بهینه‌سازی هوشمندسازی انتخابی تقاطع‌های چراغ‌دار با هدف بهبود تاب‌آوری عملکردی شبکه معابر شهری با استفاده از الگوریتم ژنتیک و مدل جایگزین یادگیری ماشین

مقاله علمی-پژوهشی

فاطمه پسیخانی سلمی، دانشجوی کارشناسی ارشد، دانشکده مهندسی عمران و محیط زیست، دانشگاه تربیت مدرس، تهران، ایران

*__امین میرزا بروجردیان (نویسنده مسئول)__، دانشیار، دانشکده مهندسی عمران و محیط زیست، دانشگاه تربیت مدرس، تهران، ایران

سعید شرافتی پور، استادیار، دانشکده مهندسی عمران و محیط زیست، دانشگاه تربیت مدرس، تهران، ایران

*__پست الکترونیک نویسنده مسئول: boroujerdian@modares.ac.ir__

دریافت: ۱۴۰۵/۰۳/۰۶- پذیرش: ۱۴۰۵/۰۸/۰۵

صفحه ۴۷۸-۴۶۵

چکیده

افزایش تقاضای سفر، پیچیدگی الگوهای ترافیکی و وقوع اختلالات پیش‌بینی‌نشده، تاب‌آوری شبکه‌های معابر شهری را به یکی از چالش‌های مهم مدیریت ترافیک تبدیل کرده است. تقاطع‌های چراغ‌دار به‌عنوان گره‌های کلیدی شبکه، نقش مهمی در ایجاد ازدحام، انتشار صف و کاهش عملکرد شبکه دارند. اگرچه هوشمندسازی کامل تقاطع‌ها می‌تواند عملکرد ترافیکی را بهبود دهد، اما به دلیل محدودیت‌های اجرایی، اقتصادی و فناورانه، همواره گزینه‌ای عملی و بهینه نیست. ازاین‌رو، هدف این پژوهش، تعیین ترکیب بهینه تقاطع‌های هوشمند با در نظر گرفتن هم‌زمان شاخص‌های عملکردی، زیست‌محیطی و هزینه اجرایی است. در این پژوهش، یک چارچوب ترکیبی مبتنی بر شبیه‌سازی ترافیکی، الگوریتم ژنتیک و مدل جایگزین یادگیری ماشین ارائه شده است. شبکه مورد مطالعه شامل شش تقاطع چراغ‌دار است که در محیط SUMO شبیه‌سازی شد. وضعیت کنترلی هر تقاطع به‌صورت متغیر دودویی تعریف گردید؛ به‌طوری‌که مقدار یک نشان‌دهنده کنترل هوشمند و مقدار صفر نشان‌دهنده کنترل سنتی زمان‌ثابت است. تمامی ۶۴ ترکیب ممکن شبیه‌سازی شده و تابع هدف چندمعیاره بر اساس زمان انتظار، اتلاف زمان، انتشار دی‌اکسیدکربن، مصرف سوخت و هزینه اجرایی تعریف شد. سپس، الگوریتم ژنتیک برای بهینه‌سازی ترکیب تقاطع‌ها و مدل تقویت گرادیانی به‌عنوان مدل جایگزین برای تخمین سریع شاخص تاب‌آوری به‌کار گرفته شد. نتایج نشان داد که سناریوی تمام‌هوشمند بهترین عملکرد را از نظر شاخص‌های عملکردی و زیست‌محیطی دارد، اما به دلیل هزینه اجرایی بالا، لزوماً گزینه بهینه نیست. ترکیب کنترلی [۱،۱،۰،۰،۱،۱] به‌عنوان سناریوی بهینه شناسایی شد که با هوشمندسازی انتخابی تقاطع‌های کلیدی، عملکردی نزدیک به سناریوی تمام‌هوشمند و هزینه اجرایی کمتر ارائه می‌دهد. همچنین، مدل تقویت گرادیانی با مقادیر $MAE=0.0248$ ،$RMSE=0.0462$ و $R^2=0.927$ توانست شاخص تاب‌آوری را با دقت مناسب تخمین زده و هزینه محاسباتی ارزیابی سناریوها را کاهش دهد. یافته‌ها نشان می‌دهد که استقرار هدفمند کنترل هوشمند می‌تواند جایگزینی کارآمد و هزینه‌اثربخش برای هوشمندسازی کامل شبکه و ابزاری مؤثر برای مدیریت تاب‌آوری شبکه‌های ترافیکی شهری باشد.

واژه‌های کلیدی: استقرار انتخابی تقاطع‌های هوشمند، الگوریتم ژنتیک، تاب‌آوری شبکه ترافیکی شهری، کنترل هوشمند تقاطع‌ها، مدل جایگزین یادگیری ماشین

۱- مقدمه

رشد شهرنشینی، افزایش تقاضای سفر و پیچیده‌تر شدن الگوهای ترافیکی، شبکه‌های حمل‌ونقل شهری را با چالش‌های فزاینده‌ای در مدیریت جریان، کنترل ازدحام و حفظ کیفیت عملکرد مواجه کرده است. در چنین شرایطی، وقوع اختلالات غیرقابل‌پیش‌بینی مانند تصادف، انسداد معابر، خرابی تجهیزات کنترلی یا افزایش ناگهانی تقاضا می‌تواند موجب افت عملکرد شبکه، انتشار صف

و گسترش ازدحام در مقیاس شبکه‌ای شود. ازاین‌رو، تمرکز صرف بر بهبود کارایی در شرایط عادی برای مدیریت شبکه‌های ترافیکی کافی نیست و توجه به تاب‌آوری، به‌عنوان توانایی شبکه در حفظ عملکرد و کاهش افت ناشی از اختلال، اهمیت ویژه‌ای یافته است. تقاطع‌های چراغ‌دار از مهم‌ترین گره‌های اثرگذار در شبکه معابر شهری هستند؛ زیرا نحوه کنترل آن‌ها به‌صورت مستقیم بر شاخص‌هایی مانند زمان انتظار، اتلاف زمان، طول صف، مصرف سوخت و انتشار آلاینده‌ها اثر می‌گذارد. روش‌های سنتی کنترل چراغ‌ها، مانند کنترل زمان‌ثابت و نیمه‌واکنشی، با وجود سادگی و قابلیت اجرا، معمولاً بر الگوهای از پیش تعیین‌شده یا داده‌های تاریخی متکی‌اند و در برابر نوسانات لحظه‌ای تقاضا و شرایط اختلالی انعطاف‌پذیری محدودی دارند. در مقابل، توسعه سامانه‌های حمل‌ونقل هوشمند، الگوریتم‌های بهینه‌سازی و روش‌های یادگیری ماشین، امکان طراحی راهبردهای کنترلی تطبیقی‌تر و داده‌محورتر را فراهم کرده است. با وجود پیشرفت‌های انجام‌شده، بخش قابل‌توجهی از مطالعات موجود بر بهینه‌سازی شاخص‌هایی مانند تأخیر، طول صف، زمان سفر یا مصرف سوخت در شرایط عادی تمرکز دارند و مسئله تاب‌آوری شبکه در مواجهه با اختلالات کمتر به‌عنوان معیار اصلی تصمیم‌گیری مورد توجه قرار گرفته است. علاوه بر این، بسیاری از رویکردهای هوشمندسازی، به‌صورت مستقیم یا غیرمستقیم، استقرار کامل سامانه‌های هوشمند در شبکه را مطلوب فرض می‌کنند؛ در حالی که در عمل، هوشمندسازی کامل همه تقاطع‌ها به دلیل محدودیت‌های اقتصادی، اجرایی، تجهیزاتی و نگهداری، همواره امکان‌پذیر یا مقرون‌به‌صرفه نیست. بنابراین، مسئله مهم‌تر آن است که مشخص شود کدام تقاطع‌ها باید در اولویت هوشمندسازی قرار گیرند تا با هزینه کمتر، بیشترین بهبود در عملکرد و تاب‌آوری شبکه حاصل شود. از سوی دیگر، انتخاب ترکیب مناسب تقاطع‌های هوشمند ماهیتی ترکیبی دارد و با افزایش تعداد تقاطع‌ها، فضای تصمیم به‌صورت نمایی گسترش می‌یابد. همچنین ارزیابی هر ترکیب کنترلی معمولاً مستلزم اجرای شبیه‌سازی ترافیکی است که در شبکه‌های بزرگ می‌تواند هزینه محاسباتی بالایی ایجاد کند. این موضوع ضرورت استفاده از روش‌هایی را برجسته می‌سازد که بتوانند ضمن حفظ دقت ارزیابی، فرآیند جست‌وجو و مقایسه سناریوها را سریع‌تر و کارآمدتر کنند. بر این اساس، هدف این پژوهش ارائه یک چارچوب بهینه‌سازی برای تعیین ترکیب مناسب تقاطع‌های هوشمند در یک شبکه شهری، با در نظر گرفتن هم‌زمان شاخص‌های عملکردی، زیست‌محیطی و هزینه اجرایی است. در این چارچوب، از شبیه‌سازی ترافیکی در محیط برای ارزیابی سناریوهای کنترلی، از الگوریتم ژنتیک برای جست‌وجوی فضای تصمیم، و از مدل جایگزین مبتنی بر یادگیری ماشین برای تقریب سریع شاخص تاب‌آوری استفاده می‌شود. نوآوری اصلی پژوهش در تلفیق تحلیل تاب‌آوری شبکه، هوشمندسازی انتخابی تقاطع‌ها، بهینه‌سازی ترکیبی و مدل جایگزین یادگیری ماشین است. در مقایسه با مطالعات پیشین، این پژوهش از چند جنبه متمایز است. نخست، به‌جای تمرکز صرف بر عملکرد شبکه در شرایط عادی، تاب‌آوری در شرایط اختلالی به‌عنوان یکی از محورهای اصلی ارزیابی در نظر گرفته شده است. دوم، به‌جای فرض هوشمندسازی کامل شبکه، مسئله به‌صورت انتخاب بهینه زیرمجموعه‌ای از تقاطع‌ها برای استقرار کنترل هوشمند فرموله شده است. سوم، برای کاهش هزینه محاسباتی ناشی از ارزیابی مکرر سناریوها، مدل جایگزین یادگیری ماشین در کنار الگوریتم ژنتیک به‌کار گرفته شده است. این چارچوب می‌تواند مبنایی برای تصمیم‌گیری هزینه–اثربخش در مدیریت هوشمند و تاب‌آور شبکه‌های ترافیکی شهری فراهم کند. ساختار مقاله به این صورت است: در بخش دوم، مطالعات مرتبط با کنترل هوشمند تقاطع‌ها، بهینه‌سازی و تاب‌آوری شبکه مرور می‌شود. در بخش سوم، روش‌شناسی پژوهش و چارچوب پیشنهادی تشریح می‌گردد. بخش چهارم به معرفی مطالعه موردی، نتایج شبیه‌سازی، بهینه‌سازی و ارزیابی مدل جایگزین اختصاص دارد. در نهایت، جمع‌بندی نتایج و پیشنهادهای پژوهشی ارائه می‌شود.

۲- پیشینه تحقیق

کنترل چراغ‌های راهنمایی یکی از محورهای اصلی مدیریت ترافیک شهری است و طی دهه‌های اخیر از روش‌های زمان‌ثابت و تحلیلی به سمت رویکردهای تطبیقی، داده‌محور و هوشمند حرکت کرده است. در روش‌های اولیه، زمان‌بندی چراغ‌ها معمولاً بر اساس شرایط متوسط ترافیک، حجم‌های تاریخی و روابط تحلیلی تعیین می‌شد. اگرچه این روش‌ها از نظر پیاده‌سازی ساده و از نظر اجرایی قابل اتکا هستند، اما در برابر نوسانات لحظه‌ای تقاضا، تغییرات غیرمنتظره جریان و اختلالات شبکه‌ای انعطاف‌پذیری محدودی دارند. در همین راستا، برخی پژوهش‌ها با استفاده از مدل‌سازی ساختاری و شبیه‌سازی، منطق عملکرد چراغ‌ها و اثر طرح‌های مختلف فازبندی را بررسی کرده‌اند. برای نمونه، Sadoun اثر طرح‌های مختلف فازبندی را بر شاخص‌هایی مانند زمان انتظار و طول صف بررسی نمود (Sadoun, 2003) و در پژوهشی چارچوبی مبتنی بر نمودارهای حالت برای مدل‌سازی رفتار سیستم‌های کنترل چراغ راهنمایی ارائه شد (Huang, 2006) و با وجود اهمیت این مطالعات، تمرکز آن‌ها بیشتر بر سطح تقاطع منفرد یا سناریوهای محدود بوده و تعاملات شبکه‌ای و شرایط اختلالی کمتر در آن‌ها

مورد توجه قرار گرفته است. با توسعه سامانه‌های حمل‌ونقل هوشمند، کنترل تطبیقی چراغ‌ها به‌عنوان جایگزینی برای روش‌های ایستا مورد توجه قرار گرفت. این رویکردها با بهره‌گیری از داده‌های بلادرنگ، امکان تنظیم پویا و واکنش سریع‌تر به تغییرات تقاضا را فراهم می‌کنند. Lee و همکاران چارچوبی برای تولید و اشتراک‌گذاری اطلاعات ترافیکی در زمان واقعی ارائه کردند (Lee et al., 2010) و De Oliveira و همکاران یک سیستم کنترل چراغ هوشمند مبتنی بر پایش بلادرنگ توسعه دادند که موجب بهبود شاخص‌های عملکردی شد (De Oliveira et al., 2020). با این حال، بخش مهمی از این مطالعات همچنان بر بهبود عملکرد در سطح تقاطع یا مسیرهای مشخص تمرکز دارند و مسئله انتخاب بهینه محل استقرار کنترل هوشمند در سطح شبکه را به‌صورت مستقل بررسی نمی‌کنند. در کنار روش‌های تطبیقی، الگوریتم‌های فراابتکاری به‌ویژه الگوریتم ژنتیک و الگوریتم ازدحام ذرات، به‌دلیل توانایی در جست‌وجوی فضاهای تصمیم بزرگ و غیرخطی، به‌طور گسترده در بهینه‌سازی زمان‌بندی چراغ‌ها به‌کار گرفته شده‌اند. Lee و همکاران از الگوریتم ژنتیک برای بهینه‌سازی زمان‌بندی چراغ‌ها استفاده کردند و بهبود عملکرد سیستم را گزارش نمودند (Lee et al., 2005). Teo و همکاران نیز کاربرد این روش را در بهینه‌سازی جریان ترافیک در تقاطع‌های شهری نشان دادند (Teo et al,. 2010). همچنین Garcia-Nieto و همکاران با استفاده از الگوریتم ازدحام ذرات، برنامه چرخه بهینه چراغ‌های راهنمایی را استخراج کردند (Garcia-Nieto et al., 2013). این مطالعات نشان می‌دهند که روش‌های فراابتکاری می‌توانند نسبت به روش‌های کلاسیک، انعطاف‌پذیری بیشتری در جست‌وجوی فضای تصمیم داشته باشند؛ با این حال، در بیشتر آن‌ها تمرکز بر تنظیم پارامترهای کنترلی چراغ‌ها بوده است، نه انتخاب ساختار کنترلی شبکه یا تعیین اینکه کدام تقاطع‌ها باید هوشمند شوند. در سال‌های اخیر، روش‌های یادگیری ماشین، یادگیری عمیق و یادگیری تقویتی نیز در مدیریت و کنترل ترافیک گسترش یافته‌اند. Guerrero-Ibañez و همکاران کاربرد یادگیری عمیق در سامانه‌های حمل‌ونقل هوشمند را بررسی کرده و ظرفیت این روش‌ها را در تحلیل داده‌های ترافیکی نشان دادند (Guerrero-Ibañez et al,. 2021). همچنین Haydari و Yılmaz مروری بر کاربرد یادگیری تقویتی عمیق در سیستم‌های حمل‌ونقل ارائه کردند و نشان دادند که این روش‌ها توانایی بالایی در یادگیری سیاست‌های کنترلی دارند (Haydari and Yılmaz, 2020). Medvei و همکاران نیز با توسعه مدل DeepSIGNAL، چارچوبی مبتنی بر یادگیری عمیق برای کنترل تطبیقی چراغ‌ها ارائه کردند (Medvei et al., 2025). با وجود قابلیت بالای این روش‌ها، نیاز به داده‌های آموزشی گسترده، زیرساخت محاسباتی مناسب و پیچیدگی پیاده‌سازی، کاربرد آن‌ها را در برخی شبکه‌های شهری محدود می‌سازد. از سوی دیگر، برخی مطالعات به سمت کنترل شبکه‌ای و روش‌های توزیع‌شده حرکت کرده‌اند. Grandinetti و همکاران چارچوبی برای بهینه‌سازی توزیع‌شده چراغ‌های راهنمایی در شبکه‌های بزرگ‌مقیاس ارائه کردند که امکان هماهنگی میان تقاطع‌ها را فراهم می‌سازد (Grandinetti et al., 2018). همچنین Wu و همکاران مسئله کنترل تقاطع‌ها را در محیط‌های چندعاملی بررسی کردند (Wu et al., 2014). این رویکردها از نظر مقیاس‌پذیری و هماهنگی شبکه‌ای اهمیت دارند، اما طراحی، پیاده‌سازی و اعتبارسنجی آن‌ها در شرایط واقعی همچنان با چالش‌های محاسباتی و اجرایی همراه است. در کنار بهینه‌سازی عملکرد ترافیکی، مفهوم تاب‌آوری به‌عنوان یکی از معیارهای مهم ارزیابی شبکه‌های حمل‌ونقل در شرایط اختلال مطرح شده است. Holling تاب‌آوری را به‌عنوان توانایی سیستم در حفظ عملکرد در مواجهه با اختلال معرفی کرد (Holling, 1973) و این مفهوم در مطالعات بعدی به حوزه حمل‌ونقل تعمیم یافت. Faturechi و Miller-Hooks تاب‌آوری شبکه‌های جاده‌ای را بر اساس تغییرات زمان سفر در شرایط اختلال ارزیابی کردند (Faturechi & Miller-Hooks, 2014) و Zhou و همکاران نیز مروری جامع بر شاخص‌ها و ابعاد تاب‌آوری سامانه‌های حمل‌ونقل ارائه دادند (Zhou et al., 2019). با وجود این، بسیاری از مطالعات تاب‌آوری بیشتر بر سنجش و تحلیل آسیب‌پذیری شبکه تمرکز داشته‌اند و کمتر به طراحی راهبردهای کنترلی برای بهبود تاب‌آوری پرداخته‌اند. در پاسخ به هزینه بالای شبیه‌سازی‌های مکرر، مدل‌های جایگزین مبتنی بر یادگیری ماشین به‌عنوان ابزاری برای تقریب سریع تابع هدف مورد توجه قرار گرفته‌اند. این مدل‌ها می‌توانند رابطه میان متغیرهای تصمیم و خروجی‌های عملکردی شبکه را یاد بگیرند و در فرآیند بهینه‌سازی، به‌جای اجرای مکرر شبیه‌سازی، مقدار تابع هدف را با سرعت بیشتری تخمین بزنند. Mao و همکاران چارچوبی ترکیبی مبتنی بر الگوریتم ژنتیک و یادگیری ماشین برای بهینه‌سازی کنترل ترافیک ارائه کردند که موجب کاهش هزینه محاسباتی شد (Mao et al., 2021). با این حال، استفاده از مدل‌ها بررسی ادبیات نشان می‌دهد که سه شکاف اصلی در این حوزه وجود دارد. نخست، بسیاری از مطالعات بر بهینه‌سازی عملکرد شبکه در شرایط عادی تمرکز دارند و تاب‌آوری در مواجهه با اختلالات را به‌عنوان معیار اصلی تصمیم‌گیری در نظر نمی‌گیرند. دوم، بخش مهمی از رویکردهای هوشمندسازی، استقرار کامل یا از پیش تعیین‌شده سامانه‌های هوشمند را فرض می‌کنند و مسئله

انتخاب زیرمجموعه‌ای از تقاطع‌های کلیدی برای هوشمندسازی کمتر بررسی شده است. سوم، ارزیابی سناریوهای کنترلی از طریق شبیه‌سازی، به‌ویژه در شبکه‌های بزرگ، هزینه محاسباتی بالایی دارد و نیازمند روش‌های سریع‌تر مانند مدل‌های جایگزین است.

بر این اساس، پژوهش حاضر با تلفیق شبیه‌سازی ترافیکی، الگوریتم ژنتیک و مدل جایگزین یادگیری ماشین، چارچوبی برای انتخاب بهینه تقاطع‌های هوشمند با هدف بهبود تاب‌آوری عملکردی شبکه معابر شهری ارائه می‌دهد. جایگزین در چارچوب تاب‌آوری شبکه و برای انتخاب بهینه محل استقرار کنترل هوشمند، همچنان کمتر مورد توجه قرار گرفته است.

جدول ۱. طبقه‌بندی مطالعات پیشین مرتبط با کنترل هوشمند، بهینه‌سازی و تاب‌آوری شبکه‌های ترافیکی

محور پژوهشی	مطالعات مرتبط	تمرکز اصلی مطالعات	شکاف مرتبط با پژوهش حاضر
کنترل سنتی، فازبندی و مدل‌سازی چراغ‌های راهنمایی	Huang et al. (2006), Sadoun (2003), Huang and Chung (2008), Huang et al. (2013), Popescu (2015)	مدل‌سازی کنترل و فازبندی چراغ	تمرکز بر تقاطع منفرد و عدم توجه کافی به انتخاب تقاطع‌های هوشمند در شبکه
کنترل تطبیقی و سامانه‌های حمل‌ونقل هوشمند	Lee et al. (2010), Mallik (2024), Qureshi and Abdullah (2013), De Oliveira et al. (2020), Qi et al. (2016), Zhang and Lu (2020), Kaffash et al. (2021)	کنترل هوشمند و داده‌محور ترافیک	عدم توجه کافی به اولویت‌بندی تقاطع‌ها با محدودیت منابع
الگوریتم‌های فراابتکاری و بهینه‌سازی چراغ‌ها	Lee et al. (2005), Teo et al. (2010), Garcia-Nieto et al. (2013), Hu et al. (2016), Nesmachnow et al. (2019) [27], Hai et al. (2022)	بهینه‌سازی پارامترهای کنترلی چراغ	تمرکز بر تنظیم چراغ‌ها، نه انتخاب تقاطع‌های هوشمند
بهینه‌سازی چندهدفه در کنترل ترافیک	Zhang et al. (2022), Zhang et al. (2023), Hai et al. (2022), Bocchini and Frangopol (2012)	بهینه‌سازی هم‌زمان شاخص‌های عملکردی	ارتباط محدود با تاب‌آوری و استقرار انتخابی کنترل هوشمند
یادگیری ماشین، یادگیری عمیق و یادگیری تقویتی در کنترل ترافیک	Guerrero-Ibañez et al. (2021), Haydari and Yılmaz (2020) , Medvei et al. (2025), Essa and Sayed (2020), Meena et al. (2020), Boukerche and Wang (2020), Chen et al. (2020)	کنترل و تصمیم‌گیری هوشمند داده‌محور	نیاز به داده و زیرساخت بالا و توجه محدود به هزینه–اثربخشی
کنترل شبکه‌ای و روش‌های توزیع‌شده	Faye et al. (2012), Tlig et al. (2014), Wu et al. (2014), Adacher and Tiriolo (2016), Grandinetti et al. (2018), Rodriguez and Fathy (2021), Shehu et al. (2020)	هماهنگی و کنترل چندتقاطعی	عدم توجه کافی به انتخاب زیرمجموعه بهینه تقاطع‌ها با لحاظ هزینه
تاب‌آوری و آسیب‌پذیری شبکه‌های حمل‌ونقل	Holling (1973), Zhou et al. (2019), Wang et al. (2019), Hosseini et al. (2016), Murray-Tuite (2006), Henry and Ramirez-Marquez (2012), Ip and Wang (2011), Faturechi and Miller-Hooks (2014), Bhavathrathan and Patil (2015)	سنجش و ارزیابی تاب‌آوری شبکه	تمرکز محدود بر بهبود تاب‌آوری از طریق هوشمندسازی انتخابی
ترکیب الگوریتم‌های بهینه‌سازی و یادگیری ماشین	Mao et al. (2021), Liu et al. (2024), Essa and Sayed (2020)	بهینه‌سازی کنترل و کاهش هزینه محاسباتی	عدم تمرکز بر انتخاب تقاطع‌های هوشمند با لحاظ تاب‌آوری، عملکرد، محیط‌زیست و هزینه

همان‌گونه که در جدول ۱ مشاهده می‌شود، مطالعات پیشین هر یک بخشی از مسئله کنترل هوشمند شبکه‌های ترافیکی را پوشش داده‌اند. برخی پژوهش‌ها بر مدل‌سازی و فازبندی چراغ‌ها، برخی بر کنترل تطبیقی و داده‌محور، برخی بر الگوریتم‌های بهینه‌سازی، برخی بر یادگیری ماشین و برخی بر تاب‌آوری شبکه تمرکز داشته‌اند. با این حال، تلفیق این محورها در قالب یک چارچوب واحد برای انتخاب بهینه زیرمجموعه‌ای از تقاطع‌های هوشمند، با در نظر گرفتن شاخص‌های عملکردی، زیست‌محیطی، هزینه اجرایی و تاب‌آوری شبکه، کمتر مورد توجه قرار گرفته است. ازاین‌رو، پژوهش حاضر تلاش می‌کند این شکاف را با ترکیب شبیه‌سازی ترافیکی، الگوریتم ژنتیک و مدل جایگزین یادگیری ماشین پوشش دهد.

۳- روش‌شناسی پژوهش

در این پژوهش، مسئله تعیین ترکیب مناسب تقاطع‌های مجهز به کنترل هوشمند در یک شبکه شهری، به‌صورت یک مسئله بهینه‌سازی ترکیبی فرموله شده است. هدف اصلی، انتخاب زیرمجموعه‌ای از تقاطع‌های چراغ‌دار است که با در نظر گرفتن هم‌زمان شاخص‌های عملکردی، زیست‌محیطی و هزینه اجرایی، بهترین عملکرد کلی را در سطح شبکه ایجاد کنند. در این چارچوب (شکل ۱)، تمرکز پژوهش بر هوشمندسازی انتخابی تقاطع‌ها است؛ به این معنا که به‌جای فرض هوشمندسازی کامل شبکه، وضعیت کنترلی هر تقاطع به‌عنوان یک متغیر تصمیم در نظر گرفته می‌شود. شبکه مورد مطالعه شامل N تقاطع چراغ‌دار است که هر یک می‌توانند در یکی از دو حالت «هوشمند» یا «غیرهوشمند» قرار گیرند. بنابراین، فضای تصمیم به‌صورت یک بردار دودویی تعریف می‌شود.

$$x_i \in \{0,1\}, \quad X = [x_1, x_2, \dots, x_N] \qquad (۱)$$

که در آن:

$x_i = 1$: تقاطع i هوشمند است.

$x_i = 0$: تقاطع i غیر هوشمند است.

تابع هدف به صورت بهینه سازی شاخص تاب‌آوری شبکه تعریف می شود که در آن R(X) بیانگر میزان تاب‌آوری شبکه تحت ترکیب کنترلی X است. این شاخص بر اساس عملکرد زمان‌مند شبکه در شرایط اختلال و بازیابی تعریف شده و از طریق شبیه‌سازی ترافیکی محاسبه می‌شود. با افزایش تعداد تقاطع‌ها، فضای جست‌وجو به‌صورت نمایی رشد می‌کند.

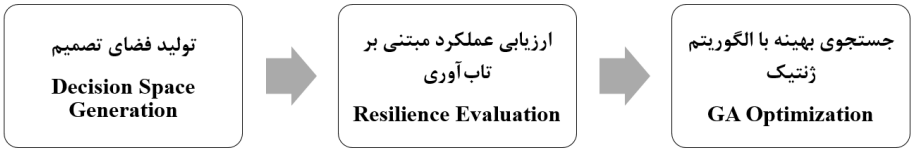
$$|SearchSpace| = 2^N \qquad (۲)$$

برای شبکه مورد مطالعه با ٦ تقاطع، تعداد حالات برابر ٦٤ است، اما در مقیاس‌های واقعی این مقدار به شدت افزایش می یابد. از سوی دیگر، ارزیابی هر حالت نیازمند اجرای شبیه سازی در محیط SUMO است که زمان‌بر می‌باشد. برای غلبه بر این چالش، یک چارچوب ترکیبی شامل دو جزء اصلی ارائه شده است. الگوریتم ژنتیک به عنوان موتور جست‌وجوی فضای تصمیم مورد استفاده قرار گرفته است و هر کروموزوم نمایانگر یک بردار دودویی از وضعیت تقاطع هاست و جمعیت اولیه به صورت تصادفی تولید می‌شود. در این پژوهش، عملکرد شبکه از طریق شاخص‌های کلیدی عملکرد ترافیکی شامل تأخیر، طول صف، زمان سفر و آلایندگی ارزیابی می‌شود. هدف از تعریف این تابع، ارزیابی هم‌زمان عملکرد ترافیکی، پیامدهای زیست‌محیطی و ملاحظات اجرایی هر سیاست کنترلی در سطح شبکه است.

تابع برازندگی به‌صورت رابطه (۳) تعریف می‌شود. وزن‌های مورد استفاده در این پژوهش به صورت $W_1 = 0.35$، $W_2 = 0.35$، $W_3 = 0.1$، $W_4 = 0.1$، $W_5 = 0.1$ انتخاب شدند.

$$KPI_k(x) = f_{sim,k}(x) \quad (۳)$$

$$F(x) = w_1.W_{norm}(x) + w_2 \times TL_{norm}(x) + w_3 \times CO2_{norm}(x) + w_4 \times Fuel_{norm}(x) + w_5 Cost_{norm} \quad (٤)$$
$$x_i \in \{0,1\} \quad i = 1,2,\dots,6$$



شکل ۱. چارچوب کلی روش‌شناسی پیشنهادی پژوهش برای بهینه‌سازی انتخابی تقاطع‌های هوشمند

این انتخاب نشان‌دهنده تمرکز اصلی پژوهش بر بهبود عملکرد ترافیکی شبکه (از طریق کاهش زمان انتظار و اتلاف زمان) است، در حالی که هم‌زمان اثرات زیست‌محیطی و هزینه اجرایی پیاده‌سازی کنترل هوشمند نیز به‌صورت صریح در فرآیند تصمیم‌گیری لحاظ شده‌اند. بدین ترتیب، تابع برازندگی تعریف‌شده امکان ارزیابی سیاست‌های کنترلی مختلف را از منظر کارایی کلی و هزینه–اثربخشی فراهم می‌سازد. پس از نرمال‌سازی، تابع برازندگی به‌صورت یک تابع کمینه‌سازی فرموله می‌شود به این معنا که مقدار کمتر تابع نشان‌دهنده عملکرد بهتر شبکه است. بنابراین، ماهیت مسئله یک مسئله کمتر–بهتر است. که در آن $P(t)$ شاخص عملکرد نرمال‌شده شبکه در بازه [۰،۱] است و مقادیر بزرگ‌تر آن نشان‌دهنده عملکرد بهتر شبکه می‌باشد.

$$P(t) = 1 - F(T) \quad (۵)$$
$$F(X) \to Min$$

برای حل مسئله بهینه سازی، از الگوریتم ژنتیک استفاده شده است. در این چارچوب، هر کروموزوم به‌صورت یک بردار دودویی X تعریف شده و نمایانگر یک سیاست کنترلی برای کل شبکه است. جمعیت اولیه به‌صورت تصادفی تولید شده و فرآیند تکاملی شامل انتخاب، تقاطع و جهش است. تابع برازندگی بر اساس مقدار $F(X)$ تعریف شده و هدف الگوریتم، یافتن ترکیبی است که مقدار آن را حداقل کند.با توجه به اینکه ارزیابی دقیق تابع برازندگی مستلزم اجرای شبیه‌سازی‌های زمان‌بر در محیط ترافیکی است، در این پژوهش از یک مدل جایگزین برای تقریب سریع تابع هدف استفاده شده است. بدین منظور، ابتدا با اجرای شبیه‌سازی کامل برای تمامی ترکیب‌های ممکن (٦٤ حالت)، یک مجموعه داده آموزشی تولید شده است. سپس، یک مدل یادگیری ماشین مبتنی بر تقویت گرادیانی برای نگاشت رابطه بین بردار تصمیم و مقدار شاخص تاب‌آوری آموزش داده شده است. این مدل به‌صورت تابعی به شکل $\hat{R} = f_{ML}(X)$ عمل کرده و در فرآیند بهینه‌سازی، به‌جای اجرای شبیه‌سازی، برای پیش‌بینی سریع مقدار تابع هدف مورد استفاده قرار می‌گیرد. برای تحلیل تاب‌آوری شبکه در برابر اختلالات، عملکرد شبکه در طول زمان مورد بررسی قرار گرفته است. زمان شبیه‌سازی به بازه‌های ثابت با طول $\Delta t=300$ ثانیه تقسیم شده است. شاخص تاب‌آوری به صورت میانگین عملکرد شبکه پس از وقوع خرابی تعریف می‌شود. (رابطه ٦)

$$R = \frac{1}{T-t_f}\sum_{k:t_k \geq t_f} \Delta t.P_k \quad (٦)$$

- Δ طول پنجره زمانی،
- P_k مقدار عملکرد شبکه زمانی در پنجره زمانی K،
- T زمان پایان شبیه سازی،
- t_f زمان وقوع خرابی است.

در این پژوهش، یک چارچوب ترکیبی برای تحلیل و بهینه‌سازی شبکه ترافیکی ارائه شده است که شامل شبیه‌سازی میکروسکوپیک SUMO، استخراج کامل فضای جستجو، الگوریتم ژنتیک و مدل جایگزین یادگیری ماشین می‌باشد. ابتدا کل فضای تصمیم به‌صورت کامل شبیه‌سازی شده و کران‌های واقعی برای نرمال‌سازی استخراج شدند. سپس تابع هدف کمینه سازی تعریف شد و الگوریتم ژنتیک برای جست‌وجوی فضای تصمیم به‌کار گرفته شد. به‌منظور کاهش هزینه محاسباتی، مدل تقویت گرادیانی به‌عنوان تقریب‌کننده تابع هدف توسعه یافت. در ادامه، شاخص تاب‌آوری شبکه بر اساس عملکرد زمان‌مند سیستم تعریف و شاخص‌های افت و بازیابی برای تحلیل دقیق‌تر رفتار سیستم استخراج شدند. این چارچوب امکان تحلیل هم‌زمان بهینه سازی عملکرد و تاب‌آوری شبکه را فراهم کرده و قابلیت تعمیم به شبکه های بزرگ‌تر را نیز داراست؛ جایی که بررسی کامل فضای جستجو عملاً غیرممکن است. انتخاب شبکه با ابعاد محدود در این پژوهش، با هدف ایجاد یک بستر کنترل‌شده برای اعتبارسنجی چارچوب پیشنهادی صورت گرفته است. در این مقیاس، امکان استخراج کامل فضای جست‌وجو و دستیابی به جواب بهینه واقعی فراهم بوده که به‌عنوان مبنایی برای ارزیابی دقت الگوریتم ژنتیک و مدل جایگزین مورد استفاده قرار گرفته است. این رویکرد امکان مقایسه مستقیم نتایج بهینه سازی با جواب بهینه واقعی را فراهم کرده و اعتبار عملکرد چارچوب پیشنهادی را تضمین می‌کند.

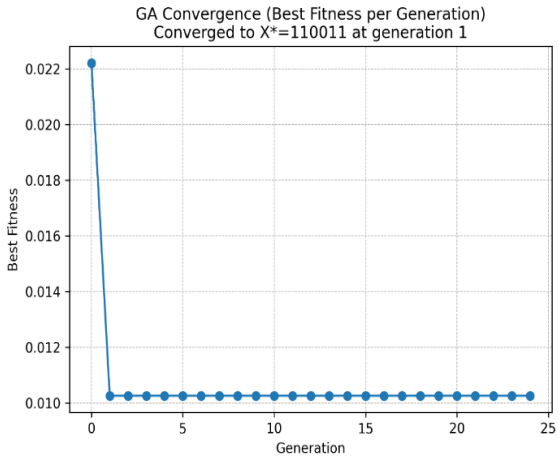
٤- نتایج

در این بخش، عملکرد ترکیب‌های مختلف وضعیت کنترلی تقاطع‌ها مورد بررسی قرار گرفت. برای شبکه مورد مطالعه با شش تقاطع تصمیم‌پذیر، تمامی ٦٤ ترکیب ممکن از وضعیت‌های کنترل هوشمند و غیرهوشمند شبیه‌سازی و ارزیابی شدند. نتایج نشان داد که عملکرد شبکه تنها به تعداد تقاطع‌های هوشمند وابسته نیست، بلکه موقعیت تقاطع‌های منتخب و نحوه توزیع آن‌ها در شبکه نیز نقش تعیین‌کننده‌ای در مقدار تابع هدف دارد. بنابراین، هوشمندسازی کامل شبکه اگرچه از نظر شاخص‌های خام عملکردی می‌تواند بهترین وضعیت را ایجاد کند، اما با در نظر گرفتن هزینه اجرایی، الزاماً گزینه بهینه در چارچوب تابع هدف چندمعیاره نیست. جدول ۲ مقایسه‌ای میان سه سناریوی اصلی شامل وضعیت پایه، سناریوی تمام‌هوشمند و سناریوی بهینه ارائه می‌دهد. همان‌گونه که مشاهده می‌شود، سناریوی تمام‌هوشمند با کروموزوم [۱،۱،۱،۱،۱،۱] کمترین مقدار زمان انتظار، اتلاف زمان، انتشار دی‌اکسیدکربن و مصرف سوخت را در میان سه سناریوی منتخب دارد. با این حال، این سناریو بیشترین هزینه اجرایی را نیز به همراه دارد. در مقابل، سناریوی بهینه با کروموزوم [۱،۱،۰،۰،۱،۱] اگرچه از نظر شاخص‌های خام عملکردی ضعیف‌تر از سناریوی تمام‌هوشمند است، اما نسبت به وضعیت پایه بهبود قابل‌توجهی ایجاد کرده و به دلیل هزینه کمتر، مقدار تابع ارزیابی پایین‌تری را به خود اختصاص داده است. این نتیجه نشان می‌دهد که راهبرد هوشمندسازی انتخابی می‌تواند گزینه‌ای هزینه–اثربخش‌تر نسبت به هوشمندسازی کامل شبکه باشد. برای بررسی کارایی روش پیشنهادی در جست‌وجوی فضای تصمیم، الگوریتم ژنتیک نیز اجرا شد.

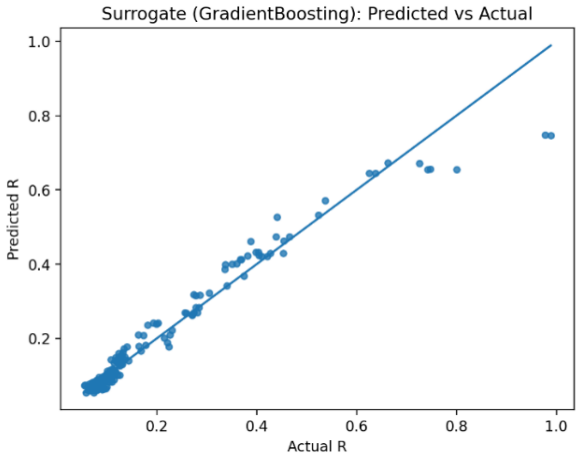
جدول ۲. مقایسه شاخص‌های عملکرد سناریوی پایه، سناریوی تمام‌هوشمند و سناریوی بهینه

سناریو	کروموزوم	میانگین زمان انتظار (ثانیه)	میانگین زمان اتلاف شده (ثانیه)	دی اکسید کربن (میلی گرم)	سوخت (میلی لیتر)	هزینه	ارزیابی
پایه	[0,0,0,0,0,0]	۹۲٫۸۰	۱٤٤٫۳۹	٤٫۰۱	۱٫۳۰	۰	۰٫٤۳
تمام هوشمند	[1,1,1,1,1,1]	۵۸٫۸۷	۹٤٫۵۳	۳٫۳۸	۱٫۱۰	٦	۰٫۲۵
بهینه	[1,1,0,0,1,1]	۷۸٫۰٤	۱۲٤٫۷۰	۳٫۷۳	۱٫۲۱	٤	۰٫۰۱

نتایج نشان داد که الگوریتم ژنتیک در اجراهای انجام‌شده به همان ترکیب بهینه شناسایی‌شده از طریق بررسی کامل فضای جست‌وجو، یعنی [۱،۱،۰،۰،۱،۱]، همگرا شده است. از آنجا که در شبکه حاضر تعداد ترکیب‌ها محدود و برابر با ٦٤ حالت است، بررسی کامل فضای جست‌وجو برای اعتبارسنجی پاسخ امکان‌پذیر بود؛ با این حال، اهمیت اصلی الگوریتم ژنتیک در شبکه‌های بزرگ‌تر آشکار می‌شود، جایی که با افزایش تعداد تقاطع‌ها، تعداد ترکیب‌های ممکن به‌صورت نمایی افزایش می‌یابد. شکل ۲ روند تغییرات مقدار بهترین تابع ارزیابی را در طول نسل‌های الگوریتم ژنتیک نشان می‌دهد. کاهش مقدار تابع هدف در نسل‌های ابتدایی و سپس ثابت ماندن آن بیانگر همگرایی الگوریتم به پاسخ مطلوب و حفظ جواب برتر در نسل‌های بعدی است. در ادامه، به‌منظور کاهش هزینه محاسباتی ارزیابی سناریوهای اختلال و تقریب سریع شاخص تاب‌آوری، مدل‌های مختلف یادگیری ماشین مورد ارزیابی قرار گرفتند. جدول ۳ عملکرد مدل‌های مختلف را بر اساس سه معیار خطای مطلق میانگین، ریشه میانگین مربعات خطا و ضریب تعیین نشان می‌دهد. نتایج نشان می‌دهد که مدل‌های تجمیعی در مجموع عملکرد بهتری نسبت به مدل‌های خطی دارند. در میان مدل‌های بررسی‌شده، تقویت گرادیانی با مقدار ریشه میانگین مربعات خطا برابر ۰,۰٤٦۲ و ضریب تعیین برابر ۰,۹۲۷ بهترین عملکرد کلی را ارائه داده است. اگرچه جنگل تصادفی مقدار میانگین خطای مطلق اندکی کمتر دارد، اما تقویت گرادیانی از نظر خطای مربعی و توان توضیح واریانس داده‌ها عملکرد مناسب‌تری نشان می‌دهد و به‌عنوان مدل جایگزین منتخب در این پژوهش در نظر گرفته شد. مقادیر ارائه‌شده در جدول ۳ نشان می‌دهد که مدل تقویت گرادیانی توانایی مناسبی در تقریب شاخص تاب‌آوری دارد.



شکل ۲. روند تغییرات مقدار بهترین تابع ارزیابی در طول نسل‌های الگوریتم ژنتیک و همگرایی به جواب بهینه



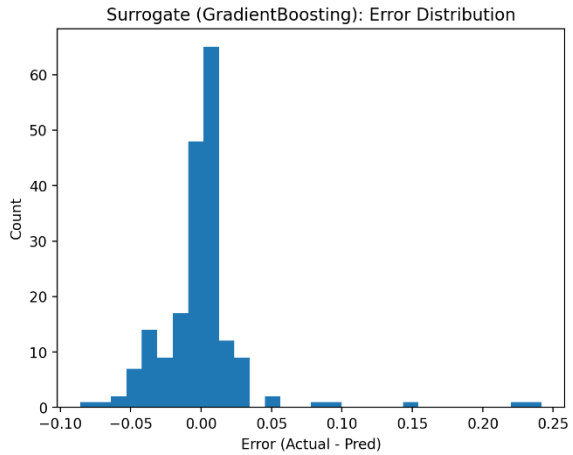
شکل ۳. مقدار پیش‌بینی شده و واقعی شاخص تاب‌آوری

جدول ۳. مقایسه عملکرد مدل‌های مختلف در تقریب شاخص تاب‌آوری

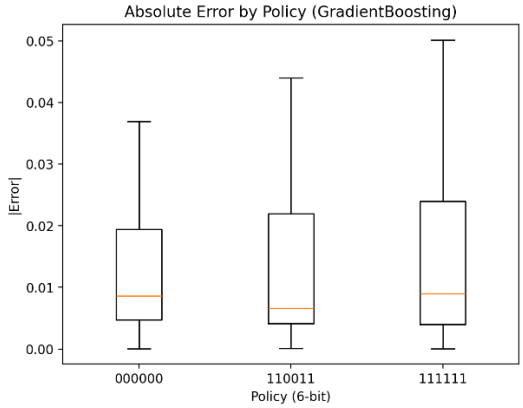
مدل	MAE	RMSE	R^2
Gradient Boosting	۰,۰۲۴۸	۰,۰۴۶۲	۰,۹۲۷
Random Forest	۰,۰۲۱۴	۰,۰۴۹۳	۰,۹۱۷
AdaBoost	۰,۰۳۳۸	۰,۰۵۴۴	۰,۸۹۹
HistGradientBoosting	۰,۰۳۱۸	۰,۰۵۶۳	۰,۸۹۲
Extra Trees	۰,۰۲۵۳	۰,۰۵۷۲	۰,۸۸۸
SVR	۰,۰۳۸۵	۰,۰۶۱۲	۰,۸۷۲
Lasso	۰,۰۸۲۸	۰,۱۱۲۳	۰,۵۶۹
ElasticNet	۰,۰۸۳۰	۰,۱۱۲۳	۰,۵۶۹
Ridge	۰,۰۸۳۱	۰,۱۱۲۴	۰,۵۶۸
KNN	۰,۰۷۷۸	۰,۱۲۱۸	۰,۴۹۳

مقدار پایین ریشه میانگین مربعات خطا نشان‌دهنده خطای محدود پیش‌بینی نسبت به مقادیر حاصل از شبیه‌سازی است و مقدار بالای ضریب تعیین بیانگر آن ا ست که بخش عمده‌ای از تغییرات شاخص تاب‌آوری تو سط مدل تو ضیح داده می شود. بنابراین، این مدل می‌تواند به‌عنوان یک ابزار جایگزین برای کاهش نیاز به اجرای مکرر شبیه‌سازی در فرآیند تحلیل سناریوها مورد استفاده قرار گیرد. شکل ۳ مقادیر پیش‌بینی شده شاخص تاب‌آوری را در برابر مقادیر واقعی حاصل از شبیه‌سازی نشان می‌دهد. تمرکز نقاط در نزدیکی خط ۴۵ درجه بیانگر تطابق مناسب میان خروجی مدل جایگزین و نتایج شبیه‌سازی است. نبود الگوی انحراف سیستماتیک در این نمودار نشان می‌دهد که مدل تقویت گرادیانی در بازنمایی رفتار کلی سیستم دچار بایاس قابل‌توجه نشده است.

شکل ٤ توزیع خطای پیش‌بینی مدل را نشان می‌دهد. تمرکز خطاها در اطراف مقدار صفر و توزیع نسبتاً متقارن آن‌ها بیانگر پایداری مدل و عدم بروز خطاهای شدید در بیشتر سناریوهای خرابی است. این نتیجه نشان می‌دهد که مدل جایگزین در مواجهه با ترکیب‌های مختلف سیاست کنترلی و الگوهای خرابی، عملکرد قابل قبولی از خود نشان داده است.

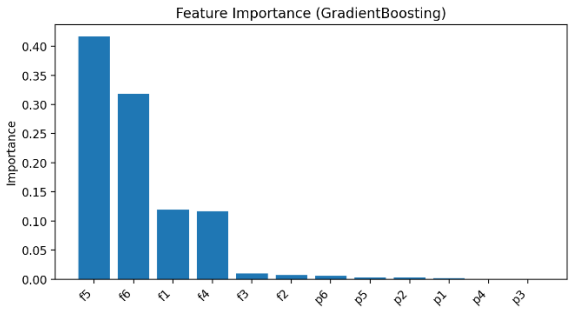


شکل ٤. توزیع خطای پیش‌بینی



شکل ۵. خطای مطلق به تفکیک سیاست کنترلی

در شکل ۵، خطای مطلق پیش‌بینی به تفکیک سیاست کنترلی نشان می‌دهد که میزان خطا در سیاست‌های دارای سطحی از کنترل هوشمند، شامل هوشمندسازی انتخابی و هوشمندسازی کامل، نسبتاً کمتر از سیاست کاملاً زمان‌ثابت است. این موضوع می‌تواند ناشی از ساختار منظم‌تر پاسخ شبکه در شرایط کنترل هوشمند باشد؛ در حالی که در حالت کاملاً زمان‌ثابت، تنوع رفتار شبکه و حساسیت آن نسبت به اختلالات بیشتر بوده و در نتیجه پیش‌بینی شاخص تاب‌آوری دشوارتر می‌شود.



شکل ٦. اهمیت ویژگی‌ها

تحلیل اهمیت ویژگی‌ها در شکل ٦ نشان می‌دهد که متغیرهای مرتبط با الگوی خرابی چراغ‌ها، سهم قابل‌توجهی در تعیین مقدار شاخص تاب‌آوری دارند. این نتیجه بیانگر آن است که محل وقوع خرابی و ترکیب چراغ‌های مختل‌شده نقش مهمی در افت عملکرد شبکه ایفا می‌کند. در مقابل، متغیرهای مربوط به سیاست کنترلی اهمیت ثانویه‌تری نشان داده‌اند. این یافته تأیید می‌کند که تاب‌آوری شبکه تنها به تعداد تقاطع‌های هوشمند وابسته نیست، بلکه به ساختار شبکه، موقعیت گلوگاه‌ها و نحوه توزیع اختلال نیز بستگی دارد. در مجموع، نتایج این بخش نشان داد که هوشمندسازی انتخابی می‌تواند نسبت به وضعیت پایه، بهبود قابل‌توجهی در شاخص‌های عملکردی و زیست‌محیطی ایجاد کند و در عین حال، با هزینه اجرایی کمتر نسبت به هوشمندسازی کامل، مقدار مطلوب‌تری از تابع هدف چندمعیاره ارائه دهد. همچنین الگوریتم ژنتیک توانست ترکیب بهینه را به‌درستی شناسایی کند و مدل جایگزین مبتنی بر گرادیانت تقویتی نیز با دقت مناسب، شاخص تاب‌آوری را تقریب زد. این یافته‌ها نشان می‌دهند که ترکیب شبیه‌سازی، بهینه‌سازی تکاملی و مدل جایگزین یادگیری ماشین می‌تواند چارچوبی کارآمد برای تحلیل و طراحی سیاست‌های کنترل هوشمند در شبکه‌های ترافیکی شهری فراهم کند.

۵- نتیجه‌گیری

نتایج این پژوهش نشان داد که رابطه میان سطح هوشمندسازی شبکه و بهبود عملکرد کلی، رابطه‌ای کاملاً خطی و یکنواخت نیست. اگرچه سناریوی تمام‌هوشمند از نظر شاخص‌های خام عملکردی، شامل زمان انتظار، اتلاف زمان، مصرف سوخت و انتشار دی‌اکسیدکربن، بهترین وضعیت را ایجاد کرد، اما با در نظر گرفتن هزینه اجرایی در تابع هدف چندمعیاره، لزوماً بهینه‌ترین گزینه محسوب نشد. این یافته نشان می‌دهد که کارایی راهبردهای کنترلی تنها به تعداد تقاطع‌های هوشمند وابسته نیست، بلکه به موقعیت مکانی تقاطع‌های منتخب، نقش آن‌ها در ساختار شبکه و اثرگذاری آن‌ها بر جریان و گلوگاه‌های ترافیکی بستگی دارد. از دیدگاه مدیریتی، نتایج پژوهش بر اهمیت هوشمندسازی انتخابی در شرایط محدودیت منابع تأکید می‌کند. در شبکه مورد مطالعه، ترکیب بهینه [۱،۱،۰،۰،۱،۱] توانست نسبت به وضعیت پایه بهبود قابل‌توجهی ایجاد کند و در عین حال، با هزینه اجرایی کمتر نسبت به سناریوی تمام‌هوشمند، مقدار مطلوب‌تری از تابع هدف چندمعیاره ارائه دهد. بنابراین، در شرایطی که بودجه، تجهیزات، زیرساخت ارتباطی و امکانات نگهداری محدود هستند، انتخاب هدفمند تقاطع‌های کلیدی می‌تواند راهبردی عملی‌تر و هزینه–اثربخش‌تر از هوشمندسازی کامل شبکه باشد. از منظر روش‌شناسی، ترکیب الگوریتم ژنتیک با مدل جایگزین یادگیری ماشین، چارچوبی کارآمد برای مواجهه با پیچیدگی محاسباتی مسائل شبیه‌سازی‌محور فراهم کرد. اگرچه در شبکه مورد مطالعه امکان بررسی کامل ٦٤ ترکیب ممکن وجود داشت، اجرای الگوریتم ژنتیک نشان داد که این روش می‌تواند بدون نیاز به بررسی صریح همه حالات، به ترکیب بهینه همگرا شود. اهمیت این ویژگی در شبکه‌های بزرگ‌تر بیشتر آشکار می‌شود؛ زیرا با افزایش تعداد تقاطع‌های تصمیم‌پذیر، فضای جست‌وجو به‌صورت نمایی رشد کرده و بررسی کامل تمامی ترکیب‌ها از نظر محاسباتی دشوار یا غیرعملی خواهد شد. عملکرد مدل تقویت گرادیانی نیز نشان داد که مدل‌های یادگیری ماشین می‌توانند به‌عنوان مدل جایگزین برای تقریب سریع شاخص تاب‌آوری مورد استفاده قرار گیرند. دقت مناسب این مدل در پیش‌بینی شاخص تاب‌آوری، همراه با مقدار بالای ضریب تعیین و خطای محدود، بیانگر آن است که مدل توانسته رابطه میان ساختار شبکه، سیاست کنترلی و سناریوهای اختلال را با دقت قابل قبولی بازنمایی کند. با این حال، باید توجه داشت که داده‌های مورد استفاده در این پژوهش در یک فضای کنترل‌شده و با تعداد محدود تقاطع‌ها تولید شده‌اند؛ بنابراین، تعمیم نتایج به شبکه‌های بزرگ‌تر و شرایط واقعی‌تر نیازمند داده‌های متنوع‌تر، سناریوهای اختلال گسترده‌تر و اعتبارسنجی دقیق‌تر است. یکی از نکات مهم پژوهش، نقش تابع برازندگی و وزن‌دهی به شاخص‌های مختلف در انتخاب سناریوی بهینه است. در این مطالعه، وزن بیشتری به شاخص‌های عملکرد ترافیکی، شامل زمان انتظار و اتلاف زمان، اختصاص داده شد و شاخص‌های زیست‌محیطی و هزینه اجرایی به‌عنوان مؤلفه‌های مکمل در تابع هدف وارد شدند. ازاین‌رو، نتایج به‌دست‌آمده وابسته به ساختار تابع هدف و وزن‌های انتخاب‌شده است. در مطالعات آینده، انجام تحلیل حساسیت نسبت به وزن‌ها و استفاده از روش‌های بهینه‌سازی چندهدفه می‌تواند تصویر دقیق‌تری از مبادله میان عملکرد ترافیکی، هزینه اجرایی و پیامدهای زیست‌محیطی ارائه دهد. با وجود دستاوردهای پژوهش، چند محدودیت نیز باید مورد توجه قرار گیرد. نخست، شبکه مورد مطالعه کوچک‌مقیاس بوده و با هدف ایجاد بستری کنترل‌شده برای ارزیابی چارچوب پیشنهادی انتخاب شده است؛ بنابراین، تعمیم نتایج به شبکه‌های شهری بزرگ‌تر نیازمند بررسی‌های تکمیلی است. دوم، سناریوهای اختلال به‌صورت محدود تعریف شده‌اند، در حالی که در شرایط واقعی، خرابی‌ها و اختلالات می‌توانند هم‌زمان، پیشرونده و همراه با عدم‌قطعیت باشند. سوم، داده‌های میدانی کامل برای کالیبراسیون دقیق ماتریس مبدأ–مقصد و رفتار واقعی شبکه در دسترس نبوده و بخشی از تقاضا و مسیرها بر اساس روش‌های تخمینی در محیط شبیه‌سازی تکمیل شده‌اند. در مجموع، این پژوهش نشان می‌دهد که در مدیریت هوشمند شبکه‌های ترافیکی، رویکرد هوشمندسازی بیشتر همواره معادل تصمیم بهتر نیست. آنچه اهمیت بیشتری دارد، انتخاب هدفمند و شبکه‌ای محل استقرار کنترل هوشمند، با توجه به عملکرد، تاب‌آوری، هزینه و پیامدهای زیست‌محیطی است. چارچوب پیشنهادی، با ترکیب شبیه‌سازی ترافیکی، الگوریتم ژنتیک و مدل جایگزین یادگیری ماشین، می‌تواند ابزاری مؤثر برای پشتیبانی تصمیم در طراحی سیستم‌های کنترل ترافیک تاب‌آور و هزینه–اثربخش در شبکه‌های شهری باشد.

٦-مراجع

-Adacher L, Tiriolo M, editors (2016). A distributed approach for traffic signal synchronization problem. 2016 Third International Conference on Mathematics and Computers in Sciences and in Industry (MCSI), *IEEE.*

-Bhavathrathan B, Patil GR (2015). Quantifying resilience using a unique critical cost on road networks subject to recurring capacity disruptions. Transportmetrica A: Transport Science. 11(9):836-55.

-Bocchini P, Frangopol DM. (2012). Restoration of bridge networks after an earthquake: Multicriteria intervention optimization. *Earthquake Spectra*. 28(2): 427-55.

-Boukerche A, Wang J. (2020). Machine learning-based traffic prediction models for intelligent transportation systems. *Computer Networks.* 181:107530.

-Chen C, Liu B, Wan S, Qiao P, Pei Q. (2020). An edge traffic flow detection scheme based on deep learning in an intelligent transportation system. *IEEE Transactions on Intelligent Transportation Systems*. 22(3):1840-52.

-De Oliveira LFP, Manera LT, Da Luz PDG. (2020). Development of a smart traffic light control system with real-time monitoring. *IEEE Internet of Things Journal*. 8(5):3384-93.

-Essa M, Sayed T. (2020). Self-learning adaptive traffic signal control for real-time safety optimization. *Accident Analysis & Prevention.* 146:105713.

-Faturechi R, Miller-Hooks E. (2014). Travel time resilience of roadway networks under disaster. *Transportation Research Part B: Methodological.* 70:47-64.

-Faye S, Chaudet C, Demeure I, editors. (2012). A distributed algorithm for multiple intersections adaptive traffic lights control using a wireless sensor networks. *Proceedings of the First Workshop on Urban Networking.*

-Garcia-Nieto J, Olivera AC, Alba E. (2013). Optimal cycle program of traffic lights with particle swarm optimization. *IEEE Transactions on Evolutionary Computation.* 17(6):823-39.

-Grandinetti P, Canudas-de-Wit C, garin F. (2018). Distributed optimal traffic lights design for large-scale urban networks. *IEEE Transactions on Control Systems Technology.* 27(3):950-63.

-Guerrero-Ibañez J, Contreras-Castillo J, Zeadally S. (2021). Deep learning support for intelligent transportation systems. *Transactions on Emerging Telecommunications Technologies.* 32(3):e4169.

-Hai DT, Manh DV, Nhat NM. (2022). Genetic algorithm application for optimizing traffic signal timing reflecting vehicle emission intensity. *Transport Problems.* 17.

-Haydari A, Yılmaz Y. (2020). Deep reinforcement learning for intelligent transportation systems: A survey. *IEEE Transactions on Intelligent Transportation Systems.* 23(1):11-32.

-Henry D, Ramirez-Marquez JE. (2012). Generic metrics and quantitative approaches for system resilience as a function of time. *Reliability Engineering & System Safety.* 99: 114-22.

-Holling CS. (1973). Resilience and stability of ecological systems. *International Institute for Applied Systems Analysis Laxenburg.*

-Hosseini S, Barker K, Ramirez-Marquez JE. (2016). A review of definitions and measures of system resilience. Reliability Engineering & System Safety. 145:47-61.

-Hu W, Wang H, Yan L, Du B. A swarm intelligent method for traffic light scheduling: application to real urban traffic networks. Applied Intelligence. 2016;44(1):208-31.

-Huang Y.S. (2006). Design of traffic light control systems using statecharts. *The Computer Journal.* 49(6):634-49.

-Huang Y.S. (2008). Chung T-H. Modeling and analysis of urban traffic lights control systems using timed CP-nets. *Journal of Information Science & Engineering.* 24(3).

-Huang Y.S. (2013). Weng Y-S, Zhou M. Modular design of urban traffic-light control systems based on synchronized timed Petri nets. *IEEE Transactions on Intelligent Transportation Systems.* 15(2):530-9.

-Ip WH, Wang D. (2011). Resilience and friability of transportation networks: Evaluation, analysis and optimization. *IEEE Systems Journal.* 5(2):189-98.

-Lee W.H., Tseng, S.S. Shieh W.Y. (2010). Collaborative real-time traffic information generation and sharing framework for the intelligent transportation system. *Information Sciences.* 180(1):62-70.

-Lee, J. Abdulhai B, Shalaby A. (2005). Chung E-H. Real-time optimization for adaptive traffic

-Meena G, Sharma D, Mahrishi M, editors. (2020). Traffic prediction for intelligent transportation system using machine learning. *2020 3rd International Conference on Emerging Technologies in Computer Engineering: Machine Learning and Internet of Things (ICETCE); IEEE.*

-Murray-Tuite PM, editor (2006). A comparison of transportation network resilience under simulated system optimum and user equilibrium conditions. *Proceedings of The 2006 Winter Simulation Conference; IEEE.*

-Nesmachnow S, Massobrio R, Arreche E, Mumford C, Olivera AC, Vidal PJ, et al. Traffic lights synchronization for Bus Rapid Transit using a parallel evolutionary algorithm. International Journal of Transportation Science and Technology. 2019;8(1):53-67.

-Popescu LG. (2015). The Development of A Model For The Traffic In A Urban Intersection. *Fascicle of Management and Technological Engineering.* 1:29-32.

2014 International Conference on Advanced Logistics and Transport (ICALT); IEEE.

-Wang J. Wang H. Zhou Y. Wang Y. Zhang, W.J. (2019). On an integrated approach to resilient transportation systems in emergency situations. *Natural Computing.* 18(4):815-23.

-Wu W. Zhang J, Luo A. Cao J. (2014). Distributed mutual exclusion algorithms for intersection traffic control. *IEEE Transactions on Parallel and Distributed Systems.* 26(1): 65-74.

-Zhang H. Lu X. (2020). Vehicle communication network in intelligent transportation system based on Internet of Things. *Computer Communications.* 160: 799-806.

-Zhang X. Fan X. Yu S. Shan A. Fan S. Xiao Y. et al. (2022). Intersection signal timing optimization: A multi-objective evolutionary algorithm. *Sustainability.* 14(3):1506.

-Zhang Z. Zhu H. Zhang W. Cai Z. Zhu L. Li Z. (2023). Multi-Objective Optimization of Traffic Signal Timing at Typical Junctions Based on Genetic Algorithms. *Computer Systems Science & Engineering.* 47(2).

-Zhou Y. Wang J. Yang H. (2019). Resilience of transportation systems: concepts and comprehensive review. *IEEE Transactions on Intelligent Transportation Systems.* 20(12):4262-76.

signal control using genetic algorithms. *Journal of Intelligent Transportation Systems*. 9(3): 111-22.

-Liu W.L. Zhong, J. Liang, P. Guo, J. Zhao, H. Zhang, J. (2024). Towards explainable traffic signal control for urban networks through genetic programming. *Swarm and Evolutionary Computation.* 88:101588.

-Mallik S. (2024). Intelligent transportation system. *International Journal of Civil Engineering Research*.

-Mao T. Mihăită A. S. Chen F. Vu, HL (2021). Boosted genetic algorithm using machine learning for traffic control optimization. *IEEE Transactions on Intelligent Transportation Systems.* 23(7):7112-41.

-Medvei MM, Bordei A-V, Niță ȘL, Țăpuș N. DeepSIGNAL-ITS, (2025). Deep Learning Signal Intelligence for Adaptive Traffic Signal Control in Intelligent Transportation Systems. *Applied Sciences.* 15(17):9396.

- Sadoun B. (2003). An efficient simulation methodology for the design of traffic lights at intersections in urban areas. *Simulation.* 79(4):243-51.

-Qi L, Zhou M, Luan W. (2016). A two-level traffic light control strategy for preventing incident-based urban traffic congestion. *IEEE Transactions on Intelligent Transportation Systems.* 19(1):13-24.

-Qureshi KN, Abdullah AH. (2013). A survey on intelligent transportation systems. *Middle-East Journal of Scientific Research*. 15(5):629-42.

-Rodriguez M, Fathy HK. (2021). Distributed Kuramoto self-synchronization of vehicle speed trajectories in traffic networks. *IEEE Transactions on Intelligent Transportation Systems.* 23(7):6786-96.

-Shehu HA, Sharif MH, Ramadan RA. (2020). Distributed mutual exclusion algorithms for intersection traffic problems. *IEEE Access.* 8:138277-96.

-Teo KTK, Kow WY, Chin Y. editors (2010). Optimization of traffic flow within an urban traffic light intersection with genetic algorithm. *2010 Second International Conference on Computational Intelligence, Modelling and Simulation; IEEE.*

-Tlig M, Buffet O. Simonin O. editors (2014). Decentralized traffic management: A synchronization-based intersection control.

Optimization of Selective Smartization of Signalized Intersections for Enhancing the Functional esilience of Urban Road Networks Using a Genetic Algorithm and a Machine Learning Surrogate Model

Fatemeh Salmi Pasikhani, M.Sc., Stud., Faculty of Civil and Environmental Engineering, Tarbiat Modares, University, Tehran, Iran.
***Aminmirza Boroujerdian,** Associate Professor, Faculty of Civil and Environmental Engineering, Tarbiat Modares University, Tehran, Iran.*
Saeid Sherafatipour, Assistant Professor, Faculty of Civil and Environmental Engineering, Tarbiat Modares University, Tehran, Iran.

E-mail: boroujerdian@modares.ac.ir

Received: May 2026- Accepted: November 2026

ABSTRACT
Increasing travel demand, complex traffic patterns, and unpredictable disruptions have made urban road network resilience a critical issue in traffic management. Signalized intersections, as key network nodes, significantly influence congestion formation, queue propagation, and performance degradation. Although full-scale intelligent control can improve traffic operations, it is not always feasible or optimal due to economic, technological, and implementation constraints. This study aims to identify the optimal combination of intelligent intersections by considering operational performance, environmental impacts, and implementation costs simultaneously. A hybrid framework integrating traffic simulation, a Genetic Algorithm (GA), and a machine learning surrogate model is proposed. The studied network consists of six signalized intersections modeled in the SUMO environment. Each intersection's control strategy was represented as a binary variable, where one indicates intelligent control and zero represents conventional fixed-time control. All 64 possible combinations were simulated, and a multi-objective function was developed based on travel delay, time loss, carbon dioxide emissions, fuel consumption, and implementation cost. The GA was then employed to optimize the control configuration, while the Gradient Boosting model was used as a surrogate model to efficiently estimate the resilience index and reduce computational costs. The results showed that the fully intelligent scenario achieved the best performance in terms of operational and environmental indicators; however, its higher implementation cost prevented it from being the optimal solution. The configuration [1,1,0,0,1,1] was identified as the optimal scenario, providing performance close to the fully intelligent strategy with lower implementation costs. Moreover, the Gradient Boosting model accurately estimated the resilience index, achieving MAE=0.0248, RMSE=0.0462, and R^2=0.927, while reducing the computational burden of scenario evaluation. The findings highlight that targeted intelligent control deployment can provide a cost-effective alternative to full network automation and support resilience-oriented urban traffic management.

Keywords: Urban Traffic Network Resilience, Intelligent Signal Control, Selective Smart Intersection Deployment, Genetic Algorithm, Machine Learning Surrogate Model