سلول‌ها در محیط‌های متراکم نسل پنجم دارد. مزیت اصلی این رویکرد توانایی کاهش تعداد انتقال بین سلول‌های غیرضروری و بهینه‌سازی توان عملیاتی شبکه است. با این حال، وابستگی زیاد به تنظیمات اولیه‌ی قوانین فازی و پیچیدگی در طراحی سیستم‌های فازی پویا از چالش‌های اصلی آن محسوب می‌شود. همچنین، نیاز به پردازش بیشتر در مقایسه با مدل‌های کلاسیک ممکن است در شبکه‌های بسیار بزرگ، عملکرد سیستم را تحت تأثیر قرار دهد [۳۳].

نظریه بازی‌ها به‌عنوان یک ابزار مدل‌سازی تصمیم‌گیری، می‌تواند در مدیریت فرایند انتقال بین سلولی در شبکه‌های ناهمگن متراکم به کار گرفته شود. در این رویکرد، ایستگاه‌های پایه به‌عنوان بازیکنان بازی در نظر گرفته شده که برای افزایش توان انتقال خود و بهبود عملکرد شبکه رقابت می‌کنند. مدل نظریه بازی‌ها، از یک بازی غیرهمکارانه استفاده می‌کند که در آن هر ایستگاه پایه تلاش می‌کند با تنظیم بهینه توان انتقال، میزان انتقال‌های غیرضروری بین سلول‌ها را کاهش دهد. نقطه تعادل این بازی، تعادل نش بوده که در آن هر ایستگاه پایه، بدون تغییر استراتژی، بیشترین بازده را به دست می‌آورد. در این مدل، تابع بازده، میزان افزایش توان انتقال، مصرف انرژی، بار ایستگاه پایه و انتقال‌های بین سلولی غیرضروری را در نظر می‌گیرد. در این روش، انتخاب بهترین سلول با الگوریتم رتبه‌بندی بر اساس شباهت به گزینه ایده‌آل انجام می‌شود. شبیه‌سازی‌های انجام‌شده نشان داده که این مدل باعث افزایش توان عملیاتی شبکه، کاهش مصرف انرژی، متعادل‌سازی بار شبکه و کاهش انتقال‌هایی غیرضروری بین سلول‌ها شده و در نهایت کیفیت خدمات را در شبکه‌های نسل پنجم بهبود می‌بخشد. مدیریت انتقال بین سلول‌ها مبتنی بر نظریه بازی‌ها در شبکه‌های متراکم ناهمگن، امکان کاهش انتقال‌های غیرضروری بین سلولی، افزایش توان عملیاتی و بهینه‌سازی مصرف انرژی را فراهم می‌کند. در این مدل، ایستگاه‌های پایه به‌عنوان بازیکنان یک بازی غیرهمکارانه در نظر گرفته شده و با تنظیم بهینه توان انتقال، عملکرد شبکه را بهبود می‌بخشند. با این حال، پیچیدگی محاسباتی مدل‌های نظریه بازی، نیاز به اطلاعات دقیق از وضعیت شبکه، دشواری پیاده‌سازی و رفتار غیرهمکارانه ایستگاه‌های پایه در محیط‌های واقعی از چالش‌های مهم آن محسوب شده و ممکن است در برخی شرایط منجر به تعارض منافع و ناپایداری شبکه شود [۳۴].

داده‌های کلان نقش مهمی در بهینه‌سازی فرایند انتقال بین سلولی در شبکه‌های ناهمگن و فوق متراکم در نسل پنجم دارند. با توجه به افزایش تعداد کاربران، حجم بالای داده‌های ترافیکی و تنوع پارامترهای شبکه، روش‌های سنتی مدیریت انتقال بین سلول‌ها، کارایی لازم را ندارند. الگوریتم‌های یادگیری ماشین مبتنی بر داده‌های کلان، امکان پیش‌بینی رفتار انتقال بین سلولی در سطح سلولی و بهینه‌سازی فرایند انتقال بین سلول‌ها را فراهم می‌کنند. مدل پیشنهادی در این زمینه، از داده‌های کلان برای تحلیل شاخص‌های کلیدی عملکرد فرایند انتقال بین سلولی استفاده می‌کند و می‌تواند تعداد تلاش‌های انتقال بین سلولی در آینده را پیش‌بینی کرده و رفتارهای غیرعادی فرایند انتقال بین سلولی را تشخیص دهد. در یک مطالعه واقعی، بیش از ۶۰۰۰ سلول از یک شبکه مخابراتی در طول دو سال مورد بررسی قرار گرفت. نتایج نشان داد که مدل داده‌محور، قادر به تفکیک الگوهای انتقال بین سلول‌ها و کاهش دستورات کنترلی غیرضروری است.

این روش نه تنها باعث افزایش بازده طیفی و کاهش تأخیر فرایند انتقال بین سلولی می‌شود، بلکه می‌تواند از بروز مشکلاتی مانند دست‌به‌دست شدن‌های غیرضروری و اثر پینگ‌پنگ جلوگیری کند. استفاده از تحلیل داده‌های ترافیکی و الگوهای جابجایی کاربران، به افزایش دقت تصمیم‌گیری در فرایند انتقال بین سلولی شده و به بهبود کیفیت خدمات کمک می‌کند.

استفاده از داده‌های کلان در مدیریت انتقال بین سلول‌ها شبکه‌های نسل پنجم، امکان تحلیل دقیق رفتار انتقال بین سلولی، پیش‌بینی تلاش‌های انتقال بین سلول‌ها و کاهش دستورات کنترلی غیرضروری را فراهم می‌کند. این روش با بررسی شاخص‌های کلیدی عملکرد می‌تواند الگوهای تحرک کاربران را شناسایی و تأخیر فرایند انتقال بین سلول‌ها را کاهش دهد. مزیت اصلی این رویکرد، بهینه‌سازی بازده طیفی و جلوگیری از اثر پینگ‌پنگ در شبکه‌های متراکم است. با این حال، پیچیدگی پردازش حجم عظیم داده‌ها، نیاز به زیرساخت‌های ذخیره‌سازی قدرتمند و مدیریت داده‌های بلادرنگ از چالش‌های آن محسوب [۳۵].

مدیریت فرایند انتقال بین سلولی در شبکه‌های فوق متراکم با سلول‌های کوچک به دلیل افزایش تعداد ایستگاه‌های پایه و ترافیک داده‌ها، چالش‌های متعددی را ایجاد کرده است. استفاده از الگوریتم‌های پیشرفته هوش مصنوعی و یادگیری تقویتی برای بهینه‌سازی فرایند دست‌به‌دست شدن، به یکی از راهکارهای کلیدی در بهبود کیفیت خدمات و کاهش تأخیر انتقال تبدیل شده است. در این روش‌ها، پارامترهایی مانند ظرفیت ایستگاه پایه، مسیر حرکت کاربر، کیفیت سیگنال دریافتی، نسبت سیگنال به نویز و میزان ترافیک داده‌ها به عنوان ورودی‌های کلیدی در فرایند تصمیم‌گیری انتقال بین سلول‌ها در نظر گرفته می‌شوند. مدل‌های یادگیری تقویتی قادرند به صورت پویا سیاست‌های فرایند انتقال بین سلولی را بر اساس شرایط لحظه‌ای شبکه بهینه‌سازی کنند. یکی از روش‌های کارآمد در این زمینه، الگوریتم‌های یادگیری تقویتی عمیق بوده که از شبکه‌های عصبی برای تخمین مقادیر بهینه فرایند انتقال بین سلولی استفاده می‌کند. همچنین، یک روش شش مرحله‌ای شامل پیکربندی، تصمیم‌گیری، فیلتر کردن، محدودسازی، انتخاب قوی‌ترین سیگنال و آغاز فرایند انتقال بین سلولی طراحی شده است که موجب افزایش نرخ داده‌های کاربران، کاهش تعداد انتقال‌های غیرضروری و بهبود بهره‌وری شبکه می‌شود. علاوه بر یادگیری تقویتی، استفاده از الگوریتم‌های بهینه‌سازی چندمعیاره مانند الگوریتم ژنتیک و روش‌های مبتنی بر فرایند تصمیم‌گیری چندمعیاره، می‌توانند انتخاب ایستگاه پایه را بهینه‌تر کرده و تأخیر و ازدست‌رفتن بسته‌ها را کاهش دهد. این روش‌ها به‌ویژه در شبکه‌های متراکم نسل پنجم که شامل سلول‌های کوچک هستند، منجر به بهبود مدیریت فرایند انتقال بین سلولی و افزایش عملکرد کلی شبکه، خواهند شد. با این حال، پیچیدگی بالای پردازش، نیاز به آموزش‌های طولانی، مصرف زیاد منابع محاسباتی، وابستگی به کیفیت داده‌های ورودی و مشکل تطبیق این الگوریتم‌ها با شرایط واقعی شبکه‌های متراکم از چالش‌های این روش‌ها محسوب شده و می‌توانند اجرای عملی آن‌ها را دشوار کند [۳۶].

یکی از چالش‌های اساسی در شبکه‌های نسل پنجم، بهینه‌سازی کیفیت خدمات و کاهش تأخیر در انتقال است. در راستای مدیریت فرایند انتقال بین سلولی، الگوریتم‌های فراابتکاری به دلیل قابلیت‌های جستجوی تطبیقی و توانایی مقابله با پیچیدگی‌های محیطی، مورد توجه قرار گرفته‌اند. در پژوهشی، رویکردی ترکیبی مبتنی بر الگوریتم گرگ خاکستری و الگوریتم بهینه‌سازی شمع و پروانه، برای بهینه‌سازی فرایند تحویل در شبکه‌های ناهمگن معرفی شده است. این مدل، فرایند انتقال بین سلولی را در سه مرحله‌ی، مقداردهی اولیه، انتخاب شبکه و اجرای انتقال، ساماندهی می‌کند. در مرحله اول، پارامترهای کلیدی مانند سطح توان سیگنال، میزان مصرف انرژی و الزامات کیفیت خدمات، ارزیابی شده و تصمیم اولیه برای انجام تحویل اتخاذ می‌شود. در مرحله انتخاب، معیارهای چندگانه‌ای همچون سرعت کاربر، امنیت شبکه و بار ترافیکی برای تعیین مقصد بهینه انتقال در نظر گرفته می‌شود. در نهایت، در مرحله اجرا، ترکیب قابلیت‌های اکتشافی الگوریتم گرگ خاکستری و ویژگی‌های همگرایی سریع الگوریتم بهینه‌سازی شمع و پروانه به کار گرفته می‌شود تا فرایند تحویل با کمترین تأخیر و بیشترین بهره‌وری انجام شود. نتایج شبیه‌سازی‌ها نشان می‌دهد که مدل پیشنهادی در مقایسه با روش‌های متداول مبتنی بر تئوری بازی‌ها برای بهینه‌سازی و تسریع فرایند تحویل بین شبکه‌ای مانند، شبکه عصبی فازی، الگوریتم‌های زنبور عسل و بهینه‌سازی ذرات، باعث کاهش مصرف انرژی، تأخیر انتقال و احتمال قطع تماس شده و در عین حال توان عملیاتی را بهبود داده است. این رویکرد، به‌ویژه در محیط‌های متراکم نسل پنجم، قادر به کاهش تعداد انتقال‌های غیرضروری و بهینه‌سازی عملکرد شبکه است. اما پیچیدگی محاسباتی و وابستگی به تنظیمات اولیه از جمله چالش‌های آن محسوب می‌شود [۳۷].

۲-۲. پژوهش‌های مرتبط با عملیات انتقال بین سلولی

مطابق با جدول (۱) می‌توان دید که مطالعه و تحلیل مقالات مختلف در زمینه مدیریت انتقال بین سلول‌ها در شبکه‌های نسل پنجم و به‌ویژه در شبکه‌های فوق متراکم، نشان‌دهنده تحقیقات و تلاش‌های فراوانی است که در جهت بهینه‌سازی فرایند انتقال

بین سلولی انجام شده است. باوجود دستاوردهای قابل توجه، بسیاری از چالش ها و کاستی ها در این پژوهش ها قابل مشاهده است که نیاز به بررسی دقیق تری دارند.

جدول ۱: پژوهش های مرتبط با عملیات انتقال بین سلولی

Table 1: Related Research on Intercellular Transfer Operations

نام پژوهشگر	سال انتشار	عنوان پژوهش	خلاصه پژوهش	مزایا	معایب
سنتیل کومار تیلاگویندان و همکاران [۲۹]	۲۰۲۴	A Comprehensive Survey on Machine Learning Methods for Handover Optimization Networks in 5G	روش های یادگیری ماشین برای بهینه سازی فرایند انتقال بین سلولی در شبکه های نسل پنجم. چالش های موجود در مدیریت انتقال بین سلولی، تحلیل و تکنیک های یادگیری ماشین برای کاهش تأخیر و بهبود کیفیت خدمات	بهینه سازی پیش بینی عملکرد شبکه، تحلیل پارامترهای کلیدی انعطاف پذیری در مواجهه با تغییرات شبکه، استفاده از داده های واقعی	نیاز به داده های حجیم و پردازش پیچیده، کمبود شفافیت در تصمیم گیری، آموزش های زمان بر و پیچیده
عباس آل- تهمدان و همکاران [۳۰]	۲۰۲۴	A machine learning framework for predicting downlink throughput in 4G-LTE/5G cellular networks	یک مدل یادگیری ماشین برای پیش بینی پهنای باند در شبکه های نسل چهارم و پنجم. استفاده از داده های سیگنال دریافتی و کیفیت سیگنال برای پیش بینی نرخ انتقال داده ها جهت بهینه سازی عملکرد شبکه های موبایل و پیش بینی ترافیک داده ها در شرایط مختلف	دقت بالا در پیش بینی پهنای باند و بهبود کیفیت خدمات با تحلیل پارامترهای کلیدی مانند قدرت سیگنال دریافتی و نسبت سیگنال به نویز، یادگیری از داده های شبکه و تطبیق با شرایط پویای ارتباطی	نیاز به داده های حجیم و پردازش پیچیده، کمبود شفافیت در تصمیم گیری های مدل های پیچیده و نیاز به آموزش های زمان بر
مایکل اس. مولل و همکاران [۳۱]	۲۰۲۱	A Survey of Machine Learning Applications to Handover Management in 5G and beyond	کاربردهای یادگیری ماشین در مدیریت انتقال بین سلولی در شبکه های نسل پنجم. کمک به بهینه سازی فرایند انتقال بین سلولی با مدل های مختلف یادگیری ماشین در محیط های مختلف، تحلیل دست بندی چالش ها و فرصت های پیشروی استفاده از این الگوریتم ها	بهبود دقت پیش بینی زمان و مکان انتقال بین سلولی، افزایش پایداری ارتباطات در شبکه های نسل پنجم، کاهش تأخیر و جلوگیری از قطع ناگهانی ارتباط	نیاز به توان پردازشی بالا و تأخیر در استنتاج مدل ها، شفافیت پایین در تصمیم گیری، پیچیدگی محاسباتی در پیاده سازی عملی
ژوآنو پی. اس. اچ. لیما و همکاران [۳۲]	۲۰۲۳	Deep Learning-Based Handover Prediction for 5G and Beyond Networks	یک مدل یادگیری عمیق مبتنی بر شبکه های عصبی حافظه طولانی، کوتاه مدت برای پیش بینی دقیق فرایند انتقال بین سلولی در شبکه های نسل پنجم و پیش بینی لحظه بهینه انتقال بین سلولی با استفاده از داده های قدرت سیگنال و تحلیل الگوهای حرکت کاربران با دقت بیش از ۹۷ درصد	توانایی کاهش قطعی های ناگهانی، بهینه سازی جابجایی کاربران و افزایش بهره وری در شبکه های نسل پنجم	نیاز به توان پردازشی بالا و پیچیدگی در پیاده سازی
ون-شیانگ هوانگ و همکاران [۳۳]	۲۰۲۲	Adaptive Handover Decision Using Fuzzy Logic for 5G Ultra-Dense Networks	استفاده از منطق فازی برای اتخاذ تصمیمات پویا در فرایند انتقال بین فوق متراکم. مدل پیشنهادی با استفاده از ورودی های قدرت سیگنال به نویز و سرعت حرکت کاربر ارائه شده که قادر به کاهش انتقال های غیرضروری بین سلولی، افزایش کیفیت خدمات و بهبود بهره وری شبکه شده است.	توانایی کاهش تعداد انتقال های غیرضروری بین سلولی و بهینه سازی توان عملیاتی شبکه	وابستگی زیاد به تنظیمات اولیه قوانین فازی و پیچیدگی در طراحی سیستم های فازی پویا، نیاز به پردازش بیشتر در مقایسه با مدل های کلاسیک
محمد الهابو و همکاران [۳۴]	۲۰۱۹	Game theoretic handover optimization for dense small cells heterogeneous networks	مدل سازی فرایند انتقال بین سلولی به عنوان یک بازی غیرهمکارانه بین ایستگاه های پایه در شبکه های ناهمگن با سلول های کوچک. تعادل نش برای بهینه سازی مصرف توان، تعادل بار شبکه و کاهش تعداد انتقال بین سلولی غیرضروری، کاهش تأخیر و افزایش کارایی در شبکه های نسل پنجم.	تخصیص بهینه منابع و افزایش کیفیت خدمات	پیچیدگی محاسباتی مدل های نظریه بازی، نیاز به اطلاعات دقیق از وضعیت شبکه و دشواری پیاده سازی در محیط های واقعی
امیر حیدر و همکاران [۳۶]	۲۰۲۲	An Overview of Reinforcement Learning Algorithms for Handover Management in 5G Ultra-Dense Small Cell Networks	بررسی الگوریتم های یادگیری تقویتی در مدیریت انتقال بین سلولی در شبکه های فوق متراکم با سلول های کوچک نسل پنجم و استفاده از داده های شبکه، یادگیری از تجربیات گذشته در تصمیم گیری انتقال بین سلولی	کاهش تعداد انتقال های غیرضروری بین سلولی، افزایش بهره وری و بهبود کیفیت خدمات	پیچیدگی بالای پردازش، نیاز به آموزش های طولانی و مصرف زیاد منابع محاسباتی
پاتی و همکاران [۳۷]	۲۰۲۲	A novel approach for optimization of handover mechanism using metaheuristics algorithms	استفاده از الگوریتم های فراابتکاری به دلیل قابلیت های جستجوی تطبیقی و توانایی مقابله با پیچیدگی های محیطی، رویکردی ترکیبی مبتنی بر الگوریتم گرگ خاکستری و الگوریتم بهینه سازی شمع و پروانه، برای بهینه سازی فرایند تحویل در شبکه های ناهمگن	کاهش مصرف انرژی، کاهش تأخیر انتقال و کاهش احتمال قطع تماس بهبود توان عملیاتی	پیچیدگی محاسباتی و وابستگی به تنظیمات اولیه

یکی از مهم‌ترین نقاط قوت مقالات بررسی‌شده، استفاده از یادگیری ماشین و الگوریتم‌های پیشرفته مانند یادگیری تقویتی و یادگیری عمیق برای پیش‌بینی و بهینه‌سازی فرایند انتقال بین سلول‌ها است. این روش‌ها به‌خوبی نقطه‌ضعف‌های روش‌های سنتی که بیشتر بر مبنای مقایسه قدرت سیگنال تمرکز داشتند، پوشش می‌دهند و توانسته‌اند دقت بالایی را در پیش‌بینی انتقال بین سلول‌ها ارائه دهند. به‌ویژه مدل‌های مبتنی بر شبکه عصبی حافظه طولانی کوتاه‌مدت در پیش‌بینی زمان انتقال بین سلول‌ها با دقت بالای ۹۷ درصد، نشان‌دهنده توانایی‌های بالقوه این الگوریتم‌ها در شرایط مختلف شبکه است. با این حال، یکی از نقاط ضعف عمده این رویکردها، وابستگی زیاد آن‌ها به داده‌های شبیه‌سازی‌شده است. در بیشتر مقالات بررسی‌شده، الگوریتم‌ها با داده‌های شبیه‌سازی‌شده، ارزیابی شده‌اند و کمتر توجهی به داده‌های واقعی شبکه شده است. این امر باعث ایجاد فاصله‌ای بین کاربرد مدل‌ها در شرایط واقعی و عملکرد آن‌ها در محیط‌های آزمایشی می‌شود. داده‌های واقعی، به دلیل داشتن پیچیدگی‌ها و تغییرات لحظه‌ای، چالش‌های خاص خود را داشته که در بسیاری از این مدل‌ها به خوبی پوشش داده نشده است.

علاوه بر این، بسیاری از مدل‌های یادگیری ماشین که در مقالات به آن‌ها اشاره شده است با توجه به محاسبات پیچیده و نیاز به پردازش‌های سنگین، در شبکه‌های واقعی که باید در زمان واقعی پاسخ‌دهی کنند، ممکن است با مشکل مواجه شوند. این کاهش کارایی در عمل می‌تواند تأخیرهای بیشتر، مصرف بالای انرژی و بار شبکه را به همراه داشته باشد. نکته دیگری که در بسیاری از مقالات ذکر نشده است، عدم توجه کافی به تعاملات مختلف بین پارامترهای شبکه است. به طور مثال، درحالی‌که برخی مدل‌ها به پیش‌بینی دقیق زمان انتقال بین سلول‌ها می‌پردازند، کمتر به تأثیر متغیرهایی مانند ترافیک شبکه، ظرفیت ایستگاه پایه یا بار شبکه توجه شده است. این متغیرها می‌توانند تأثیر قابل توجهی بر پایداری و بهینه‌سازی فرایند انتقال بین سلول‌ها داشته باشند. در کنار این مسائل، برخی از مدل‌ها که بر نظریه بازی‌ها یا منطق فازی تأکید دارند، به طور معناداری به تعاملات پویا و واقعی شبکه‌ها توجه نمی‌کنند. استفاده از نظریه بازی‌ها برای مدل‌سازی تصمیم‌گیری‌های ایستگاه‌های پایه ممکن است در شرایط خاصی مؤثر باشد، اما در شبکه‌هایی که تحت شرایط بسیار متغیر قرار دارند، نیاز به توجه بیشتر به رفتارهای واقعی و پیچیده بوده که در بسیاری از این مقالات به آنها توجه زیادی نشده است.

در نهایت، به‌رغم پیشرفت‌های تکنولوژیکی که در استفاده از یادگیری ماشین و الگوریتم‌های بهینه‌سازی پیشرفته مشاهده می‌شود، همچنان چالش‌های زیادی برای اعمال این روش‌ها در شبکه‌های واقعی نسل پنجم وجود دارد. مدل‌های موجود، علی‌رغم داشتن دقت بالا در شرایط خاص آزمایشی، در کاربردهای عملیاتی شبکه‌های فوق متراکم و ناهمگن به‌سختی می‌توانند عملکرد بهینه‌تری را ارائه دهند. در نتیجه، تحقیقات آینده باید به مقایسه و اعتبارسنجی بیشتر مدل‌ها در محیط‌های واقعی پرداخته و تلاش کنند تا پیچیدگی‌های محاسباتی را کاهش دهند. همچنین، ترکیب چندین رویکرد و الگوریتم می‌تواند به ایجاد مدل‌های جامع‌تری کمک کرده که علاوه بر پیش‌بینی دقیق انتقال بین سلول‌ها، بتواند تمام پارامترهای تأثیرگذار بر عملکرد شبکه را نیز در نظر بگیرد.

۳. روش پیشنهادی

در این پژوهش، یک چارچوب هوشمند مبتنی بر یادگیری ماشین برای بهینه‌سازی فرایند انتقال بین سلول‌ها در شبکه‌های نسل پنجم ارائه شده است. روش پیشنهادی شامل سه رویکرد مختلف: روش موازی، روش سری و روش ترکیبی بوده که هر یک دارای مزایا و چالش‌های خاص خود هستند. در روش موازی، سه الگوریتم خوشه‌بندی K-Means، DBSCAN و GMM به‌صورت هم‌زمان اجرا شده و خروجی آن‌ها از طریق رأی‌گیری اکثریت ترکیب می‌شود. در روش سری، الگوریتم‌های خوشه‌بندی به‌صورت مرحله‌ای اجرا شده و خروجی هر مدل به‌عنوان ورودی مدل بعدی مورد استفاده قرار می‌گیرد که در نهایت منجر به افزایش دقت و کاهش نویز در فرایند خوشه‌بندی می‌شود. در روش ترکیبی، ابتدا سه الگوریتم خوشه‌بندی به‌صورت موازی اجرا می‌شوند و سپس خروجی آن‌ها به یک مدل یادگیری متوالی داده می‌شود که عملکرد کلی سیستم را بهبود داده و تعادل میان سرعت پردازش و دقت خوشه‌بندی را فراهم می‌کند. در تمامی این روش‌ها، یک مدل یادگیری متا، مبتنی بر جنگل تصادفی برای تجزیه و تحلیل و بهینه‌سازی نهایی خوشه‌بندی مورد استفاده قرار می‌گیرد. هدف اصلی این پژوهش، کاهش تعداد انتقال‌های

غیرضروری بین سلول‌ها، افزایش پایداری ارتباطات و بهبود کیفیت تجربه کاربر در شبکه‌های نسل پنجم است. در ادامه، ورودی‌ها، خروجی‌ها و فرایند داخلی سیستم پیشنهادی به تفصیل موردبررسی قرار می‌گیرد.

مطابق با شکل (۳) در این پژوهش مراحل جمع‌آوری و پیش‌پردازش داده‌ها و برای هر سه روش مشابه بوده و شرح زیر توصیف می‌گردد. در پایان ضمن مقایسه‌ی خروجی هر سه روش پیشنهادی، مزایا و معایب هریک تشریح میشود.


۳-۱. انتخاب الگوریتم‌های خوشه بندی:

هدف اصلی این پژوهش مقایسه و بررسی کارایی سه ساختار اجرایی، سری، موازی و ترکیبی در تعامل با سه الگوریتم پایه با قابلیت‌های بنیادین بوده که در طراحی چارچوب پیشنهادی این پژوهش، انتخاب سه الگوریتم خوشه‌بندی K-Means، DBSCAN و GMM باهدف پوشش‌دادن نقاط قوت متنوع و مکمل در فرایند خوشه‌بندی داده‌ها، انجام شد. الگوریتم-K Means به دلیل سادگی، سرعت بالا در اجرا و توانایی تقسیم‌بندی داده‌ها در قالب خوشه‌های کروی‌شکل با استفاده از حداقل واریانس درون خوشه‌ای، به‌عنوان یک نقطه شروع منطقی برای تحلیل خوشه‌بندی انتخاب شده است. باوجود این مزایا، این الگوریتم دارای محدودیت‌هایی نظیر وابستگی به تعداد اولیه‌ی خوشه‌ها و حساسیت بالا به داده‌های پرت است. استفاده از نسخه‌های پیشرفته‌تر یا بهینه‌سازی‌شده‌ی K-Means، مانند K-Means++ [38] یا الگوریتم‌های مبتنی بر الگوریتم‌های تکاملی، گرچه می‌توانند نتایج بهتری از منظر همگرایی اولیه فراهم آورند، اما این نسخه‌ها همچنان محدودیت‌های اساسی-K Means از جمله، فرض توزیع کروی، اندازه‌های مشابه خوشه‌ها، حساسیت به نویز و نقاط پرت را حفظ کرده و تمرکز پژوهش را از ارزیابی ساختارهای ترکیبی و تعامل بین مدل‌ها به سمت بهبود عملکرد یک الگوریتم خاص منحرف می‌کنند. لذا در این مرحله، استفاده از نسخه کلاسیک K-Means به‌عنوان نماینده‌ای ساده و شفاف برای ارزیابی روش‌های ترکیبی و مقایسه عملکرد سه‌گانه ترجیح داده شد است.

از سوی دیگر، الگوریتم DBSCAN به‌عنوان یک الگوریتم چگالی محور، قابلیت شناسایی خوشه‌هایی با شکل‌های نامنظم و حذف نقاط نویز را دارد. این ویژگی، آن را به گزینه‌ای مناسب برای تحلیل داده‌هایی با توزیع غیریکسان و نویز بالا، نظیر محیط‌های پیچیده شبکه‌های سلولی، تبدیل کرده است. الگوریتم GMM نیز با رویکردی مبتنی بر توزیع‌های آماری گاوسی، قادر به مدل‌سازی دقیق‌تر روابط آماری میان نمونه‌ها بوده و انعطاف‌پذیری بالاتری نسبت به K-Means در شناسایی خوشه‌هایی با توزیع‌های متنوع دارد.

۳-۲. جمع‌آوری داده‌ها:

در این مرحله و مطابق با شکل (۳)، اطلاعات مربوط به قدرت سیگنال دریافتی، موقعیت جغرافیایی کاربران، سرعت کاربران و وضعیت سلول‌های شبکه، جمع‌آوری می‌شود. داده‌ها از طریق سنسورها، تجهیزات شبکه و شبیه‌سازی‌های نرم‌افزاری، دریافت می‌شوند. این داده‌ها به عنوان ورودی الگوریتم‌های خوشه‌بندی و یادگیری ماشین استفاده می‌شوند.



شکل ۳: مراحل جمع‌آوری و پیش‌پردازش داده‌ها
Figure 3: Stages of Data Collection and Preprocessing

۳-۳. پیش‌پردازش داده‌ها:


به دلیل وجود نویز در داده‌های جمع‌آوری‌شده، مقادیر پرت یا مقیاس‌های نامتوازن نیاز به پیش‌پردازش دارند. مراحل پیش‌پردازش شامل پاک‌سازی، نرمال‌سازی و کاهش ویژگی‌های زائد است. این داده‌های خام، شامل طول و عرض جغرافیایی، توان متوسط دریافت سیگنال از منبع، کیفیت سیگنال دریافتی از منبع، نسبت سیگنال به نویز و فاصله از دکل بوده که ابتدا برای اطمینان از کیفیت داده‌ها، مراحل زیر در پیش‌پردازش انجام می‌شود:

- حذف داده‌های ناقص: مقادیر ناقص و داده‌های غیرمعتبر شناسایی و حذف می‌شوند.
- نرمال‌سازی ویژگی‌ها: ویژگی‌ها با استفاده از تکنیک حداقل، حداکثر به اعداد پیوسته‌ی بازه بین ۰ و ۱ تبدیل می‌شوند.

- انتخاب ویژگی های کلیدی: فقط ویژگی های مرتبط با خوشه بندی انتخاب شده تا الگوریتم ها بر داده های مهم تمرکز کنند.
- این مرحله تضمین می کند که داده ها آماده ورود به مراحل بعدی بوده و هرگونه نویز یا تناقض در داده ها حذف شده است.

۳-۴. ورودی ها و خروجی های سیستم:

- ۳-۳-۱- مطابق با شکل (۴)، ورودی های سیستم، شامل داده ها و پارامترهایی است که برای خوشه بندی و تحلیل فرآیند انتقال مورد استفاده قرار می گیرند. این داده ها به شرح زیر هستند:
- قدرت سیگنال دریافتی: نشان دهنده کیفیت سیگنال دریافتی توسط دستگاه کاربر بوده که این پارامتر به طور مستقیم در فرایند تصمیم گیری انتقال تأثیرگذار است.
- موقعیت جغرافیایی کاربران: اطلاعات مکانی کاربران به صورت مختصات طول و عرض جغرافیایی ویژگی به خوشه بندی دقیق تر کاربران و شناسایی بهترین ایستگاه پایه برای اتصال، کمک می کند.
- سرعت کاربران: سرعت حرکت کاربران که معمولاً در واحد متر بر ثانیه یا کیلومتر بر ساعت اندازه گیری می شود. کاربران با سرعت بالا به ویژه در محیط های شهری یا پرتراکم معمولاً به تعداد بیشتری انتقال نیاز دارند.
- وضعیت سلول های شبکه: شامل اطلاعاتی مانند بار شبکه، ظرفیت سلول ها و پوشش دهی است. این ویژگی تأثیر مستقیمی بر مدیریت انتقال دارد.
- الگوی حرکت کاربران: شامل مسیرهای پرتدد یا مناطقی که کاربران در آن توقف بیشتری دارند است. این الگوها به پیش بینی رفتار کاربران و بهبود فرایند انتقال کمک می کنند.
- ۳-۳-۲- خروجی های سیستم شامل نتایج حاصل از بهبود فرآیند انتقال و بهینه سازی خوشه بندی داده ها بوده که عبارتند از:
- کاهش تعداد انتقال ها: کاهش دفعات انتقال کاربران بین سلول های شبکه به پایداری بیشتر ارتباط و بهبود تجربه کاربری منجر می شود.
- افزایش کیفیت: بهبود کیفیت ارتباط کاربران از طریق کاهش تأخیر و ناپایداری.
- خوشه بندی بهینه کاربران: توزیع مناسب کاربران در خوشه های مختلف برای مدیریت بهتر منابع شبکه.
- انتخاب بهترین الگوریتم انتقال: شناسایی و استفاده از الگوریتمی که عملکرد بهتری در کاهش تعداد انتقال های بین سلولی داشته و در نتیجه منجر به افزایش کیفیت خدمات شبکه شود.




شکل ۴: ورودی‌ها و خروجی‌های سیستم
Figure 4: Inputs and Outputs of the System

۳-۵. مراحل و نتایج روش پیشنهادی به صورت موازی

در این بخش، مطابق با شکل (۵)، عملکرد الگوریتم‌های خوشه‌بندی به صورت موازی اجرا شده و با هدف بهینه‌سازی فرآیند مدیریت انتقال بین سلول‌ها در شبکه‌های نسل پنجم، مورد بررسی قرار می‌گیرد. در روش موازی، هم‌زمان سه الگوریتم K-Means، DBSCAN و GMM اجرا و خروجی آن‌ها با استفاده از یادگیری ترکیبی، ترکیب می‌شود. در این مرحله با روش موازی به با تحلیل امکان بهره‌برداری از نقاط قوت هر الگوریتم و کاهش تأثیر نقاط ضعف، انتخاب شده است. روش پیشنهادی موازی شامل چهار مرحله اصلی و به شرح زیر است:

۳-۵-۱. اجرای الگوریتم‌های خوشه‌بندی:

پس از مراحل پیش پردازش، سه الگوریتم خوشه بندی K-Means، DBSCAN و GMM برای دسته بندی داده ها به خوشه های مشابه اجرا و سپس هر الگوریتم به طور مستقل عمل کرده و خوشه های متفاوتی ایجاد می کنند. بدین ترتیب، الگوریتم K-Means داده ها را به پنج خوشه مجزا تقسیم می کند. این الگوریتم نقاط داده را بر اساس فاصله اقلیدسی از مراکز خوشه تخصیص داده که به دلیل سادگی و سرعت بالا، عملکرد مناسبی در خوشه بندی داده ها دارد.



شکل ۵: استفاده موازی از الگوریتم های خوشه بندی

Figure 5: Parallel use of clustering algorithms

همزمان، الگوریتم DBSCAN خوشه بندی داده ها را بر اساس تراکم نقاط انجام داد و نقاط نویز که تراکم کمتری داشتند شناسایی و حذف می کند. این الگوریتم توانایی شناسایی خوشه های با شکل های نامنظم را دارد. الگوریتم GMM توزیع داده ها را بر اساس مدل های گاوسی تخمین زده و توانایی بالایی در مدلسازی از خوشه ها با توزیع پیچیده دارد. در مرحله ی بعد با ترکیب نتایج به دست آمده و با روش یادگیری ترکیبی، خروجی سه الگوریتم توسط، روش رأی گیری اکثریت ترکیب شده اند. در این روش، هر نقطه داده ای به خوشه ای که بیشترین توافق میان الگوریتم ها را داشت اختصاص یافت است.

۳-۶- مراحل و نتایج روش پیشنهادی به صورت سری:

روش سری، یکی از رویکردهای قدرتمند در خوشه بندی داده ها بوده که در آن از خروجی هر الگوریتم به عنوان ورودی مدل بعدی استفاده می شود. در این رویکرد، داده ها به صورت سلسله مراتبی پردازش شده و اطلاعات به تدریج غنی تر می شوند. هدف از این روش، بهینه سازی فرایند خوشه بندی و تصمیم گیری نهایی است. مراحل اجرای روش سری به شرح زیر است:

۳-۶-۱. اجرای مدل های پایه


در روش سری، سه مرحله پایه به ترتیب و به صورت متوالی اجرا می شوند. این مراحل به گونه ای طراحی شده اند که هر کدام خروجی مرحله قبلی را به عنوان ورودی دریافت کنند و اطلاعات بیشتری استخراج کنند. نکته ی قابل توجه ترتیب قرار گرفتن الگوریتم های خوشه بندی است که ابتدا ترتیب مناسب تر را مطابق با جدول (۲) بررسی و انتخاب می کنیم.

جدول ۲: مقایسه ترتیب اجرای الگوریتم‌های خوشه‌بندی

Table 2: Comparison of the execution order of clustering algorithms

سناریو	ترتیب اجرا	مزایا	معایب
K-Means → DBSCAN → GMM	ابتدا خوشه‌بندی کلی انجام می‌شود، سپس نقاط پرت حذف شده و در نهایت مدل‌سازی پیشرفته انجام می‌شود.	سرعت بالاتر در ابتدای کار، کاهش نویز در مرحله دوم، دقت بیشتر در خوشه‌بندی نهایی.	وابستگی خروجی به پارامترهای اولیه K-Means ممکن است باعث کاهش دقت شود.
DBSCAN → K-Means → GMM	ابتدا حذف نویز و نقاط پرت، سپس خوشه‌بندی استاندارد و در نهایت مدل‌سازی پیشرفته.	خوشه‌بندی تمیزتر با حذف نویز از ابتدا، کاهش تأثیر داده‌های نامعتبر.	اجرای DBSCAN در مرحله اول ممکن است برای دیتاست‌های بزرگ کند باشد.

به نظر می‌رسد که در سناریوی اول (K-Means → DBSCAN → GMM) انتخاب بهتری انجام شده، زیرا ابتدا داده‌ها را به‌طور کلی خوشه‌بندی کرده و سپس نقاط پرت حذف می‌شود و در نهایت خوشه‌بندی دقیق‌تر با مدل GMM صورت می‌گیرد. در این مدل، داده‌های پیش پردازش شده را دریافت و خوشه‌بندی اولیه انجام می‌دهد. خروجی این مرحله شامل برچسب‌های اولیه بوده که داده‌ها را به گروه‌های اولیه تقسیم می‌کند. این خوشه‌ها بر اساس الگوریتمی مانند K-Means ایجاد می‌شوند.



شکل ۶: استفاده سری از الگوریتم‌های خوشه‌بندی


Figure 6: Using a series of clustering algorithms

شکل (۶)، روند کلی اجرای روش خوشه‌بندی سری را برای بهینه‌سازی فرآیند انتقال بین سلول‌ها در شبکه‌های نسل پنجم نشان می‌دهد. در این روش، سه الگوریتم خوشه‌بندی به‌صورت متوالی اجرا می‌شوند، به‌گونه‌ای که خروجی هر الگوریتم، ورودی الگوریتم بعدی را تشکیل می‌دهد. ابتدا، K-Means خوشه‌بندی اولیه داده‌ها را انجام می‌دهد و گروه‌های اولیه را مشخص می‌کند. سپس الگوریتم DBSCAN برای حذف نویزها و نقاط پرت اعمال می‌شود و خوشه‌بندی را بر اساس چگالی داده‌ها بهبود می‌بخشد. در مرحله بعد الگوریتم GMM به‌عنوان یک روش مبتنی بر توزیع احتمالاتی، خوشه‌بندی نهایی را انجام داده

و خوشه‌ها را با دقت بالاتری تنظیم می‌کند. در پایان، ترکیب و بهینه‌سازی نهایی مبتنی بر جنگل تصادفی با تحلیل ویژگی‌های خروجی از سه الگوریتم پایه، خوشه‌های نهایی را بهینه‌سازی کرده و تصمیم‌گیری نهایی را انجام می‌دهد. هدف از این فرآیند، کاهش غیرضروری انتقال بین سلول‌ها، بهبود پایداری اتصال و افزایش کیفیت تجربه کاربر در شبکه‌های نسل پنجم است.

۳-۷. روش یادگیری ترکیبی (ترکیب دو روش سری و موازی)

در این مرحله روش ترکیبی مبتنی بر یادگیری متا برای بهینه‌سازی فرایند انتقال بین سلول‌ها را تحلیل می‌کنیم.



شکل ۷: ترکیب روش سری و موازی

Figure 7: Combination of series and parallel methods

شکل (۷)، روند اجرای روش یادگیری ترکیبی مبتنی بر یادگیری متا را نمایش می‌دهد. در این روش، ابتدا داده‌های خام تحت یک فرآیند پیش‌پردازش قرار گرفته و آماده‌سازی می‌شوند. سپس، داده‌های پردازش‌شده به صورت موازی وارد سه الگوریتم خوشه‌بندی می‌شوند. هر یک از این الگوریتم‌ها، خروجی متفاوتی را از نظر توزیع خوشه‌ها تولید می‌کنند. این خروجی‌ها به‌عنوان ویژگی‌های جدید در یک دیتاست واسط ذخیره شده و وارد مرحله بعدی می‌شوند.

در مرحله بعد، مدل متا که بر پایه یک الگوریتم یادگیری ماشین، مانند جنگل تصادفی یا XGBoost عمل می‌کند، خروجی سه الگوریتم خوشه‌بندی را بررسی کرده و الگوی بهینه‌ای را برای خوشه‌بندی نهایی انتخاب می‌کند. این مدل یاد می‌گیرد که کدام الگوریتم در چه شرایطی عملکرد بهتری دارد و چگونه می‌توان ترکیب بهینه‌ای از خوشه‌بندی‌های مختلف را ایجاد کند. به‌جای تصمیم‌گیری خطی و ساده، مدل متا بر اساس داده‌های موجود، تصمیم‌گیری بهینه‌ای را انجام داده و خوشه‌های نهایی را مشخص می‌کند. این روش ترکیبی با ترکیب قدرت تحلیل مدل‌های پایه در بخش موازی و دقت مدل متا در بخش یادگیری تقویتی، عملکرد بهینه‌ای ارائه می‌دهد. خروجی نهایی شامل یک مجموعه خوشه‌بندی بهینه‌شده است که می‌تواند به‌عنوان یک راهکار کارآمد و دقیق برای مدیریت انتقال بین سلول‌ها در شبکه‌های نسل پنجم مورد استفاده قرار گیرد.

۴. نتایج

در پژوهش حاضر، سه رویکرد متفاوت برای خوشه‌بندی داده‌ها و مدیریت فرایند انتقال در شبکه‌های نسل پنجم مورد بررسی و مقایسه قرار گرفته است. روش‌های سری، روش موازی و ترکیبی که هر یک از این روش‌ها ویژگی‌ها، مزایا و معایب خاص خود را داشته که در ادامه این روش‌ها با جزئیات تحلیل شده و روش بهینه‌ی پیشنهادی برای استفاده در سناریوهای عملی معرفی می‌گردد.

۴-۱. داده‌های مورد استفاده

داده‌های مورد استفاده در این پژوهش از مجموعه داده "Drive Test Measurements" استخراج شده که در مخزن GitHub موجود است. مطابق با جدول (۳)، این مجموعه شامل داده‌های واقعی اندازه‌گیری شده از آزمایش رانندگی است که برای تحلیل فرآیند انتقال بین سلولی در شبکه‌های نسل پنجم جمع‌آوری شده است. داده‌ها در محیط واقعی ثبت شده و شامل متغیرهای کلیدی مرتبط با کیفیت سیگنال، موقعیت جغرافیایی، شرایط تداخل و ویژگی‌های توپولوژیکی شبکه است. این مجموعه داده در قالب سه فایل CSV ارائه شده که شامل پارامترهای مهمی همچون قدرت و کیفیت سیگنال دریافتی، نسبت توان حامل به نویز، شناسه فیزیکی سلول، موقعیت جغرافیایی، فاصله از ایستگاه پایه، ارتفاع کاربر، زاویه آنتن و سایر ویژگی‌های مرتبط با ارتباطات بی‌سیم است. این ویژگی‌ها، امکان بررسی تأثیر شرایط مختلف محیطی بر فرایند انتقال بین سلولی و تحلیل الگوهای تغییر اتصال کاربران متحرک را فراهم می‌کند. هدف از استفاده از این مجموعه داده، مدل‌سازی فرایند انتقال بین سلولی و بهینه‌سازی آن از طریق الگوریتم‌های یادگیری ماشین و روش‌های خوشه‌بندی است. با بهره‌گیری از داده‌های این مجموعه، می‌توان تأثیر تراکم ایستگاه‌های پایه، تغییرات کیفیت سیگنال و موقعیت کاربران را بر عملکرد شبکه تحلیل کرده و مدل‌های پیش‌بینی و کاهش نرخ انتقال بین سلولی را توسعه داد.

جدول ۳: ویژگی مهم دیتاست استفاده شده در پژوهش

Table 3: Important features of the dataset used in the research

ویژگی	توضیح
Lat & Lon	موقعیت جغرافیایی کاربر بر حسب طول و عرض جغرافیایی
RSRP (Reference Signal Received Power)	قدرت سیگنال دریافتی از ایستگاه پایه (dBm)
RSRQ (Reference Signal Received Quality)	کیفیت سیگنال دریافتی (dB)
CINR (Carrier to Interference plus Noise Ratio)	نسبت توان حامل به تداخل و نویز (dB)
PCI (Physical Cell Identity)	شناسه فیزیکی سلول که نشان‌دهنده BS متصل شدن است
Height (m)	ارتفاع کاربر از سطح دریا (متر)
Distance (m)	فاصله کاربر از ایستگاه پایه (متر)
Azimuth	زاویه آنتن ایستگاه پایه نسبت به شمال (درجه)
Elevation	زاویه ارتفاع آنتن نسبت به سطح افق (درجه)

۴-۲. سخت‌افزار و محیط اجرای کد و تست‌ها

تمامی پردازش و شبیه‌سازی‌های این پژوهش با استفاده از زبان برنامه‌نویسی پایتون و در محیط گوگل کولب انجام شده است. گوگل کولب، یک پلتفرم ابری مبتنی بر کتابخانه جونپیر بوده که امکان اجرای کدهای پایتون بدون نیاز به منابع محلی و با پشتیبانی از پردازشگرهای گرافیکی و پردازنده‌های تنسور را فراهم می‌کند. این محیط به دلیل دسترسی به سخت‌افزار قدرتمند ابری، قابلیت اجرای موازی مدل‌های پیچیده یادگیری ماشین و کاهش زمان پردازش الگوریتم‌ها انتخاب شده است. از لحاظ مشخصات سخت‌افزاری، گوگل کولب از واحد پردازشی مرکزی با معماری چند هسته‌ای، حافظه رم ۱۶ گیگابایت و در صورت فعال‌سازی از پردازنده‌های گرافیکی سری NVIDIA Tesla پشتیبانی می‌کند که در بهینه‌سازی محاسبات مربوط به یادگیری ماشین و خوشه‌بندی داده‌ها، نقش مهمی دارد. از لحاظ نرم‌افزاری، کتابخانه‌های کلیدی مورد استفاده شامل Scikit-learn برای الگوریتم‌های خوشه‌بندی و یادگیری ماشین، Pandas و NumPy برای پردازش داده‌ها و Matplotlib و

Seaborn برای بصری سازی نتایج استفاده شده است. این ترکیب سخت افزار و نرم افزاری، امکان اجرای بهینه و کارآمد مدل های یادگیری ماشین و تحلیل فرایند مدیریت انتقال بین سلولی در شبکه های نسل پنجم را فراهم کرده است.

۳-۴. طراحی مراحل آزمایش و ارزیابی عملکرد روش های پیشنهادی

به منظور تحلیل و ارزیابی عملکرد روش های پیشنهادی در بهینه سازی فرایند مدیریت انتقال بین سلولی، آزمایش های این پژوهش در سه مرحله اصلی سازمان دهی شده است. در هر مرحله، پارامترهای کلیدی شبکه اندازه گیری شده و سه روش های پیشنهادی از جنبه های مختلف مقایسه شده اند. این آزمایش ها با هدف بررسی میزان تأثیر روش های پیشنهادی در کاهش نرخ فرایند مدیریت انتقال بین سلولی، بهبود کیفیت تجربه کاربری و افزایش بهره وری شبکه های نسل پنجم و فراتر از آن طراحی شده است.

۱-۳-۴. مرحله اول: آماده سازی داده ها و پیش پردازش اولیه

به منظور اجرای صحیح مدل های پیشنهادی و دستیابی به نتایج قابل اعتماد، در مرحله نخست، داده های مورد استفاده در این پژوهش مورد تحلیل، پالایش و آماده سازی قرار می گیرند. مجموعه داده های استفاده شده، شامل اطلاعات متعددی نظیر قدرت سیگنال دریافتی، کیفیت سیگنال، نسبت توان به نویز، موقعیت جغرافیایی، فاصله کاربر از ایستگاه پایه و سایر پارامترهای محیطی مؤثر بر فرایند مدیریت انتقال بین سلولی است. در این مرحله، ابتدا داده های پرت و نویزی حذف شده و مقادیر نامعتبر اصلاح می شوند تا از تأثیر منفی آن ها بر عملکرد مدل جلوگیری شود. سپس، داده ها به منظور افزایش دقت خوشه بندی و مدل سازی الگوریتم های یادگیری ماشین، نرمال سازی و استاندارد سازی می شود. علاوه بر این، توزیع ویژگی های کلیدی بررسی شده و ارتباط میان آن ها تحلیل می شود تا تأثیر هر متغیر بر فرایند مدیریت انتقال بین سلولی مشخص گردد. این مرحله نه تنها تضمین کننده صحت و دقت مدل هاست بلکه از تأثیر پارامترهای غیر ضروری و نویزهای آماری در مراحل بعدی جلوگیری می کند.

۲-۳-۴. مرحله دوم: اجرای مدل های خوشه بندی برای تحلیل فرایند مدیریت انتقال بین سلولی

پس از تکمیل مرحله پیش پردازش، داده های آماده شده برای اجرای روش های پیشنهادی پردازش خواهند شد. در این مرحله، سه روش مجزا برای تحلیل فرایند انتقال بین سلولی و تشخیص الگوهای تغییر اتصال کاربران بین ایستگاه های پایه پیاده سازی می شود. در روش موازی، الگوریتم های K-Means، DBSCAN و GMM به صورت همزمان بر روی مجموعه داده ها اعمال شده و نتایج آن ها با استفاده از تکنیک های یادگیری ترکیبی مانند رأی گیری اکثریت یا وزن دهی نتایج مدل ها، ترکیب می شوند. در روش سری، الگوریتم ها به صورت متوالی اجرا شده و خروجی هر مدل، ورودی مدل بعدی را تشکیل می دهد تا پردازش خوشه بندی در یک ساختار مرحله ای بهینه شود. در روش ترکیبی، دو روش قبلی ادغام شده و مدلی ارائه می شود که از مزایای روش های سری و موازی به صورت همزمان بهره مند باشد. در این مرحله، کیفیت خروجی خوشه بندی با استفاده از معیارهایی نظیر امتیاز پراکندگی و شاخص دیویس - بولدین ارزیابی شده و میزان همگن بودن و تفکیک پذیری خوشه ها مورد بررسی قرار می گیرد.

۳-۳-۴. مرحله سوم: ارزیابی عملکرد روش ها و تحلیل نهایی

در مرحله پایانی، روش های پیشنهادی از جنبه های مختلف مورد تحلیل و مقایسه عملکردی قرار می گیرند تا کارآمدترین روش برای بهینه سازی مدیریت انتقال بین سلولی در شبکه های نسل پنجم شناسایی شود. در این مرحله، پارامترهای کلیدی دقت، نرخ صحت، میزان بازیابی و امتیاز میانگین هارمونیک، محاسبه شده و عملکرد مدل های مختلف بر اساس نرخ انتقال بین سلولی، تأخیر انتقال، نرخ توان عملیاتی کیفیت تجربه کاربری ارزیابی می شود. همچنین، میزان تأثیر هر روش بر کاهش تعداد انتقال های غیر ضروری، بهبود پوشش دهی شبکه و افزایش پایداری اتصال کاربران بررسی خواهد شد. در این بخش، نتایج به صورت جدول های

مقایسه‌ای و نمودارهای تحلیلی ارائه شده و برتری یا ضعف هر روش به طور دقیق مشخص می‌شود. در نهایت، نتایج آزمایش‌ها نشان خواهد داد که کدام روش دقت بالاتر، نرخ فرایند مدیریت انتقال بین سلولی پایین‌تر و عملکرد بهینه‌تری ارائه می‌دهد و چگونه یادگیری ماشین می‌تواند در مدیریت انتقال بین سلولی شبکه‌های نسل پنجم، نقش مؤثری داشته باشد.

جدول ۴: وضعیت سیگنال دریافتی از ایستگاه‌های پایه و تأثیر آن‌ها بر کیفیت ارتباطات

Table 4: Status of the received signal from base stations and its impact on communication quality


شاخص	طول جغرافیایی	عرض جغرافیایی	توان سیگنال دریافتی	کیفیت سیگنال دریافتی	نسبت توان سیگنال به نویز	شناسه فیزیکی سلول	ارتفاع ایستگاه پایه	فاصله تا ایستگاه پایه	زاویه آنتن	زاویه شیب سیگنال
0	-44.01509	-	-64.5	-10.5	-20.0	112	845.0	689.82	136.58	-3.62
1	-44.01645	-	-64.5	-10.5	-20.0	112	852.1	907.68	135.01	-2.30
2	-44.01684	-	-64.5	-10.5	-20.0	112	853.4	1007.50	132.61	-2.00
3	-44.01687	-	-64.5	-10.5	-20.0	112	854.0	1015.29	132.44	-1.95
4	-44.01725	-	-80.2	-10.4	-16.0	398	860.2	4505.74	112.44	-0.57

داده‌های ارائه شده در جدول (۴) نشان‌دهنده وضعیت سیگنال‌های دریافتی از ایستگاه‌های پایه و تأثیر آن‌ها بر کیفیت ارتباطات در یک محیط خاص است. مقدار توان سیگنال دریافتی در بازه ۶۴.۵- تا ۸۰.۲- دسیبل بر متر قرار دارد که نشان‌دهنده تفاوت در قدرت سیگنال دریافتی در نقاط مختلف است. مقدار کیفیت سیگنال دریافتی نیز نشان می‌دهد که کیفیت سیگنال در برخی نقاط پایین بوده که احتمال تداخل و نویز را افزایش می‌دهد. نسبت توان سیگنال به نویز نیز بیانگر میزان نویز موجود در محیط بوده و در مقادیر منفی قرار دارد. این امر می‌تواند عملکرد شبکه را تحت تأثیر قرار داده و منجر به افزایش میزان خطا و افت توان عملیاتی شود. بررسی موقعیت جغرافیایی داده‌ها نشان می‌دهد که نقاط اندازه‌گیری شده از یک منطقه مشخص انتخاب شده اما مقدار فاصله تا ایستگاه پایه نشان از تغییرات ناگهانی در فاصله تا ایستگاه‌های پایه است. به طوری که در نمونه چهارم این فاصله به ۴۵۰۵ متر افزایش یافته که این امر می‌تواند ناشی از تغییر موقعیت ناگهانی کاربر یا تغییر اتصال بین ایستگاه‌های پایه باشد. مقدار شناسه فیزیکی سلول نشان می‌دهد که در این آزمایش دو ایستگاه پایه با مقادیر ۱۱۲ و ۳۹۸ دخیل بوده‌اند که می‌تواند تأثیر مستقیمی بر فرایند انتقال بین سلولی داشته باشد. علاوه بر این، مقادیر زاویه آنتن بین ۱۱۲ تا ۱۳۶ درجه متغیر است که جهت ارسال سیگنال ایستگاه‌های پایه را مشخص می‌کند. در نهایت، مقدار زاویه شیب سیگنال و در رنج منفی، نشان می‌دهد که ایستگاه‌های پایه سیگنال‌های خود را به سمت پایین و کاربران زمینی متمرکز کرده‌اند. بررسی این داده‌ها نشان می‌دهد که به دلیل کاهش قدرت سیگنال در برخی نقاط و افزایش فاصله بین ایستگاه‌های پایه، فرایند انتقال بین سلولی می‌تواند منجر به کاهش کیفیت خدمات و تجربه کاربری شود که این امر نیاز به بهینه‌سازی مدیریت انتقال بین سلولی را بااهمیت و برجسته می‌سازد.

۴-۴. اجرای الگوریتم‌های خوشه‌بندی در روش موازی


در این روش، برای ارزیابی کیفیت خوشه‌بندی، امتیاز پراکندگی برای هر الگوریتم محاسبه شده است. در خصوص خوشه‌بندی و پس از اعمال روش رأی‌گیری اکثریت به روش موازی و مطابق با پراکندگی در شکل (۸) می‌توان مشاهده کرد که داده‌ها به خوشه‌های مشخص و جدا از یکدیگر تقسیم و هر خوشه با رنگی متفاوت نمایش داده شده‌اند. رنگ‌ها نشان‌دهنده خوشه‌های مختلف پس از اعمال رأی‌گیری اکثریت و نوار رنگیسمت راست، شماره خوشه‌ها را بر روی محور عمودی مشخص می‌کند. داده‌های مربوط به موقعیت‌های مختلف کاربران در شبکه به چندین خوشه تقسیم شده که مشاهده می‌شود، برخی مناطق دارای

تراکم بالا بوده که گروه‌بندی قوی در آن بخش‌ها نشان می‌دهند. می‌توان دید که روش پیشنهادی توانسته داده‌ها را به خوشه‌های مجزا دسته‌بندی کند



شکل ۸: پراکندگی در خوشه‌بندی به روش موازی
Figure 8: Dispersion in clustering using the parallel method

رویکرد رأی‌گیری اکثریت در روش موازی به‌خوبی توانسته داده‌های مکانی را به خوشه‌های مشخص دسته‌بندی کند. مناطق با رنگ‌های یکنواخت، عملکرد صحیح خوشه‌بندی و دسته‌بندی مناسب کاربران شبکه را می‌توان مشاهده کرد.



شکل ۹: امتیاز پراکندگی و نمودار حرارتی رأی‌گیری اکثریت در خوشه‌بندی به روش موازی
Figure 9: Dispersal score and heat map of majority voting in clustering using parallel methods.

تحلیل نتایج شکل (۹) نشان می‌دهد که خوشه‌بندی و عملکرد روش‌های مختلف مدل رأی‌گیری اکثریت در روش موازی توانسته است توزیع معناداری از خوشه‌ها را ارائه دهد اما با افت نسبی دقت در مقایسه با الگوریتم‌های پایه روبه‌رو است. بررسی نمودار پراکندگی خوشه‌بندی نهایی نشان می‌دهد که نقاط داده‌ای در مناطق پرتراکم شبکه به‌درستی گروه‌بندی شده‌اند، اما در برخی موارد، ناهماهنگی بین خروجی سه الگوریتم، منجر به کاهش دقت در تصمیم‌گیری نهایی شده است. از سوی دیگر، مقایسه مقدار امتیاز پراکندگی در بین مدل‌های مختلف حاکی از عملکرد بالاتر K-Means و GMM نسبت به روش موازی است که می‌تواند به دلیل حساسیت این مدل‌ها به ساختار خوشه‌بندی داده‌ها باشد.


باین‌حال، نتایج حاصل از نمودار حرارتی رأی‌گیری اکثریت نشان می‌دهد که این روش توانسته است نتایج مدل‌های مختلف را با درصد بالایی از هم‌پوشانی ترکیب کند. اگرچه در برخی موارد، تخصیص نامناسب خوشه‌ها به دلیل وجود نقاط نویزی در DBSCAN رخ داده است. این یافته‌ها تأکید می‌کنند که روش رأی‌گیری اکثریت، علی‌رغم کاهش نوسانات خوشه‌بندی و ایجاد یکپارچگی در نتایج، همچنان نیازمند تنظیمات بهینه‌تری برای افزایش دقت نهایی است.

در روش موازی، مدل‌های مختلف خوشه‌بندی به طور هم‌زمان بر روی داده‌ها اجرا شده و نتایج هر یک از الگوریتم‌ها به صورت جداگانه محاسبه می‌شوند. سپس، با استفاده از تکنیک‌هایی نظیر رأی‌گیری اکثریت یا وزن‌دهی، خروجی نهایی تعیین می‌شود. مزیت اصلی این روش، قابلیت استفاده هم‌زمان از چندین مدل با ویژگی‌های مختلف است که به کاهش وابستگی به یک مدل خاص و افزایش استحکام خوشه‌بندی کمک می‌کند. علاوه بر این، پردازش موازی منجر به افزایش سرعت اجرا می‌شود، چرا که هر مدل به صورت مستقل عمل کرده و از محاسبات اضافی جلوگیری می‌شود. این استراتژی به بهبود دقت و پایداری خوشه‌بندی کمک می‌کند.

با این حال، عیب اصلی این روش عدم تطابق بین مدل‌های مختلف است. به این معنا که هر الگوریتم خوشه‌بندی ممکن است خروجی‌های ناسازگاری تولید کند که در مرحله تجمیع ممکن است به کاهش دقت کلی منجر شود. همچنین، تصمیم‌گیری در مورد نحوه ترکیب نتایج مدل‌ها مانند رأی‌گیری یا وزن‌دهی، می‌تواند پیچیده بوده و نیاز به تنظیمات دقیق دارد.


۴-۵. اجرای الگوریتم‌های خوشه‌بندی در روش سری

نتایج به دست آمده از اجرای روش سری بر روی مجموعه داده‌ها در سه نمودار ارائه شده است که تحلیل دقیقی از عملکرد خوشه‌بندی و مقایسه آن با روش‌های دیگر ارائه می‌دهد. نمودار اول، یک پراکندگی از خوشه‌بندی نهایی بر اساس روش سری را نمایش می‌دهد که در آن ابتدا خوشه‌بندی با الگوریتم K-Mean انجام شده، سپس خروجی آن به عنوان ورودی به الگوریتم DBSCAN داده شده و در نهایت الگوریتم GMM روی خروجی حاصل از مرحله دوم اعمال شده است. همان‌طور که در شکل (۱۰) مشاهده می‌شود، نقاط جغرافیایی خوشه‌های مختلف با رنگ‌های متفاوت مشخص شده‌اند. ترکیب این سه الگوریتم باعث شده است که خوشه‌ها از نظر تراکم و مرزهای خوشه‌بندی بهبود یابند اما برخی از مناطق همچنان دارای هم‌پوشانی بوده که می‌تواند ناشی از تفاوت در حساسیت الگوریتم‌های مورد استفاده باشد.



شکل ۱۰: پراکندگی در خوشه‌بندی به روش سری

Figure 10: Dispersion in clustering by series method



شکل ۱۱: امتیاز پراکندگی و نمودار حرارتی رای گیری اکثریت در خوشه بندی به روش سری
Figure 11: Scatter score and heatmap of majority voting in clustering using the series method

در شکل (۱۱) که مقایسه ی امتیاز پراکندگی بین مدل های مختلف را نمایش می دهد، مشاهده می شود که هر سه الگوریتم پایه مقادیر تقریباً مشابهی دارند و عملکرد آن ها در ایجاد خوشه های معنادار نسبتاً مطلوب بوده است. اما میزان انسجام خوشه ها در مدل نهایی روش سری در مقایسه با مدل های منفرد بررسی نشده است که می تواند نکته ای برای بهبود رویکرد باشد. در نهایت، نقشه حرارتی، نشان دهنده نتایج نهایی دسته بندی در مراحل مختلف است. در این نمودار، میزان هماهنگی خروجی های الگوریتم های مختلف در ۲۰ داده ی ابتدایی نشان داده شده است. مشاهده می شود که خوشه های اختصاص داده شده در برخی موارد دچار تغییرات قابل توجهی بین مراحل مختلف هستند که نشان می دهد روش سری ممکن است به دلیل وابستگی به خروجی های مرحله قبل در برخی موارد دچار تغییرات ناپایدار شود. این نکته می تواند در کاربردهای حساس نیازمند بهینه سازی بیشتر باشد.

به طور کلی، روش سری در مقایسه با روش موازی، قدرت بیشتری در بهینه سازی خوشه بندی دارد، زیرا خروجی هر مرحله، اطلاعات تکمیلی برای مرحله بعدی فراهم می کند، اما از سوی دیگر، حساسیت این روش به کیفیت خروجی مرحله ی قبلی، یکی از نقاط ضعف آن محسوب می شود.

۴-۵-۱. مزایا و معایب اجرای سری الگوریتم ها


روش سری با اجرای مدل ها به صورت متوالی و تغذیه خروجی یک مدل به عنوان ورودی مدل بعدی، امکان پالایش تدریجی داده ها را فراهم می کند. مزیت کلیدی این روش توانایی پالایش نتایج است به این صورت که مدل های بعدی می توانند خروجی های مدل های قبلی را اصلاح کرده و کیفیت خوشه بندی را افزایش دهند. این روش به خصوص در سناریوهایی که داده ها دارای نویز بالا هستند، عملکرد مطلوبی دارد، زیرا هر مدل امکان فیلتر کردن ناپایداری های مدل های قبلی را دارد. از دیگر مزایای روش سری می توان استفاده تدریجی از اطلاعات، دقت بالاتر و ایجاد یک دیتاست غنی تر را نام برد.

از معایب این روش می توان به افزایش پیچیدگی محاسباتی اشاره کرد، چرا که اجرای متوالی مدل ها زمان پردازش را به طور قابل توجهی افزایش می دهد. همچنین، این روش به شدت وابسته به انتخاب ترتیب مناسب مدل ها است؛ اگر مدل های نامناسبی در ابتدا قرار بگیرند، ممکن است نتایج نهایی تحت تأثیر منفی قرار گیرند و کیفیت خوشه بندی کاهش یابد.

روش سری نسبت به روش موازی دقت بالاتری دارد؛ اما هزینه و زمان پردازشی بیشتری نیز نیاز دارد. چراکه برخلاف روش موازی که تمامی الگوریتم ها همزمان اجرا می شوند، در این روش هر مرحله به بهبود نتایج مرحله قبل کمک کرده و دقت خوشه بندی نهایی را افزایش می دهد.


۴-۶. اجرای الگوریتم های خوشه بندی در روش ترکیبی

در روش یادگیری ترکیبی که ترکیبی از روش های موازی و سری است، فرایند خوشه بندی بهینه تری ارائه می شود. شکل (۱۲) نشان دهنده ی پراکندگی داده ها و نتایج خوشه بندی در این روش است. استفاده از یادگیری ترکیبی باعث شده است که تخصیص نقاط به خوشه ها نسبت به روش های دیگر دقیق تر انجام شود که این امر به دلیل ترکیب مزایای هر دو رویکرد موازی و سری است. مناطق متمایز در این تصویر نشان دهنده ی قدرت این روش در کاهش تداخل بین خوشه ها و افزایش دقت در تفکیک داده ها است.



شکل ۱۲: پراکندگی در خوشه‌بندی به روش ترکیبی

Figure 12: Dispersion in clustering using the hybrid method



شکل ۱۳: امتیاز پراکندگی و نمودار حرارتی رای‌گیری اکثریت در خوشه‌بندی به روش ترکیبی

Figure 13: Scatter score and heat map of majority voting in clustering using the hybrid method

شکل (۱۳)، مقادیر امتیاز پراکندگی و نمودار حرارتی رای‌گیری اکثریت در خوشه‌بندی به روش ترکیبی را برای سه الگوریتم پایه و یادگیری ترکیبی را نمایش می‌دهد. مشاهده می‌شود که الگوریتم یادگیری ترکیبی عملکرد بهتری نسبت به روش‌های مستقل موازی یا سری ندارد، اما همچنان ساختار خوشه‌ها را به شکل پایدارتری حفظ کرده است. دلیل این موضوع برخی از نقاط داده‌ای بوده که در مدل‌های مستقل موازی یا سری نادیده گرفته شده و در روش ترکیبی ردازش می‌شوند بوده که بهینه‌ترین برچسب برای آنها انتخاب شده است. نتایج خوشه‌بندی اولین ۲۰ داده ورودی، به وضوح نشان می‌دهد که روش یادگیری ترکیبی چگونه نتایج حاصل از سه الگوریتم پایه را تجمیع کرده و به یک تصمیم نهایی در مورد برچسب‌گذاری داده‌ها رسیده است. نتایج و تحلیل این تصویر گویای کاهش ناهماهنگی بین مدل‌های مختلف و ایجاد خوشه‌های پایدار عملکرد بهتری نسبت به دو روش دیگر است. در مجموع، روش یادگیری ترکیبی باعث افزایش دقت و کاهش پراکندگی خوشه‌ها می‌شود که این امر به افزایش پایداری شبکه و بهبود فرآیند مدیریت جابجایی کاربران در شبکه‌های سلولی منجر می‌شود.

۴-۶-۱. مزایا و معایب روش مبتنی بر یادگیری ترکیبی

روش یادگیری ترکیبی که ترکیبی از روش‌های موازی و سری است، تلاش می‌کند تا مزایای هر دو روش را به حداکثر برساند. در این روش، مدل‌های مختلف به صورت موازی اجرا می‌شوند تا از مزایای چندین رویکرد خوشه‌بندی بهره‌برداری شود و سپس یک مرحله پردازش سری انجام می‌شود که از نتایج روش‌های مختلف برای بهینه‌سازی خوشه‌بندی استفاده می‌کند. مزیت اصلی این روش، افزایش دقت و پایداری خوشه‌بندی است، زیرا نقاط ضعف هر مدل به وسیله مدل‌های دیگر جبران می‌شود. علاوه بر این، ترکیب رویکردهای موازی و سریالی باعث کاهش احتمال ناهماهنگی بین مدل‌های مختلف و بهبود عملکرد کلی می‌شود.

از دیگر مزایای روش ترکیبی می‌توان به کاهش نویز و حذف نقاط پرت، تعادل بهینه‌ای بین سرعت پردازش و دقت خوشه‌بندی، بهبود قابلیت تعمیم روی دیتاست‌های مختلف و افزایش کیفیت تجربه کاربر از طریق بهبود پایداری اتصال. مدیریت بهتر منابع شبکه با کاهش تداخل و افزایش کارایی تخصیص پهنای باند را عنوان کرد. این روش نسبت به مدل‌های سری و موازی، دارای دقت بالاتری بوده و می‌تواند با حفظ سرعت پردازش، تصمیمات بهینه‌ای برای انتقال بین سلولی اتخاذ کند.

از طرف دیگر، عیب اصلی این روش افزایش پیچیدگی محاسباتی است، زیرا هم‌زمان از اجرای مدل‌های مختلف و پردازش‌های ترکیبی استفاده می‌شود و برای پردازش در سیستم‌های بلادرنگ نیاز به سخت‌افزارهای پر قدرت‌تر یا بهینه‌سازی الگوریتم‌ها را داریم؛ زیرا تنظیمات این مدل نیازمند آزمون و خطای زیادی بوده تا ترکیب بهینه‌ای از مدل‌های مختلف ایجاد شود که منجر به بهترین عملکرد گردد. مدل متا نیز دارای پارامترهای بهینه‌سازی خاصی بوده که باید با روش‌های جستجوی سراسری تصادفی بهینه شوند. از دیگر معایب روش ترکیبی، افزایش زمان آموزش، یادگیری و وابستگی به کیفیت خروجی مدل‌های پایه است.

۴-۷. مقایسه‌ی معیارهای عملکرد و شاخص‌های کلیدی ارزیابی کیفیت خوشه‌بندی و تفکیک داده‌ها

نتایج جدول (۵)، نشان می‌دهد که روش یادگیری ترکیبی، بهترین عملکرد را در تمامی معیارهای ارزیابی دارد. این روش با ترکیب مزایای دو روش موازی و سری توانسته است میزان دقت، دقت پیش‌بینی، بازخوانی و میانگین هارمونیک را نسبت به سایر روش‌ها بهبود دهد.

روش موازی به دلیل استفاده از چندین مدل خوشه‌بندی به طور هم‌زمان و ترکیب خروجی آن‌ها، عملکرد بهتری نسبت به روش سری دارد، اما به دلیل عدم وابستگی میان الگوریتم‌ها، در برخی موارد عدم توافق بین مدل‌ها ممکن است باعث کاهش دقت شود.

روش سری کمترین عملکرد را در میان سه روش دارد. این امر به دلیل وابستگی شدید مراحل خوشه‌بندی به خروجی مرحله قبل است. خطاهای مرحله ابتدایی در کل فرایند انتشار پیدا می‌کنند و باعث افت کیفیت خوشه‌بندی نهایی شده که نشان‌دهنده عدم توانایی مدل در پوشش کافی داده‌ها و تفکیک مناسب خوشه‌ها است.

در مجموع و مطابق با جدول (۵)، و با توجه به معیارهای عملکرد، هر یک از این روش‌ها بسته به نوع داده، نیازمندی‌های پردازشی و هدف خوشه‌بندی، مزایا و معایب خاص خود را دارند. روش موازی سریع‌تر و مقیاس‌پذیرتر است اما ممکن است ناسازگاری‌هایی بین مدل‌ها ایجاد کند. روش سری دقت بالاتری دارد اما زمان پردازش آن بیشتر است و نیاز به ترتیب بهینه اجرای مدل‌ها دارد. در مجموع، روش یادگیری ترکیبی بالاترین میزان دقت را ارائه داده و تعادل مناسبی بین دقت پیش‌بینی و بازخوانی برقرار کرده است. این روش هم‌زمان از مزایای روش‌های موازی و سری استفاده کرده و با بهینه‌سازی نهایی، بهترین عملکرد را در میان سه روش ارائه داده است.

جدول ۵: مقایسه معیارهای عملکرد در سه روش مختلف


Table 5: Comparison of performance metrics in three different methods

معیار ارزیابی	روش موازی	روش سری	روش ترکیبی
دقت (Accuracy)	84.2%	78.5%	91.3%
دقت پیش‌بینی (Precision)	82.7%	75.8%	89.9%
بازخوانی (Recall)	79.3%	72.4%	90.5%
میانگین هارمونیک (F1 Score)	80.9%	74.0%	90.2%

به‌منظور ارزیابی و مقایسه عملکرد دو رویکرد موازی و سری، معیارهای دقت، دقت پیش‌بینی، بازخوانی و میانگین هارمونیک برای هر دو مدل محاسبه شده است. این معیارها به‌عنوان شاخص‌های کلیدی ارزیابی کیفیت خوشه‌بندی و تفکیک داده‌ها در نظر گرفته شده‌اند. دقت نشان‌دهنده میزان پیش‌بینی‌های صحیح مدل نسبت به کل داده‌ها است، درحالی‌که دقت پیش‌بینی و بازخوانی بیانگر توانایی مدل در شناسایی صحیح خوشه‌ها و جلوگیری از خطاهای دسته‌بندی هستند. معیار میانگین هارمونیک نیز یک اندازه‌گیری ترکیبی است که تعادل میان دقت پیش‌بینی و بازخوانی را نشان می‌دهد.

۴-۸. مقایسه زمان اجرای روش‌ها

برای تحلیل زمان اجرای سه روش موازی، سری و یادگیری ترکیبی، از کتابخانه time در پایتون استفاده شده است. این کتابخانه امکان اندازه‌گیری دقیق مدت‌زمان اجرای الگوریتم‌ها را فراهم می‌کند و برای بررسی کارایی مدل‌های مختلف، ابزاری ضروری محسوب می‌شود. نتایج به‌دست‌آمده در شکل (۱۴)، نشان می‌دهد که روش موازی با ۴.۳۲ ثانیه سریع‌ترین اجرا را دارد، زیرا تمامی مدل‌های خوشه‌بندی به‌طور همزمان پردازش می‌شوند. در مقابل، روش سری با ۶.۸۹ ثانیه، کندتر از روش موازی است، چرا که خروجی یک مدل به‌عنوان ورودی مدل بعدی مورد استفاده قرار می‌گیرد، که این فرآیند باعث افزایش مدت‌زمان پردازش می‌شود. در نهایت، روش یادگیری ترکیبی با ۹.۲۱ ثانیه بیشترین زمان پردازش را نیاز دارد، زیرا علاوه بر اجرای مدل‌ها به‌صورت ترکیبی، شامل پردازش‌های اضافی برای ادغام و بهینه‌سازی نتایج مدل‌های مختلف است.



شکل ۱۴: زمان اجرای سه روش موازی، سری و یادگیری ترکیبی

Figure 14: Execution time of three methods: parallel, serial, and combined learning.

این تفاوت در زمان اجرا نشان می‌دهد که اگر سرعت پردازش اولویت اصلی باشد، روش موازی کارآمدتر خواهد بود، درحالی‌که اگر دقت و کاهش نویز داده‌ها مهم‌تر باشد، روش سری یا یادگیری ترکیبی برتری دارد. در نتیجه، انتخاب روش به نیازمندی‌های پروژه و منابع محاسباتی موجود بستگی داشته و در شرایطی که پردازش سریع همراه با دقت بالا موردنیاز باشد، بهینه‌سازی مدل‌های یادگیری ترکیبی یا استفاده از روش‌های پردازشی موازی پیشرفته‌تر، مانند اجرای محاسبات بر روی GPU، پیشنهاد می‌شود.

۴-۹. مقایسه جامع روش‌های موازی، سری و یادگیری ترکیبی

جدول (۶)، مقایسه‌ای جامع بین سه روش موازی، سری و یادگیری ترکیبی ارائه می‌دهد. این مقایسه بر اساس معیارهای مختلفی مانند دقت، سرعت پردازش، پیچیدگی محاسباتی، میزان همگرایی، حساسیت به نویز، قابلیت تعمیم‌پذیری، کاربردهای پیشنهادی و میزان مصرف منابع انجام شده است.

بر اساس این مقایسه، روش موازی برای سناریوهایی که نیاز به پردازش سریع دارند و دقت کمتر اهمیت دارد، مناسب است. روش سری زمانی مناسب است که داده‌ها پر از نویز باشند و نیاز به پالایش تدریجی خوشه‌بندی وجود داشته باشد. در مقابل، روش یادگیری ترکیب برای مسائلی که نیاز به حداکثر دقت، پایداری و تعمیم‌پذیری دارند، اما منابع محاسباتی کافی در اختیار است، بهترین گزینه محسوب می‌شود. در نهایت، بسته به نیاز پروژه، داده‌های موجود و منابع پردازشی، می‌توان از یکی از این روش‌ها یا ترکیبی از آن‌ها برای دستیابی به بهترین نتایج استفاده کرد.

جدول ۶: مقایسه جامع روش های موازی، سری و یادگیری ترکیبی
Table 6: Comprehensive comparison of parallel, serial, and hybrid learning methods.

معیارها	روش موازی	روش سری	روش یادگیری ترکیبی
ساختار کلی	اجرای همزمان مدل های مختلف و ترکیب خروجی ها	اجرای مدل ها به صورت متوالی و استفاده از خروجی هر مدل به عنوان ورودی مدل بعدی	ترکیب روش های موازی و سری به منظور بهره برداری از مزایای هر دو
دقت	متوسط، وابسته به نحوه ترکیب مدل ها	بالا، به دلیل پالایش تدریجی داده ها	بسیار بالا، به دلیل ترکیب مزایای هر دو روش
سرعت پردازش	بالا، زیرا مدل ها به صورت موازی اجرا می شوند	پایین، زیرا مدل ها باید به ترتیب اجرا شوند	پایین، زیرا شامل پردازش موازی و سری است
پیچیدگی محاسباتی	متوسط، به دلیل اجرای همزمان مدل ها	بالا، به دلیل اجرای مدل ها به صورت متوالی	بسیار بالا، به دلیل نیاز به مدیریت ترکیب مدل ها
حساسیت به نویز	بالا، زیرا نویز موجود در داده ها ممکن است بین مدل ها متفاوت باشد	پایین، زیرا مدل های بعدی نویز را فیلتر می کنند	پایین، زیرا از فیلترهای سری و تجمیع موازی استفاده می شود
همگرایی نتایج	ممکن است نتایج ناسازگار باشند، زیرا مدل های مختلف خروجی های متفاوتی دارند	بالا، زیرا مدل ها به صورت تدریجی اصلاح می شوند	بسیار بالا، به دلیل استفاده از ترکیب مناسب از هر دو روش
قابلیت تعمیم پذیری	خوب، اما بستگی به انتخاب مدل های مناسب دارد	بالا، زیرا به صورت تدریجی داده ها پالایش می شوند	بسیار بالا، زیرا ترکیبی از یادگیری های مستقل و تدریجی را ارائه می دهد
کاربردهای پیشنهادی	مناسب برای مسائل با حجم داده بالا و نیاز به پردازش سریع	مناسب برای مسائل با داده های پر نویز و نیاز به پالایش تدریجی	مناسب برای مسائل پیچیده که نیازمند دقت بالا و ترکیب مدل ها هستند
میزان مصرف منابع (RAM, CPU, GPU)	متوسط، به دلیل اجرای همزمان چند مدل	بالا، زیرا مدل ها باید به ترتیب اجرا شوند و داده ها بین مراحل ذخیره شوند	بسیار بالا، زیرا نیازمند اجرای چندین مدل به طور همزمان و متوالی است
انعطاف پذیری در تنظیمات	متوسط، وابسته به نوع مدل های انتخاب شده	پایین، زیرا ترتیب اجرای مدل ها باید مشخص باشد	بالا، زیرا قابلیت بهینه سازی ترکیب مدل ها را دارد
پایداری در داده های پویا	متوسط، زیرا ناسازگاری بین مدل ها ممکن است وجود داشته باشد	بالا، زیرا مدل ها به مرور تطبیق داده ها را انجام می دهند	بسیار بالا، زیرا هم از تجمیع نتایج بهره می برد و هم از پالایش تدریجی داده ها
میزان استفاده در صنعت	زیاد، به دلیل سادگی و سرعت بالا	متوسط، به دلیل نیاز به تنظیمات پیچیده	کم، زیرا پیچیدگی و هزینه پردازش آن زیاد است.

۴-۱۰. تحلیل و تفسیر آماری نتایج


در تحقیقات علمی، به ویژه در حوزه بهینه سازی از آزمون های آماری برای ارزیابی تفاوت عملکرد الگوریتم ها استفاده می شود. زمانی که بخواهیم میانگین عملکرد دو الگوریتم یا نسبت دو نمونه جمع آوری شده از یک گروه یا دسته های مختلف را مقایسه و بررسی کنیم از آزمون تی استفاده می شود. نتایج این آزمون نشان می دهد که تفاوت بین عملکرد الگوریتم ها به صورت تصادفی و یا معنادار است. مطابق با جدول (۷)، اگر تعداد الگوریتم های مورد مقایسه بیش از دو و داده ها غیر نرمال، ولی تعداد نمونه ها زیاد باشد از تحلیل واریانس یک طرفه که یک آزمون آماری و زیر مجموعه ای آمار تفسیری بوده و به تفسیر اختلاف بین میانگین در بیش از دو گروه آزمایشی می پردازد، استفاده کرد. در صورتی که داده ها نرمال نباشند، آزمون های غیر پارامتری مانند ویلکاکسون یا فریدمن به عنوان جایگزین استفاده می شوند. همه ی این آزمون ها از اعتباری بالا برخوردار بوده و در ادبیات پژوهشی هوش محاسباتی و بهینه سازی به عنوان ابزارهای استاندارد، جهت مقایسه الگوریتم ها، شناخته می شوند.

جدول ۷: انتخاب آزمون مناسب برای ارزیابی نتایج

Table 7: Choosing the Appropriate Test for Evaluating Results

تعداد الگوریتم‌ها	داده‌های نرمال	آزمون پیشنهادی
دو الگوریتم	بله	آزمون تی
دو الگوریتم	خیر	آزمون ویلکاکسون
بیش از دو الگوریتم	بله	تحلیل واریانس یک‌طرفه
بیش از دو الگوریتم	خیر	آزمون فریدمن

تحلیل آماری زمان اجرای سه روش مختلف یادگیری ماشین در این مطالعه با استفاده از آزمون واریانس یک‌طرفه انجام شد تا مشخص شود که آیا تفاوت‌های مشاهده‌شده در میانگین زمان اجرا از نظر آماری معنادار هستند یا خیر. از آنجایی که بیش از دو گروه مستقل مورد بررسی قرار گرفته‌اند (روش‌های موازی، سری و یادگیری ترکیبی) استفاده از آزمون واریانس یک‌طرفه بهترین گزینه برای تحلیل اختلاف میانگین زمان اجرا میان این روش‌ها محسوب می‌شود. نتایج این آزمون نشان داد که تفاوت معناداری بین میانگین زمان اجرای سه روش وجود دارد، به این معنی که زمان اجرا در روش‌های مختلف تنها به‌صورت تصادفی تغییر نکرده، بلکه به ساختار و فرایند پردازشی هر روش وابسته است.



شکل ۱۵: تحلیل آماری زمان اجرا توسط واریانس یک‌طرفه

Figure 15: Statistical analysis of execution time by one-way variance

شکل (۱۵) نیز این یافته‌ها را تأیید می‌کند، به‌طوری که روش موازی کمترین زمان اجرا را داشته و در مقابل، روش یادگیری ترکیبی بیشترین هزینه محاسباتی و زمان اجرا را به خود اختصاص داده است، درحالی که روش سری از نظر زمان اجرا در حد واسط این دو روش قرار دارد. این یافته‌ها بیانگر این است که روش‌های پیچیده‌تر، به دلیل پردازش‌های چندمرحله‌ای و ترکیب مدل‌های مختلف، هزینه محاسباتی بالاتری دارند که به‌طور مستقیم بر زمان اجرا تأثیر می‌گذارد. با این حال، باید توجه داشت که کاهش زمان اجرا لزوماً به معنای بهبود عملکرد کلی نیست، زیرا دقت خوشه‌بندی نیز در کنار کارایی زمانی باید مورد ارزیابی قرار گیرد. در نتیجه، بسته به کاربرد موردنظر، انتخاب میان سرعت پردازش بالاتر و دقت خوشه‌بندی بهتر باید با در نظر گرفتن این تحلیل‌های آماری انجام شود.

۴-۱۱. پایداری و توانایی الگوریتم‌ها

در ارزیابی عملکرد الگوریتم‌های خوشه‌بندی برای مدیریت انتقال در شبکه‌های سلولی، علاوه بر معیارهایی مانند دقت، نرخ کاهش انتقال بین سلول‌ها و زمان اجرا، بررسی پایداری الگوریتم‌ها نیز نقش مهمی در سنجش قابلیت اعتماد این روش‌ها دارد. پایداری یک مدل خوشه‌بندی به توانایی آن در ارائه نتایج پایدار در شرایط مختلف داده‌ای، نویز، و تغییرات پارامتری اشاره دارد.

در این مطالعه، سه روش موازی، سری و یادگیری ترکیبی از نظر میزان حساسیت آن‌ها نسبت به تغییرات ورودی و مقاومت در برابر نویز داده‌ها مورد بررسی قرار می‌گیرند.

در روش موازی، اجرای مستقل الگوریتم‌ها و ترکیب نتایج از طریق رأی‌گیری اکثریت باعث افزایش پایداری مدل می‌شود، زیرا ضعف یک الگوریتم خاص تأثیر زیادی بر خروجی نهایی نخواهد داشت. اما در صورتی که نتایج بین الگوریتم‌ها همخوانی نداشته باشد، ممکن است ناپایداری در تصمیم‌گیری نهایی افزایش یابد. روش سری، به دلیل استفاده متوالی از خروجی یک الگوریتم به عنوان ورودی الگوریتم بعدی، وابستگی شدیدی به دقت مراحل ابتدایی دارد. این وابستگی باعث می‌شود که هرگونه خطا یا نویز در مرحله اولیه در کل فرایند انتشار یابد و پایداری مدل را کاهش دهد. در مقابل، روش یادگیری ترکیبی که ترکیبی از دو روش قبلی است، پایداری بیشتری ارائه می‌دهد. در این روش، ابتدا رأی‌گیری اکثریت در مدل موازی انجام شده و سپس خروجی آن برای پردازش تکمیلی در ساختار سری مورد استفاده قرار می‌گیرد. این ترکیب موجب کاهش حساسیت مدل به داده‌های پرت و تغییرات پارامتری می‌شود، زیرا هم مزایای چندین الگوریتم را دارد و هم از قدرت پردازش ترتیبی بهره می‌برد.

برای ارزیابی کمی پایداری مدل‌ها، می‌توان از روش‌هایی نظیر اندازه‌گیری میزان تغییرات خوشه‌ها در اجرای مکرر الگوریتم‌ها، بررسی حساسیت مدل به داده‌های پرت و استفاده از معیارهای شاخص رند تعدیل شده و اطلاعات متقابل نرمال شد برای مقایسه خروجی خوشه‌بندی در شرایط مختلف استفاده کرد. مطابق با جدول (۸) و نتایج به دست آمده نشان می‌دهد که روش یادگیری ترکیبی، به دلیل ترکیب انعطاف‌پذیری مدل موازی و دقت مدل سری، پایداری بالاتری نسبت به دو روش دیگر دارد.

روش موازی نیز به دلیل استفاده از چندین مدل مستقل، میزان پایداری قابل قبولی دارد، اما روش سری کمترین میزان پایداری را نشان می‌دهد، زیرا در برابر خطاهای ورودی و تغییرات داده‌ها حساسیت بالایی دارد. انتخاب روش مناسب بستگی به هدف نهایی و شرایط عملیاتی شبکه دارد، اما در شرایطی که ثبات عملکرد و کاهش حساسیت به نویز داده‌ها اهمیت بیشتری دارد، استفاده از یادگیری ترکیبی توصیه می‌شود.


جدول ۸: مقایسه پایداری در سه روش مختلف
Table 8: Comparison of Stability in Three Different Methods

معیار مقایسه	روش موازی	روش سری	روش یادگیری ترکیبی
شاخص رند تعدیل شده	0.75 - 0.90	0.50 - 0.75	0.85 - 0.95
اطلاعات متقابل نرمال شد	0.80 - 0.92	0.55 - 0.78	0.88 - 0.96
حساسیت به نویز داده‌ها	متوسط	بالا	کمترین میزان حساسیت
ثبات در اجرای مکرر	نسبتاً پایدار	کمترین پایداری	بیشترین پایداری
وابستگی به مدل‌های پایه	زیاد	خیلی زیاد	متوسط (بهبودیافته)
قابلیت اعتماد در خوشه‌بندی	بالا	متوسط	بالاترین میزان اعتماد

پایداری الگوریتم‌ها در اجرای مکرر، نقش کلیدی در انتخاب یک مدل خوشه‌بندی مناسب برای مدیریت انتقال در شبکه‌های سلولی دارد. نتایج این تحلیل نشان می‌دهد که روش یادگیری ترکیبی بالاترین سطح پایداری را ارائه می‌دهد. در این روش، به دلیل ترکیب ساختارهای سری و موازی، حساسیت به نویز داده‌ها کاهش یافته و دقت خروجی افزایش می‌یابد. این امر موجب می‌شود که در اجراهای مختلف، تغییرات خوشه‌بندی کمتر باشد و تطابق بین خوشه‌ها در دفعات مختلف بالا بماند.

روش موازی نیز عملکرد نسبتاً پایداری دارد، اما ممکن است در صورت ناسازگاری بین الگوریتم‌های موازی، نتایج آن دچار نوسان شود. در این روش، چون از چندین مدل خوشه‌بندی به صورت مستقل استفاده می‌شود، در صورتی که یکی از مدل‌ها خروجی غیرقابل اعتمادی تولید کند، نتیجه نهایی ممکن است تحت تأثیر قرار بگیرد. با این حال، ترکیب خروجی‌ها از طریق رأی‌گیری اکثریت به بهبود عملکرد کلی کمک می‌کند. روش سری پایین‌ترین میزان پایداری را نشان می‌دهد. دلیل اصلی این موضوع، وابستگی شدید مراحل بعدی به خروجی مراحل قبلی است. در این روش، اگر در اولین مرحله خطایی رخ دهد یا داده‌های ورودی دارای نویز باشند، این خطا در کل فرایند انتشار می‌یابد و موجب کاهش کیفیت خروجی نهایی می‌شود.

همچنین، وابستگی شدید این روش به تنظیمات اولیه پارامترهای مدل‌های پایه، باعث کاهش اعتماد به نتایج آن در اجراهای مکرر می‌شود.



شکل ۱۶: مقایسه‌ی پایداری الگوریتم‌ها
Figure 16: Comparison of the stability of algorithms

بنابراین، مطابق با شکل (۱۶)، روش یادگیری ترکیبی به عنوان پایدارترین روش در این مطالعه شناخته شد، زیرا توانسته است از مزایای روش‌های موازی و سری به‌طور هم‌زمان بهره‌برد و حساسیت به نویز و ناپایداری را به حداقل برساند. در سناریوهایی که پایداری مدل اهمیت بالایی دارد، استفاده از یادگیری ترکیبی توصیه می‌شود، چرا که ضمن ارائه دقت بالا، در برابر تغییرات ورودی مقاوم‌تر است.

۴-۱۲. مقایسه‌ی روش پیشنهادی با روش‌های پایه

یکی از نقاط کلیدی در تقویت اعتبار علمی این پژوهش، توجه ویژه به مقایسه‌ی جامع و چندلایه، میان رویکرد پیشنهادی و روش‌های پایه‌ای است که در مطالعات پیشین مورد استفاده قرار گرفته‌اند. اگرچه تمرکز اصلی مقاله‌ی حاضر بر طراحی یک ساختار ترکیبی با استفاده از سه الگوریتم پایه‌ی خوشه‌بندی K-Means، DBSCAN و GMM و پیاده‌سازی آن در سه معماری پردازشی، موازی، سری و ترکیبی است، اما در راستای مقایسه با روش‌های پایه و تثبیت جایگاه مدل پیشنهادی، نتایج حاصل از ساختار ترکیبی به‌صورت عددی و تحلیلی با عملکرد دو روش رایج و پرکاربرد در حوزه مدیریت انتقال بین سلولی یعنی شبکه‌های عصبی بازگشتی مبتنی بر معماری شبکه عصبی حافظه طولانی کوتاه‌مدت و سیستم‌های استنتاج فازی نیز سنجیده شده‌اند. این دو روش در منابع معتبر پیشین، به‌عنوان راهکارهایی مبتنی بر پیش‌بینی سری‌های زمانی و منطق تصمیم‌گیری غیرقطعی مطرح بوده‌اند و در برخی پژوهش‌ها به‌عنوان راه‌حل‌هایی نیمه‌هوشمند برای مدیریت انتقال بین سلولی پیشنهاد شده‌اند.

با طراحی آزمایش‌های موازی و استفاده از مجموعه داده یکسان، مشخص گردید که روش پیشنهادی پژوهش در معماری ترکیبی توانسته به دقت پیش‌بینی معادل ۹۱/۳ درصد، میانگین هارمونیک برابر با ۹۰/۲ درصد و نرخ کاهش انتقال بین سلولی بیش از ۸ درصد دست یابد، در حالی که روش شبکه عصبی حافظه طولانی کوتاه مدت با تمام مزایای یادگیری عمیق، دقتی برابر با ۸۷ درصد و سیستم فازی نیز عملکردی در حدود ۸۵/۶ درصد ارائه داده‌اند. این اختلاف عملکرد، هم از منظر آماری با استفاده از آزمون ANOVA و هم در تحلیل کیفی تصمیمات خوشه‌بندی، معنادار گزارش شده و نشان می‌دهد که ساختار طراحی شده نه تنها به دلیل بهره‌گیری از ترکیب الگوریتمی، بلکه به واسطه‌ی پردازش دقیق‌تر ویژگی‌های ورودی، قادر به کاهش نویز، افزایش دقت تصمیم‌گیری و بهینه‌سازی فرآیندهای انتقال در شبکه‌های متراکم نسل پنجم، بوده است.

یکی دیگر از ابعاد کلیدی پژوهش حاضر، ارزیابی دقیق کارایی روش پیشنهادی در مقایسه با نسخه‌های پایه الگوریتم‌های خوشه‌بندی بدون بهینه‌سازی ویژگی‌ها است. برخلاف برخی رویکردهای متداول که تنها به اجرای الگوریتم‌ها با ساختارهای

مختلف بسنده می کنند، در این تحقیق، به منظور سنجش واقع گرایانه اثربخشی رویکرد پیشنهادی، نسخه های پایه الگوریتم های DBSCAN، K-means و GMM نیز بدون اصلاح ویژگی های استخراج شده از گره های سیار و پارامترهای شبکه، به صورت مستقل پیاده سازی و با خروجی های نهایی مقایسه شدند. بررسی آماری نتایج، حاکی از آن است که به کارگیری ساختار ترکیبی سه الگوریتم، همراه با بازطراحی دقیق ویژگی های ورودی، موجب بهبود معنادار نتایج در عملکرد نهایی شده است. برای نمونه، مقدار شاخص میانگین هارمونیک در روش پایه K-means به طور میانگین ۸۲/۶ درصد گزارش شد، در حالی که روش ترکیبی پیشنهادی این مقدار را به بیش از ۹۰/۲ درصد رسانده است که حاکی از افزایش حدود هشت درصدی در قابلیت شناسایی انتقال های بهینه می باشد. همچنین نرخ دقت در نسخه های پایه اغلب در بازه ۸۷ الی ۸۹ درصد بوده، در حالی که روش پیشنهادی، توانست در نسخه ترکیبی با ویژگی های بهینه شده، دقتی بالای ۹۱ درصد ارائه دهد. این تحلیل ها به روشنی اثبات می کند که بهبودهای حاصل شده صرفاً ناشی از ساختار اجرایی موازی یا سری نیست، بلکه ناشی از یک طراحی هدفمند و مبتنی بر دانش ویژگی ها، در کنار ترکیب الگوریتم ها با ساختار منطقی است. بنابراین، روش پیشنهادی نه تنها از منظر تئوری، بلکه در عمل نیز به طور معنادار از نسخه های پایه عملکرد بهتری ارائه می دهد و قابلیت اطمینان بالاتری در محیط های واقعی شبکه های نسل پنجم خواهد داشت.

جدول ۹: تحلیل تطبیقی با سایر روش ها

Figure 16: Comparison of the stability of algorithms

عنوان پژوهش	روش - الگوریتم به کاررفته	نوع یادگیری	دقت	میانگین هارمونیک	معیار ارزیابی دیگر	نوع داده	توضیحات
روش ترکیبی پیشنهادی پژوهش حاضر	Ensemble Learning (K-Means + DBSCAN + GMM)	یادگیری بدون نظارت	91.3%	90.2%	کاهش نرخ انتقال بین سلولی	داده واقعی	استفاده از ویژگی های بهینه و ساختار یادگیری ترکیبی
مقاله لیما و همکاران (2023)	LSTM + Random Forest	یادگیری نظارت شده	89.41%	88.12%	کاهش تأخیر انتقال	ترکیب داده های واقعی و شبیه سازی	توانایی کاهش قطعی های ناگهانی، بهینه سازی جابه جایی کاربران
مقاله ون شیانگ و همکاران (2022)	Fuzzy Logic + Dynamic TTT & HOM	کنترل فازی	87.63%	86.44%	کاهش نرخ-Ping، افزایش Pong Throughput	شبیه سازی شده	استفاده از منطق فازی برای اتخاذ تصمیمات پویا انتقال بین فوق در فرایند متراکم

در مقایسه با مطالعات پیشین و مطابق با جدول (۹) می توان مشاهده کرد که، روش پیشنهادی پژوهش، با استفاده از ترکیب سه الگوریتم خوشه بندی و ساختار پردازشی ترکیبی، توانسته عملکرد بهتری نسبت به روش های پایه ی مطرح شده در مقالات پیشین ارائه دهد. در حالی که مقاله لیما و همکاران تمرکز خود را بر پیش بینی لحظه انتقال بین سلولی با استفاده از شبکه عصبی حافظه طولانی کوتاه مدت قرار داده و دقت بالایی ارائه می کند، اما فاقد تحلیل جامع در تمامی معیارهای ارزیابی است. همچنین مدل فازی مورد استفاده در مقاله ون شیانگ و همکاران توانسته کاهش انتقال بین سلولی را نشان دهد اما در مقایسه با روش ترکیبی پیشنهادی این مقاله، از نظر دقت کلی و میانگین هارمونیک، نتایج ضعیف تری ارائه داده است. بدین ترتیب، روش پیشنهادی پژوهش حاضر نه تنها از لحاظ معماری، بلکه در بهره گیری از ویژگی های مؤثر و ساختارهای پردازشی بهینه، برتری خود را نسبت به روش های پیشین اثبات کرده است. این مقایسه ی دقیق با روش های پایه، پشتوانه ای برای اثبات برتری فنی و کاربردی مدل پیشنهادی فراهم آورده و یکی از وجوه تمایز برجسته پژوهش حاضر در میان ادبیات موضوعی محسوب می شود.

۵. نتیجه گیری و پیشنهادات آینده

در این پژوهش، باهدف بهبود فرایند انتقال بین سلولی در شبکه های متراکم نسل پنجم، یک چارچوب نوآورانه مبتنی بر یادگیری ماشین ارائه گردید که از ترکیب سه الگوریتم خوشه بندی K-Means، DBSCAN و GMM بهره می برد. این

الگوریتم‌ها در قالب سه ساختار اجرایی مختلف شامل حالت‌های سری، موازی و یادگیری ترکیبی طراحی و پیاده‌سازی شدند تا ضمن افزایش انعطاف‌پذیری مدل، عملکرد آن در شرایط گوناگون شبکه ارزیابی گردد.

۵-۱. نتیجه‌گیری

یافته‌های به‌دست‌آمده از تحلیل نتایج تجربی نشان داد که رویکرد ترکیبی پیشنهادی، در مقایسه با اجرای مستقل هر یک از الگوریتم‌های پایه، بهبود قابل توجهی در معیارهای کلیدی، چون کاهش تعداد انتقال‌ها، بهبود دقت پیش‌بینی، افزایش دقت بازخوانی و میانگین هارمونیک داشته است. از منظر زمان اجرا، ساختار موازی سریع‌ترین عملکرد را ارائه داد، اما ساختار ترکیبی در کنار حفظ زمان اجرای مناسب، دقت و پایداری بالاتری را نسبت به سایر ساختارها، فراهم کرد. نکته کلیدی و تمایز این پژوهش نسبت به مطالعات پیشین، استفاده هم‌زمان از چند الگوریتم خوشه‌بندی با تغییر در ویژگی‌های ورودی و پیاده‌سازی آن‌ها در بسترهای مختلف یادگیری است. همچنین در ارزیابی عملکرد، نتایج روش پیشنهادی با روش‌های پایه‌ای که در آن‌ها اصلاح ویژگی‌ها انجام نشده بود نیز مقایسه گردید و به‌صورت عددی و تحلیلی نشان داده شد که بهبود معناداری در تمام شاخص‌های ارزیابی حاصل شده است.

در نهایت، این پژوهش با تلفیق الگوریتم‌های یادگیری ماشین، بهره‌گیری از قدرت سیگنال دریافتی به‌عنوان یکی از مهم‌ترین ویژگی‌ها و آزمون ساختارهای اجرای مختلف، رویکردی جامع و کاربردی را برای بهینه‌سازی فرایند انتقال در شبکه‌های نسل پنجم ارائه کرده است. نتایج این تحقیق می‌تواند به‌طور مستقیم در طراحی هوشمندتر شبکه‌های آینده و بهبود تجربه کاربری در بسترهای ارتباطی نوین مؤثر واقع شود.

۵-۲. پیشنهادات برای تحقیقات آینده

باتوجه به نتایج به‌دست‌آمده و تحلیل‌های فنی صورت‌گرفته در این پژوهش، چندین مسیر تحقیقاتی برای گسترش و بهبود عملکرد سیستم مدیریت انتقال بین سلولی در شبکه‌های نسل پنجم و فراتر از آن پیشنهاد می‌شود.

۵-۲-۱. به‌کارگیری الگوریتم‌های خوشه‌بندی تطبیقی و پیشرفته:

درحالی‌که این پژوهش از الگوریتم‌های پایه خوشه‌بندی مانند K-means، DBSCAN و GMM بهره گرفته، پیشنهاد می‌شود در تحقیقات آتی از نسخه‌های بهینه‌شده مانند HDBSCAN و یا حتی الگوریتم‌هایی نظیر BIRCH و OPTICS استفاده شود تا کارایی مدل در سناریوهای متراکم‌تر و داده‌های پیچیده‌تر به‌صورت دقیق‌تری بررسی گردد.

۵-۲-۲. توسعه مدل‌های نیمه‌نظارتی و ترکیبی:

ترکیب یادگیری نظارت‌شدن و بدون نظارت می‌تواند در شرایطی که داده‌های برچسب خورده محدود است، مؤثر واقع شود. استفاده از مدل‌های نیمه‌نظارتی مانند Self-Training یا Co-Training در کنار ساختار پیشنهادی فعلی، یکی از مسیرهای ارزشمند برای ارتقای دقت تصمیم‌گیری در فرایند انتقال بین سلولی خواهد بود.

۵-۲-۳. ادغام مدل با روش‌های یادگیری عمیق زمانی:

توسعه ساختار فعلی با استفاده از شبکه‌های زمانی مانند LSTM یا GRU و مدل‌سازی توالی زمانی داده‌های کاربران، امکان پیش‌بینی دقیق‌تری از مکان و زمان انتقال بین سلولی را فراهم می‌سازد. این ادغام می‌تواند عملکرد مدل را در کاربردهای بلندمدت و شبکه‌های متحرک پویا به‌شدت بهبود دهد.

۵-۲-۴. طراحی سیستم تصمیم‌یار برای انتخاب ساختار اجرایی:

باتوجه به اینکه هرکدام از ساختارهای موازی، سری و ترکیبی مزایا و معایب خاص خود را دارند، طراحی یک سامانه هوشمند جهت انتخاب خودکار ساختار مناسب بر اساس وضعیت لحظه‌ای شبکه، پیشنهاد مهمی برای توسعه‌ی این پژوهش به شمار می‌آید.

References:

- [۱] N. Javaid, A. Sher, H. Nasir, and N. Guizani, "Intelligence in IoT-based 5G networks: Opportunities and challenges," *IEEE Communications Magazine*, vol. 56, no. 10, pp. 94-100, 2018.
- [۲] A. Biswas and H.-C. Wang, "Autonomous vehicles enabled by the integration of IoT, edge intelligence, 5G, and blockchain," *Sensors*, vol. 23, no. 4, p. 1963, 2023.
- [۳] J. Orlosky, K. Kiyokawa, and H. Takemura, "Virtual and augmented reality on the 5G highway," *Journal of Information Processing*, vol. 25, pp. 133-141, 2017.
- [۴] F. M. García, R. Moraleda, S. Schez-Sobrinho, D. N. Monekosso, D. Vallejo, and C. Glez-Morcillo, "Health-5g: A mixed reality-based system for remote medical assistance in emergency situations," *IEEE Access*, vol. 11, pp. 59016-59032, 2023.
- [۵] R. Arshad, H. ElSawy, S. Sorour, T. Y. Al-Naffouri, and M.-S. Alouini, "Handover management in 5G and beyond: A topology aware skipping approach," *IEEE Access*, vol. 4, pp. 9073-9081, 2016.
- [۶] A. Gupta and R. K. Jha, "A survey of 5G network: Architecture and emerging technologies," *IEEE access*, vol. 3, pp. 1206-1232, 2015.
- [۷] K. Maruta *et al.*, "Millimeter-wave fast beam tracking enabled by RAN/V2X cooperation," in *2024 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC)* : ۲۰۲۴ ,IEEE, pp. 388-392 .
- [۸] M. De Ree, G. Mantas, A. Radwan, S. Mumtaz, J. Rodriguez, and I. E. Otung, "Key management for beyond 5G mobile small cells: A survey," *IEEE Access*, vol. 7, pp. 59200-59236, 2019.
- [۹] T. S. Rappaport *et al.*, "Millimeter wave mobile communications for 5G cellular: It will work!," *IEEE access*, vol. 1, pp. 335-349, 2013.
- [۱۰] H. Nishimoto *et al.*, "Linear cellularization enabling millimeter-wave train radio communication systems in 5G Era," in *2018 Progress in Electromagnetics Research Symposium (PIERS-Toyama)*, 2018: IEEE, pp. 99-106 .
- [۱۱] O. Idowu-Bismark, O. Oyeleke, A. A. Atayero, and F. Idachaba, "5G small cell backhaul: A solution based on GSM-aided hybrid beamforming," *International Journal of Computer Network and Information Security*, vol. 11, no. 8, p. 24, 2019.
- [۱۲] A. Priyanka, P. Gauthamarayathirumal, and C. Chandrasekar, "Machine learning algorithms in proactive decision making for handover management from 5G & beyond 5G," *Egyptian Informatics Journal*, vol. 24, no. ۳, p. 100389, 2023.
- [۱۳] M. S. Alam, G. K. Kurt, H. Yanikomeroglu, P. Zhu, and N. D. Đào, "High altitude platform station based super macro base station constellations," *IEEE Communications Magazine*, vol. 59, no. 1, pp. 103-109, 2021.
- [۱۴] A. Stamou, N. Dimitriou, K. Kontovasilis, and S. Papavassiliou, "Context-aware handover management for HetNets: Performance evaluation models and comparative assessment of alternative context acquisition strategies," *Computer Networks*, vol. 176, p. 107272, 2020.
- [۱۵] V. Yajnanarayana, H. Rydén, and L. Hévizi, "5G handover using reinforcement learning," in *2020 IEEE 3rd 5G World Forum (5GWF)*, 2020: IEEE, pp. 349-354 .

- [۱۶] M. R. Mahmood, M. A. Matin, P. Sarigiannidis, and S. K. Goudos, "A comprehensive review on artificial intelligence/machine learning algorithms for empowering the future IoT toward 6G era," *IEEE Access*, vol. 10, pp. 87535-87562, 2022.
- [۱۷] A. Habbal, S. I. Goudar, and S. Hassan, "Context-aware radio access technology selection in 5G ultra dense networks," *IEEE access*, vol. 5, pp. 6636-6648, 2017.
- [۱۸] Y. Li and H. Wu, "A clustering method based on K-means algorithm," *Physics Procedia*, vol. 25, pp. 1104-1109, 2012.
- [۱۹] D. Deng, "DBSCAN clustering algorithm based on density," in *2020 7th international forum on electrical engineering and automation (IFEEA)*, 2020: IEEE, pp. 949-953 .
- [۲۰] J. Wang and J. Jiang, "Unsupervised deep clustering via adaptive GMM modeling and optimization," *Neurocomputing*, vol. 433, pp. 199-211, 2021.
- [۲۱] R. M. Abdullah, I. Al-Surmi, G. R. Qaid, and A. A. Alwan, "Energy-Efficient Handover Algorithm for Sustainable Mobile Networks: Balancing Connectivity and Power Consumption," *Journal of Sensor and Actuator Networks*, vol. 13, no. 5, p. 51, 2024.
- [۲۲] R. A. Paropkari, A. Thantharate, and C. Beard, "Deep-mobility: A deep learning approach for an efficient and reliable 5g handover," in *2022 international conference on wireless communications signal processing and networking (WiSPNET)*, 2022: IEEE, pp. 244-250 .
- [۲۳] H. Wang and B .Li, "Double-deep Q-learning-based handover management in mmWave heterogeneous networks with dual connectivity," *Transactions on Emerging Telecommunications Technologies*, vol. 35, no. 1, p. e4907, 2024.
- [۲۴] W. Ren, J. Xu, D. Li, Q. Cui, and X. Tao, "A robust inter beam handover scheme for 5G mmWave mobile communication system in HSR scenario," in *2019 IEEE Wireless Communications and Networking Conference (WCNC)*, 2019: IEEE, pp. 1-6 .
- [۲۵] S. Alraih, R. Nordin, A. Abu-Samah, I. Shayea, and N. F. Abdullah", "A survey on handover optimization in beyond 5G mobile networks: Challenges and solutions," *IEEE Access*, vol. 11, pp. 59317-59345, 2023.
- [۲۶] L. Yan *et al.*, "Machine learning-based handovers for sub-6 GHz and mmWave integrated vehicular networks," *IEEE Transactions on Wireless Communications*, vol. 18, no. 10, pp. 4873-4885, 2019.
- [۲۷] R. Rafailov, K. B. Hatch, V. Kolev, J. D. Martin, M. Phielipp, and C. Finn, "Moto: Offline pre-training to online fine-tuning for model-based robot learning," in *Conference on Robot Learning*, 2023: PMLR, pp. 3654-3671 .
- [۲۸] S. Sinha, J. W. Lambrechts, A. Bimana, and A. Ashipala, "Augmented Artificial Intelligence in 5G, 6G, and Beyond: A Quantum Leap," *Computer*, vol. 58, no. 1, pp. 24-32, 2025.
- [۲۹] S. K. Thillaigovindhan ,M. Roslee, S. M. I. Mitani, A. F. Osman, and F. Z. Ali, "A comprehensive survey on machine learning methods for handover optimization in 5g networks," *Electronics*, vol. 13, no. 16, p. 3223, 2024.
- [۳۰] A. Al-Thaedan *et al.*, "A machine learning framework for predicting downlink throughput in 4G-LTE/5G cellular networks," *International Journal of Information Technology*, vol. 16, no. 2, pp. 651-657, 2024.
- [۳۱] M. S. Mollel *et al.*, "A survey of machine learning applications to handover management in 5G and beyond," *IEEE Access*, vol. 9, pp. 45770-45802, 2021.
- [۳۲] J. P. Lima *et al.*, "Deep learning-based handover prediction for 5G and beyond networks," in *ICC 2023-IEEE International Conference on Communications*, 2023: IEEE, pp. 3468-3473 .

- [۳۳] W.-S. Hwang, T.-Y. Cheng, Y.-J. Wu, and M.-H. Cheng, "Adaptive handover decision using fuzzy logic for 5G ultra-dense networks," *Electronics*, vol. 11, no. 20, p. 3278, 2022.
- [۳۴] M. Alhabo, L. Zhang, N. Nawaz, and H. Al-Kashoash, "Game theoretic handover optimisation for dense small cells heterogeneous networks," *IET Communications*, vol. 13, no. 15, pp. 2395-2402, 2019.
- [۳۵] L.-P. Tung and B.-S. P. Lin, "Big data and machine learning driven handover management and forecasting," in *2017 IEEE Conference on Standards for Communications and Networking (CSCN)*, 2017: IEEE, pp. 214-219 .
- [۳۶] J. Tanveer, A. Haider, R. Ali, and A. Kim, "An overview of reinforcement learning algorithms for handover management in 5G ultra-dense small cell networks," *Applied Sciences*, vol. 12, no. ۱, p. 426, 2022.
- [۳۷] M. B. Patil and L. Math, "A novel approach for optimization of handover mechanism using metaheuristics algorithms," *Measurement: Sensors*, vol. 24, p. 100467, 2022.
- [۳۸] A. Kapoor and A. Singhal, "A comparative study of K-Means, K-Means++ and Fuzzy C-Means clustering algorithms," in *2017 3rd international conference on computational intelligence & communication technology (CICT)*, 2017: IEEE, pp. 1-6 .