

پژوهشی

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

بابک لطفی*^۱ | یاسر علمی سولانی^۲

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، با هدف 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.

^۱ دانشجوی دکتری تخصصی مهندسی فناوری اطلاعات، گروه مهندسی کامپیوتر و فناوری اطلاعات، واحد سبزوار، دانشگاه آزاد اسلامی، سبزوار، ایران

babak.lotfi@iau.ac.ir

^۲ استادیار گروه 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، دانشگاه آزاد اسلامی واحد سبزوار، سبزوار، ایران

babak.lotfi@iau.ac.ir

تاریخ دریافت: ۱۴۰۴/۰۱/۰۴

تاریخ پذیرش: ۱۴۰۴/۰۱/۲۷

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

تازه های تحقیق:


- استفاده هم زمان از چند الگوریتم خوشه بندی با تغییر در ویژگی های ورودی و پیاده سازی آن ها در بسترهای مختلف.
- پیش پردازش ویژگی هایی مانند موقعیت کاربر، قدرت سیگنال دریافتی و وضعیت سلول، به منظور ارتقاء دقت خوشه بندی.
- مقایسه جامع عملکرد الگوریتم ها با نسخه های پایه، بدون بهینه سازی ویژگی ها برای ارزیابی واقعی تأثیر داده های اصلاح شده.
- اثبات بهبود معنادار عملکرد شبکه از طریق تحلیل آماری شاخص های ارزیابی در ساختار ترکیبی نسبت به سایر روش ها.
- تلفیق خروجی الگوریتم ها در ساختار ترکیبی با استفاده از تصمیم گیری لایه ای.

۱. مقدمه

شبکه‌های نسل پنجم به عنوان یک فناوری پیشرفته‌ی ارتباطی، تحولی شگرف در سرعت و قابلیت‌های ارتباطاتی بی‌سیم، ایجاد کرده‌اند. این شبکه‌ها با ارائه‌ی پهنای باند وسیع‌تر، تأخیر کمتر و ظرفیت بالاتر، زمینه‌ساز توسعه و پیاده‌سازی برنامه‌های 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 چالش‌های اصلی در شبکه‌های نسل پنجم، مدیریت مؤثر فرآیند انتقال [۵] بین سلول‌های مختلف شبکه است.

متراکم سازی شبکه، مکانیسمی بنیادی برای افزایش تراکم ایستگاه‌های پایه در یک منطقه خاص در جهت بالا بردن ظرفیت شبکه دسترسی رادیویی است که انتظار می‌رود شبکه‌های 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 می‌شود که در این رویکرد، سایر ایستگاه‌های 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 می‌شود [۶].

در شبکه‌های 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، به‌طور مداوم بین ایستگاه‌های پایه‌ی مختلف، جابه‌جا شده که می‌تواند باعث اختلال در اتصال، کاهش سرعت و افت کیفیت خدمات شود. با ظهور شبکه‌های متراکم و استفاده از امواج میلی‌متری [۷]، مشکل انتقال بین سلول‌ها تشدید شده است. زیرا فرکانس‌های بالاتر محدوده پوشش‌دهی کمتری دارند. به همین دلیل، برای پوشش بهتر، نیاز به نصب تعداد بیشتری ایستگاه پایه است. اما این افزایش پایه‌ها باعث افزایش تعداد انتقال بین سلولی شده و کیفیت خدمات به کاربران را کاهش می‌دهد. یکی از راه‌حل‌های ممکن، جهت افزایش کیفیت خدمات و بهبود مشکلات ناشی از افزایش تعداد انتقال بین سلول‌ها، استفاده از سلول‌های کوچک است [۸]. این سلول‌ها در نقاط پرتراکم نصب شده و با بهینه‌سازی پوشش و استفاده مجدد از فرکانس‌ها، امکان راه‌اندازی ایستگاه‌های پایه‌ی بیشتری را فراهم کرده که به کاهش تأثیرات منفی انتقال بین سلول‌ها، کمک می‌کند. علاوه بر این، امواج میلی‌متری، چالش‌های خاص خود را دارند. هرچه فرکانس بالاتر باشد، میزان افت سیگنال نیز بیشتر خواهد شد. یعنی سیگنال مسافت کوتاه‌تری را طی کرده و پوشش‌دهی ایستگاه‌های پایه، کاهش می‌یابد. همچنین، سیگنال‌هایی که پهنای باند بیشتری دارند، برد کوتاه‌تری خواهند داشت. این ویژگی‌ها باعث می‌شوند که ایستگاه‌های پایه با فاصله کمتری از هم نصب شده و ارتباطات پایدارتری را برای کاربران، فراهم کنند [۹].




شکل ۱: انتقال بین سلول‌ها در شبکه نسل پنجم

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 به‌شدت کاهش یافته به‌طوری‌که در فرکانس‌های پایین مانند ۲.۶ 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 می کند. زیرا تعداد بیشتری ایستگاه های پایه، برای پوشش دهی مناسب در فرکانس های بالا مورد نیاز بوده که باعث افزایش نرخ جابه جایی کاربر بین سلول ها، می شود. در فرکانس های ۶۰ و ۱۰۰ گیگاهرتز، این مقدار به بیشینه ی خود رسیده و به طور قابل ملاحظه ای بر کیفیت تجربه ی کاربر، تأثیر منفی، می گذارد.

نمودار سمت راست، ظرفیت شبکه را بر حسب نرخ فرآیند انتقال بین سلول ها نشان می دهد. ظرفیت شبکه در فرکانس های بالاتر به رغم افزایش نرخ فرآیند انتقال بین سلول ها، در مقایسه با فرکانس های پایین، بیشتر است [۱۰]. این امر به دلیل پهنای باند وسیع تر در فرکانس های با امواج میلیمتری بوده که امکان انتقال داده ها با نرخ بالاتر را فراهم می کند. با این حال، افزایش نرخ فرآیند انتقال بین سلول ها در این باندها، چالشی جدی در حفظ پایداری اتصال محسوب می شود. نتایج این تحلیل تأکیدی بر ضرورت استفاده از تکنیک هایی نظیر سلول های پایه ی کوچک، تشکیل پرتو هوشمند [۱۱] و الگوریتم های یادگیری ماشین [۱۲]، جهت بهینه سازی فرآیند انتقال بین سلول ها در شبکه های نسل پنجم و فراتر از آن داشته تا ضمن افزایش ظرفیت شبکه، نرخ جابه جایی کاربران بین سلول ها، مدیریت شده و از تأثیرات منفی آنها، کاسته شود.



شکل ۲: تأثیر افزایش فرکانس بر پوشش سلولی

با افزایش تعداد ایستگاه های پایه در یک محیط معین، دستگاه های کاربر، ملزم به انجام انتقال بین سلولی بیشتری، می شوند. این افزایش، ناشی از کاهش اندازه سلول ها و افزایش تراکم ایستگاه های پایه بوده که باعث می شود، محدوده ی پوشش هر ایستگاه پایه، کوچک تر و دستگاه های کاربر، سریع تر از محدوده ی یک ایستگاه خارج شوند [۱۳]. در نتیجه، تعداد انتقال ها افزایش یافته که می تواند بر پایداری اتصال و کیفیت تجربه کاربر، تأثیر منفی بگذارد. از آنجایی که میانگین توان عملیاتی کاربر با تعداد انتقال ها، رابطه ی 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 سطح رضایت کاربران شده و می تواند اهداف کلیدی شبکه های نسل پنجم از جمله پایداری اتصال، کاهش تأخیر و تجربه ی کاربری یکپارچه را تحت تأثیر قرار دهد [۱۴].

مواجه شدن با تعداد و هزینه ی انتقال های تحمیل شده در طول یک جلسه پیامدهای نامطلوبی دارد. به همین دلیل، عمده تحقیقات در مورد مدیریت انتقال بر دو موضوع کاهش تعداد و هزینه ی هر انتقال، متمرکز شده است. علی رغم این واقعیت و با توجه به اطلاعات مربوطه به رشد ایستگاه های پایه، اینترنت اشیا و همچنین افزایش تقاضا برای خدمات داده محور، عمدتاً تاکنون، آمارها منفی گزارش شده است. اپراتورهای شبکه برای فعال کردن مدیریت موثرتر، ممکن است از حجم وسیعی از داده های ایجاد شده توسط شبکه های سلولی استفاده کرده که به طور قابل توجهی نیز در حال گسترش است. به عبارت دیگر، هرچه شبکه ها بزرگ تر و پیچیده تر شوند، همچنان حجم عظیمی از داده های تولید شده که توجه به کاهش این پیچیدگی ها، بسیار ضروری است. به همین دلیل، روش های یادگیری ماشین توجه زیادی را در حوزه ارتباطات بی سیم به خود جلب کرده است. چرا که مقادیر زیادی از داده ها را می توان به طور موثر برای آموزش مدل های یادگیری ماشین مورد استفاده قرار داد که منجر به تصمیم گیری فعال تر و آگاهانه تر شود [۱۵].

هوش مصنوعی و یادگیری ماشین نقش محوری در شبکه های نسل ششم ایفا خواهند کرد، زیرا انتظار می رود این شبکه ها به صورت هوشمند مدیریت، کنترل و بهینه سازی شوند. در این راستا، مدیریت فرآیند انتقال بین سلولی از اهمیت بالایی برخوردار بوده و نیازمند توسعه روش های کارآمد، مبتنی بر یادگیری ماشین است. بنابراین، بررسی پیشرفت های اخیر در مدیریت انتقال

مبتنی بر یادگیری ماشین در شبکه‌های سلولی، به‌ویژه در نسل پنجم و ششم، همراه با تحلیل داده‌های مورد استفاده در این الگوریتم‌ها، ضرورتی اجتناب‌ناپذیر به شمار می‌رود [۱۶، ۱۲].

در عصر ارتباطات سیار، تداوم ارتباط باکیفیت یکی از عوامل کلیدی در شبکه‌های تلفن همراه محسوب می‌شود. فرآیند انتقال بین سلولی به‌عنوان 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 می‌باشند. ظهور فناوری‌های توانمندساز در شبکه‌های نسل پنجم، از جمله اینترنت اشیا، 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 فرآیند انتقال بین سلولی را پیچیده‌تر کرده و نیازمند روش‌های پیشرفته‌تر برای بهینه‌سازی این فرآیند 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 فرآیند 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 فرآیندهای 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، به‌طور چشمگیری برجسته‌تر است. بهینه‌سازی و مدیریت کارآمد فرآیند انتقال در این شبکه‌ها نه‌تنها از اهمیت ویژه‌ای برخوردار است، بلکه می‌تواند به‌طور قابل‌توجهی 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 می‌باشند. الگوریتم‌های مختلفی می‌توانند در افزایش دقت خوشه‌بندی و کاهش تعداد انتقال بین سلول‌ها نقش بسزایی ایفا کنند.

الگوریتم K-Means [۱۸]، به‌عنوان 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 فرآیند انتقال بین سلولی محسوب می‌شود. این پارامتر به‌عنوان یک شاخص قابل‌اعتماد برای ارزیابی کیفیت ارتباط و پایداری لینک مخابراتی، نقش مهمی در تصمیم‌گیری‌های مرتبط با فرآیند 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 فرآیند 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].

با توجه به مباحث مطرح‌شده، این پژوهش بر دو نوآوری کلیدی ترکیب سه الگوریتم خوشه‌بندی برای بهینه‌سازی فرآیند 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 فرآیند 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 چالش های موجود در حل مسئله تحلیل شده است. فصل سوم روش پیشنهادی را به تفصیل تشریح می کند. در فصل چهارم نحوه پیاده سازی و تحلیل نتایج ارائه شده و در نهایت، فصل پنجم به جمع بندی و نتیجه گیری نهایی اختصاص یافته است.

۲. مروری بر ادبیات پژوهش

همانگونه که در بخش مقدمه گفته شد با توجه به ویژگی های جدید شبکه های نسل پنجم و چالش های تحمیل شده به این شبکه ها، راه حل های مرسوم در مدیریت انتقال، قادر به مقابله با افزایش مشکلات و پیچیدگی هایی که استفاده از امواج میلی متری و باندهای فرکانسی بیشتر در شبکه های نسل پنجم برای مدیریت دست به دست شدن ایجاد می کند، نیستند. در شبکه های مخابرات سیار، فرایند انتقال بین سلول ها به فرایندی اطلاق می شود که در آن، ارتباط فعال یک کاربر از یک ایستگاه پایه به ایستگاه پایه دیگری منتقل می شود تا پیوستگی خدمات و کیفیت ارتباط حفظ گردد. این مکانیزم به ویژه در شبکه های نسل پنجم با توجه به معماری فوق متراکم و تعداد بالای ایستگاه های پایه، اهمیت بیشتری یافته است. در این شبکه ها، مدیریت مؤثر فرایند انتقال بین سلول ها برای اطمینان از تأخیر کم، پایداری اتصال و تجربه کاربری بهینه ضروری است. تحقیقات نشان می دهد که استفاده از الگوریتم های یادگیری ماشین و روش های تحلیلی پیشرفته، می تواند به بهبود فرایند فرایند انتقال بین سلول ها و کاهش نرخ شکست آن، کمک کند [۲۲]. در ابتدا، فاصله ی انتقال برای این محدوده فرکانسی به دلیل تضعیف شدید، محدود خواهد شد. در نتیجه، برای پوشش همان منطقه ای که از فرکانس های مایکروویو استفاده می کردند، ایستگاه های پایه اضافی باید ساخته شوند. این نشان می دهد که شبکه از نظر اندازه و پیچیدگی به طور قابل توجهی رشد خواهد کرد و کاربران انتقال های بین سلولی بیشتری را تجربه خواهند کرد، که به کیفیت خدمات آنها، به ویژه برای کاهش کیفیت و عملکرد ارتباط کاربران و برنامه های تلفن همراه منجر خواهد شد. ضمناً از آنجایی که شبکه های امواج میلی متری از پرتوهای هدایت شده برای انتقال استفاده می کنند، 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 شبکه های ارتباطی موج میلی متری 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 فرایند مدیریت انتقال به دلیل تعداد زیاد پرتو هایی که کاربر باید در طول هر نمونه انتقال انتخاب کند، در نظر گرفته شود که این موضوع پیچیدگی بیشتری را به فرایند مدیریت انتقال اضافه می کند [۲۴]. در نتیجه، بهینه سازی 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 انتقال های اضافی یا غیر ضروری را به حداقل رسانده و در نهایت، شناسایی و اجتناب از موانع را، تسهیل می کند. در مقایسه ی شبکه های ارتباطی موج میلی متری با نسل های قبلی شبکه سلولی، موارد ذکر شده تنها برخی از مشکلاتی هستند که مدیریت بهینه سازی انتقال را دشوارتر می کنند. علاوه بر این، اکثر روش های سنتی مدیریت فرایند انتقال بین سلولی را بسیار دشوار می دانند، زیرا به چندین فاکتور شبکه نیاز داشته که باید در زمان واقعی در نظر گرفته شوند و برای فعال کردن انتقال بی عیب و نقص تنظیم شوند. یکی از مشکل تکنیک های سنتی مدیریت انتقال نیاز به قدرت پردازش زیادی در زمان اجرا، به ویژه در شبکه ها با ابعاد و اندازه ی بزرگ است [۲۴]. ضمناً این الگوریتم ها قادر به ثبت دقیق برخی از ویژگی های شبکه مانند وجود موانع در اندازه ها و انواع مختلف و الگوهای تقاضای ترافیک پویا که مشخصه شبکه های نسل پنجم بوده، نیستند. با این وجود، رویکردهای یادگیری ماشین ممکن است به هوشمندسازی و پشتیبانی از بهینه سازی شبکه ها کمک کنند [۲۵].

تکنیک های یادگیری ماشین ممکن است برای یادگیری ویژگی های مختلف شبکه از داده های تولید شده توسط شبکه به منظور بهینه سازی ویژگی های مختلف شبکه مورد استفاده قرار گیرند. این تکنیک ها می توانند الگوها و جزئیات پنهانی از شبکه را که روش های تحلیلی عادی قادر به استخراج آنها نیستند، کشف کنند. این الگوریتم ها می توانند خواسته های آتی کاربران یا شبکه را پیش بینی کرده و از قبل به چنین درخواست هایی واکنش نشان دهند. این تکنیک ها، شبکه را قادر می سازند تا در صورت رخداد درخواست های پیش بینی شده کاربران، آماده رسیدگی به آنها بوده و می توانند به طور مستقل با تغییرات در محیط شبکه، تطبیق یابند [۲۶].

بخش آموزش الگوریتم‌های یادگیری ماشین که اغلب از نظر محاسباتی فشرده است به صورت آفلاین انجام شده و از نظر محاسباتی بخش اجرایی الگوریتم شبکه را می‌توان به طور کارآمدتری، طراحی کرد. سپس، مدل آموزش‌دیده ممکن است به صورت 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 به عنوان 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 آنجا که 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 به عنوان 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 جابجایی کاربران و بهینه‌سازی فرایند انتقال بین سلول‌های شبکه پیشنهاد شده‌اند. در این میان، مدل‌های یادگیری تقویتی مانند یادگیری تقویتی ارزش محورو 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 آموزش داده شده 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 فرایند انتقال بین سلول‌ها، بهبود کیفیت خدمات و افزایش رضایت کاربران است.

با توجه به توانایی این الگوریتم‌ها در یادگیری از داده‌های شبکه و تطبیق با شرایط پویای ارتباطی، به عنوان 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 قابل توجهی 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 به‌طور 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 به‌شمار می‌رود. علاوه بر این، ممکن است این مدل‌ها در شبکه‌هایی با شرایط خاص عملکرد ضعیف‌تری داشته و نیاز به بازآموزی مستمر در محیط‌های پرتغییر 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 فرآیند 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 قابل توجهی 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 فرآیند 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 فرآیند 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 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 فرآیند 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 فرآیند 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، به صورت 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 به عنوان ورودی‌های کنترل کننده فازی بهره می‌برد. نتایج شبیه سازی با برنامه‌ی ns-3 نشان می‌دهد که این مدل نسبت به روش‌های سنتی، تعداد دست به دست شدنهای غیر ضروری را کاهش داده، اثر پینگ پنگ را کنترل کرده و توان عملیاتی کلی شبکه را بهبود می‌بخشد. این مدل به دلیل انعطاف پذیری 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 سلول‌ها های غیر ضروری و بهینه سازی 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 به عنوان یک ابزار مدل سازی تصمیم گیری، می‌تواند در مدیریت فرایند انتقال بین سلولی در شبکه‌های ناهمگن متراکم به کار گرفته شود. در این رویکرد، ایستگاه‌های پایه به عنوان 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 انتقال های غیر ضروری 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 غیر ضروری را در نظر می‌گیرد. در این روش، انتخاب بهترین سلول با الگوریتم رتبه بندی بر اساس شباهت به گزینه ایده آل انجام می‌شود. شبیه سازی‌های انجام شده نشان داده که این مدل باعث افزایش توان عملیاتی شبکه، کاهش مصرف انرژی، متعادل سازی بار شبکه و کاهش انتقال‌هایی غیر ضروری 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 غیر ضروری بین سلولی، افزایش توان عملیاتی و بهینه سازی مصرف انرژی را فراهم می‌کند. در این مدل، ایستگاه‌های پایه به عنوان 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 پیاده سازی 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 بهینه سازی 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 پیش بینی رفتار انتقال بین سلولی در سطح سلولی و بهینه سازی 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 پیش بینی 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 داده محور، قادر به تفکیک الگوهای انتقال بین سلول‌ها و کاهش دستورات کنترلی غیر ضروری است.

این روش نه تنها باعث افزایش بازده طیفی و کاهش تأخیر فرایند انتقال بین سلولی می‌شود، بلکه می‌تواند از بروز مشکلاتی مانند دست به دست شدنهای غیر ضروری و اثر پینگ پنگ جلوگیری کند. استفاده از تحلیل داده‌های ترافیکی و الگوهای جابجایی کاربران، به افزایش دقت تصمیم گیری 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، پیش بینی تلاش‌های انتقال بین سلول‌ها و کاهش دستورات کنترلی غیر ضروری 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، بهینه سازی بازده طیفی و جلوگیری از اثر پینگ پنگ در شبکه‌های متراکم است. با این حال، پیچیدگی پردازش حجم عظیم داده‌ها، نیاز به زیرساخت‌های ذخیره سازی قدرتمند و مدیریت داده‌های بلادرنگ از چالش‌های آن محسوب [۳۵].

مدیریت فرایند انتقال بین سلولی در شبکه های فوق متراکم با سلول های کوچک به دلیل افزایش تعداد ایستگاه های پایه و ترافیک داده ها، چالش های متعددی را ایجاد کرده است. استفاده از الگوریتم های پیشرفته هوش مصنوعی و یادگیری تقویتی برای بهینه سازی فرآیند دست به دست شدن، به یکی از راهکارهای کلیدی در بهبود کیفیت خدمات و کاهش تأخیر انتقال تبدیل شده است. در این روش ها، پارامترهایی مانند ظرفیت ایستگاه پایه، مسیر حرکت کاربر، کیفیت سیگنال دریافتی، نسبت سیگنال به نویز و میزان ترافیک داده ها به عنوان ورودی های کلیدی در فرآیند تصمیم گیری انتقال بین سلول ها در نظر گرفته می شوند. مدل های یادگیری تقویتی قادرند به صورت پویا سیاست های فرایند انتقال بین سلولی را بر اساس شرایط لحظه ای شبکه بهینه سازی کنند. یکی از روش های کارآمد در این زمینه، الگوریتم های یادگیری تقویتی عمیق بوده که از شبکه های عصبی برای تخمین مقادیر بهینه فرایند انتقال بین سلولی استفاده می کند. همچنین، یک روش شش مرحله ای شامل پیکربندی، تصمیم گیری، فیلتر کردن، محدودسازی، انتخاب قوی ترین سیگنال و آغاز فرآیند انتقال بین سلولی طراحی شده است که موجب افزایش نرخ داده های کاربر، کاهش تعداد انتقال های غیرضروری و بهبود بهره وری شبکه می شود. علاوه بر یادگیری تقویتی، استفاده از الگوریتم های بهینه سازی چندمعیاره مانند الگوریتم ژنتیک و روش های مبتنی بر فرآیند تصمیم گیری چندمعیاره، می توانند انتخاب ایستگاه پایه را بهینه تر کرده و تأخیر و از دست رفتن بسته ها را کاهش دهد. این روش ها به ویژه در شبکه های متراکم نسل پنجم که شامل سلول های 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 آموزش های طولانی، مصرف زیاد منابع محاسباتی، وابستگی به کیفیت داده های ورودی و مشکل تطبیق این الگوریتم ها با شرایط واقعی شبکه های متراکم از چالش های این روش ها محسوب شده و می توانند اجرای عملی آن ها را دشوار کند [۳۶].

یکی از چالش های اساسی در شبکه های نسل پنجم، بهینه سازی کیفیت خدمات و کاهش تأخیر در انتقال است. در راستای مدیریت فرآیند انتقال بین سلولی، الگوریتم های فراابتکاری به دلیل قابلیت های جستجوی تطبیقی و توانایی مقابله با پیچیدگی های محیطی، مورد توجه قرار گرفته اند. در پژوهشی، رویکردی ترکیبی مبتنی بر الگوریتم گرگ خاکستری و الگوریتم بهینه سازی شمع و پروانه، برای بهینه سازی فرآیند تحویل در شبکه های ناهمگن معرفی شده است. این مدل، فرآیند انتقال بین سلولی را در سه مرحله ای، مقداردهی اولیه، انتخاب شبکه و اجرای انتقال، ساماندهی می کند. 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 می شود. در مرحله انتخاب، معیارهای چندگانه ای همچون سرعت کاربر، امنیت شبکه و بار ترافیکی برای تعیین مقصد بهینه انتقال در نظر گرفته می شود. در نهایت، در مرحله اجرا، ترکیب قابلیت های اکتشافی الگوریتم گرگ خاکستری و ویژگی های همگرایی سریع الگوریتم بهینه سازی شمع و پروانه به کار گرفته می شود تا فرآیند تحویل با کمترین تأخیر و بیشترین بهره وری انجام شود. نتایج شبیه سازی ها نشان می دهد که مدل پیشنهادی در مقایسه با روش های متداول مبتنی بر تئوری بازی ها برای بهینه سازی و تسریع فرآیند تحویل بین شبکه ای مانند، شبکه عصبی فازی، الگوریتم های زنبور عسل و بهینه سازی ذرات، باعث کاهش مصرف انرژی، تأخیر انتقال و احتمال قطع تماس شده و درعین حال توان عملیاتی را بهبود داده است. این رویکرد، به ویژه در محیط های متراکم نسل پنجم، قادر به کاهش تعداد انتقال های غیرضروری و بهینه سازی عملکرد شبکه است. اما پیچیدگی محاسباتی و وابستگی به تنظیمات اولیه از جمله چالش های آن محسوب می شود [۳۷].

۲-۲. پژوهش های مرتبط با عملیات انتقال بین سلولی

مطابق با جدول (۱) می توان دید که مطالعه و تحلیل مقالات مختلف در زمینه مدیریت انتقال بین سلول ها در شبکه های نسل پنجم و به ویژه در شبکه های فوق متراکم، نشان دهنده تحقیقات و تلاش های فراوانی است که در جهت بهینه سازی فرآیند انتقال بین سلولی انجام شده است. با وجود 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: پژوهش‌های مرتبط با عملیات انتقال بین سلولی

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 in 5G Networks	روش‌های یادگیری ماشین برای بهینه‌سازی فرآیند انتقال بین سلولی در شبکه‌های نسل پنجم، چالش‌های موجود در مدیریت انتقال بین سلولی، تحلیل و تکنیک‌های یادگیری ماشین برای کاهش تأخیر و بهبود کیفیت خدمات	بهینه‌سازی پیش‌بینی عملکرد شبکه، تحلیل پارامترهای کلیدی انعطاف‌پذیری در مواجهه با تغییرات شبکه، استفاده از داده‌های واقعی	نیاز به داده‌های حجیم و پردازش پیچیده، کمبود شفافیت در تصمیم‌گیری، آموزش‌های زمان‌بر و پیچیده
عباس‌آل-تهمدان و همکاران [۳۰]	۲۰۲۴	A machine learning framework for predicting downlink throughput in 4G-LTE/5G cellular networks	یک مدل یادگیری ماشین برای پیش‌بینی پهنای باند در شبکه‌های نسل چهارم و پنجم، استفاده از داده‌های سیگنال دریافتی و کیفیت سیگنال برای پیش‌بینی نرخ انتقال داده‌ها جهت بهینه‌سازی عملکرد شبکه‌های موبایل و پیش‌بینی ترافیک داده‌ها در شرایط مختلف	دقت بالا در پیش‌بینی پهنای باند و بهبود کیفیت خدمات با تحلیل پارامترهای کلیدی مانند قدرت سیگنال دریافتی و نسبت سیگنال به نویز، یادگیری از داده‌های شبکه و تطبیق با شرایط پویای ارتباطی	نیاز به داده‌های حجیم و پردازش پیچیده، کمبود شفافیت در تصمیم‌گیری‌های مدل‌های پیچیده و نیاز به آموزش‌های زمان‌بر
مایکل اس. مولر 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 شبکه‌های نسل پنجم، کمک به بهینه‌سازی فرآیند انتقال بین سلولی با مدل‌های مختلف یادگیری ماشین در محیط‌های مختلف، تحلیل دسته‌بندی چالش‌ها و فرصت‌های پیش روی استفاده از این الگوریتم‌ها	بهبود دقت پیش‌بینی زمان و مکان انتقال بین سلولی، افزایش پایداری ارتباطات در شبکه‌های نسل پنجم، کاهش تأخیر و جلوگیری از قطع ناگهانی ارتباط	نیاز به توان پردازشی بالا و تأخیر در استنتاج مدل‌ها، شفافیت پایین در تصمیم‌گیری، پیچیدگی محاسباتی در پیاده‌سازی عملی
ژوآئو پی. اس. اچ. لیم و همکاران [۳۲]	۲۰۲۳	Deep Learning-Based Handover Prediction for 5G and Beyond Networks	یک مدل یادگیری عمیق مبتنی بر شبکه‌های عصبی حافظه طولانی، کوتاه مدت برای پیش‌بینی دقیق فرآیند انتقال بین سلولی در شبکه‌های نسل پنجم و پیش‌بینی لحظه بهینه انتقال بین سلولی با استفاده از داده‌های قدرت سیگنال و تحلیل الگوهای حرکت کاربران با دقت بیش از ۹۷ درصد	توانایی کاهش قطعی‌های ناگهانی، بهینه‌سازی جابجایی کاربران و افزایش بهره‌وری در شبکه‌های نسل پنجم	نیاز به توان پردازشی بالا و پیچیدگی در پیاده‌سازی
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 فرآیند انتقال بین فوق متراکم. مدل پیشنهادی با استفاده از ورودی‌های قدرت سیگنال به نویز و سرعت حرکت کاربر ارائه شده که قادر به کاهش انتقال‌های غیرضروری بین سلولی، افزایش کیفیت خدمات و بهبود بهره‌وری شبکه شده است.	توانایی کاهش تعداد انتقال‌های غیرضروری بین سلولی و بهینه‌سازی توان عملیاتی شبکه	وابستگی زیاد به تنظیمات اولیه قوانین فازی و پیچیدگی طراحی سیستم‌های فازی پویا، نیاز به پردازش بیشتر در مقایسه با مدل‌های کلاسیک
محمد اله‌بابو و همکاران [۳۴]	۲۰۱۹	Game theoretic handover optimization for dense small cells heterogeneous networks	مدل‌سازی فرآیند انتقال بین سلولی به‌عنوان یک بازی غیرهمکارانه بین ایستگاه‌های پایه در شبکه‌های ناهمگن با سلول‌های کوچک. تعادل نش برای بهینه‌سازی مصرف توان، تعادل بار شبکه و کاهش تعداد انتقال بین سلولی غیرضروری، کاهش تأخیر و افزایش کارایی در شبکه‌های نسل پنجم.	تخصیص بهینه منابع و افزایش کیفیت خدمات	پیچیدگی محاسباتی مدل‌های نظریه بازی، نیاز به اطلاعات دقیق از وضعیت شبکه و دشواری پیاده‌سازی در محیط‌های واقعی
امیر حیدر و همکاران [۳۶]	۲۰۲۲	An Overview of Reinforcement Learning Algorithms for Handover Management in 5G Ultra-Dense Small Cell Networks	بررسی الگوریتم‌های یادگیری تقویتی در مدیریت انتقال بین سلولی در شبکه‌های فوق متراکم با سلول‌های کوچک نسل پنجم و استفاده از داده‌های شبکه، یادگیری از تجربیات گذشته در تصمیم‌گیری انتقال بین سلولی	کاهش تعداد انتقال‌های غیرضروری بین سلولی، افزایش بهره‌وری و بهبود کیفیت خدمات	پیچیدگی بالای پردازش، نیاز به آموزش‌های طولانی و مصرف زیاد منابع محاسباتی
پاتی و همکاران [۳۷]	۲۰۲۲	A novel approach for optimization of handover mechanism using metaheuristics algorithms	استفاده از الگوریتم‌های فراابتکاری به دلیل قابلیت‌های جستجوی تطبیقی و توانایی مقابله با پیچیدگی‌های محیطی، رویکردی ترکیبی مبتنی بر الگوریتم گرگ خاکستری و الگوریتم بهینه سازی شمع و پروانه، برای بهینه‌سازی فرآیند تحویل در شبکه‌های ناهمگن	کاهش مصرف انرژی، کاهش تأخیر انتقال و کاهش احتمال قطع تماس بهبود توان عملیاتی	پیچیدگی محاسباتی و وابستگی به تنظیمات اولیه

یکی از مهم ترین نقاط قوت مقالات بررسی شده، استفاده از یادگیری ماشین و الگوریتم های پیشرفته مانند یادگیری تقویتی و یادگیری عمیق برای پیش بینی و بهینه سازی فرآیند انتقال بین سلول ها است. این روش ها به خوبی نقطه ضعف های روش های سنتی که بیشتر بر مبنای مقایسه قدرت سیگنال تمرکز داشتند، پوشش می دهند و توانسته اند دقت بالایی را در پیش بینی انتقال بین سلول ها ارائه دهند. به ویژه مدل های مبتنی بر شبکه عصبی حافظه طولانی کوتاه مدت در پیش بینی زمان انتقال بین سلول ها با دقت بالای ۹۷ درصد، نشان دهنده توانایی های بالقوه این الگوریتم ها در شرایط مختلف شبکه است. با این حال، یکی از نقاط ضعف عمده این رویکردها، وابستگی زیاد آن ها به داده های شبیه سازی شده است. در بیشتر مقالات بررسی شده، الگوریتم ها با داده های شبیه سازی شده، ارزیابی شده اند و کمتر توجهی به داده های واقعی شبکه شده است. این امر باعث ایجاد فاصله ای بین کاربرد مدل ها در شرایط واقعی و عملکرد آن ها در محیط های آزمایشی می شود. داده های واقعی، به دلیل داشتن پیچیدگی ها و تغییرات لحظه ای، چالش های خاص خود را داشته که در بسیاری از این مدل ها به خوبی پوشش داده نشده است.

علاوه بر این، بسیاری از مدل های یادگیری ماشین که در مقالات به آن ها اشاره شده است با توجه به محاسبات پیچیده و نیاز به پردازش های سنگین، در شبکه های واقعی که باید در زمان واقعی پاسخ دهی کنند، ممکن است با مشکل مواجه شوند. این کاهش کارایی در عمل می تواند 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، در حالی که برخی مدل ها به پیش بینی دقیق زمان انتقال بین سلول ها می پردازند، کمتر به تأثیر متغیرهایی مانند ترافیک شبکه، ظرفیت ایستگاه پایه یا بار شبکه توجه شده است. این متغیرها می توانند تأثیر قابل توجهی بر پایداری و بهینه سازی فرآیند انتقال بین سلول ها داشته باشند. در کنار این مسائل، برخی از مدل ها که بر نظریه بازی ها یا منطق فازی تأکید دارند، به طور معناداری به تعاملات پویا و واقعی شبکه ها توجه نمی کنند. استفاده از نظریه بازی ها برای مدل سازی تصمیم گیری های ایستگاه های پایه ممکن است در شرایط خاصی مؤثر باشد، اما در شبکه هایی 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، به رغم پیشرفت های تکنولوژیکی که در استفاده از یادگیری ماشین و الگوریتم های بهینه سازی پیشرفته مشاهده می شود، همچنان چالش های زیادی برای اعمال این روش ها در شبکه های واقعی نسل پنجم وجود دارد. مدل های موجود، علی رغم داشتن دقت بالا در شرایط خاص آزمایشی، در کاربردهای عملیاتی شبکه های فوق متراکم و ناهمگن به سختی می توانند عملکرد بهینه تری را ارائه دهند. در نتیجه، تحقیقات آینده باید به مقایسه و اعتبارسنجی بیشتر مدل ها در محیط های واقعی پرداخته و تلاش کنند تا پیچیدگی های محاسباتی را کاهش دهند. همچنین، ترکیب چندین رویکرد و الگوریتم می تواند به ایجاد مدل های جامع تری کمک کرده که علاوه بر پیش بینی دقیق انتقال بین سلول ها، 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 بهینه سازی فرآیند انتقال بین سلول ها در شبکه های 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 چالش های خاص خود هستند. در روش موازی، سه الگوریتم خوشه بندی K-Means، DBSCAN و GMM به صورت هم زمان اجرا شده و خروجی آن ها از طریق رأی گیری اکثریت ترکیب می شود. در روش سری، الگوریتم های خوشه بندی به صورت مرحله ای اجرا شده و خروجی هر مدل به عنوان ورودی مدل بعدی مورد استفاده قرار می گیرد که در نهایت منجر به افزایش دقت و کاهش نویز در فرآیند خوشه بندی می شود. در روش ترکیبی، ابتدا سه الگوریتم خوشه بندی به صورت موازی اجرا می شوند و سپس خروجی آن ها به یک مدل یادگیری متوالی داده می شود که عملکرد کلی سیستم را بهبود داده و تعادل میان سرعت پردازش و دقت خوشه بندی را فراهم می کند. در تمامی این روش ها، یک مدل یادگیری متا، مبتنی بر جنگل تصادفی برای تجزیه و تحلیل و بهینه سازی نهایی خوشه بندی مورد استفاده قرار می گیرد. هدف اصلی این پژوهش، کاهش تعداد انتقال های غیر ضروری بین سلول ها، افزایش پایداری ارتباطات و بهبود کیفیت تجربه کاربر در شبکه های نسل پنجم است. در ادامه، ورودی ها، خروجی ها و فرآیند داخلی سیستم پیشنهادی به تفصیل مورد بررسی قرار می گیرد.

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 خوشه‌بندی:

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 با هدف پوشش دادن نقاط قوت متنوع و مکمل در فرآیند 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. با وجود این مزایا، این الگوریتم دارای محدودیت‌هایی نظیر وابستگی به تعداد اولیه‌ی خوشه‌ها و حساسیت بالا به داده‌های پرت می‌باشد. استفاده از نسخه‌های پیشرفته‌تر یا بهینه‌سازی شده‌ی 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 نماینده‌ی ساده و شفاف برای ارزیابی روش‌های ترکیبی و مقایسه عملکرد سه‌گانه ترجیح داده شد است.

از سوی دیگر، الگوریتم DBSCAN به‌عنوان یک الگوریتم چگالی‌محور، 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.



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 و 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 ویژگی‌های کلیدی: فقط ویژگی‌های مرتبط با خوشه‌بندی انتخاب شده تا الگوریتم‌ها بر داده‌های مهم تمرکز کنند.


این مرحله تضمین می‌کند که داده‌ها آماده ورود به مراحل بعدی بوده و هرگونه نویز یا تناقض در داده‌ها حذف شده است.

۳-۴. ورودی‌ها و خروجی‌های سیستم:

- ۳-۳-۱- مطابق با شکل (۴)، ورودی‌های سیستم، شامل داده‌ها و پارامترهایی است که برای خوشه‌بندی و تحلیل فرآیند انتقال مورد استفاده قرار می‌گیرند. این داده‌ها به شرح زیر هستند:
- قدرت سیگنال دریافتی: نشان‌دهنده کیفیت سیگنال دریافتی توسط دستگاه کاربر بوده که این پارامتر به طور مستقیم در فرآیند تصمیم‌گیری انتقال تأثیرگذار است.
 - موقعیت جغرافیایی کاربران: اطلاعات مکانی کاربران به صورت مختصات طول و عرض جغرافیایی ویژگی به خوشه‌بندی دقیق‌تر کاربران و شناسایی بهترین ایستگاه پایه برای اتصال، کمک می‌کند.
 - سرعت کاربران: سرعت حرکت کاربران که معمولاً در واحد متر بر ثانیه یا کیلومتر بر ساعت اندازه‌گیری می‌شود. کاربران با سرعت بالا به‌ویژه در محیط‌های شهری یا پرتراکم معمولاً به تعداد بیشتری انتقال نیاز دارند.
 - وضعیت سلول‌های شبکه: شامل اطلاعاتی مانند بار شبکه، ظرفیت سلول‌ها و پوشش‌دهی است. این ویژگی تأثیر مستقیمی بر مدیریت انتقال دارد.
 - الگوی حرکت کاربران: شامل مسیرهای پرتردد یا مناطقی که کاربران در آن توقف بیشتری دارند می‌باشد. این الگوها به پیش‌بینی رفتار کاربران و بهبود فرآیند انتقال کمک می‌کنند.
- ۳-۳-۲- خروجی‌های سیستم شامل نتایج حاصل از بهبود فرآیند انتقال و بهینه‌سازی خوشه‌بندی داده‌ها بوده که عبارتند از:
- کاهش تعداد انتقال‌ها: کاهش دفعات انتقال کاربران بین سلول‌های شبکه به پایداری بیشتر ارتباط و بهبود تجربه کاربری منجر می‌شود.
 - افزایش کیفیت: بهبود کیفیت ارتباط کاربران از طریق کاهش تأخیر و ناپایداری.
 - خوشه‌بندی بهینه کاربران: توزیع مناسب کاربران در خوشه‌های مختلف برای مدیریت بهتر منابع شبکه.
 - انتخاب بهترین الگوریتم انتقال: شناسایی و استفاده از الگوریتمی که عملکرد بهتری در کاهش تعداد انتقال‌های بین سلولی داشته و در نتیجه منجر به افزایش کیفیت خدمات شبکه شود.

موقعیت جغرافیایی کاربران

وضعیت سلول‌های شبکه



شکل ۴: ورودی ها و خروجی های سیستم


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

در این بخش، مطابق با شکل (۵)، عملکرد الگوریتم های خوشه بندی به صورت موازی اجرا شده و با هدف بهینه سازی فرآیند مدیریت انتقال بین سلول ها در شبکه های نسل پنجم، مورد بررسی قرار می گیرد. در روش موازی، همزمان سه الگوریتم K-Means، DBSCAN و GMM اجرا و خروجی آن ها با استفاده از یادگیری ترکیبی، ترکیب می شود. در این مرحله با روش موازی به با تحلیل امکان بهره برداری 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 الگوریتم های خوشه بندی:

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 داده‌ها را به پنج خوشه مجزا تقسیم می‌کند. این الگوریتم نقاط داده را بر اساس فاصله اقلیدسی از مراکز خوشه تخصیص داده که به دلیل سادگی و سرعت بالا، عملکرد مناسبی در خوشه‌بندی داده‌ها دارد.



شکل ۵: استفاده موازی از الگوریتم‌های خوشه‌بندی

همزمان، الگوریتم DBSCAN خوشه‌بندی داده‌ها را بر اساس تراکم نقاط انجام داد و نقاط نویز که تراکم کمتری داشتند شناسایی و حذف می‌کند. این الگوریتم توانایی شناسایی خوشه‌های با شکل‌های نامنظم را دارد. الگوریتم GMM توزیع داده‌ها را بر اساس مدل‌های گاوسی تخمین زده و توانایی بالایی در مدلسازی از خوشه‌ها با توزیع پیچیده دارد. در مرحله‌ی بعد با ترکیب نتایج به دست آمده و با روش یادگیری ترکیبی، خروجی سه الگوریتم توسط، روش رأی‌گیری اکثریت ترکیب شده‌اند. در این روش، هر نقطه داده‌ای به خوشه‌ای که بیشترین توافق میان الگوریتم‌ها را داشت اختصاص یافت است.

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

روش سری، یکی از رویکردهای قدرتمند در خوشه‌بندی داده‌ها بوده که در آن از خروجی هر الگوریتم به عنوان ورودی مدل بعدی استفاده می‌شود. در این رویکرد، داده‌ها به صورت سلسله‌مراتبی پردازش شده و اطلاعات به تدریج غنی‌تر می‌شوند. هدف از این روش، بهینه‌سازی فرآیند خوشه‌بندی و تصمیم‌گیری نهایی است. مراحل اجرای روش سری به شرح زیر است:

۳-۶-۱. اجرای مدل‌های پایه


در روش سری، سه مرحله پایه به ترتیب و به صورت متوالی اجرا می‌شوند. این مراحل به گونه‌ای طراحی شده‌اند که هر کدام خروجی مرحله قبلی را به عنوان ورودی دریافت کنند و اطلاعات بیشتری استخراج کنند. نکته‌ی قابل توجه

ترتیب قرار گرفتن الگوریتم های خوشه بندی می باشد که ابتدا ترتیب مناسب تر را مطابق با جدول (۲) بررسی و انتخاب می کنیم.

جدول ۲: مقایسه ترتیب اجرای الگوریتم های خوشه بندی

سناریو	ترتیب اجرا	مزایا	معایب
K-Means → DBSCAN → GMM	ابتدا خوشه بندی کلی انجام می شود، سپس نقاط پرت حذف شده و در نهایت مدل سازی پیشرفته انجام می شود.	سرعت بالاتر در ابتدای کار، کاهش نویز در مرحله دوم، دقت بیشتر در خوشه بندی 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 خوشه بندی استاندارد و در نهایت مدل سازی پیشرفته	خوشه بندی تمیزتر با حذف نویز از ابتدا، کاهش تأثیر داده های نامعتبر.	اجرای DBSCAN در مرحله اول ممکن است برای دیتاست های بزرگ کند باشد.

به نظر می رسد که در سناریوی اول (K-Means → DBSCAN → GMM) انتخاب بهتری انجام شده، زیرا ابتدا داده ها را به طور کلی خوشه بندی کرده و سپس نقاط پرت حذف می شود و در نهایت خوشه بندی دقیق تر با مدل GMM صورت می گیرد. در این مدل، داده های پیش پردازش شده را دریافت و خوشه بندی اولیه انجام می دهد. خروجی این مرحله شامل برچسب های اولیه بوده که داده ها را به گروه های اولیه تقسیم می کند. این خوشه ها بر اساس الگوریتمی مانند K-Means ایجاد می شوند.




شکل ۶: استفاده سری از الگوریتم های خوشه بندی

شکل (۶)، روند کلی اجرای روش خوشه بندی سری را برای بهینه سازی فرآیند انتقال بین سلول ها در شبکه های نسل پنجم نشان می دهد. در این روش، سه الگوریتم خوشه بندی به صورت متوالی اجرا می شوند، به گونه ای که خروجی هر الگوریتم، ورودی الگوریتم بعدی را تشکیل می دهد. ابتدا، K-Means خوشه بندی اولیه داده ها را انجام می دهد و گروه های 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 فرآیند انتقال بین سلول‌ها را تحلیل می‌کنیم.



شکل ۷: ترکیب روش سری و موازی

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 فرآیند انتقال در شبکه‌های نسل پنجم مورد بررسی و مقایسه قرار گرفته‌اند. 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 می‌باشد. 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 فرآیند انتقال بین سلولی و تحلیل الگوهای تغییر اتصال کاربران متحرک را فراهم می‌کند. هدف از استفاده از این مجموعه داده، مدل‌سازی فرآیند 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

ویژگی	توضیح
Lat & Lon	موقعیت جغرافیایی کاربر برحسب 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 شده 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

Seaborn برای بصری‌سازی نتایج استفاده شده است. این ترکیب سخت‌افزار و نرم‌افزاری، امکان اجرای بهینه و کارآمد مدل‌های یادگیری ماشین و تحلیل فرآیند مدیریت انتقال بین سلولی در شبکه‌های نسل پنجم را فراهم کرده است.

۳-۴. طراحی مراحل آزمایش و ارزیابی عملکرد روش‌های پیشنهادی

به‌منظور تحلیل و ارزیابی عملکرد روش‌های پیشنهادی در بهینه‌سازی فرآیند مدیریت انتقال بین سلولی، آزمایشات این پژوهش در سه مرحله اصلی سازمان‌دهی شده است. در هر مرحله، پارامترهای کلیدی شبکه اندازه‌گیری شده و سه روش‌های پیشنهادی از جنبه‌های مختلف مقایسه شده‌اند. این آزمایشات با هدف بررسی میزان تأثیر روش‌های پیشنهادی در کاهش نرخ فرآیند مدیریت انتقال بین سلولی، بهبود کیفیت تجربه کاربری و افزایش بهره‌وری شبکه‌های نسل پنجم و فراتر از آن طراحی شده است.

۱-۳-۴. مرحله اول: آماده‌سازی داده‌ها و پیش‌پردازش اولیه

به‌منظور اجرای صحیح مدل‌های پیشنهادی و دستیابی به نتایج قابل اعتماد، در مرحله نخست، داده‌های مورد استفاده در این پژوهش مورد تحلیل، پالایش و آماده‌سازی قرار می‌گیرند. مجموعه داده‌های 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 فرآیند مدیریت انتقال بین سلولی است. در این مرحله، ابتدا داده‌های پرت و نویزی حذف شده و مقادیر نامعتبر اصلاح می‌شوند تا از تأثیر منفی آن‌ها بر عملکرد مدل جلوگیری شود. سپس، داده‌ها به‌منظور افزایش دقت خوشه‌بندی و مدل‌سازی الگوریتم‌های یادگیری ماشین، نرمال‌سازی و استانداردسازی می‌شوند. علاوه بر این، توزیع ویژگی‌های کلیدی بررسی شده و ارتباط میان آن‌ها تحلیل می‌شود تا تأثیر هر متغیر بر فرآیند مدیریت انتقال بین سلولی مشخص گردد. این مرحله نه‌تنها تضمین‌کننده صحت و دقت مدل‌هاست بلکه از تأثیر پارامترهای غیرضروری و نویزهای آماری در مراحل بعدی جلوگیری می‌کند.

۲-۳-۴. مرحله دوم: اجرای مدل‌های خوشه‌بندی برای تحلیل فرآیند مدیریت انتقال بین سلولی

پس از تکمیل مرحله پیش‌پردازش، داده‌های آماده‌شده برای اجرای روش‌های پیشنهادی پردازش خواهند شد. در این مرحله، سه روش مجزا برای تحلیل فرآیند انتقال بین سلولی و تشخیص الگوهای تغییر اتصال کاربران بین ایستگاه‌های پایه پیاده‌سازی می‌شود. در روش موازی، الگوریتم‌های K-Means، DBSCAN و GMM به صورت هم‌زمان بر روی مجموعه داده‌ها اعمال شده و نتایج آن‌ها با استفاده از تکنیک‌های یادگیری ترکیبی مانند رأی‌گیری اکثریت یا وزن‌دهی نتایج مدل‌ها، ترکیب می‌شوند. در روش سری، الگوریتم‌ها به‌صورت متوالی اجرا شده و خروجی هر مدل، ورودی مدل بعدی را تشکیل می‌دهد تا پردازش خوشه‌بندی در یک ساختار مرحله‌ای بهینه شود. در روش ترکیبی، دو روش قبلی ادغام شده و مدلی ارائه می‌شود که از مزایای روش‌های سری و موازی به‌صورت هم‌زمان بهره‌مند باشد. در این مرحله، کیفیت خروجی خوشه‌بندی با استفاده از معیارهایی نظیر امتیاز پراکندگی شاخص دیویس-بولدین ارزیابی شده و میزان همگن بودن و تفکیک‌پذیری خوشه‌ها مورد بررسی قرار می‌گیرد.

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

در مرحله پایانی، روش‌های پیشنهادی از جنبه‌های مختلف مورد تحلیل و مقایسه عملکردی قرار می‌گیرند تا کارآمدترین روش برای بهینه‌سازی مدیریت انتقال بین سلولی در شبکه‌های نسل پنجم شناسایی شود. در این مرحله، پارامترهای کلیدی دقت، نرخ صحت، میزان بازیابی و امتیاز میانگین هارمونیک، محاسبه شده و عملکرد مدل‌های مختلف بر اساس نرخ انتقال بین سلولی، تأخیر انتقال، نرخ توان عملیاتیو کیفیت تجربه کاربری ارزیابی می‌شود. همچنین، میزان تأثیر هر روش بر کاهش تعداد انتقال‌های غیرضروری، بهبود پوشش دهی شبکه و افزایش پایداری اتصال کاربران بررسی خواهد شد. در این بخش، نتایج به‌صورت جدول‌های

مقایسه‌ای و نمودارهای تحلیلی ارائه شده و برتری یا ضعف هر روش به‌طور دقیق مشخص می‌شود. در نهایت، نتایج آزمایشات 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


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	-19.8482	-64.5	-10.5	-20.0	112	845.0	689.82	136.58	-3.62
1	-44.01645	-19.8467	-64.5	-10.5	-20.0	112	852.1	907.68	135.01	-2.30
2	-44.01684	-19.8458	-64.5	-10.5	-20.0	112	853.4	1007.50	132.61	-2.00
3	-44.01687	-19.8457	-64.5	-10.5	-20.0	112	854.0	1015.29	132.44	-1.95
4	-44.01725	-19.8448	-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. به‌طوری‌که 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 رنگیست 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

رویکرد رأی‌گیری اکثریت در روش موازی به خوبی 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

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.

با این حال، 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.


۴-۴-۱. مزایا و معایب اجرای موازی الگوریتم‌ها

در روش موازی، مدل های مختلف خوشه بندی به طور همزمان بر روی داده ها اجرا شده و نتایج هر یک از الگوریتم ها به صورت جداگانه محاسبه می شوند. سپس، با استفاده از تکنیک هایی نظیر رأی گیری اکثریت یا وزن دهی، خروجی نهایی تعیین می شود. مزیت اصلی این روش، قابلیت استفاده همزمان از چندین مدل با ویژگی های مختلف است، که به کاهش وابستگی به یک مدل خاص و افزایش استحکام خوشه بندی کمک می کند. علاوه بر این، پردازش موازی منجر به افزایش سرعت اجرا می شود، چرا که هر مدل به صورت مستقل عمل کرده و از محاسبات اضافی جلوگیری می شود. این استراتژی به بهبود دقت و پایداری خوشه بندی کمک می کند.


با این حال، عیب اصلی این روش عدم تطابق بین مدل های مختلف است. به این معنا که هر الگوریتم خوشه بندی ممکن است خروجی های ناسازگاری تولید کند که در مرحله تجمیع ممکن است به کاهش دقت کلی منجر شود. همچنین، تصمیم گیری در مورد نحوه ترکیب نتایج مدل ها مانند رأی گیری یا وزن دهی، می تواند پیچیده بوده و نیاز به تنظیمات دقیق دارد.

۴-۵. اجرای الگوریتم های خوشه بندی در روش سری

نتایج به دست آمده از اجرای روش سری بر روی مجموعه داده ها در سه نمودار ارائه شده است که تحلیل دقیقی از عملکرد خوشه بندی و مقایسه آن با روش های دیگر ارائه می دهد. نمودار اول، یک پراکندگی از خوشه بندی نهایی بر اساس روش سری را نمایش می دهد، که در آن ابتدا خوشه بندی 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. همان طور که در شکل (۱۰) مشاهده می شود، نقاط جغرافیایی خوشه های مختلف با رنگ های متفاوت مشخص شده اند. ترکیب این سه الگوریتم باعث شده است که خوشه ها از نظر تراکم و مرزهای خوشه بندی بهبود یابند اما برخی از مناطق همچنان دارای هم پوشانی بوده که می تواند ناشی از تفاوت در حساسیت الگوریتم های مورد استفاده باشد.



شکل ۱۰: پراکندگی در خوشه بندی به روش سری



شکل ۱۱: امتیاز پراکندگی و نمودار حرارتی رای‌گیری اکثریت در خوشه‌بندی به روش سری

در شکل (۱۱) که مقایسه‌ی امتیاز پراکندگی بین مدل‌های مختلف را نمایش می‌دهد، مشاهده می‌شود که هر سه الگوریتم پایه مقادیر تقریباً مشابهی دارند و عملکرد آن‌ها در ایجاد خوشه‌های معنادار نسبتاً مطلوب بوده است. اما میزان انسجام خوشه‌ها در مدل نهایی روش سری در مقایسه با مدل‌های منفرد بررسی نشده است که می‌تواند نکته‌ای برای بهبود رویکرد باشد.

در نهایت، نقشه حرارتی، نشان‌دهنده نتایج نهایی دسته‌بندی در مراحل مختلف است. در این نمودار، میزان هماهنگی خروجی‌های الگوریتم‌های مختلف در ۲۰ داده‌ی ابتدایی نشان داده شده است. مشاهده می‌شود که خوشه‌های اختصاص داده‌شده در برخی موارد دچار تغییرات قابل توجهی بین مراحل مختلف هستند که نشان می‌دهد روش سری ممکن است به دلیل وابستگی به خروجی‌های مرحله قبل در برخی موارد دچار تغییرات ناپایدار شود. این نکته می‌تواند در کاربردهای حساس نیازمند بهینه‌سازی بیشتر باشد.

به‌طور کلی، روش سری در مقایسه با روش موازی، قدرت بیشتری در بهینه‌سازی خوشه‌بندی دارد، زیرا خروجی هر مرحله، اطلاعات تکمیلی برای مرحله بعدی فراهم می‌کند، اما از سوی دیگر، حساسیت این روش به کیفیت خروجی مرحله قبلی، یکی از نقاط ضعف آن محسوب می‌شود.


۴-۵-۱. مزایا و معایب اجرای سری الگوریتم‌ها

روش سری با اجرای مدل‌ها به‌صورت متوالی و تغذیه خروجی یک مدل به‌عنوان ورودی مدل بعدی، امکان پالایش تدریجی داده‌ها را فراهم می‌کند. مزیت کلیدی این روش توانایی پالایش نتایج است به این صورت که مدل‌های بعدی می‌توانند خروجی‌های مدل‌های قبلی را اصلاح کرده و کیفیت خوشه‌بندی را افزایش دهند. این روش به‌خصوص در سناریوهایی که داده‌ها دارای نویز بالا هستند، عملکرد مطلوبی دارد، زیرا هر مدل امکان فیلتر کردن ناپایداری‌های مدل‌های قبلی را دارد. از دیگر مزایای روش سری می‌توان استفاده تدریجی از اطلاعات، دقت بالاتر و ایجاد یک دیتاست غنی‌تر را نام برد.


از معایب این روش می‌توان به افزایش پیچیدگی محاسباتی اشاره کرد، چرا که اجرای متوالی مدل‌ها زمان پردازش را به‌طور قابل توجهی افزایش می‌دهد. همچنین، این روش به شدت وابسته به انتخاب ترتیب مناسب مدل‌ها است؛ اگر مدل‌های نامناسبی در ابتدا قرار بگیرند، ممکن است نتایج نهایی تحت تأثیر منفی قرار گیرند و کیفیت خوشه‌بندی 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 الگوریتم‌ها هم‌زمان اجرا می‌شوند، در این روش هر مرحله به بهبود نتایج مرحله قبل کمک کرده و دقت خوشه‌بندی نهایی را افزایش می‌دهد.

۴-۶. اجرای الگوریتم‌های خوشه‌بندی در روش ترکیبی

در روش یادگیری ترکیبی که ترکیبی از روش‌های موازی و سری است، فرآیند خوشه‌بندی بهینه‌تری ارائه می‌شود. شکل (۱۲) نشان‌دهنده پراکندگی داده‌ها و نتایج خوشه‌بندی در این روش است. استفاده از یادگیری ترکیبی باعث شده است که تخصیص نقاط به خوشه‌ها نسبت به روش‌های دیگر دقیق‌تر انجام شود که این امر به دلیل ترکیب مزایای هر دو رویکرد موازی و سری است. مناطق متمایز در این تصویر نشان‌دهنده قدرت این روش در کاهش تداخل بین خوشه‌ها و افزایش دقت در تفکیک داده‌ها است.



شکل ۱۲: پراکندگی در خوشه‌بندی به روش ترکیبی



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

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 پرقدرت‌تر 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 سراسریا 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 به‌طور 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 فرآیند 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

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

به منظور 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، در حالی که 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.

۸-۴. مقایسه زمان اجرای روش ها

برای تحلیل زمان اجرای سه روش موازی، سری و یادگیری ترکیبی، از کتابخانه time در پایتون استفاده شده است. این کتابخانه امکان اندازه گیری دقیق مدت زمان اجرای الگوریتم ها را فراهم می کند و برای بررسی کارایی مدل های مختلف، ابزاری ضروری محسوب می شود. نتایج به دست آمده در شکل (۱۴)، نشان می دهد که روش موازی با ۴.۳۲ ثانیه سریع ترین اجرا را دارد، زیرا تمامی مدل های خوشه بندی به طور همزمان پردازش می شوند. در مقابل، روش سری با ۶.۸۹ ثانیه، کندتر از روش موازی است، چرا که خروجی یک مدل به عنوان ورودی مدل بعدی مورد استفاده قرار می گیرد، که این فرآیند باعث افزایش مدت زمان پردازش می شود. در نهایت، روش یادگیری ترکیبی با ۹.۲۱ ثانیه بیشترین زمان پردازش را نیاز دارد، زیرا علاوه بر اجرای مدل ها به صورت ترکیبی، شامل پردازش های اضافی برای ادغام و بهینه سازی نتایج مدل های مختلف است.



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

این تفاوت در زمان اجرا نشان می دهد که اگر سرعت پردازش اولویت اصلی باشد، روش موازی کارآمدتر خواهد بود، در حالی که اگر دقت و کاهش نویز داده ها مهم تر باشد، روش سری یا یادگیری ترکیبی برتری دارد. در نتیجه، انتخاب روش به نیازمندی های پروژه و منابع محاسباتی موجود بستگی داشته و در شرایطی که پردازش سریع همراه با دقت بالا مورد نیاز باشد، بهینه سازی مدل های یادگیری ترکیبی یا استفاده از روش های پردازشی موازی پیشرفته تر، مانند اجرای محاسبات بر روی GPU، پیشنهاد می شود.

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

جدول (۶)، مقایسه ای جامع بین سه روش موازی، سری و یادگیری ترکیبی ارائه می دهد. این مقایسه بر اساس معیارهای مختلفی مانند دقت، سرعت پردازش، پیچیدگی محاسباتی، میزان همگرایی، حساسیت به نویز، قابلیت تعمیم پذیری، 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 داده ها پر از نویز باشند و نیاز به پالایش تدریجی خوشه بندی وجود داشته باشد. در مقابل، روش یادگیری ترکیبی برای مسائلی که نیاز به حداکثر دقت، پایداری و تعمیم پذیری دارند، اما منابع محاسباتی کافی در اختیار است، بهترین گزینه محسوب می شود. در نهایت، بسته به نیاز پروژه، داده های موجود و منابع پردازشی، می توان از یکی از این روش ها یا ترکیبی از آن ها برای دستیابی به بهترین نتایج استفاده کرد.

جدول ۶: مقایسه جامع روش های موازی، سری و یادگیری ترکیبی

معیارها	روش موازی	روش سری	روش یادگیری ترکیبی
---------	-----------	---------	--------------------

ساختار کلی	اجرای همزمان مدل‌های مختلف و ترکیب خروجی‌ها	اجرای مدل‌ها به صورت متوالی و استفاده از خروجی هر مدل به عنوان ورودی مدل بعدی	ترکیب روش‌های موازی و سری به منظور بهره‌برداری از مزایای هر دو
دقت	متوسط، وابسته به نحوه ترکیب مدل‌ها	بالا، به دلیل پالایش تدریجی داده‌ها	بسیار بالا، به دلیل ترکیب مزایای هر دو روش
سرعت پردازش	بالا، زیرا مدل‌ها به صورت موازی اجرا می‌شوند	پایین، زیرا مدل‌ها باید به ترتیب اجرا شوند	پایین، زیرا شامل پردازش موازی و سری است
پیچیدگی محاسباتی	متوسط، به دلیل اجرای همزمان مدل‌ها	بالا، به دلیل اجرای مدل‌ها به صورت متوالی	بسیار بالا، به دلیل نیاز به مدیریت ترکیب مدل‌ها
حساسیت به نویز	بالا، زیرا نویز موجود در داده‌ها ممکن است بین مدل‌ها متفاوت باشد	پایین، زیرا مدل‌های بعدی نویز را فیلتر می‌کنند	پایین، زیرا از فیلترهای سری و تجمیع موازی استفاده می‌شود
همگرایی نتایج	ممکن است نتایج ناسازگار باشند، زیرا مدل‌های مختلف خروجی‌های متفاوتی دارند	بالا، زیرا مدل‌ها به صورت تدریجی اصلاح می‌شوند	بسیار بالا، به دلیل استفاده از ترکیب مناسب از هر دو روش
قابلیت تعمیم‌پذیری	خوب، اما بستگی به انتخاب مدل‌های مناسب دارد	بالا، زیرا به صورت تدریجی داده‌ها پالایش می‌شوند	بسیار بالا، زیرا ترکیبی از یادگیری‌های مستقل و تدریجی را ارائه می‌دهد
کاربردهای پیشنهادی	مناسب برای مسائل با حجم داده بالا و نیاز به پردازش سریع	مناسب برای مسائل با داده‌های پرنویز و نیاز به پالایش تدریجی	مناسب برای مسائل پیچیده که نیازمند دقت بالا و ترکیب مدل‌ها هستند
میزان مصرف منابع (RAM, CPU, GPU)	متوسط، به دلیل اجرای همزمان چند مدل	بالا، زیرا مدل‌ها باید به ترتیب اجرا شوند و داده‌ها بین مراحل ذخیره شوند	بسیار بالا، زیرا نیازمند اجرای چندین مدل به طور همزمان و متوالی است
انعطاف‌پذیری در تنظیمات	متوسط، وابسته به نوع مدل‌های انتخاب شده	پایین، زیرا ترتیب اجرای مدل‌ها باید مشخص باشد	بالا، زیرا قابلیت بهینه‌سازی ترکیب مدل‌ها را دارد
پایداری در داده‌های پویا	متوسط، زیرا ناسازگاری بین مدل‌ها ممکن است وجود داشته باشد	بالا، زیرا مدل‌ها به مرور تطبیق داده‌ها را انجام می‌دهند	بسیار بالا، زیرا هم از تجمیع نتایج بهره می‌برد و هم از پالایش تدریجی داده‌ها
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، به‌ویژه در حوزه بهینه‌سازی از آزمون‌های آماری برای ارزیابی تفاوت عملکرد الگوریتم‌ها استفاده می‌شود. زمانی که بخواهیم میانگین عملکرد دو الگوریتم یا نسبت دو نمونه جمع آوری شده از یک گروه یا دسته‌های مختلف را مقایسه و بررسی کنیم از آزمون تی استفاده می‌شود. نتایج این آزمون نشان می‌دهد که تفاوت بین عملکرد الگوریتم‌ها به صورت تصادفی و یا معنادار است. مطابق با جدول (۷)، اگر تعداد الگوریتم‌های مورد مقایسه بیش از دو و داده‌ها غیر نرمال، ولی تعداد نمونه‌ها زیاد باشد از تحلیل واریانس یک‌طرفه که یک آزمون آماری و زیر مجموعه‌ی آمار تفسیری بوده و به تفسیر اختلاف بین میانگین در بیش از دو گروه آزمایشی می‌پردازد، استفاده کرد. در صورتی که داده‌ها نرمال نباشند، آزمون‌های غیرپارامتری مانند ویلکاکسون یا فریدمن به عنوان جایگزین استفاده می‌شوند. همه‌ی این آزمون‌ها از اعتباری بالا برخوردار بوده و در ادبیات پژوهشی هوش محاسباتی و بهینه‌سازی به عنوان ابزارهای استاندارد، جهت مقایسه الگوریتم‌ها، شناخته می‌شوند.

جدول ۷: انتخاب آزمون مناسب برای ارزیابی نتایج

تعداد الگوریتم‌ها	داده‌های نرمال	آزمون پیشنهادی
دو الگوریتم	بله	آزمون تی

آزمون ویلکاکسون	خیر	دو الگوریتم
تحلیل واریانس یک طرفه	بله	بیش از دو الگوریتم
آزمون فریدمن	خیر	بیش از دو الگوریتم

تحلیل آماری زمان اجرای سه روش مختلف یادگیری ماشین در این مطالعه با استفاده از آزمون واریانس یک طرفه انجام شد تا مشخص شود که آیا تفاوت های مشاهده شده در میانگین زمان اجرا از نظر آماری معنادار هستند یا خیر. از آنجایی که بیش از دو گروه مستقل مورد بررسی قرار گرفته اند (روش های موازی، سری و یادگیری ترکیبی) استفاده از آزمون واریانس یک طرفه بهترین گزینه برای تحلیل اختلاف میانگین زمان اجرا میان این روش ها محسوب می شود. نتایج این آزمون نشان داد که تفاوت معناداری بین میانگین زمان اجرای سه روش وجود دارد، به این معنی که زمان اجرا در روش های مختلف تنها به صورت تصادفی تغییر نکرده، بلکه به ساختار و فرآیند پردازشی هر روش وابسته است.



شکل ۱۵: تحلیل آماری زمان اجرا توسط واریانس یک طرفه

شکل (۱۵) نیز این یافته ها را تأیید می کند، به طوری 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، در حالی که روش سری از نظر زمان اجرا در حد واسط این دو روش قرار دارد. این یافته ها بیانگر این است که روش های پیچیده تر، به دلیل پردازش های چند مرحله ای و ترکیب مدل های مختلف، هزینه محاسباتی بالاتری دارند که به طور مستقیم بر زمان اجرا تأثیر می گذارد. با این حال، باید توجه داشت که کاهش زمان اجرا لزوماً به معنای بهبود عملکرد کلی نیست، زیرا دقت خوشه بندی نیز در کنار کارایی زمانی باید مورد ارزیابی قرار گیرد. در نتیجه، بسته به کاربرد مورد نظر، انتخاب میان سرعت پردازش بالاتر و دقت خوشه بندی بهتر باید با در نظر گرفتن این تحلیل های آماری انجام شود.

۴-۱۱. پایداری و توانایی الگوریتم ها

در ارزیابی عملکرد الگوریتم های خوشه بندی برای مدیریت انتقال در شبکه های سلولی، علاوه بر معیارهایی مانند دقت، نرخ کاهش انتقال بین سلول ها و زمان اجرا، بررسی پایداری الگوریتم ها نیز نقش مهمی در سنجش قابلیت اعتماد این روش ها دارد. پایداری یک مدل خوشه بندی به توانایی آن در ارائه نتایج پایدار در شرایط مختلف داده ای، نویز، و تغییرات پارامتری اشاره دارد. در این مطالعه، سه روش موازی، سری و یادگیری ترکیبی از نظر میزان حساسیت آن ها نسبت به تغییرات ورودی و مقاومت در برابر نویز داده ها مورد بررسی قرار می گیرند.


در روش موازی، اجرای مستقل الگوریتم ها و ترکیب نتایج از طریق رأی گیری اکثریت باعث افزایش پایداری مدل می شود، زیرا ضعف یک الگوریتم خاص تأثیر زیادی بر خروجی نهایی نخواهد داشت. اما در صورتی که نتایج بین الگوریتم ها همخوانی نداشته باشد، ممکن است ناپایداری در تصمیم گیری نهایی افزایش یابد. روش سری، به دلیل استفاده متوالی از خروجی یک الگوریتم

به‌عنوان ورودی الگوریتم بعدی، وابستگی شدیدی به دقت مراحل ابتدایی دارد. این وابستگی باعث می‌شود که هرگونه خطا یا نویز در مرحله اولیه در کل فرآیند 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 تعدیل‌شده و اطلاعات متقابل نرمال شد برای مقایسه خروجی خوشه‌بندی در شرایط مختلف استفاده کرد. مطابق با جدول (۸) و نتایج به‌دست‌آمده 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

معیار مقایسه	روش موازی	روش سری	روش یادگیری ترکیبی
شاخص رند تعدیل‌شده	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 به‌صورت مستقل استفاده می‌شود، در صورتی که یکی از مدل‌ها خروجی غیرقابل اعتمادی تولید کند، نتیجه نهایی ممکن است تحت تأثیر قرار بگیرد. باین‌حال، 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 فرآیند 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

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 کوتاه مدت 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 آزمایشات 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 به‌واسطه‌ی 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 می‌کنند، در این تحقیق، به‌منظور سنجش واقع‌گرایانه اثربخشی رویکرد پیشنهادی، نسخه‌های پایه الگوریتم‌های K-means، DBSCAN و GMM نیز بدون اصلاح ویژگی‌های استخراج‌شده از گره‌های سیار و پارامترهای شبکه، به‌صورت مستقل پیاده‌سازی و با خروجی‌های نهایی مقایسه شدند. بررسی آماری نتایج، حاکی از آن است که به‌کارگیری ساختار ترکیبی

سه الگوریتم، همراه با بازطراحی دقیق ویژگی‌های ورودی، موجب بهبود معنادار نتایج در عملکرد نهایی شده است. برای نمونه، مقدار شاخص میانگین هارمونیک در روش پایه K-means به‌طور 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 انتقال‌های بهینه می‌باشد. همچنین نرخ دقت در نسخه‌های پایه اغلب در بازه ۸۷ الی ۸۹ درصد بوده، در حالی که روش پیشنهادی، توانست در نسخه ترکیبی با ویژگی‌های بهینه‌شده، دقتی بالای ۹۱ درصد ارائه دهد. این تحلیل‌ها به روشنی اثبات می‌کند که بهبودهای حاصل شده صرفاً ناشی از ساختار اجرایی موازی یا سری نیست، بلکه ناشی از یک طراحی هدفمند و مبتنی بر دانش ویژگی‌ها، در کنار ترکیب الگوریتم‌ها با ساختار منطقی است. بنابراین، روش پیشنهادی نه تنها از منظر تئوری، بلکه در عمل نیز به‌طور معنادار از نسخه‌های پایه عملکرد بهتری ارائه می‌دهد و قابلیت اطمینان بالاتری در محیط‌های واقعی شبکه‌های نسل پنجم خواهد داشت.

جدول ۹: تحلیل تطبیقی با سایر روش‌ها

عنوان پژوهش	روش-الگوریتم به‌کاررفته	یادگیری نوع	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 ویژگی‌های بهینه و ساختار یادگیری ترکیبی
مقاله لیما و همکاران (2023) Deep Learning-Based Handover Prediction for 5G	LSTM + Random Forest	یادگیری نظارت‌شده	89.41%	88.12%	کاهش تأخیر انتقال	داده‌های واقعی و شبیه‌سازی	توانایی کاهش قطعی‌های ناگهانی، بهینه‌سازی جابجایی کاربران
مقاله ون‌شیانگ و همکاران (2022) Fuzzy Logic for 5G Ultra-Dense Networks	Fuzzy Logic + Dynamic TTT & HOM	کنترل فازی	87.63%	86.44%	کاهش نرخ Ping-Pong افزایش Throughput	شبیه‌سازی شده	استفاده از منطق فازی برای اتخاذ تصمیمات پویا در انتقال بین فوق متراکم فرآیند

در مقایسه با مطالعات پیشین و مطابق با جدول (۹) می‌توان مشاهده کرد که، روش پیشنهادی پژوهش، با استفاده از ترکیب سه الگوریتم خوشه‌بندی و ساختار پردازشی ترکیبی، توانسته عملکرد بهتری نسبت به روش‌های پایه‌ی مطرح‌شده در مقالات پیشین ارائه دهد. در حالی که مقاله لیما و همکاران تمرکز خود را بر پیش‌بینی لحظه انتقال بین سلولی با استفاده از شبکه عصبی حافظه طولانی کوتاه مدت قرار داده و دقت بالایی ارائه می‌کند، اما فاقد تحلیل جامع در تمامی معیارهای ارزیابی است. همچنین مدل فازی مورد استفاده در مقاله ون‌شیانگ 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 ضعیف‌تری ارائه داده است. بدین ترتیب، روش پیشنهادی پژوهش حاضر نه تنها از لحاظ معماری، بلکه در بهره‌گیری از ویژگی‌های مؤثر و ساختارهای پردازشی بهینه، برتری خود را نسبت به روش‌های پیشین اثبات کرده است. این مقایسه‌ی دقیق با روش‌های پایه، پشتوانه‌ای برای اثبات برتری فنی و کاربردی مدل پیشنهادی فراهم آورده و یکی از وجوه تمایز برجسته پژوهش حاضر در میان ادبیات موضوعی محسوب می‌شود.

۵. نتیجه‌گیری و پیشنهادات آینده

در این پژوهش، با هدف بهبود فرآیند انتقال بین سلولی در شبکه‌های متراکم نسل پنجم، یک چارچوب نوآورانه مبتنی بر یادگیری ماشین ارائه گردید که از ترکیب سه الگوریتم خوشه‌بندی K-Means، DBSCAN و GMM بهره می‌برد. 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 فرآیند 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

با توجه 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:

در حالی که 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 نظارت‌شده و بدون نظارتی می‌تواند در شرایطی که داده‌های برچسب‌خورده 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 ارتقاء دقت تصمیم‌گیری در فرآیند 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 بلادرنگ و شبکه‌های متحرک پویا به‌شدت بهبود دهد.

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

با توجه 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 براساس وضعیت لحظه‌ای شبکه، پیشنهاد مهمی برای توسعه‌ی این پژوهش به شمار می‌آید.

Research Article

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

Babak Lotfi, PhD Student^{1*}  | Yaser Elmo Sola, Assistant Professor² 

Abstract

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

²Yaser Elmi Sola, Assistant Professor, Department of Computer Engineering and Information Technology, Islamic Azad University, Sabzevar Branch, Sabzevar, Iran, yasser.elmi@iau.ac.ir

Corresponding Author

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

Main Subjects: HandOver in 5G Networks

Received: 24 March 2025

Revised: 5 April 2025

Accepted:

With the rapid expansion of fifth-generation (5G) networks and the increasing density of base stations, the inter-cell handover process has become one of the major challenges in ensuring Quality of Service (QoS) and maintaining communication stability. This study presents a machine learning-based approach aimed at improving handover management by implementing three clustering algorithms—K-Means, DBSCAN, and GMM—within three distinct execution frameworks: parallel, sequential, and ensemble. In this framework, input features such as users' geographic location, received signal strength, and cell status are meticulously preprocessed, and the clustering models are refined and trained accordingly.

Implementation results demonstrate that the ensemble structure performs better than other approaches,

showing significant improvement in key metrics such as Precision (91.3%) and F1 Score (90.2%). To evaluate the effectiveness of the proposed model, a comparative analysis was conducted with two well-known methods: a Long Short-Term Memory (LSTM) Recurrent Neural Network and a fuzzy logic-based approach. The comparisons indicate that the proposed approach demonstrates superior performance in terms of accuracy, handover rate, and clustering stability.

Furthermore, statistical analysis using the ANOVA test confirms the significant performance differences among the methods. Overall, the findings of this research underscore the effectiveness of the proposed ensemble method in reducing unnecessary handovers, enhancing connection stability, and improving communication quality in dense 5G network environments.

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

Highlights

- Simultaneous utilization of multiple clustering algorithms with modified input features, implemented across diverse execution frameworks.
- Preprocessing of features such as user location, received signal strength, and cell status to enhance clustering accuracy.
- Comprehensive performance comparison of algorithms with their baseline versions, without feature optimization, to realistically assess the impact of refined input data.
- Demonstrating significant improvement in network performance through statistical analysis of evaluation metrics in the ensemble structure compared to other methods.
- Integrating the outputs of algorithms in the ensemble structure using layered decision-making.

References:

- [1] 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.
- [2] 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.
- [3] 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.
- [4] 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.
- [5] 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.
- [6] A. Gupta and R. K. Jha, "A survey of 5G network: Architecture and emerging technologies," *IEEE access*, vol. 3, pp. 1206-1232, 2015.
- [7] 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) :2024*, IEEE, pp. 388-392 .
- [8] 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.
- [9] T. S. Rappaport *et al.*, "Millimeter wave mobile communications for 5G cellular: It will work!," *IEEE access*, vol. 1, pp. 335-349, 2013.
- [10] 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 .
- [11] 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.
- [12] 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. 3, p. 100389, 2023.
- [13] 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.
- [14] 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.
- [15] V. Yajnanarayana, H. Rydén, and L. Hévizsi, "5G handover using reinforcement learning," in *2020 IEEE 3rd 5G World Forum (5GWF)*, 2020: IEEE, pp. 349-354 .
- [16] 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.

- [17] 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.
- [18] Y. Li and H. Wu, "A clustering method based on K-means algorithm," *Physics Procedia*, vol. 25, pp. 1104-1109, 2012.
- [19] D. Deng, "DBSCAN clustering algorithm based on density," in *2020 7th international forum on electrical engineering and automation (IFEEA)*, 2020: IEEE, pp. 949-953 .
- [20] J. Wang and J. Jiang, "Unsupervised deep clustering via adaptive GMM modeling and optimization," *Neurocomputing*, vol. 433, pp. 199-211, 2021.
- [21] 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.
- [22] 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 .
- [23] 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.
- [24] 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 .
- [25] S. Alraih, R. Nordin, A. Abu-Samah, I. Shaya, 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.
- [26] 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.
- [27] 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 .
- [28] 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.
- [29] 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.
- [30] 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.
- [31] 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.
- [32] 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 .
- [33] 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.

- [34] 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.
- [35] 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 .
- [36] 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 ,1 .p. 426, 2022.
- [37] M. B. Patil and L. Math, "A novel approach for optimization of handover mechanism using metaheuristics algorithms," *Measurement: Sensors*, vol. 24, p. 100467, 2022.
- [38] 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 .