فصلنامه مهندسی ترافیک، سال بیست و چهارم، شماره ۹۷، تابستان ۱۴۰۳، ص. ۳۱-۱۵

زمان‌بندی چراغ‌های ترافیکی با استفاده از ترکیب شبکه‌های عصبی بازگشتی، یادگیری تقویتی و روش‌های بهینه‌سازی

اسحاق جهانبخشی (مسئول مکاتبات)، گروه مهندسی کامپیوتر و فناوری اطلاعات، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران

E-mail: isaac.jahanbakhshi@yahoo.com

فاطمه شهبازی، گروه مهندسی کامپیوتر، واحد کرمانشاه، دانشگاه علمی و کاربردی جهاد دانشگاهی، کرمانشاه، ایران

چکیده

ازدحام ترافیک یک مسئله جدی است که زندگی مردم را در سراسر جهان تحت تأثیر قرار داده است. حل این مسئله نیاز به راه‌حل‌هایی دارد که بتواند با محیط‌های ترافیکی در حال تغییر سازگار شود و تراکم ترافیک را نه‌تنها در تقاطع‌های محلی، بلکه در سراسر شبکه جاده‌ای کاهش دهد. برنامه‌های زمان‌بندی سیگنال ناکارآمد یکی از دلایل اصلی کاهش کار آیی سیگنال‌های ترافیکی در جریان‌های شهری است. استراتژی‌های موجود برای کنترل ترافیک نمی‌توانند با پویایی دنیای واقعی سازگار شوند. طراحی کنترل‌کننده‌های تطبیقی بر مبنای روش‌های هوش مصنوعی که قادر به رسیدگی به شرایط ترافیکی غیرقابل‌پیش‌بینی هستند، از محبوبیت بالایی برخوردار شده‌است. در این تحقیق، با بهره‌گیری از قدرت شبکه‌های عصبی بازگشتی و یادگیری تقویتی در مقابله با پویایی ترافیک و انتخاب زمان‌بندی بهینه فاز سبز با استفاده از ترکیب روش‌های بهینه‌سازی، یک مدل زمان‌بندی سیگنال‌های ترافیکی کارآمد با رویکرد کاهش تأخیر و افزایش گذردهی تقاطع‌ها ارائه شده است. برای این هدف، با استفاده از شبکه عصبی خود رمزنگار (AE)، الگوی ترافیکی جامعه بر اساس تقاضاهای تردد در سطوح روزانه، هفتگی و ماهانه و با لحاظ کردن مناسبت‌ها و وقوع رخدادهای خاص اجتماعی پیش‌بینی می‌شود. در ادامه با بهره‌گیری از شبکه عصبی U-net به تخمین ترافیک ورودی به یک تقاطع بر اساس ترافیک خروجی از تقاطع‌های همجوار پرداخته می‌شود. پس از فرموله سازی مسئله زمان‌بندی سیگنال ترافیکی به‌عنوان یک مسئله بهینه‌سازی، زمان‌بندی بهینه فازهای سبز چراغ‌های راهنمایی و رانندگی با استفاده از ترکیب تکنیک‌های فرا ابتکاری ژنتیک (GA) و عقاب طلایی (GEO) محاسبه می‌شود. همچنین با استفاده از روش یادگیری تقویتی، وزن اهمیت شاخص‌های تابع هدف روش بهینه‌سازی به‌روزرسانی می‌گردد. درنهایت اثر وقوع رخدادهای انسدادی (تصادف، تعمیرات و...) در زمان‌بندی نهایی اعمال می‌شود. نتایج شبیه‌سازی نشان می‌دهد که روش پیشنهادی حتی با وجود افزایش نرخ جریان ورودی به عملکرد مطلوب‌تری نسبت به روش‌های مرسوم دست یافته است و با کاهش زمان بیکاری در تقاطع‌ها، بهره‌وری فاز سبز تقاطع‌ها را افزایش داده است.

واژه‌های کلیدی: زمان‌بندی سیگنال‌های کنترلی، گذردهی، زمان انتظار، شبکه عصبی خود رمزنگار، بهینه‌سازی

۱. مقدمه

ازدحام ترافیک[1] یکی از مشکلات عمده شهرهای مدرن است که باعث اتلاف زمان، آلودگی و مصرف بیش‌ازحد سوخت می شود. این مشکل با رشد مداوم تعداد وسایل نقلیه و عدم کارآمدی مدیریت ترافیک تشدید می‌شود. زمان‌بندی فاز سبز چراغ‌های تقاطع‌های جاده‌ای به‌عنوان سیگنال‌های راهنمایی و رانندگی برای تنظیم ترافیک استفاده می‌شود. کارایی این سیگنال‌های کنترل ترافیک به توانایی متعادل کردن تناوب جریان‌های خودرو بدون افزایش زمان انتظار، طول صف‌ها و ازدحام بستگی دارد. بیشتر علائم راهنمایی و رانندگی در حالت‌های از پیش زمان‌بندی‌شده در حالت‌های ترافیکی عمل می‌کنند. درحالی‌که کنترل از پیش تعیین‌شده بر اساس زمان‌بندی سیگنال ثابت است. اخیراً، بیشتر جاده‌های شهری به دستگاه‌های سیستم‌های حمل‌ونقل هوشمند مجهز شده‌اند که قادر به گزارش داده‌های جمع‌آوری‌شده در وضوح زمانی و مکانی بالا هستند که به ما این فرصت را می‌دهد تا بر نقص‌های زمان‌بندی سیگنال سنتی غلبه کنیم. در حالت هوشمندتر می‌بایست کنترل ترافیکی از کاهش‌ها و افزایش‌های کارآمد زمان فاز سبز برای تنظیم خروجی هر تقاطع استفاده کند. متأسفانه، به دلیل عدم قطعیت بالای ورودی‌های ترافیک، ایجاد مقادیر بهینه درازمدت برای فازها دشوار است. علاوه بر این، به دلیل رفتار از پیش تعیین‌شده، این طرح‌ها قادر به واکنش به رویدادهای غیرمعمولی که تردد را مختل می‌کنند، نیستند. درنتیجه، چنین کنترل‌کننده‌هایی مستعد ایجاد صف‌های طولانی و توقف بالا به دلیل زمان‌بندی بیش‌ازحد یا کمتر از مقدار موردنیاز هستند.

یک راهکار مناسب برای مدیریت مؤثر ترافیک و اجتناب از ازدحام، استفاده از کنترل‌کننده‌های ترافیک تطبیقی در مسئله زمان‌بندی سیگنال به‌عنوان یک مسئله انطباقی است به‌طوری‌که بتوان در عین استفاده از روش‌های بهینه‌سازی برای تعیین فاز سبز هر لاین از تقاطع، از قابلیت‌های مکانیزم‌های تطبیقی مانند روش‌های یادگیری تقویتی و یا روش‌های کنترل فازی مبتنی بر قانون استفاده کرد. در راستای ارتقای وضعیت زمان‌بندی سیگنال‌های ترافیکی، رویکردهای متعددی بر اساس یادگیری تقویتی، شبکه‌های عصبی، یادگیری تقویتی عمیق و منطق فازی، ارائه شده است. روش‌های شبکه‌های عصبی، یادگیری تقویتی عمیق و منطق فازی به دلیل دقت، الزامات محاسباتی و همچنین مقادیر پشتیبانی شده از حالت‌ها و اقدامات، بهترین عملکرد را نشان داده‌اند. نوآوری‌های طرح جاری شامل تشخیص الگوی حرکتی جامعه بر اساس تقاضاهای ترافیکی روزانه، هفتگی و ماهانه، تخمین ترافیک ورودی به یک تقاطع بر اساس تخمین ترافیک خروجی از تقاطع‌های همجوار و زمان‌بندی فاز سبز برای هر تقاطع با استفاده از تکنیک‌های فرا ابتکاری است که در بخش ۳ به‌طور مشروح، بیان خواهد شد.

۲. ادبیات پژوهش

دو[2] و همکاران برای اولین بار استانداردهای ایمنی جاده را برای حصول اطمینان از ایمن بودن مکانیزم‌های زمان‌بندی مبتنی بر روش‌های یادگیری تقویتی موجود و ایجاد تقاطع‌هایی با احتمال برخورد صفر ترکیب کرده‌اند. آن‌ها یک روش یادگیری تقویتی باقیمانده با ایمنی ارتقاءیافته[3] (SafeLight) را پیشنهاد کرده‌اند و از تکنیک‌های بهینه‌سازی چندگانه، مانند تابع اتلاف چندهدفه و شکل‌دهی پاداش برای ادغام بهتر دانش، استفاده کرده‌اند. بیشتر متون در مورداستفاده از روش‌های یادگیری تقویتی چندعاملی برای کنترل سیگنال‌های ترافیکی بر روی استفاده از روش‌های یادگیری چندعاملی Q و روش‌های کنترل مبتنی بر عمل گسسته متمرکز شده‌اند. شانموگاساندارام[4] و همکارش، کنترل سیگنال ترافیک را با استفاده از گرادیان‌های سیاست قطعی عمیق تأخیری چندعاملی[5] (MATD3) پیشنهاد کرده‌اند. استراتژی کنترل پیشنهادی با قرار دادن آن در معرض جریان‌های ترافیکی متغیر با زمان در شبیه‌سازی شبکه‌های جاده‌ای ایجادشده بر روی پلتفرم شبیه‌سازی ترافیک SUMO ارزیابی گردید و مشاهده شد که روش پیشنهادی در برابر انواع

مختلف جریان‌های ترافیکی پایدار عمل می‌کند و با کاهش قابل‌توجه میانگین تأخیر خودرو و طول صف، به‌طور مداوم از روش‌های موجود برتری دارد.

رن[6] و همکارانش، یک چارچوب کنترل پیش‌بینی کننده مدل سلسله مراتبی به‌صورت توزیع‌شده و قوی[7] (HD-RMPC) برای کنترل سیگنال ترافیکی[8] (TSC) شهری پیشنهاد داده‌اند. این چارچوب توزیع‌شده عملکرد بی‌درنگ کنترل پیش‌بینی کننده مدل[9] (MPC) را در شبکه‌های ترافیک شهری تضمین می‌کند. در لایه به‌روزرسانی سریع، یک مدل پیش‌بینی بهبودیافته را با مدل‌سازی صریح اختلال اتخاذ کرده‌اند و خطای پیش‌بینی را کاهش داده‌اند. از طریق بهینه‌سازی پیوسته و ناهمزمان نقطه تنظیم و مدل پیش‌بینی، چارچوب به‌طور قابل‌توجهی اثر کنترل را بهبود می‌بخشد. جیانگ[10] و همکارانش، چارچوبی برای اجرای رانندگی به‌صورت انرژی کارآمد در محیط کنترل سیگنال ترافیک تطبیقی پیشنهاد داده‌اند که با بهره‌گیری از الگوریتم یادگیری تقویتی مبتنی بر ارزش تحقق می‌یابد. پس از ارائه مدل کنترل بهینه، چارچوب از فرآیند تصمیم‌گیری مارکوف[11] (MDP) استفاده می‌کند تا به مسئله کنترل بهینه برسد. مکانیسم اشتراک‌گذاری وضعیت به‌وسیله نقلیه اجازه می‌دهد تا اطلاعات وضعیت عوامل سیگنال ترافیک را به دست آورد. تابع پاداش در MDP مصرف انرژی، تحرک ترافیک و راحتی رانندگی را در نظر می‌گیرد. نتایج شبیه‌سازی نشان می‌دهد که مصرف انرژی وسیله نقلیه کنترل‌شده را می‌توان با میزان متفاوتی از تحرک در مقایسه با مدل رانندگی دستی کاهش داد.

آرتیگا[12] و همکارانش، یک کنترل‌کننده سیگنال ترافیک تطبیقی مبتنی بر منطق فازی را پیشنهاد کرده‌اند که از نرخ جریان، بازیابی شده از شمارنده‌های ترافیک ساده، به‌عنوان یک نیاز ورودی منحصربه‌فرد استفاده می‌کند. کنترل‌کننده به‌صورت پویا مدت چرخه را با توجه به نرخ‌های جریان ورود محاسبه می‌کند و یک سیستم استنتاج فازی را اجرا می‌کند که توسط استدلال هدایت می‌شود. داس[13] و همکارانش، یک سیستم هماهنگی مبتنی بر اولویت را ارائه داده‌اند که رفتار ترجیحی را برای وسایل نقلیه‌ای که در امتداد یک مسیر هماهنگ حرکت می‌کنند ارائه می‌دهد. یک مدل برنامه‌ریزی خطی عدد صحیح مختلط برای در نظر گرفتن هماهنگی به‌عنوان شکلی از اولویت همراه با اولویت چندوجهی برای وسایل نقلیه واجد شرایط اضطراری، حمل‌ونقل و حمل‌ونقل بهبودیافته است و حفاظت از منطقه بحرانی را برای وسایل نقلیه باری در یک محیط حمل‌ونقل متصل فراهم می‌کند.

الشایب[14] و همکارانش، رویکردی را معرفی کرده‌اند که یک معیار جایگزین جدید برای مصرف سوخت، نرم‌افزار میکرو شبیه‌سازی ترافیک و یک الگوریتم ژنتیک تصادفی را برای بهینه‌سازی تأخیر ادغام می‌کند. این مطالعه همچنین تأثیر حضور وسایل نقلیه سنگین در ناوگان بر زمان سیگنال و صرفه‌جویی در مصرف سوخت را موردبررسی قرار داده است. زمان بهینه‌شده سیگنال، راه‌حل‌هایی را ارائه می‌دهد که هم مصرف سوخت و هم تحرک (گذردهی) را متعادل می‌کند. توسط لیو[15] و همکارانش، یک رویکرد کنترل مشترک که به‌طور هم‌زمان سیگنال‌های ترافیکی و مسیرهای گشت‌زنی خودروهای مشارکتی (اتوماتیک) را در تقاطع‌های شهری بهینه می‌کند، ارائه شده است. در رویکرد پیشنهادی، طول فاز سیگنال و شتاب‌های گشت‌زنی کنترل‌شده برای به حداکثر رساندن راحتی و به حداقل رساندن تأخیر سفر در چرخه سیگنال، مشروط به محدودیت‌های حرکت در سرعت‌ها، شتاب‌ها و اسلات‌های زمانی ایمن بهینه‌سازی شده‌اند. روش پیشنهادی با تکنیک برنامه‌ریزی خطی عدد صحیح مختلط[16] (MILP) پس از خطی‌سازی تابع هدف حل می‌شود. بر اساس نتایج شبیه‌سازی، مزایای روش پیشنهادی بر روی میانگین تأخیر سفر، گذردهی، مصرف سوخت با مقایسه با رویکرد پیشرفته بهینه‌سازی سیگنال اثبات می‌شود.

اتخاذ تکنیک‌های خودآموز در محیط‌های ترافیکی آینده مانند یادگیری تقویتی در حضور وسایل نقلیه متصل و خودکار[۱۷] (CAV)تا حد زیادی یک چالش باز باقی می‌ماند. معادی و همکارانش، یک کنترل سیگنال ترافیک تطبیقی مبتنی بر یادگیری تقویتی در زمان واقعی ایجاد کرده‌اند که یک طرح سیگنال را برای به حداقل رساندن طول صف کلی بهینه می‌کند و درعین‌حال بهCAV ها اجازه می‌دهد تا سرعت خود را بر اساس یک استراتژی زمان‌بندی ثابت برای کاهش تأخیر کلی تنظیم کنند. نکته برجسته این کار، ترکیب یک سیستم هدایت سرعت با یک کنترل سیگنال ترافیکی مبتنی بر یادگیری تقویتی است. چنگ[۱۸] و همکارانش، یک مدل بهینه‌سازی زمان‌بندی سیگنال ترافیک مبتنی بر شبیه‌سازی VISSIM با هدف پرداختن به مسائل ازدحام ترافیک شهری پیشنهاد داده‌اند. مدل پیشنهادی از مدل YOLO-X برای به دست آوردن اطلاعات جاده از داده‌های نظارت تصویری استفاده می‌کند و جریان ترافیک آینده را با استفاده از مدل حافظه کوتاه‌مدت طولانی[۱۹] (LSTM) پیش‌بینی می‌کند. مدل با استفاده از الگوریتم بهینه‌سازی مار[۲۰] (SO) بهینه شده است.

برای پرداختن به تغییرات روزانه در تقاضای ترافیک، شیرک[۲۱] و همکارانش، یک چارچوب جدید مبتنی بر سناریو آفلاین، به نام روش طرح مقاوم مبتنی بر فرا ابتکاری[۲۲] (MHRA) ارائه داده‌اند که یک طرح مقاوم در برابر تغییرات تقاضای تردد برای سیگنال‌های زمان ثابت را شناسایی می‌کند. روش MHRA شامل یک روش فرا ابتکاری است که زمان‌بندی سیگنال بهینه را برای سناریوهای مختلف تقاضا و هزینه‌های مربوطه برای یافتن یک راه‌حل قوی در نظر می‌گیرد. ژانگ[۲۳] و همکارانش، یک مسئله زمان‌بندی سیگنال ترافیک شهری چندهدفه را موردمطالعه قرار داده‌اند که به پارامتر زمان‌بندی سیگنال معقول تحت شرایط جریان ترافیک معین نیاز دارد تا ظرفیت ترافیک، تأخیر و شاخص انتشار آلاینده‌ها را در تقاطع‌ها در نظر بگیرد. به‌منظور به دست آوردن یک طرح زمان‌بندی سیگنال بهتر، این مقاله روش ترکیب استراتژی محدودیت ترکیبی[۲۴] و چارچوب NSGA-IIIرا معرفی می‌کند که به‌اختصار HCNSGA-III نامیده می‌شود. نتایج نشان می‌دهد که شاخص‌های ظرفیت ترافیک، تأخیر و انتشار آلاینده‌های به‌دست‌آمده با روش پیشنهادی وضعیت مطلوب‌تری دارند. روش ارائه‌شده توسط آن[۲۵] و همکارانش، الگوریتم الهام گرفته از گارا روفا[۲۶] (GRI) را معرفی می‌کند که برای بهینه‌سازی مدل کنترل سیگنال ترافیک با در نظر گرفتن تعداد وسایل نقلیه در یک صف استفاده می‌شود. GRI دارای ویژگی‌های استفاده از متغیرهای تصمیم کد به‌عنوان شیء عملیات، استفاده مستقیم از مقدار تابع هدف برای اطلاعات جستجو، استفاده هم‌زمان از چندین نقطه جستجو و استفاده از فناوری جستجوی احتمالی است. نتایج تجزیه‌وتحلیل نشان می‌دهد که GRI تعداد وسایل نقلیه موجود در صف را کاهش می‌دهد.

جدول ۱. مقایسه روش‌های زمان‌بندی سیگنال‌های ترافیکی

سال	تکنیک استفاده‌شده	پارامترهای ارزیابی
۲۰۲۳	یادگیری تقویتی بهبودیافته	نرخ برخورد، گذردهی
۲۰۲۲	یادگیری تقویتی چندعاملی	میانگین تأخیر خودروها و طول صف
۲۰۲۲	کنترل پیش‌بینی کننده مدل	تأخیر
۲۰۲۲	یادگیری تقویتی، تصمیم‌گیری مارکوف، روش بهینه‌سازی سیاست نزدیک به مبدأ	مصرف انرژی، میانگین ازدحام، مجموع زمان سفر
۲۰۲۲	منطق فازی	زمان انتظار، تراکم ترافیک[۲۷]

سال	تکنیک استفاده‌شده	پارامترهای ارزیابی
۲۰۲۳	برنامه‌ریزی خطی عدد صحیح مختلط	زمان سفر، طول سفر
۲۰۲۳	الگوریتم ژنتیک تصادفی	میزان سوخت مصرفی و میانگین تأخیر خودروها
۲۰۲۲	برنامه‌ریزی خطی عدد صحیح مختلط	تأخیر سفر، گذردهی، مصرف سوخت
۲۰۲۲	یادگیری تقویتی	مجموع تأخیر وسیله نقلیه، طول صف (شاخص PI)
۲۰۲۳	الگوریتم بهینه‌سازی مار و شبکه عصبی LSTM	میانگین تأخیر خودروها
۲۰۲۲	طرح مقاوم مبتنی بر فرا ابتکاری با استفاده از ماتریس تأخیر	میانگین تأخیر
۲۰۲۲	ترکیب محدودیت ترکیبی و NSGA-III	سرعت سفر، گذردهی ترافیک، تأخیر و میزان انتشار آلاینده‌ها
۲۰۲۲	گارا روفا (مدل مبتنی بر صف)	تعداد خودرو در صف، زمان سفر و گذردهی

۳. روش پژوهش

رشد سریع شهرها به تضاد جدی بین عرضه و تقاضای منابع جاده‌ای منجر شده و تقاطع‌ها به گلوگاه اصلی تراکم ترافیک تبدیل شده‌اند. به‌طورکلی، ظرفیت و تأخیر اغلب به‌عنوان شاخص‌هایی برای بهبود کارایی تقاطع استفاده می‌شود، اما شاخص‌های کمکی مانند آلایندگی وسایل نقلیه که به توسعه ترافیک پایدار کمک می‌کنند نیز باید در نظر گرفته شوند. یک طرح زمان‌بندی باید به‌گونه‌ای قوی باشد که نسبت به تغییرات تقاضا حساسیت کمتری داشته باشد و بتواند عملکرد تقریباً بهینه را در طول تقاضای ترافیک متغیر حفظ کند. در طرح پیشنهادی قصد داریم برای مدیریت فاز سبز سیگنال‌های ترافیکی در تقاطع‌ها از روش پیشنهادی به شرح زیر استفاده کنیم.

۱- پیش‌بینی الگوی حرکتی جامعه در سه مقطع جداگانه روزانه، هفتگی و ماهانه برای لحاظ کردن تغییرات تقاضای ترافیکی در برهه‌های مختلف روز و در روزهای مختلف هفته با لحاظ کردن مناسبت‌ها، عادات و مدل رفتاری افراد جامعه (روش شبکه عصبی خود رمزنگار)

۲- پیش‌بینی درصد ترافیک ورودی به هر لاین تقاطع بر اساس تخمین ترافیک خروجی از تقاطع‌های منتهی به تقاطع هدف بر اساس یک مدل چند گامی(سلسله مراتبی) با بهره‌گیری از شبکه عصبی کانالوشنی

۳- زمان‌بندی فاز سبز برای هر تقاطع به‌صورت سلسله مراتبی با بهره‌گیری از تکنیک فرا ابتکاری ترکیبی ژنتیک (GA) و عقاب طلایی[۲۸] (GEO) تحت عنوان GA-GEO و لحاظ کردن الگوی رفتار ترافیکی، وقوع رخدادهای خاص اجتماعی (همایش‌ها، نمایشگاه‌ها، مراسمات مذهبی، ...) و نرخ ترافیک تخمینی ورودی به تقاطع بر اساس تشخیص شبکه عصبی کانالوشنی

٤- به‌روزرسانی وزن اهمیت شاخص‌های تابع هدف در روش بهینه‌سازی با استفاده از روش یادگیری تقویتی

۵- اعمال تأثیر رخدادهای انسدادی (تصادف، تعمیرات و...) در زمان‌بندی نهایی

۳-۱ پیش‌بینی الگوی حرکتی جامعه در سه مقطع مجزا به‌صورت روزانه، هفتگی و ماهانه

در فاز اول این طرح می‌خواهیم با ثبت ترددهای صورت گرفته در هر تقاطع به کمک تعبیه تردد‌شمارها و تحلیل اطلاعات آن، یک تخمین از میزان تقاضای تردد در هر تقاطع در برهه‌های زمانی مختلف طول روز (ساعات خلوتی روز، ساعات شلوغی روز، ساعات خلوتی شب و ساعات شلوغی شب) به دست آوریم. درواقع می‌خواهیم بدانیم بر اساس نوع رفتار ترافیکی

مردم در طول روز، انتظار می‌رود در یک بازه زمانی مشخص (مثلاً ساعت ۰۷۰۰ تا ۰۷۳۰) چه میزان تقاضای تردد داشته باشیم. عوامل اثیر گذار متعددی در تغییرات تقاضای ترافیکی در برهه‌های مختلف زمانی وجود دارند مانند شروع کار ادارات و مدارس، بازگشایی کسب‌وکارها، مناسبت‌ها، عادات و مدل رفتاری افراد جامعه. ازآنجاکه اطلاعات به‌دست‌آمده به‌مثابه یک سری زمانی است که یک وابستگی زمانی بین مقادیر آن وجود دارد، بنابراین در طرح جاری از یک شبکه عصبی بازگشتی تحت عنوان شبکه عصبی خود رمزنگار[۲۹] (AE) استفاده خواهیم کرد که پیش‌بینی را بر اساس مقادیر قبلی تقاضای ترافیک در خطوط مختلف تقاطع‌ها انجام دهد.

خود رمزنگار یا رمزنگار خودکار (AE) به یکی از قدرتمندترین رویکردها برای ثبت ویژگی‌های اصلی داده‌ها تبدیل شده است. این ساختار نوعی شبکه عصبی برای وظایف یادگیری بدون نظارت است، خود رمزنگار به سیستم کمک می‌کند تا الگوی ترافیکی افراد را با یادگیری کارآمد رابطه غیرخطی بین ترددها و برهه‌های زمانی و رمزگذاری انتزاعات پیچیده در نمایش داده‌ها، بهتر درک کند (شکل ۱).

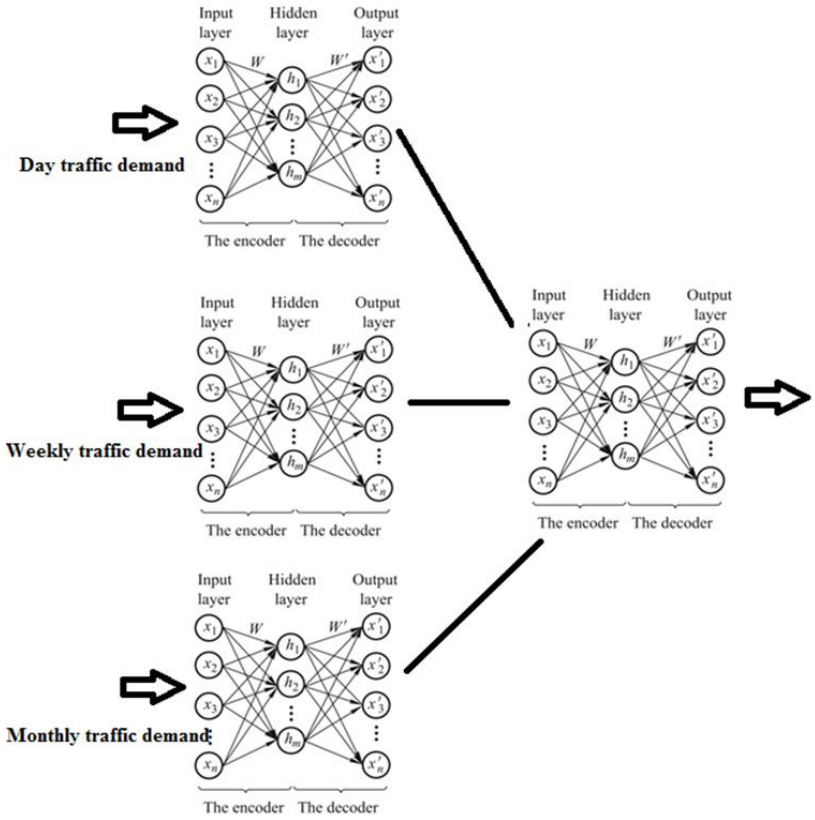

شکل ۱. ساختار شبکه سلسله مراتبی مبتنی بر اتوانکدر برای پیش‌بینی ترافیک ورودی هر تقاطع

اگر مقدار تخمینی سه شبکه AE موازی برای تخمین این سه مقدار به‌صورت V1، V2 و V3 باشد آنگاه در خود رمزنگار نهایی تصمیم‌گیری می‌شود که درنهایت چه ضرایبی از این سه متغیر ورودی به‌عنوان بایاس درنتیجه نهایی میزان تقاضای ترافیکی نهایی در آن تقاطع تأثیر خواهد داشت. به‌عبارت‌دیگر، مقدار نهایی تقاضای ترافیک تخمین زده‌شده به‌صورت رابطه زیر است که ضرایب آن بر اساس آموزش مدل شبکه عصبی تعیین می‌گردد.

$$V(i,j,t) = \alpha * V_1(i,j,t) + \beta * V_2(i,j,t) + \gamma * V_3(i,j,t) \quad (۱)$$

به‌طوری‌که $V(i,j,t)$ مقدار تقاضای تردد تخمین زده‌شده برای لاین i از تقاطع j در برهه زمانی t است.

۳-۲ تخمین درصد ترافیک ورودی بر اساس تخمین ترافیک خروجی از تقاطع‌های همجوار

در فاز دوم این طرح می‌خواهیم تأثیر میزان تردد در چندلایه قبلی منتهی به تقاطع کنونی را بر روی میزان درخواست تردد در تقاطع هدف بررسی کنیم. مدل ارائه‌شده در شکل ۲ را در نظر بگیرید. در این حالت ما برای به دست آوردن ترافیک ورودی به تقاطع هدف در مرکز دایره، ضرایبی را از هر لاین خروجی به تقاطع هدف در دو سطح level1 و Level2 در نظر می‌گیریم. ازآنجاکه تخمین کنونی، نیاز به حل یک معادله مرتبه ۲ از متغیرهای متعدد دارد لذا ترافیک خروجی هرکدام از ۲٤ خط تقاطع‌های هشتگانه منتهی به تقاطع هدف را به‌عنوان ۲٤ نورون ورودی به یک شبکه عصبی کانولوشنی در نظر می‌گیریم که می‌خواهد میزان ترافیک ورودی به هرکدام از ٤ خط تقاطع هدف را معین نماید (٤ نورون خروجی).

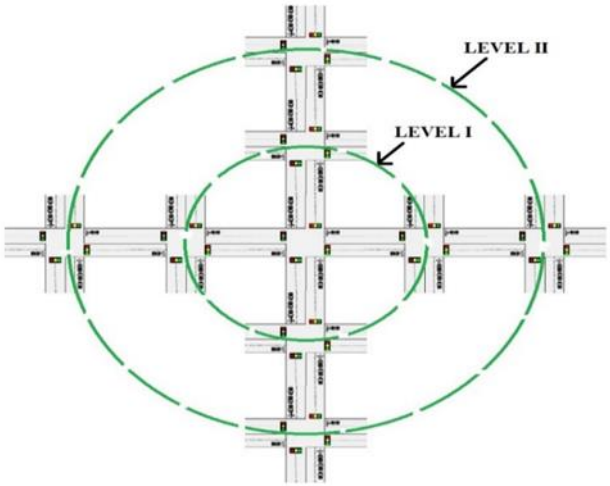

شکل ۲. انتخاب سطوح همگام‌سازی سیگنال‌های کنترلی به‌صورت سلسله مراتبی

شبکه عصبی کانولوشن در نظر گرفته‌شده جهت تخمین ترافیک ورودی تقاطع‌ها به‌صورت یک شبکه عصبی U-net است. U-Net یک شبکه عصبی کانولوشنی است که در بخش علوم کامپیوتر دانشگاه فرایبورگ توسعه یافته است. معماری U-Net از اصطلاح "شبکه کانولوشنی کامل[۳۰]" که توسط لانگ، شلهامر و دارل در سال ۲۰۱٤ پیشنهاد شد، سرچشمه می‌گیرد. ایده اصلی، تکمیل یک شبکه قراردادی معمول با لایه‌های متوالی است که در آن عملیات ادغام با اپراتورهای نمونه‌برداری جایگزین می‌شود. ازاین‌رو این لایه‌ها وضوح خروجی را افزایش می‌دهند. اثبات شده است که چنین شبکه‌ای را می‌توان به‌صورت سراسری برای داده‌های بسیار کمی آموزش داد. مقادیر داده‌های ترافیکی تقاطع‌ها در طول زمان برای ۲٤ نرون موجود در قالب یک ساختار ماتریسی (مانند یک تصویر) به شبکه U-net داده می‌شود (شکل ۳). بدین ترتیب به‌مرورزمان با تغییر تأثیر ترافیک تقاطع‌ها بر روی یکدیگر، این شبکه نیز با دادن داده‌های جدید آموزش داده می‌شود و وزن‌های خود را به‌روزرسانی می‌کند بدین ترتیب سیستم پیشنهادی در فاز تخمین ترافیک ورودی، کاملاً اصلاح‌پذیر است و می‌تواند خود را بر اساس رخدادهای ترافیکی مختلف سازگار کند.

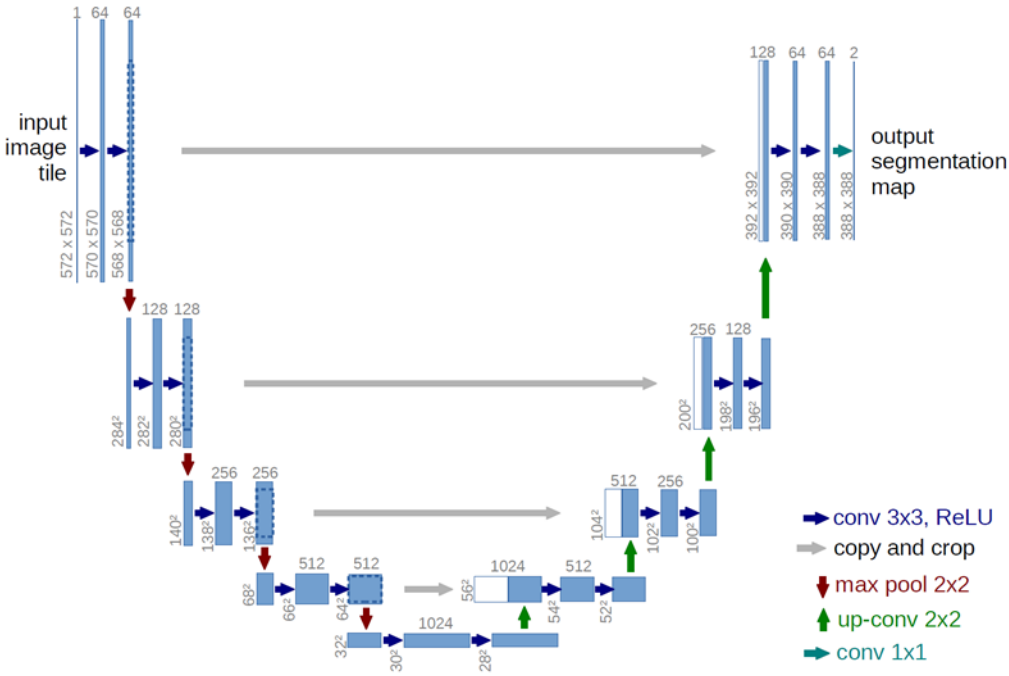

شکل ۳. معماری شبکه عصبی کانولوشنی U-Net برای تخمین

۳-۳ زمان‌بندی سیگنال‌های کنترلی با بهره‌گیری از تکنیک فرا ابتکاری ترکیبی GA-AVOA

در فاز سوم این طرح، مسئله زمان‌بندی سیگنال‌های کنترلی را به‌صورت یک مسئله بهینه‌سازی فرموله خواهیم کرد و در ادامه با استفاده از ترکیب دو روش فرا ابتکاری ژنتیک (GA) و عقاب طلایی (GEO) تحت عنوان GA-GEO زمان‌بندی فاز سبز برای هر تقاطع را تعیین خواهیم نمود. برای رسیدن به یک تابع هدف جدید و ارائه جواب بهینه مسئله، الگوی رفتار ترافیکی جامعه، وقوع رخدادهای خاص اجتماعی (همایش‌ها، نمایشگاه‌ها، مراسمات مذهبی، ...)، رخدادهای انسدادی (تصادف، تعمیرات و...) و نرخ ترافیک تخمینی ورودی به تقاطع بر اساس نرخ خروجی از تقاطع‌های قبلی را لحاظ خواهیم کرد.

فرض می‌کنیم تعداد k تقاطع در اختیار داریم بنابراین زمان‌بندی فاز سبز برای ٤*k خط تقاطع‌ها باید انجام شود. این متغیرها به‌عنوان متغیر مستقل به‌صورت GP در نظر می‌گیریم.

$$GP = \{gp_1, gp_2, .., gp_{4*k}\} \quad (۲)$$

از طرفی میزان ترافیک خروجی از هر تقاطع را در برهه‌های زمانی قبلی به‌صورت TH در اختیار داریم.

$$TH = \{th_1, th_2, .., th_{4*k}\} \quad (۳)$$

مقدار پیش‌بینی ترافیک عموم جامعه را برای خطوط مختلف تقاطع‌ها بر اساس خروجی خود رمزنگار به‌صورت SPR و مقدار مجموع تأثیر ترافیکی تقاطع‌های همجوار بر روی ترافیک هر خط از تقاطع‌ها را به‌صورت NPR در نظر می‌گیریم:

$$SPR = \{spr_1, spr_2, .., spr_{4*k}\} \quad (٤)$$

$$NPR = \{npr_1, npr_2, .., npr_{4*k}\} \quad (٥)$$

$$npr_i = \sum_{j=1}^{4*k} q(i,j) * thr(j, t-1) \quad (٦)$$

به‌طوری‌که $q(i,j)$ ضریب تأثیر تقاضای ترافیکی در خط j بر روی خط i در تقاطع هدف و $thr(j,t-1)$ میزان گذردهی تقاطع j بر اساس اطلاعات تردد‌شمارها در برهه زمانی گذشته است. اگر بخواهیم بر اساس فاز سبز تخصیصی به یک لاین و بر اساس ترافیک تخمین زده‌شده ورودی به یک لاین تقاطع (مجموع ترافیک تخمینی از الگوی تردد عمومی جامعه و میزان تأثیر تقاضای ترافیکی بر اساس میزان ترددها در

تقاطع‌های همجوار) مقدار زمان انتظار، طول صف (تعداد خودروهای باقیمانده در تقاطع) و گذردهی را تعیین کنیم از روابط زیر استفاده خواهیم کرد.

$$throughput(j,T) = \frac{(npr_j + spr_j + remain_{j,t-1})}{length(T)} \quad (۷)$$

به‌طوری‌که $length(T)$ مقدار زمان فاز سبز برای تقاطع j بر اساس زمان‌بندی بهینه پیشنهادی است. $remain_{j,t-1}$ مقدار خودرو باقیمانده در صف انتظار تقاطع برای خروج از فاز سبز قبلی است که در ابتدا برای هر تقاطع برابر صفر می‌گیریم.

$$exit(i,j) = \frac{(remain_{j,t})}{throughput(j,T)} * length(T) \quad (۸)$$

$$wait(i,j) = exit(i,j) - v(i,j) \quad (۹)$$

$$remain_{j,t} = (npr_j + spr_j + remain_{j,t-1}) - throughput(j,T) \quad (۱۰)$$

به‌طوری‌که $v(i,j)$ زمان ورود خودرو i به تقاطع j و قرار گرفتن در صف است. $wait(i,j)$ مدت‌زمان انتظار خودرو برای خروج از تقاطع و $remain_{j,t}$ طول صف پس از اجرای یک دور فاز سبز می‌باشد.

اگر بخواهیم میانگین زمان سفر را در تابع هدف در نظر بگیریم، چون زمان سفر، مجموع زمان انتظار خودرو زمان موردنیاز برای طی نمودن مسیر سفر است و مسیر تردد

$$idle_{j,t} = \begin{cases} length(T) * \left(1 - \left(\frac{throughput(j,T) - remain_{j,t}}{throughput(j,T)}\right)\right) & if \ \frac{(remain_{j,t})}{throughput(j,T)} < 1 \\ 0 & else \end{cases} \quad (۱۱)$$

از بین سه شاخص گذردهی، زمان انتظار و طول صف، چون شاخص اول دربرگیرنده دو شاخص دیگراست در تابع هدف از میزان گذردهی استفاده خواهیم کرد. به‌عبارت‌دیگر با افزایش گذردهی، طول صف کاهش و مدت‌زمان انتظار خودروها افزایش خواهد یافت.

تابع برازندگی به ازای چند دوره اجرای فاز سبز (مثلاً N بار) بررسی و ارزیابی گردد تا اثر تغییرات لحظه‌ای ترافیک در ارزیابی نهایی پنهان شود. بدین ترتیب مسئله زمان‌بندی خودروهای مختلف متفاوت است بنابراین نمی‌توانیم به ارزیابی درستی از میزان برازندگی راه‌حل‌های ارائه‌شده دست یابیم. شاخص‌هایی مانند رضایتمندی رانندگان، مصرف سوخت، انتشار آلاینده‌ها نیز متغیرهای وابسته به زمان سفر و زمان انتظار می‌باشند که مناسب‌تر این است که متغیر در سطوح اولیه را در تابع هدف قرار دهیم نه متغیرهای برآیند چند وضعیت مستقل. شاخص میانگین سرعت وسایل نقلیه نیز اگرچه از شاخص‌های ذکرشده در بالا مؤثرتر و نشان‌دهنده خوبی برای وضعیت تردد است اما وابسته به توقف‌های متعدد در طول سفر و نحوه رانندگی فرد است.

اگر زمان فاز سبز به‌قدری زیاد باشد که زمان لختی ایجاد شود و در برهه‌ای از زمان، هیچ خودرویی از تقاطع در زمان فاز سبز خروج نکند بهره‌وری سیستم زمان‌بندی کاهش خواهد یافت. اگر مدت این زمان خیلی کم باشد، به علت توقف‌های طولانی و زمان‌های مربوط به تغییر سیگنال ترافیکی، اختلال‌هایی در تردد رخ خواهد داد و نا رضایتمندی رانندگان را در پی خواهد داشت. بدین ترتیب از زمان بیکاری (به‌عنوان دوره زمانی که هیچ خودرویی در فاز سبز از تقاطع عبور نمی کند) در تابع هدف استفاده خواهیم کرد که به‌صورت زیر محاسبه می‌گردد:

سیگنال‌های کنترلی به‌صورت زیر فرموله می‌گردد که سعی داریم آن را تحت محدودیت‌های موجود بیشینه کنیم:

$$finess(sol_u) = \frac{\left(c_1 * \sum_{T=1}^{N} \sum_{j=1}^{4*k} throughput(j,T)\right)}{\left(c_2 * \sum_{T=1}^{N} \sum_{j=1}^{4*k} idle_{j,T}\right)} \quad (۱۲)$$

به‌طوری‌که ضرایب c_1 و c_2 ضرایب اهمیت شاخص‌های گذردهی و زمان بیکاری است.

هسته اصلی روش فرا ابتکاری عقاب طلایی برگرفته از هوش این عقاب در تنظیم سرعت در مراحل مختلف مسیر مار پیچش در هنگام شکار است. در مراحل ابتدایی آن‌ها بیشتر تمایلشان به گشتن و جستجوی طعمه است و بیشتر در مراحل پایانی تمایل به حمله دارند، درواقع یک عقاب طلایی این دو مؤلفه را طوری تنظیم می‌کند تا بتواند در کمترین زمان ممکن بهترین طعمه را در ناحیه موردنظر به دست آورد. این رفتار عقاب طلایی به‌صورت ریاضی مدل‌سازی شده است تا بتوان از آن برای اکتشاف (جستجوی طعمه) و بهره‌برداری (استثمار طعمه) در یک روش بهینه‌سازی سراسری استفاده کرد. در طرح پیشنهادی هر عقاب از جمعیت اولیه، یک راه‌حل بالقوه برای مسئله تعیین زمان‌بندی سیگنال کنترل ترافیک خواهد بود. این عقاب‌ها به‌صورت تصادفی در فضای مسئله ایجاد می‌شوند. بردار حمله برای عقاب طلایی i به‌صورت رابطه زیر محاسبه می‌شود:

$$\overrightarrow{A_\iota} = \overrightarrow{X_f} - \overrightarrow{X_\iota} \qquad (۱۳)$$

در این فرمول Ai بردار حمله عقاب i و Xf بهترین مکانی (طعمه) که تابه‌حال توسط عقاب f مشاهده شده است و Xi موقعیت فعلی عقاب i است. بردار اکتشاف بر اساس بردار حمله محاسبه می‌شود. درواقع بردار اکتشاف یک بردار مماس بر دایره و عمود بر بردار حمله است. اکتشاف را می‌توان به‌عنوان سرعت خطی عقاب طلایی نسبت به طعمه نیز در نظر گرفت. بردار اکتشاف در ابعاد n بعدی، در داخل ابر صفحه مماس بر دایره قرار دارد. جابجایی عقاب‌های طلایی شامل حمله و اکتشاف برای عقاب طلایی i در تکرار tام به‌صورت رابطه زیر نشان داده می‌شود:

$$\Delta x_i = r_1 p_a \frac{\overrightarrow{A_\iota}}{\|\overrightarrow{A_\iota}\|} + r_2 p_c \frac{\overrightarrow{C_\iota}}{\|\overrightarrow{C_\iota}\|} \qquad (۱۴)$$

که در این معادله p_a ضریب حمله و p_c ضریب اکتشاف در هر تکرار t است و تنظیم می‌کند که عقاب‌های طلایی چگونه تحت تأثیر حمله و اکتشاف قرار می‌گیرند. بردارهای r1 و r2 بردارهای تصادفی هستند که عناصر آن‌ها در بازه صفر و یک قرار دارند. $\|\overrightarrow{A_\iota}\|$ و $\|\overrightarrow{C_\iota}\|$ نرم اقلیدسی بردارهای attack و cruise هستند که با استفاده از معادلات زیر محاسبه می‌شوند.

$$\|\overrightarrow{A_\iota}\| = \sqrt{\sum_{j=1}^{n} a_j^2} \qquad (۱۵)$$

$$\|\overrightarrow{C_\iota}\| = \sqrt{\sum_{j=1}^{n} c_j^2} \qquad (۱۶)$$

موقعیت عقاب‌های طلایی در تکرار t + 1 به‌راحتی با افزودن بردار جابجایی به موقعیت فعلی در تکرار t محاسبه می‌شود:

$$x^{t+1} = x^t + \Delta x_i^t \qquad (۱۷)$$

در طرح پیشنهادی برای ایجاد زمان‌بندی بهینه سیگنال‌های ترافیکی، برخلاف روش پایه عقاب طلایی، پس از به دست آمدن جواب جدید از مکان بهترین تجربه عقاب f، از عملگرهای ترکیب و جهش روش ژنتیک بر روی جواب جدید تولیدشده x^{t+1} و بهترین جواب مسئله در دور جاری (مکان عقاب f)، استفاده خواهیم کرد. بدین ترتیب از قابلیت‌های هر دو الگوریتم در یک روش بهینه‌سازی یکپارچه بهره خواهیم برد. بر اساس عملگر ترکیب، کروموزوم‌ها دوبه‌دو با هم ترکیب می‌شوند (شکل ٤). در ادامه بر اساس عملگر جهش، بخشی از کروموزوم‌ها با در نظر گرفتن نرخ جهش برای جهش در کروموزوم‌ها انتخاب می‌شود. سپس بر اساس الگوی جهش پیشنهادی، تغییر موردنظر در کروموزوم اعمال گردیده و بدین ترتیب، کروموزوم جدیدی به جمعیت اضافه می‌گردد (شکل۵).

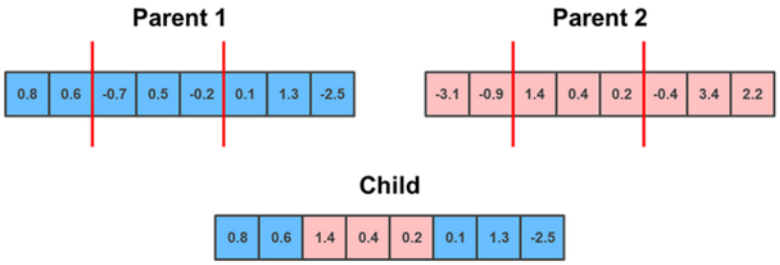

شکل ٤. فرآیند ترکیب در الگوریتم بهینه‌سازی ژنتیک

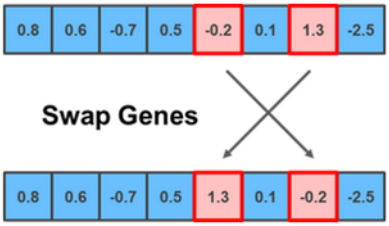

شکل ٥. فرآیند جهش در الگوریتم بهینه‌سازی ژنتیک

هر راه‌حل در روش بهینه‌سازی معادل مقدار زمان برهه سبز چراغ‌های راهنمایی و رانندگی برای عبور خودروها در آن لاین است. به‌عنوان نمونه برای ٤ تقاطع، یک راه‌حل به‌صورت جدول زیر خواهیم داشت.

جدول ۲. ساختار یک نمونه راه‌حل در طرح پیشنهادی

تقاطع	تقاطع ۱				تقاطع ۲				تقاطع ۳				تقاطع ٤			
زمان فاز سبز	۳۰	۲۵	٤٥	۲۰	٤٥	٤٥	۱۵	۱۵	۳۰	۳۰	۱۵	٤٥	۳۰	۳۰	۳۰	۳۰

٤-۳ به‌روزرسانی وزن شاخص‌های تابع هدف روش بهینه‌سازی با استفاده از یادگیری تقویتی

اینکه مقدار اهمیت کدام شاخص بیشتر است و آیا این ضرایب اهمیت باید مقادیر ثابتی داشته باشند یا به‌صورت مقادیر اصلاح شونده و سازگار با تغییر تقاضاهای ترافیکی باشد خود یک جنبه تحقیقاتی باز است که به مطالعات آتی موکول خواهد شد؛ اما در طرح جاری می‌خواهیم مقدار اهمیت ضرایب به‌صورت متغیر بر اساس یادگیری تقویتی[۳۱]، (اخذ بازخورد از افزایش یا کاهش مقدار ضریب اهمیت پارامتر در تابع هدف) تعیین گردد. در فاز چهارم این طرح به‌روزرسانی وزن اهمیت شاخص‌های تابع هدف در روش بهینه‌سازی با استفاده از روش یادگیری تقویتی تعیین می‌گردد. با پایش میزان ازدحام (طول صف) خواهیم توانست، زمان‌بندی بهینه را متناسب با تقاضاهای ترافیکی تغییر دهیم. پارامتر تأثیرگذار در سمت خودروها که می‌توان از روی مقادیر آن، وضعیت وقوع ازدحام را در یک تقاطع برآورد طول صف است. در طرح پیشنهادی، تغییر ضریب اهمیت پارامترهای گذردهی و زمان بیکاری، با محاسبه تغییرات طول صف به‌صورت زیر تعیین می‌گردد:

$$RWD_t(i) = \frac{PL^i_{t-1} - PL^i_t}{\max(PL^i_t,\ PL^i_{t-1})} \qquad (۱۸)$$

متغیرهای PL^i_t و PL^i_{t-1} به ترتیب نشان‌دهنده طول صف در لحظه $\mathbf{i}$ و لحظه ماقبل آن است. $RWD_t(i)$ نیز میزان پاداش حاصل از تغییر ضرایب اهمیت در تابع هدف روش بهینه‌سازی است. طبق فرمول زیر ضریب اهمیت پارامتر تغییر داده‌شده در برهه زمانی قبلی، به‌روزرسانی می‌گردد.

$$q^i_{t+1} = q^i_t * \left(1 + RWD_t(i)\right) \qquad (۱۹)$$

q_t^i مقدار ضریب اهمیت شاخص متناظر در زمان t و q_{t+1}^i مقدار اهمیت شاخص در برهه زمانی بعدی است. مقدار RWD عددی در بازه [-1,1] است.

۳-۵ اعمال تأثیر رخدادهای انسدادی در زمان‌بندی نهایی

وقوع رخداد انسدادی مثل تصادفات، خرابی خودروها یا اقدامات تعمیر و بازسازی جاده‌ها، در یک لاین منتهی به تقاطع یا خروجی از آن به‌مرورزمان باعث برهم‌نهی ازدحام می‌گردد. اگر میزان فاز سبز تقاطع‌ها را طوری تنظیم کنیم که تا یک بازه زمانی مشخص پس از وقوع رخداد (مثلاً ۳۰ دقیقه)، از حجم تردد ورودی به یک جاده کاهش یابد، باعث کاستن از فشار ازدحام و تصمیم مردم به تغییر مسیر قبل از رسیدن به محل وقوع می‌گردد. این امر همچنین در رانندگی ایمن با توجه به سوابق بروز تصادفات متوالی در مسیرهای دچار نقص یا حادثه نیز نقش بسزایی خواهد داشت. در طرح جاری با داشتن گزارش وقوع رخداد انسدادی تا یک برهه زمانی m دقیقه‌ای، یک شاخص کاهنده را تحت عنوان con در زمان‌بندی نهایی لحاظ خواهیم کرد.

$$Con_{j,t} = \begin{cases} 0.12 & if\ there\ are\ constraint\ event\ in\ j\ lane \\ 0 & else \end{cases} \quad (۲۰)$$

بدین ترتیب فاز سبز هر تقاطع به‌صورت رابطه زیر محاسبه می‌گردد.

$$TOD_u(j,T) = sol_u(j,T) * (1 - Con_{j,t}) \quad (۲۱)$$

به‌طوری‌که $sol_u(j,T)$ زمان‌بندی فاز سبز بهینه برای تقاطع j در برهه زمانی T است.

٤. تحلیل داده‌ها

برای مقایسه عملکرد طرح پیشنهادی با روش‌های برجسته موجود از سه روش مبتنی بر منطق فازی سازگار شونده و زمان‌بندی سیگنال‌های ترافیکی مبتنی بر NSGA-III و روش زمان‌بندی سیگنال GRI، استفاده کرده‌ایم. پارامترهای ارزیابی شامل میانگین گذردهی تقاطع‌ها، زمان انتظار خودروها (تأخیر) و زمان بیکاری است. برای شبیه‌سازی از محیط matlab R2019 استفاده شده است. در طرح جاری یک منطقه شهری با ۹ تقاطع در نظر گرفته شده است که در هر تقاطع زمان فاز سبز مستقل به ازای هر سمت (توقفگاه) در نظر گرفته می‌شود به‌عبارت‌دیگر هیچ دو لاین مقابل هم به‌صورت همزمان از تقاطع عبور نمی‌کنند. با بررسی آمارهای موجود در خصوص میانگین میزان ترددهای ثبت‌شده به این ناحیه توسط دستگاه‌های ترددشمار، به ورودی این منطقه شهری یک ترافیک با توزیع نمایی با میانگین ٤٠ خودرو در دقیقه تخصیص داده می‌شود. شبیه‌سازی در مدت ۲۰ فاز سبز برای تمام تقاطع‌ها انجام شده است. مجموع زمان یک فاز سبز برای یک تقاطع با چهار لاین به‌صورت ثابت برابر ۱۲۰ ثانیه است. تعداد خودروهای ورودی درمجموع تعداد ۱۰۰۰ خودرو است که در سناریوهای مختلف برای بررسی تأثیر تعداد خودرو بر متغیرهای ارزیابی عملکرد، مقدار آن از ۲۰۰ خودرو تا ۱۰۰۰ خودرو تغییر داده شده است.

یکی از مهم‌ترین پارامترهای ارزیابی عملکرد، گذردهی تقاطع‌ها است. باید سعی کنیم زمان‌بندی به صورتی باشد که درمجموع از تقاطع‌ها، خودرو بیشتری عبور نماید. نتایج شبیه‌سازی در شکل ٦ نشان می‌دهد که میزان گذردهی تقاطع‌های موردبررسی با استفاده از زمان‌بندی فاز سبز پیشنهادی، بیشتر از این مقدار در طرح‌های پایه است به‌طوری‌که حداقل ۱۰ درصد و حداکثر ۲۸ درصد بهبود داشته است. علت این بهبود ارائه زمان‌بندی سیگنال کنترلی بر اساس پیش‌بینی بار ترافیکی ورودی و سازگاری طرح با تغییرات تقاضاهای ترافیکی است.

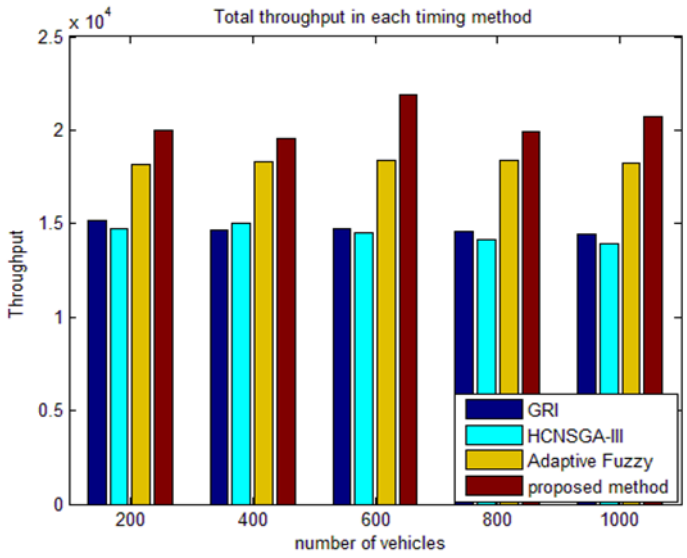

شکل ٦. مقایسه مجموع گذردهی تقاطع‌ها در روش‌های مختلف زمان‌بندی سیگنال ترافیکی

زمان بیکاری به زمانی اتلاق می‌شود که چراغ یک خط سبز بوده اما وسیله نقلیه‌ای در صف انتظار عبور از چهارراه وجود ندارد. بدین ترتیب می‌توان زمان بیکاری را به‌صورت ظرفیت انتقال از دست داده‌شده در نظر گرفت. باید زمان‌بندی را به‌گونه‌ای انجام دهیم که این زمان بیکاری حداقل شود. مطمئناً اگر زمان بیکاری یک خط از یک تقاطع زیاد باشد و در خط دیگری از همان تقاطع انبوهی از خودروها منتظر سبز شدن چراغ باشند، زمان‌بندی مناسب و بهینه نبوده است. همان‌گونه که در شکل ۷ می‌بینیم، مجموع زمان بیکاری تمام تقاطع‌ها در طرح پیشنهادی کمتر از طرح‌های پایه است که نشان‌دهنده و بهره‌گیری بهینه از زمان فاز سبز در تقاطع‌ها است. علت بهبود جاری قدرت روش بهینه‌سازی ترکیبی برای استخراج زمان بندی بهینه بر مبنای شاخص‌های مؤثر مانند زمان بیکاری و گذردهی است.

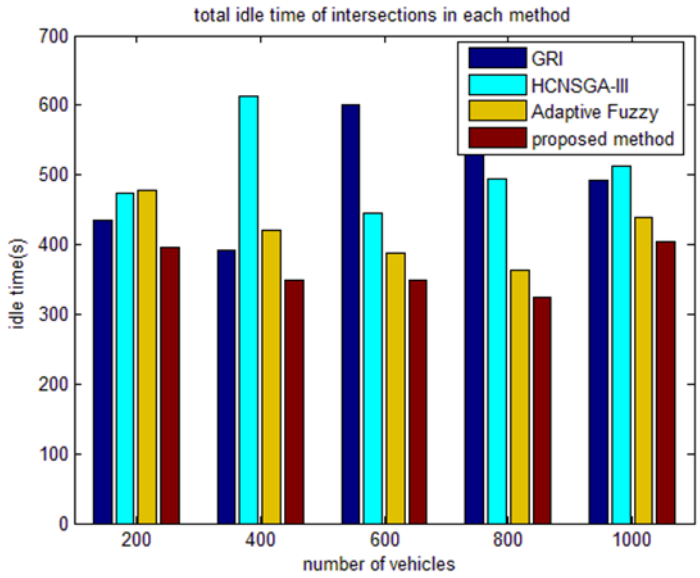

شکل ۷. مقایسه مجموع زمان بیکاری تقاطع‌ها در روش‌های مختلف زمان‌بندی سیگنال ترافیکی

درنهایت مجموع زمان انتظار خودروها را تحت عنوان تأخیر در طرح خود با طرح‌های پایه مقایسه نمودیم. با ورود ترافیک به منطقه تحت شبیه‌سازی و پر شدن صف انتظار در تقاطع‌ها، به‌مرورزمان میزان زمان انتظار خودروها افزایش می‌یابد. در شکل ۸ می‌بینیم که همواره مقدار تأخیر در طرح پیشنهادی کمتر از طرح‌های پایه است به‌طوری‌که بین ٦ تا ۱۹ درصد بهبود داشته است؛ بنابراین توانستیم با پیش‌بینی ترافیک ورودی از سایر تقاطع‌ها و به‌کارگیری روش فرا ابتکاری ترکیبی GA-GEO، زمان‌بندی مناسبی برای فاز سبز ارائه کنیم.

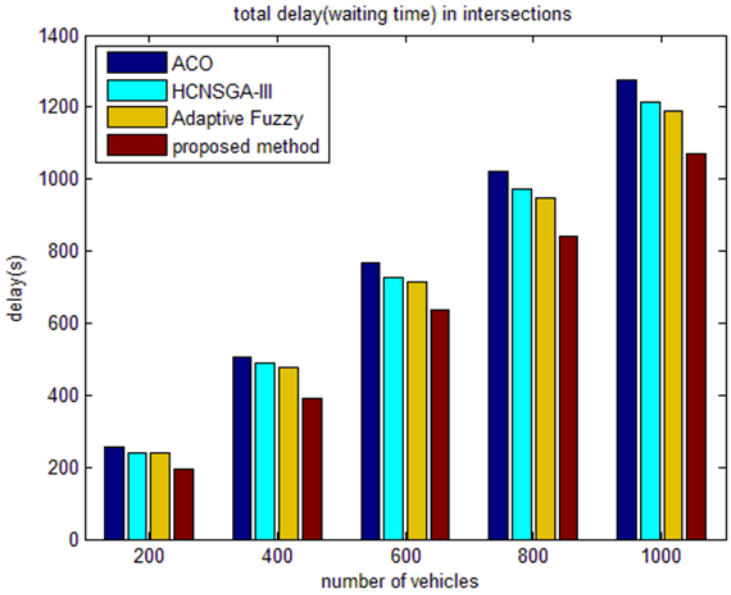

شکل ۸. مقایسه مجموع تأخیر تقاطع‌ها در روش‌های مختلف زمان‌بندی سیگنال ترافیکی

۵. نتیجه‌گیری

چراغ‌های راهنمایی در شبکه‌های جاده‌ای برای کنترل جریان ترافیک در تقاطع‌ها نصب و استفاده می‌شود. این چراغ‌ها با زمان‌بندی چراغ سبز در درجه اول برای افزایش امنیت وسایل نقلیه و سرنشینان آن در زمان عبور از تقاطع‌ها استفاده می‌شود. با ادامه رشد سریع مناطق شهری، مشکلاتی مانند تراکم ترافیک و آلودگی محیط‌زیست به‌طور فزاینده‌ای رایج شده است. کاهش این مشکلات مستلزم پرداختن به بهینه‌سازی و زمان‌بندی سیگنال‌های کنترلی است که اجزای حیاتی مدیریت ترافیک شهری هستند. نتایج به‌کارگیری طرح جاری شامل موارد ذیل است:

- افزایش گذردهی تقاطع‌ها با استفاده بهینه‌سازی زمان فاز سبز خطوط چهارگانه تقاطع‌ها
- کاهش زمان انتظار خودروهای موجود در تقاطع‌ها
- کاهش زمان بیکاری
- کاهش مصرف سوخت و انتشار آلاینده‌های محیطی با کاهش مجموع زمان سفر
- متعادل‌سازی تردد در لاین‌های مختلف تقاطع‌ها با زمان‌بندی فاز سبز بر اساس رخدادهای انسدادی

در این طرح، یک روش زمان‌بندی سیگنال‌های ترافیکی ارائه گردید. برای این هدف، با استفاده از شبکه عصبی خود رمزنگار (AE)، الگوی ترافیکی جامعه بر اساس تقاضاهای تردد در سطوح روزانه، هفتگی و ماهانه و با لحاظ کردن مناسبت‌ها و وقوع رخدادهای خاص اجتماعی پیش‌بینی گردید. در ادامه با بهره‌گیری از شبکه عصبی U-net به تخمین ترافیک ورودی به یک تقاطع بر اساس ترافیک خروجی از تقاطع‌های همجوار پرداخته شد. پس از فرموله سازی مسئله زمان‌بندی سیگنال

ترافیکی به‌عنوان یک مسئله بهینه‌سازی، زمان‌بندی بهینه فازهای سبز چراغ‌های راهنمایی و رانندگی با استفاده از ترکیب تکنیک‌های فرا ابتکاری ژنتیک (GA) و عقاب طلایی (GEO) محاسبه گردید. همچنین با استفاده از روش یادگیری تقویتی، وزن اهمیت شاخص‌های تابع هدف روش بهینه‌سازی به‌روزرسانی شد. درنهایت اثر وقوع رخدادهای انسدادی (تصادف، تعمیرات و...) در زمان‌بندی نهایی اعمال گردید.

ارزیابی عملکرد روش پیشنهادی، با مقایسه مقدار شاخص‌های گذردهی، زمان انتظار (تأخیر) و زمان بیکاری با سه روش جدید برجسته در ادبیات تحقیق انجام شد. بر اساس نتایج به‌دست‌آمده، طرح پیشنهادی به بهبود قابل‌توجهی در شاخص‌های ارزیابی دست یافته است و توانسته با بهره‌گیری از قدرت پیش‌بینی شبکه‌های عصبی بازگشتی، مدل‌های محاسباتی و تکنیک‌های یادگیری ماشین و روش‌های بهینه‌سازی، گذردهی تقاطع‌ها را با زمان‌بندی فاز سبز مناسب برای هر خط تقاطع، افزایش دهد و ضمن کاهش زمان انتظار خودروها در صف عبور از تقاطع، با کاهش زمان بیکاری، بهره‌وری فاز سبز را افزایش دهد.

در تحقیقات بعدی قصد داریم، با اعمال تکنیک‌های پردازش تصویر مناسب برای ثبت ترددهای انجام‌شده و ردگیری مسیر حرکت خودروها بر اساس شماره پلاک، با دقت بالاتری به پیش‌بینی نرخ ورودی به هر تقاطع بر اساس ترددهای تقاطع های همجوار بپردازیم. به‌طوری‌که مشخص باشد اگر در بخشی از شهر هوشمند موردمطالعه، تقاضاهای ترافیک برای عبور از یک تقاطع افزایش یافت، تمام تقاطع‌های همجوار، زمان‌بندی سیگنال خود را برای سازگاری با این بار ترافیکی و در حداقل زمان ممکن به‌روزرسانی نمایند.

٦. پی‌نوشت‌ها

1. Traffic congestion
2. Du
3. Safety-enhanced residual reinforcement learning method
4. Shanmugasundaram
5. Multi-agent Twin Delayed Deep Deterministic policy Gradients
6. Ren
7. Hierarchical, distributed, and robust model predictive control
8. Traffic signal control
9. Model predictive control
10. Jiang
11. Markov Decision Process
12. Arteaga
13. Das
14. Alshayeb
15. Liu
16. Mixed integer linear programming
17. Connected and automated vehicles
18. Cheng
19. Long short-term memory
20. Snake optimization
21. Shirke
22. Metaheuristic Robust plan Approach
23. Zhang
24. Hybrid constraint strategy
25. An
26. Garra Rufa
27. Traffic density
28. Golden eagle optimization
29. Autoencoder
30. Fully convolutional network
31. Reinforcement learning

۷. مراجع

– M. Eom, BI. Kim, 2020, The traffic signal control problem for intersections: a review. European transport research review, 12, pages 1-20.

– S. S. S. M. Qadri, M. A. Gökçe, E. Öner, 2020, State-of-art review of traffic signal control methods: challenges and opportunities. European transport research review, 12, pages 1-23.

– N. Dobrota, N. Mitrovic, S. Gavric, & A. Stevanovic, 2022. Comprehensive data

Proceedings of the AAAI conference on artificial intelligence. 37(12), pages 14801-14810.

– P. Shanmugasundaram, S. Bhatnagar, 2022. Robust Traffic Signal Timing Control using Multiagent Twin Delayed Deep Deterministic Policy Gradients. In ICAART (2), pages 477-485.

– Y. Ren, et.al, 2022. HD-RMPC: A Hierarchical Distributed and Robust Model Predictive Control Framework for Urban Traffic Signal Timing. Journal of Advanced Transportation.

– X. Jiang, J. Zhang, B. Wang, 2022. Energy-efficient driving for adaptive traffic signal control environment via explainable reinforcement learning. Applied Sciences, 12(11), 5380.

– D. Das, N. V. Altekar, & K. L. Head, 2023. Priority-based traffic signal coordination system with multi-modal priority and vehicle actuation in a connected vehicle environment. Transportation research record, 03611981221134627.

– S. Alshayeb, A. Stevanovic, J. Stevanovic, N. Dobrota, 2023. Optimizing of Traffic-Signal Timing Based on the FCIC-PI—A Surrogate Measure for Fuel Consumption. Future Transportation, 3(2), pages 663-683.

– M. Liu, J. Zhao, S. Hoogendoorn, M. Wang, 2022. A single-layer approach for joint optimization of traffic signals and cooperative vehicle trajectories at isolated intersections. Transportation research part C: emerging technologies, 134, 103459.

– S. Maadi, S. Stein, J. Hong, R. Murray-Smith, 2022. Real-time adaptive traffic signal control in a connected and automated vehicle analysis approach for appropriate scheduling of signal timing plans. Future transportation, 2(2), pages 482-500.

– S. Alshayeb, A. Stevanovic, N. Mitrovic, E. Espino, 2022. Traffic Signal Optimization to Improve Sustainability: A Literature Review. Energies, 15(22), 8452.

– V. M. Madrigal Arteaga, J. R. Pérez Cruz, A. Hurtado-Beltrán, & J. Trumpold, 2022. Efficient Intersection Management Based on an Adaptive Fuzzy-Logic Traffic Signal. Applied Sciences, 12(12), 6024.

– M. Aslani, M.S. Mesgari, M. Wiering, 2017. Adaptive traffic signal control with actor-critic methods in a real-world traffic network with different traffic disruption events. Transportation Research Part C: Emerging Technologies 85, pages 732-752.

– L. Jiang, Y. Li, Y. Liu, C. Chen, 2017. Traffic signal light control model based on evolutionary programming algorithm optimization BP neural network. In Proceedings of the 2017 7th IEEE International Conference on Electronics Information and Emergency Communication (ICEIEC), Macau, China, 21–23 July 2017; pages 564–567.

– H. Ge, Y. Song, C. Wu, J. Ren, G. Tan, 2019. Cooperative Deep Q-Learning with Q-Value Transfer for Multi-Intersection Signal Control. IEEE Access 2019, 7, pages 40797–40809.

– Y.C. Chiou, Y.F. Huang, 2013. Stepwise genetic fuzzy logic signal control under mixed traffic conditions. Journal of advanced transportation, 47(1), pages 43-60.

– W. Du, et.al, 2023. Safelight: A reinforcement learning method toward collision-free traffic signal control. In

environment: optimisation of signal planning with reinforcement learning under vehicle speed guidance. Sensors, 22(19), 7501.

– R. Cheng, Z. Qiao, J. Li, J. Huang, 2023. Traffic signal timing optimization model based on video surveillance data and snake optimization algorithm. Sensors, 23(11), 5157.

– C. Shirke, N. Sabar, E. Chung, A. Bhaskar, 2022. Metaheuristic approach for designing robust traffic signal timings to effectively serve varying traffic demand. Journal of Intelligent Transportation Systems, 26(3), pages 343-355.

– X. Zhang, et.al, 2022. Intersection signal timing optimization: A multi-objective evolutionary algorithm. Sustainability, 14(3), 1506.

– H. K. An, et.al, 2022. Optimized Intersection Signal Timing: An Intelligent Approach-Based Study for Sustainable Models. Sustainability, 14(18), 11422.

– O. Ronneberger, P. Fischer, T. Brox, 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation. In Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III 18, pages 234-241.

– E. Shelhamer, J. Long, T. Darrell, 2014. Fully Convolutional Networks for Semantic Segmentation. IEEE Transactions on Pattern Analysis and Machine Intelligence. 39 (4), pages 640–651.

– Mohammadi-Balani, M. D. Nayeri, A. Azar, M. Taghizadeh-Yazdi, 2021. Golden eagle optimizer: A nature-inspired metaheuristic algorithm. Computers & Industrial Engineering, 152, 107050.