

## پیش‌بینی مکانی-زمانی ترافیک با استفاده از شبکه‌های عصبی گرافی و واحد بازگشتی دروازه‌ای با رویکرد ساختار مکانی شبکه

فاطمه نوری الموتی<sup>۱\*</sup>، محمد سعدی مسگری<sup>۲</sup>

۱- دانشجوی دکتری سیستم اطلاعات مکانی، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی  
۲- دانشیار گروه سیستم اطلاعات مکانی، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی

تاریخ دریافت مقاله: ۱۴۰۴/۱۰/۲۱ تاریخ پذیرش مقاله: ۱۴۰۵/۰۲/۲۶

### چکیده

مدیریت بهینه ترافیک شهری مستلزم پیش‌بینی دقیق و به‌هنگام وضعیت ترافیکی معابر در مقیاس مکانی - زمانی است، زیرا الگوهای تراکم ترافیکی در شبکه معابر شهری تحت تأثیر تعاملات پیچیده مکانی بین خیابان‌ها و پویایی‌های زمانی کوتاه‌مدت و بلندمدت قرار دارند. از این رو، توسعه چارچوب‌هایی که قادر به استخراج هم‌زمان وابستگی‌های مکانی و زمانی باشند، نقشی کلیدی در پیش‌بینی ترافیک و پشتیبانی از تصمیم‌سازی شهری ایفا می‌کند. در این پژوهش، یک چارچوب ترکیبی مکانی - زمانی مبتنی بر شبکه‌های عصبی گرافی (GNN) و واحد بازگشتی دروازه‌ای (GRU) برای پیش‌بینی کلاس‌های ترافیکی ارائه می‌شود. داده‌های مورد استفاده شامل شبکه معابر چهار منطقه شهر تهران و وضعیت ترافیکی ۵۰۳۷ قطعه خیابان در بازه‌های زمانی ۱۵ دقیقه‌ای طی یک دوره سه‌ماهه است. شبکه معابر به‌صورت یک گراف جهت‌دار مدل‌سازی شده و به‌عنوان ورودی به شبکه عصبی گرافی در نظر گرفته شده است. به‌منظور تقویت مدل‌سازی مکانی، علاوه بر ماتریس همسایگی مرتبه اول، همسایگی مرتبه دوم و شاخص‌های ساختاری شبکه شامل بینابینی، نزدیکی و درجه وزنی به‌صورت صریح در فرآیند یادگیری گرافی ادغام شده‌اند. شبکه عصبی گرافی، روابط مکانی و تعاملات ساختاری بین معابر را استخراج کرده و خروجی آن به‌همراه دنباله‌های زمانی وضعیت ترافیکی، به واحد بازگشتی GRU منتقل می‌شود تا پیش‌بینی در افق‌های زمانی ۱۵، ۳۰ و ۶۰ دقیقه‌ای انجام گیرد. نتایج تجربی نشان می‌دهد مدل پیشنهادی (Enhanced GNN-GRU) در تمامی افق‌های پیش‌بینی عملکرد بهتری نسبت به مدل‌های پایه LSTM، GRU و GNN ارائه می‌دهد. به‌طور مشخص، مقدار دقت (ACC) مدل Enhanced GNN-GRU در افق ۱۵ دقیقه به ۰.۷۶ و مقدار امتیاز FI به ۰.۶۷ رسیده است که در مقایسه با مدل پایه GNN-GRU بهبود معناداری را نشان می‌دهد. این بهبود در افق‌های زمانی بلندتر نیز به‌صورت پایدار حفظ شده است. نتایج به‌دست‌آمده نشان می‌دهد که ادغام صریح همسایگی چندمرتب‌ه‌ای و شاخص‌های ساختاری شبکه، موجب تقویت مدل‌سازی مکانی، بهبود تمایز بین کلاس‌های مختلف تراکم و افزایش پایداری پیش‌بینی در افق‌های زمانی بلندتر می‌شود و نقش ساختار مکانی شبکه معابر را به‌عنوان یک مؤلفه کلیدی در مدل‌سازی و پیش‌بینی ترافیک شهری برجسته می‌سازد.

**کلیدواژه‌ها:** پیش‌بینی ترافیک، مدل‌های مکانی-زمانی، ساختار مکانی شبکه، شبکه‌های عصبی گرافی، واحدهای بازگشتی

\* نویسنده مکاتبه‌کننده: تهران، خیابان ولیعصر، بالاتر از میدان ونک، تقاطع میرداماد، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی.

تلفن: ۰۹۱۲۷۸۹۳۸۹۸

## ۱- مقدمه

رشد شتابان شهرنشینی، افزایش مستمر تقاضای سفر، پیچیدگی‌های ساختاری معابر و محدودیت ظرفیت زیرساخت‌های حمل‌ونقل، مدیریت ترافیک شهری را به یکی از چالش‌های راهبردی و محورهای اصلی پژوهش در حوزه سیستم‌های حمل‌ونقل هوشمند تبدیل کرده است. رفتار ترافیکی جاری بر روی شبکه معابر شهری، که به‌عنوان ستون فقرات جابه‌جایی در کلان‌شهرها عمل می‌کند، ماهیتی پویا، پیچیده و وابسته به شرایط مکانی - زمانی دارد و تحت تأثیر مجموعه‌ای گسترده از عوامل درونی و بیرونی قرار می‌گیرد. چنین پویایی چندلایه سبب می‌شود که نوسانات ترافیک به‌صورت شبکه‌ای و در بازه‌های زمانی کوتاه مدت و بلند مدت رخ دهد، به‌گونه‌ای که تغییر وضعیت یک معبر می‌تواند اثرات سرائیتی قابل توجهی بر معابر مجاور داشته باشد. در این چارچوب پیچیده، پیش‌بینی دقیق و بلادرنگ وضعیت آینده ترافیک نه‌تنها یک نیاز عملیاتی برای مدیریت جریان، کنترل تطبیقی سیگنال‌ها، تخصیص منابع و بهینه‌سازی مسیر است، بلکه ضرورتی علمی برای کاهش زمان سفر، افزایش بهره‌وری شبکه و کاهش اثرات منفی زیست‌محیطی به‌شمار می‌آید.

[۱ و ۲]

با وجود پیشرفت‌های قابل توجه در حوزه مدل‌های پیش‌بینی ترافیک، طیف وسیعی از روش‌های کلاسیک (از مدل‌های سری زمانی خطی گرفته تا رویکردهای متعارف یادگیری ماشین) در مواجهه با ماهیت پیچیده، غیرخطی و مکان محور جریان ترافیک با محدودیت‌های بنیادی روبرو هستند. این مدل‌ها معمولاً قادر به مدل‌سازی وابستگی‌های چندلایه و بلندمدت زمانی نبوده و از مدل‌سازی دقیق ویژگی‌های ساختاری شبکه معابر، همچون ساختار گراف‌ی، تعاملات مکانی سلسله‌مراتبی، پویایی‌های سرریز بین معابر و نقش‌های مرکزی یا اتصال‌پذیری معابر، ناتوان‌اند. در حالی که شواهد تجربی و مطالعات متعدد نشان می‌دهد الگوهای تراکم و ازدحام در معابر ماهیتی شبکه‌ای داشته و

تغییر وضعیت یک معبر می‌تواند در سطوح وابستگی درجه اول، دوم و حتی بالاتر، بر رفتار معابر مجاور اثرگذار باشد؛ امری که ناشی از سرریز جریان و پیوستگی ساختاری شبکه ترافیک است. از این‌رو، رویکردهای نقطه‌محور یا مدل‌هایی که به روابط مکانی خطی و ساده‌سازی شده متکی‌اند، قادر به توصیف واقع‌گرایانه پویایی مکانی-زمانی ترافیک نبوده و در استخراج الگوهای تعاملی پیچیده میان اجزای شبکه دقت کافی از خود نشان نمی‌دهند. [۳ و ۴]

گسترش یادگیری عمیق و ظهور رویکردهای مکانی-زمانی در سال‌های اخیر تحولی بنیادین در مدل‌سازی داده‌های ساختارمند شهری ایجاد کرده است. در این میان، شبکه‌های عصبی گراف (*GNN*)<sup>۱</sup> به‌عنوان یکی از پیشرفته‌ترین ابزارهای تحلیل داده‌های گراف‌محور، امکان مدل‌سازی مستقیم ساختار توپولوژیک شبکه معابر و استخراج وابستگی‌های پیچیده بین گره‌ها را از طریق سازوکار انتشار پیام فراهم می‌کنند؛ قابلیت‌هایی که به مدل اجازه می‌دهد روابط همسایگی چندمرتب‌ه‌ای، نقش‌های ساختاری معابر و تعاملات سلسله‌مراتبی جریان را به‌طور عمیق مدل‌سازی نماید. از سوی دیگر، شبکه‌های عصبی واحد بازگشتی<sup>۲</sup> (*GRU*) با برخورداری از مکانیزم حافظه و توانایی یادگیری وابستگی‌های بلندمدت زمانی، یکی از مؤثرترین رویکردها برای مدل‌سازی پویایی سری‌های زمانی ترافیک محسوب می‌شوند. ادغام این دو دسته مدل در قالب یادگیری عمیق مکانی - زمانی، ظرفیتی فراهم کرده است که در آن وابستگی‌های مکانی پیچیده شبکه و پویایی‌های زمانی چندمقیاسی به‌صورت هم‌زمان و یکپارچه مورد تحلیل قرار گیرند؛ رویکردی که امکان مدل‌سازی واقع‌بینانه‌تر رفتار شبکه‌های ترافیکی و دستیابی به پیش‌بینی‌هایی با دقت و جامعیت بی‌سابقه را میسر ساخته است. [۵ و ۶]

<sup>1</sup> Graph Neural Network

<sup>2</sup> Gated Recurrent Unit

از ماتریس همسایگی چندلایه و شاخص‌های شبکه‌ای، نمایش برداری عمیقی از ساختار و نقش‌های ساختاری معابر تولید می‌کند. سپس در گام زمانی، *GRU* با دریافت توالی تاریخچه‌ای کلاس‌های ترافیک و وابستگی‌های زمانی، الگوهای پویای جریان را مدل‌سازی کرده و خروجی به صورت یک مدل مکانی - زمانی یکپارچه تولید می‌شود. این ترکیب تقویت‌شده از *GNN* و *GRU*، همراه با غنی‌سازی ساختار مکانی در مدل مکانی، امکان استخراج الگوهای غیرخطی، چندمقیاسی و تعاملی را فراهم کرده و پتانسیل قابل توجهی برای بهبود عملکرد سامانه‌های پیش‌بینی ترافیک بلادرنگ و توسعه سامانه‌های مدیریت هوشمند جریان شهری ایجاد می‌کند. [۹ و ۱۰]

## ۲- مروری بر مطالعات پیشین

پیش‌بینی ترافیک شهری یکی از مهم‌ترین موضوعات پژوهشی در حوزه حمل‌ونقل هوشمند است که طی سال‌های اخیر با توسعه داده‌های مکانی - زمانی و روش‌های یادگیری ماشین، پیشرفت قابل توجهی داشته است. رویکردهای ارائه‌شده در این حوزه از مدل‌های آماری کلاسیک و شبکه‌های عصبی بازگشتی تا معماری‌های پیشرفته مبتنی بر شبکه‌های عصبی گراف را شامل می‌شوند. هر یک از این روش‌ها تلاش کرده‌اند بخشی از پیچیدگی‌های زمانی و مکانی ترافیک را مدل‌سازی کنند، اما همچنان چالش‌هایی نظیر بازنمایی کامل ساختار شبکه معابر، مدل‌سازی اثرات غیرمستقیم ترافیک و بهره‌گیری از ویژگی‌های ساختاری شبکه وجود دارد. در ادامه، مطالعات پیشین در چهار دسته اصلی شامل مدل‌های کلاسیک، مدل‌های مبتنی بر توالی زمانی، مدل‌های مکانی - زمانی مبتنی بر گراف و مدل‌های پیشرفته تقویت‌شده با ساختار شبکه و داده‌های بیرونی مورد بررسی قرار می‌گیرند.

### ۲-۱- مدل‌های کلاسیک و یادگیری ماشین سنتی

#### در پیش‌بینی ترافیک

نخستین تلاش‌ها در پیش‌بینی ترافیک شهری عمدتاً بر

با وجود پیشرفت چشمگیر مدل‌های مبتنی بر شبکه‌های عصبی گراف و معماری‌های ترکیبی مکانی-زمانی، بسیاری از پژوهش‌های موجود همچنان با محدودیت‌هایی در مدلسازی عمیق ساختار مکانی شبکه ترافیک مواجه‌اند. اغلب مطالعات صرفاً به استفاده از همسایگی مرتبه اول در گراف معابر بسنده کرده و از ویژگی‌های ساختاری کلیدی نظیر بینابینی<sup>۱</sup>، نزدیکی<sup>۲</sup> و درجه وزن دار<sup>۳</sup> که نقش تعیین‌کننده‌ای در فهم نقش ساختاری معابر و نحوه انتشار سرریزهای ترافیکی دارند، غفلت کرده‌اند. این در حالی است که شواهد تجربی نشان می‌دهد الگوهای انتشار تراکم و انتقال جریان در بسیاری از موارد از همسایگی مرتبه دوم و حتی سوم تبعیت می‌کنند و تحلیل شبکه بر پایه همسایگی سطحی قادر نیست پویایی‌های واقعی جریان را مدلسازی کند. از سوی دیگر، مطالعات اندکی سازوکارهای مکانی مبتنی بر *GNN* را با مدل‌سازی‌های زمانی قدرتمند مانند *GRU* به گونه‌ای تلفیق کرده‌اند که هم‌زمان بتوانند روابط مکانی چندمرتب‌ه‌ای و وابستگی‌های زمانی کوتاه‌مدت و میان‌مدت را به صورت یکپارچه پوشش دهد. [۷ و ۸]

در راستای رفع این شکاف‌ها، پژوهش حاضر، یک چارچوب پیش‌بینی ترافیک گراف‌محور و مکانی - زمانی ارائه می‌کند که در آن ساختار شبکه معابر تهران بر پایه گرافی غنی‌سازی شده شامل روابط همسایگی مرتبه اول و دوم، ویژگی‌های ساختاری و عملکردی معابر مدلسازی شده است. برای این منظور، داده‌های شبکه‌ی معابر چهار منطقه شهری تهران به همراه کلاس‌های ترافیکی استخراج‌شده از تصاویر گوگل در بازه زمانی سه‌ماهه، از سازمان کنترل ترافیک شهرداری تهران دریافت شده و گرافی جامع با ریزدانه‌گی بالا ساخته شده است. در گام مکانی، *GNN* با بهره‌گیری

<sup>1</sup> Betweenness

<sup>2</sup> Closeness

<sup>3</sup> Weighted degree

مدل‌سازی پویایی زمانی ترافیک به کار گرفته شدند. نقطه قوت کلیدی این مدل‌ها، توانایی یادگیری وابستگی‌های زمانی کوتاه‌مدت و میان‌مدت و مدیریت مشکل ناپدیدشدن گرادیان است. در بسیاری از مطالعات، این مدل‌ها نسبت به روش‌های آماری کلاسیک بهبود محسوسی در دقت پیش‌بینی نشان داده‌اند. [۱۲]

با وجود این مزایا، ضعف اساسی این دسته از مدل‌ها در نادیده‌گرفتن ساختار مکانی شبکه معابر نهفته است. در اغلب کاربردها، هر معبر یا ایستگاه به صورت یک سری زمانی مستقل مدل‌سازی می‌شود و تعاملات مکانی تنها به طور ضمنی یا از طریق ویژگی‌های ساده لحاظ می‌گردد. این رویکرد سبب می‌شود مدل در مواجهه با پدیده‌هایی نظیر سرریز ترافیکی، انتقال و اثرات شبکه‌ای، به‌ویژه در افق‌های پیش‌بینی بلندتر، دچار افت عملکرد شود. [۱۴ و ۱۳]

در چارچوب پژوهش حاضر، *GRU* به‌عنوان ماژول زمانی انتخاب شده است، اما نه به صورت مستقل. بلکه این مدل زمانی بر پایه مدل‌سازی مکانی غنی‌شده‌ای عمل می‌کند که از طریق *GNN* و ویژگی‌های ساختاری شبکه استخراج شده است. بدین ترتیب، ضعف ذاتی مدل‌های صرفاً زمانی از طریق تقویت مکانی به صورت ساختاری جبران می‌شود.

## ۲-۳- مدل‌های مکانی - زمانی مبتنی بر گراف و یادگیری وابستگی‌های محلی

با درک ماهیت شبکه‌ای ترافیک شهری، مدل‌های مبتنی بر شبکه‌های عصبی گراف به‌عنوان چارچوبی قدرتمند برای پیش‌بینی مکانی - زمانی معرفی شدند. معماری‌هایی نظیر <sup>۳</sup>*(DCRNN)* و <sup>۴</sup>*(STGCN)* با ترکیب کانولوشن گرافی و مدل‌سازی توالی زمانی، نشان دادند که ادغام صریح ساختار شبکه معابر می‌تواند دقت پیش‌بینی را به طور قابل توجهی افزایش

مدل‌های آماری کلاسیک و یادگیری ماشین سنتی متمرکز بوده‌اند. روش‌هایی نظیر میانگین متحرک یکپارچه خودرگرسیون (*ARIMA*)، مدل‌های فضای حالت و رگرسیون‌های خطی و غیرخطی، به دلیل سادگی پیاده‌سازی و قابلیت تفسیر، برای پیش‌بینی کوتاه‌مدت ترافیک مورد استفاده قرار گرفته‌اند. نقطه قوت اصلی این دسته از روش‌ها، نیاز محاسباتی پایین و شفافیت روابط مدل است که آن‌ها را برای کاربردهای محدود و شبکه‌های کوچک مناسب می‌سازد.

با این حال، ضعف بنیادین این مدل‌ها در فرض‌های محدودکننده آن‌ها نهفته است. فرض اولیه این روش‌ها، عموماً ایستایی زمانی، خطی بودن روابط و استقلال نسبی مشاهدات است؛ فرض‌هایی که با ماهیت واقعی ترافیک شهری، که متأثر از تعاملات غیرخطی، شوک‌های ناگهانی و وابستگی‌های مکانی پیچیده است، همخوانی ندارد. [۱۱] علاوه بر این، این مدل‌ها فاقد سازوکار صریح برای لحاظ‌کردن ساختار شبکه معابر هستند و در بهترین حالت، اطلاعات مکانی را به صورت متغیرهای کمکی ساده وارد مدل می‌کنند.

از منظر روش *Enhanced GNN-GRU*، مدل‌های کلاسیک را می‌توان به‌عنوان خط مبنای مفهومی تلقی کرد که نشان می‌دهند چرا گذار به چارچوب‌های شبکه‌محور و مکانی - زمانی ضروری است. ضعف این مدل‌ها در ناتوانی در مدل‌سازی همزمان ساختار شبکه و پویایی زمانی می‌باشد که انگیزه اصلی برای حرکت به سمت معماری‌های ترکیبی مبتنی بر گراف در پژوهش حاضر بوده است.

## ۲-۲- مدل‌های یادگیری عمیق مبتنی بر توالی زمانی

با گسترش داده‌های ترافیکی با تفکیک زمانی بالا، شبکه‌های عصبی بازگشتی نظیر حافظه کوتاه مدت طولانی <sup>۲</sup>*(LSTM)* و *GRU* به‌طور گسترده برای

<sup>3</sup> Diffusion Convolutional Recurrent Neural Network

<sup>4</sup> Spatial Temporal Graph Convolutional Network

<sup>1</sup> Autoregressive Integrated Moving Average

<sup>2</sup> Long short-term memory

با وجود این پیشرفت‌ها، این مدل‌ها غالباً بر یادگیری ضمنی روابط مکانی تکیه دارند و کمتر به ادغام صریح دانش ساختاری شبکه مانند شاخص‌های مرکزیت و همسایگی چندمرتب‌ه‌ای می‌پردازند. این امر موجب می‌شود که تفسیرپذیری مدل کاهش یابد و نقش ساختاری معابر به صورت شفاف در فرآیند یادگیری بازتاب نیابد. [۲۴، ۲۳، ۲۲]

با وجود پیشرفت‌های فوق، ادبیات پژوهشی اخیر نشان می‌دهد که چند خلاصه اساسی هنوز به طور جامع برطرف نشده است. نخست، بسیاری از مدل‌ها همچنان تنها از همسایگی مرتبه اول بهره می‌برند، در حالی که شواهد تجربی و مدل‌سازی شبکه‌ای نشان می‌دهد الگوهای سرریز ترافیکی و انتشار بار شبکه‌ای غالباً از طریق همسایگی مرتبه دوم و حتی سوم رخ می‌دهد. [۱۷، ۱۶، ۱۵] دوم، بخش قابل توجهی از پژوهش‌ها، در مدل مکانی تنها به مدل‌سازی محلی ساختار مکانی پرداخته و در بعد سراسری، شاخص‌های ساختاری شبکه را در طراحی ماتریس مجاورت یا ویژگی‌های ورودی لحاظ نمی‌کنند؛ در حالی که این شاخص‌ها نقش تعیین‌کننده‌ای در میزان تأثیرگذاری بر توزیع جریان ایفا می‌کنند و نادیده گرفتن آن‌ها سبب کاهش توان مدل در بازنمایی ساختار واقعی شبکه می‌شود [۲۴، ۲۳، ۲۲].

بر این اساس، روش *Enhanced GNN-GRU* با تلفیق یادگیری داده‌محور و دانش ساختاری شبکه، چارچوبی ارائه می‌دهد که در آن همسایگی چندمرتب‌ه‌ای و شاخص‌های مرکزیت به عنوان مؤلفه‌های صریح و قابل تفسیر وارد مدل می‌شوند. این رویکرد نه تنها دقت پیش‌بینی را بهبود می‌بخشد، بلکه امکان تحلیل نقش ساختاری معابر و پویایی انتشار ترافیک را نیز فراهم می‌کند؛ ویژگی‌ای که در بسیاری از مدل‌های پیشرفته موجود کمتر مورد توجه قرار گرفته است.

### ۳- روش تحقیق

این پژوهش یک چارچوب پیش‌بینی مکانی-زمانی مبتنی بر ترکیب شبکه‌های عصبی گراف و شبکه‌های

دهد. [۱۲] نقطه قوت اصلی این مدل‌ها، توانایی استخراج وابستگی‌های مکانی محلی و یادگیری الگوهای انتشار جریان در شبکه است.

با این حال، بخش قابل توجهی از این مدل‌ها به دو محدودیت اساسی دچار هستند. نخست، وابستگی مکانی غالباً تنها بر اساس همسایگی مرتبه اول تعریف می‌شود و اثرات غیرمستقیم شبکه‌ای نادیده گرفته می‌شود. دوم، تنها ماتریس مجاورت به مدل معرفی می‌شود و نقش ساختار کلان شبکه و موقعیت ساختاری معابر به طور صریح در فرآیند یادگیری لحاظ نمی‌گردد. [۱۷، ۱۶، ۱۵]

روش *Enhanced GNN-GRU*، ضمن حفظ مزایای *GNN* در یادگیری وابستگی‌های محلی، با معرفی همسایگی مرتبه دوم و استفاده صریح از شاخص‌های ساختاری، این محدودیت‌ها را هدف قرار می‌دهد. بدین ترتیب، مدل قادر است علاوه بر تعاملات مستقیم، اثرات غیرمستقیم و سرریزهای شبکه‌ای را نیز به طور مؤثر در فرآیند پیش‌بینی لحاظ کند.

### ۲-۴- مدل‌های پیشرفته تقویت شده با ساختار شبکه و داده‌های بیرونی

در سال‌های اخیر، پژوهش‌ها به سمت توسعه مدل‌های پیشرفته‌تری حرکت کرده‌اند که از سازوکارهای تطبیقی، توجه و ادغام داده‌های چندمنبعی بهره می‌برند. مدل‌هایی نظیر گراف ویونت<sup>۱</sup> و شبکه کانولوشنی گرافی مکانی-زمانی مبتنی بر توجه<sup>۲</sup> (*ASTGCN*) با معرفی ماتریس‌های وابستگی قابل یادگیری و مکانیزم توجه، توانسته‌اند روابط مکانی پنهان و الگوهای زمانی پیچیده را استخراج کنند. افزون بر این، مطالعات جدید نشان داده‌اند که ادغام داده‌های محیطی و جوی می‌تواند دقت پیش‌بینی را به طور معناداری بهبود بخشد [۱۸، ۱۹، ۲۰، ۲۱].

<sup>۱</sup> Graph WaveNet

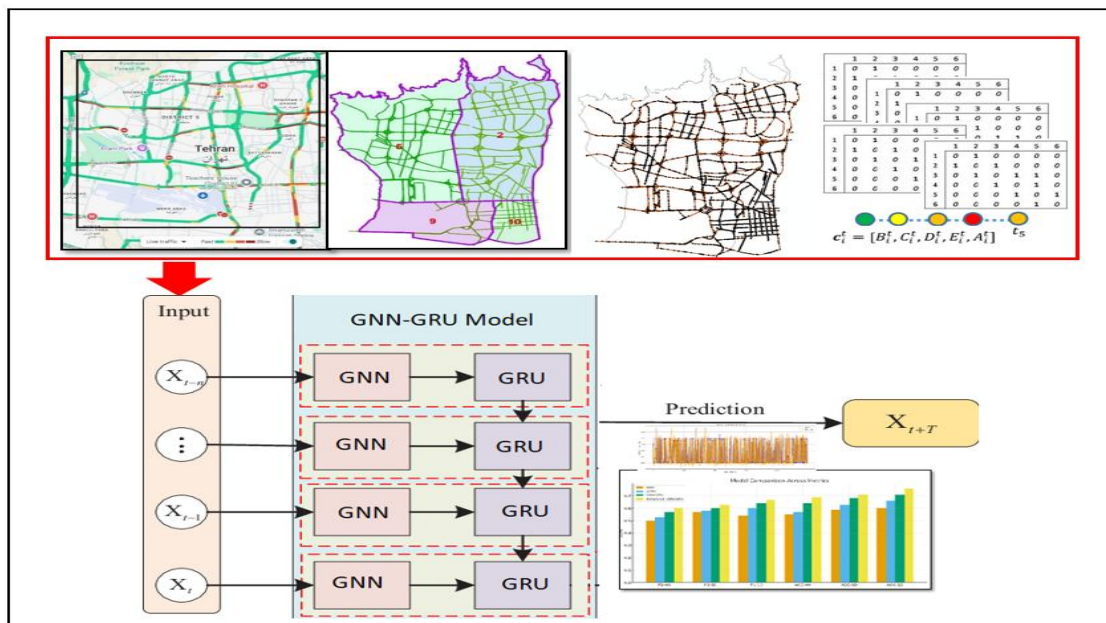
<sup>۲</sup> Attention-based Spatio-Temporal Graph Convolutional Network

مکانی با توالی زمانی کلاس‌های ترافیک و در نهایت اجرای مدل پیش‌بینی و ارزیابی آن است. در این چارچوب، ابتدا شبکه مکانی معابر و ویژگی‌های مرکزیت آنها پردازش شده و گراف شهری تشکیل می‌شود. سپس ماتریس‌های همسایگی مرتبه اول و دوم محاسبه و در کنار ویژگی‌های ساختاری به‌عنوان ورودی لایه‌ی گرافی به کار گرفته می‌شوند تا نمایش بهتری از ساختار شبکه استخراج گردد. در ادامه، خروجی *GNN* به صورت یک توالی زمانی ساختار یافته با داده‌های تاریخی ترافیک ترکیب شده و وارد واحدهای *GRU* می‌شود تا پویایی زمانی جریان در بازه‌ی تحلیل‌شده مدل‌سازی شود. در مرحله‌ی نهایی، لایه‌ی خروجی با استفاده از یک تابع خطای مناسب، کلاس ترافیکی آینده را پیش‌بینی کرده و مدل از طریق فرایند یادگیری انتها-به-انتها آموزش داده می‌شود. این معماری، با یکپارچه‌سازی دانش مکانی عمیق مبتنی بر ساختار گراف و توانایی یادگیری زمانی مبتنی بر *GRU*، امکان استخراج الگوهای پیچیده، غیرخطی و چندمقیاسی ترافیک شهری را فراهم می‌آورد (شکل (۱)). در بخش‌های بعدی، ابعاد مختلف این چارچوب توضیح داده می‌شود.

عصبی واحد بازگشتی ارائه می‌کند که برای مدل‌سازی دقیق وضعیت ترافیک در سطح معبر طراحی شده است. معماری پیشنهادی بر سه اصل بنیادین استوار است:

- ۱- نمایش غنی و ساختارمند شبکه معابر از طریق ساخت گراف چندمرتبه‌ای و اعمال شاخص‌های توپولوژیک و ساختاری پیشرفته همچون بینابینی، نزدیکی و درجه وزن‌دار با هدف تقویت بیان ساختاری هر گره در مدل مکانی طراحی شده؛
- ۲- استخراج وابستگی‌های مکانی و الگوهای انتشار جریان در مقیاس شبکه از طریق لایه‌های *GNN* که قادر است نه تنها روابط همسایگی مرتبه اول بلکه سرریزهای مرتبه دوم و ساختار سلسله‌مراتبی معابر را نیز مدل‌سازی کنند؛
- ۳- مدل‌سازی پویایی زمانی کوتاه‌مدت و میان‌مدت با بهره‌گیری از *GRU* که با سازوکار حافظه‌ی درونی خود، وابستگی‌های طولی در سری‌های زمانی ترافیک را به صورت مؤثر یاد می‌گیرد.

فرایند پیشنهادی در یک زنجیره‌ی منسجم شامل مراحل پیش‌پردازش داده‌ها، ساخت گراف چندلایه، غنی‌سازی ویژگی‌های مکانی - ساختاری، استخراج اهمیت معیارهای مکانی با *GNN*، ترکیب خروجی



شکل ۱: معماری روش Enhanced GNN-GRU

## ۳-۱- استخراج و پردازش داده‌های مکانی

در این پژوهش، استخراج و آماده‌سازی داده‌های مکانی با هدف ساخت نمایش دقیق، شبکه‌محور و مناسب برای تحلیل جریان ترافیک انجام می‌شود. نخست، شبکه معابر شهری از طریق داده‌های مکانی دریافت شده از سازمان کنترل ترافیک شهرداری تهران پردازش شده و مجموعه‌ای از قطعات معابر<sup>۱</sup> و تقاطع‌ها به‌عنوان هندسه پایه تولید می‌گردد. با این حال، گراف اولیه‌ای که در آن هر تقاطع به مثابه گره و هر معبر به مثابه یال تعریف می‌شود، برای مدل‌سازی دقیق جریان ترافیک کفایت نمی‌کند؛ زیرا جریان ترافیک بر روی معابر جاری است و تعاملات دینامیک بین معابر در قالب انتشار سرریز، تغییر ظرفیت و وابستگی‌های جهت‌دار و نه صرفاً در نقاط تقاطع رخ می‌دهد. از این رو، در پژوهش حاضر با پیروی از مطالعات اخیر پیش‌بینی ترافیک، شبکه به گراف دوگان<sup>۲</sup> تبدیل شد که در آن هر معبر به‌عنوان یک گره و هر اتصال فیزیکی بین دو معبر به‌عنوان یک یال تعریف شد. این ساختار این امکان را می‌دهد تا فرآیند انتشار جریان، تأثیرات متقابل معابر و پویایی‌های شبکه‌ای با دقت بیشتری مدل شود.

شواهد پژوهشی جدید نیز این رویکرد را تأیید می‌کنند؛ به‌گونه‌ای که مطالعات مبتنی بر گراف در سال‌های اخیر نشان داده‌اند مدل‌هایی که نمایش مسیرمحور<sup>۳</sup> را جایگزین گراف تقاطع‌محور می‌کنند، توانایی بالاتری در استخراج وابستگی‌های مکانی و دینامیک جریان دارند [۲۵ و ۲۶]. برای مثال، مدل شبکه عصبی گرافی ترکیبی<sup>۴</sup> در سال ۲۰۲۵ نشان داد که مدل‌سازی مبتنی بر مسیر (به‌ویژه هنگامی که ساختار گراف قادر به استخراج وابستگی‌های پویا میان معابر باشد) به شکل معناداری دقت پیش‌بینی جریان را نسبت به مدل‌های مبتنی بر گراف اولیه افزایش می‌دهد [۲۵ و ۲۶]. این

یافته‌ها تأیید می‌کنند که گراف دوگان در مدل‌سازی جریان و سرریز ترافیک از گراف اولیه مناسب‌تر است. در این مدل هر یال (معبر) یک گره در نظر گرفته می‌شود و یال‌ها بر اساس اتصال فیزیکی و جهت جریان تعریف می‌شوند که به صورت گراف وزن‌دار  $G = (V, E, A)$  نمایش داده می‌شود که در آن  $\{v_1, v_2, \dots, v_N\}$  مجموعه‌ای از  $N$  گره را نشان می‌دهد و  $E$  مجموعه یال‌های جهت‌دار میان گره‌هاست و  $A \in \mathbb{R}^{N \times N}$  ماتریس همسایگی گراف را نشان می‌دهد.

[۲۷ و ۲۸]

پس از ایجاد گراف دوگان شبکه بزرگراهی، مجموعه‌ای از ویژگی‌های ساختاری از این گراف استخراج می‌شود تا اطلاعات مکانی شبکه به‌صورت صریح و کمی در اختیار مدل یادگیری عمیق قرار گیرد. در این راستا، ابتدا روابط همسایگی بین معابر با استفاده از ماتریس‌های همسایگی مرتبه اول و دوم مدل‌سازی می‌شوند. ماتریس همسایگی مرتبه اول  $A^1$  به صورت رابطه (۱) تعریف می‌شود:

رابطه (۱)

$$A_{ij} = \begin{cases} 1 & \text{اگر بین بزرگراه‌های } i, j \text{ ارتباط مکانی وجود داشته باشد} \\ 0 & \text{در غیر این صورت} \end{cases}$$

این ماتریس بیانگر روابط مستقیم بین معابر مجاور است و انتقال فوری جریان ترافیک بین بخش‌های متصل شبکه را مدل‌سازی می‌کند. با این حال، در شبکه‌های شهری، اثرات ترافیکی اغلب محدود به معابر مجاور نبوده و می‌توانند از طریق مسیرهای واسط به معابر غیرمجاور نیز منتقل شوند. به‌منظور لحاظ کردن این سرریزهای مکانی، ماتریس همسایگی مرتبه دوم  $A^2$  به‌صورت حاصل ضرب ماتریس همسایگی مرتبه اول با خودش تعریف می‌شود (رابطه (۲)):

$$A^2 = A^1 \times A^1 \quad \text{رابطه (۲)}$$

وجود یک درایه غیرصفر در  $A_{ij}^{(2)}$  نشان‌دهنده آن است که بین معابر  $i$  و  $j$  یک مسیر دو مرحله‌ای از طریق یک گره واسط وجود دارد. این نوع همسایگی برای

<sup>1</sup> road segments<sup>2</sup> dual graph<sup>3</sup> segment-based representation<sup>4</sup> Mixed-Graph Neural Network

مهمی در سرعت انتشار پدیده‌های ترافیکی دارند [۳۴ و ۳۵].

در نهایت، مرکزیت درجه وزن دار (رابطه (۵)) به‌منظور لحاظ کردن شدت و کیفیت ارتباطات هر معبر تعریف می‌شود و به‌صورت رابطه (۵) محاسبه می‌گردد:

$$WD(i) = \sum_{j \in N(i)} w_{ij} \quad \text{رابطه (۵)}$$

در رابطه (۵)،  $N(i)$  مجموعه همسایگان گره  $i$  و  $w_{ij}$  وزن یال بین دو معبر است. در شبکه‌های حمل‌ونقل، این وزن می‌تواند بر اساس متغیرهایی نظیر طول معبر، ظرفیت، یا زمان سفر آزاد تعیین شود. گره‌هایی با درجه وزن دار بالا معمولاً دارای اتصالات متعدد یا مسیرهای پرفریت بوده و نقش کلیدی در توزیع و جذب جریان ترافیک ایفا می‌کنند. [۳۶ و ۳۷]

تمامی شاخص‌های استخراج‌شده پس از نرمال‌سازی، به‌صورت مستقیم به‌عنوان ویژگی‌های گره‌ها به ماژول مکانی شبکه عصبی گرافی ارائه می‌شوند. بدین ترتیب، خروجی این مرحله یک گراف دوگان غنی شده است که علاوه بر ساختار پایه شبکه، شامل اطلاعات چندمرته‌ای همسایگی و مجموعه‌ای از شاخص‌های ساختاری کلیدی است. این گراف به‌عنوان ورودی اصلی بخش مکانی مدل *Enhanced GNN-GRU* عمل کرده و بستری فراهم می‌کند تا *GNN* بتواند وابستگی‌های پیچیده شبکه‌ای را استخراج کند و نمایش مکانی دقیق و معناداری برای بخش زمانی مدل فراهم سازد. افزودن همسایگی مرتبه دوم و شاخص‌های مرکزیت با این هدف انجام شده است که مدل بتواند فراتر از وابستگی‌های محلی، الگوهای سرریز ترافیکی و نقش ساختاری معابر را در مقیاس شبکه‌ای درک کند. در شبکه‌های شهری متراکم، تغییر وضعیت یک معبر لزوماً تنها بر معابر مجاور تأثیر نمی‌گذارد، بلکه از طریق مسیرهای واسطه، اثرات غیرمستقیم و تأخیری ایجاد می‌کند. از این رو، انتظار می‌رود ادغام همسایگی چندمرته‌ای و ویژگی‌های مرکزیت، به‌ویژه در افق‌های پیش‌بینی بلندتر، منجر به بهبود پایداری و دقت پیش‌بینی شود.

مدل‌سازی پدیده‌هایی نظیر انتشار غیرمستقیم تراکم، انسدادهای زنجیره‌ای و تأثیر تقاطع‌های واسطه بر وضعیت ترافیکی معابر ضروری است. در این پژوهش، ترکیب همسایگی‌های مرتبه اول و دوم امکان مدل‌سازی دقیق‌تری از وابستگی‌های مکانی شبکه بزرگراهی تهران را فراهم می‌کند. [۲۹ و ۳۰]

علاوه بر ساختار همسایگی، به‌منظور کمی‌سازی نقش عملکردی هر معبر در شبکه، شاخص‌های اصلی مرکزیت استخراج و به‌عنوان ویژگی‌های ساختاری مورد استفاده قرار می‌گیرند. این شاخص‌ها شامل مرکزیت بینابینی، مرکزیت نزدیکی و مرکزیت درجه وزن دار هستند که در ادبیات شبکه‌های پیچیده به‌عنوان توصیف‌کننده‌های معتبر اهمیت ساختاری گره‌ها شناخته می‌شوند. [۳۱]

مرکزیت بینابینی (رابطه (۳)) برای گره  $i$  به‌صورت زیر تعریف می‌شود:

$$Bt(i) = \sum_{s \neq i \neq t} \frac{\sigma_{st}(i)}{\sigma_{st}} \quad \text{رابطه (۳)}$$

در رابطه (۳)،  $\sigma_{st}$  تعداد کل کوتاه‌ترین مسیرها بین گره‌های  $s, t$  و  $\sigma_{st}(i)$  تعداد آن مسیرهایی است که از گره  $i$  عبور می‌کنند. این شاخص، میزان اهمیت یک معبر را به‌واسطه قرارگیری آن بر مسیرهای اصلی انتقال جریان نشان می‌دهد. معابری با مرکزیت بینابینی بالا معمولاً نقش گلوگاه‌ها، مفاصل حرکتی یا مسیرهای حیاتی شبکه را ایفا می‌کنند و در صورت بروز اختلال، می‌توانند موجب انتشار گسترده تراکم شوند. [۳۲ و ۳۳]

مرکزیت نزدیکی (رابطه (۴)) برای گره  $i$  به‌صورت معکوس فاصله متوسط آن تا سایر گره‌های شبکه تعریف می‌شود:

$$Cl(i) = \frac{N-1}{\sum_{j \neq i} d(i,j)} \quad \text{رابطه (۴)}$$

در رابطه (۴)،  $d(i,j)$  کوتاه‌ترین فاصله بین گره‌های  $i$  و  $j$  و  $N$  تعداد کل گره‌ها است. این معیار بیانگر میزان دسترس‌پذیری یک معبر در شبکه است. گره‌هایی با مرکزیت نزدیکی بالا قادرند تغییرات ترافیکی را سریع‌تر به سایر بخش‌های شبکه منتقل یا دریافت کنند و نقش

دو لایه با واحدهای حافظه چندگانه به کار گرفته شد تا وابستگی‌های دیرینه زمانی و الگوهای تکرارشونده به‌طور دقیق مدل شوند. حذف تصادفی نورون‌ها<sup>۳</sup> برای جلوگیری از بیش‌برازش اعمال شد. خروجی تعبیه‌شده  $GNN$  و دنباله زمانی  $GRU$  از طریق اتصال<sup>۴</sup> و سپس یک لایه کاملاً متصل ترکیب شدند تا نمایه‌ای مشترک از پویایی مکانی-زمانی ساخته شود. برای پیش‌بینی کلاس وضعیت ترافیک، لایه خروجی تابع بیشینه‌سازی نرم<sup>۵</sup> استفاده شد. برای هر گره در گام زمانی آینده، احتمال تعلق به هر کلاس برآورد گردید. [۴۲ و ۴۳]

برای آموزش مدل، تابع هزینه مدل<sup>۶</sup> از تابع آنتروپی با وزن‌دهی متناسب با توزیع نامتوازن کلاس‌ها استفاده شد (رابطه (۸)):

$$\mathcal{L} = - \sum \log y_c w_c(\hat{y}_c) \quad \text{رابطه (۸)}$$

بهینه‌سازی مدل با برآورد مومنت سازگار<sup>۷</sup> ( $Adam$ ) و نرخ یادگیری پویا انجام شد [۴۴]. از توقف زودهنگام<sup>۸</sup> برای جلوگیری از بیش‌برازش استفاده شد. پیاده‌سازی مدل در محیط برنامه نویسی پایتون ۳/۱۰ با استفاده از کتابخانه پایتورچ ژئومتریک<sup>۹</sup> انجام شد. تمامی کدها طوری تنظیم شدند که بازتولید نتایج بامقدار اولیه تصادفی<sup>۱۰</sup> ثابت تضمین شود. فلوجارت کلی روش تحقیق در شکل (۲) نمایش داده شده است [۴۵].

این رویکرد موجب می‌شود مدل نهایی نه تنها پویایی‌های زمانی ترافیک، بلکه منطق ساختاری و الگوهای انتشار جریان در مقیاس شبکه شهری به صورت محلی و سراسری را نیز به‌صورت هم‌زمان فراگیرد و در نتیجه پیش‌بینی وضعیت ترافیک با دقت و پایداری بیشتری انجام شود.

### ۳-۲- مدل‌سازی مکانی با $GNN$

برای استخراج وابستگی‌های مکانی از شبکه‌های  $GNN$  با قاعده انتشار پیام (رابطه (۶)) استفاده می‌شود:

$$H^{(l+1)} = \sigma(\tilde{A}H^{(l)}w^{(l)}) \quad \text{رابطه (۶)}$$

در رابطه (۶)،  $H$  بیانگر ماتریس ویژگی گره‌ها،  $\tilde{A}$  ماتریس مجاورت چند مرتبه‌ای نرمال شده،  $w^{(l)}$  وزن‌های قابل یادگیری و  $\sigma$  تابع فعال‌سازی  $ReLU$ <sup>۱</sup> است. [۳۸ و ۳۹]

به‌منظور لحاظ کردن وابستگی‌های کوتاه‌برد و بلندبرد، خروجی لایه‌های مبتنی بر  $A^1$  و  $A^2$  از طریق مکانیزم همجوشی وزنی ترکیب شدند (رابطه (۷)):

$$H = H\alpha^1 + (1 - H)\alpha^2 \quad \text{رابطه (۷)}$$

در رابطه (۷)،  $H$  بیانگر ویژگی گره‌ها پس از ادغام اطلاعات چند مرتبه‌ای همسایگی و  $\alpha$  ضریب وزن‌دهی همسایگی مرتبه اول و دوم برای تنظیم تعادل بین اطلاعات محلی و وابستگی‌های شبکه‌ای بلند برد می‌باشد. این ادغام انعطاف‌پذیر به مدل اجازه می‌دهد الگوهای مکانی پنهان و سرریزهای غیرمستقیم را با دقت بیشتری استخراج کند. [۴۰ و ۴۱]

### ۳-۳- مدل‌سازی زمانی با $GRU$

برای هر گره، پنجره زمانی لغزان<sup>۲</sup> با طول بهینه انتخاب گردید تا روندهای کوتاه‌مدت و میان‌مدت در جریان ترافیک پوشش داده شود. سپس معماری  $GRU$

<sup>3</sup> Dropout

<sup>4</sup> concatenation

<sup>5</sup> Softmax

<sup>6</sup> Loss Function

<sup>7</sup> Adaptive Moment Estimation

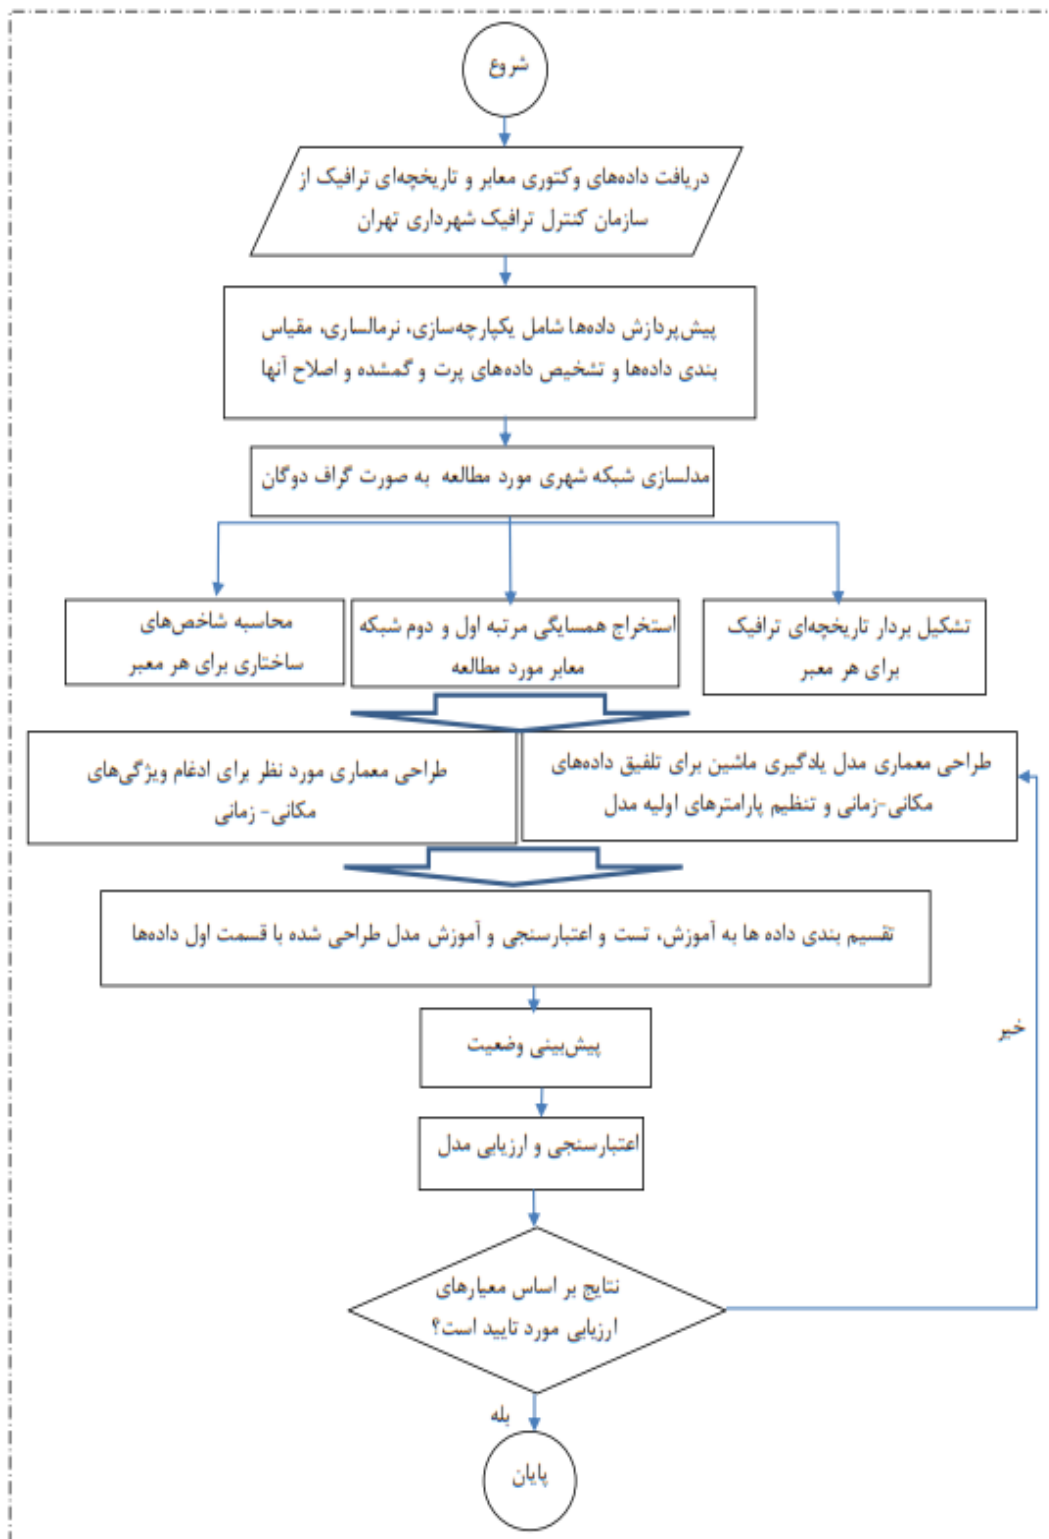
<sup>8</sup> Early Stopping

<sup>9</sup> PyTorch Geometric

<sup>10</sup> seed

<sup>1</sup> Rectified Linear Unit

<sup>2</sup> sliding window



شکل ۲: فرآیند کلی تحقیق

بخش‌هایی پرتردد و دارای الگوهای پیچیده جریان ترافیک شناخته می‌شوند (شکل ۳). تهران یکی از شلوغ‌ترین و پرتراфик‌ترین کلان‌شهرهای جهان به شمار می‌آید و وقوع ازدحام‌های شدید در ساعات مشخص روز، همراه با وجود شریان‌های حیاتی عبوری در این مناطق، آن را به محیطی ایده‌آل برای توسعه و ارزیابی مدل‌های پیش‌بینی ترافیک مبتنی بر یادگیری عمیق تبدیل کرده است. انتخاب این چهار منطقه نه تنها به دلیل تراکم جمعیت و فعالیت‌های روزانه انجام شده است، بلکه به دلیل آن است که این مناطق از نظر ساختار شبکه‌ای، تنوع عملکردی معابر، الگوهای سفر و شدت نوسانات زمانی ترافیک، نماینده‌ی مناسبی با تنوع کافی از الگوی جریان در مقیاس بزرگ شهری محسوب می‌شوند و شرایطی فراهم می‌کنند که بتوان پایداری و قابلیت تعمیم مدل *Enhanced GNN-GRU* را در محیط واقعی و پویا بررسی کرد.

### ۳-۴- پیاده‌سازی

به منظور ارزیابی کارایی مدل پیشنهادی *Enhanced GNN-GRU*، فرآیند پیاده‌سازی بر پایه داده‌های واقعی ترافیکی و شبکه معابر شهری انجام شد. در این مرحله، ابتدا داده‌های مکانی و زمانی مورد نیاز جمع‌آوری و پیش‌پردازش شدند و سپس ساختار گرافی شبکه معابر، ویژگی‌های توپولوژیکی و اطلاعات ترافیکی در قالب ورودی‌های مدل سازماندهی گردیدند. در ادامه، مدل پیشنهادی آموزش داده شده و عملکرد آن در افق‌های مختلف پیش‌بینی با استفاده از معیارهای ارزیابی مناسب مورد سنجش قرار گرفت. در این بخش، ابتدا منطقه مورد مطالعه و داده‌های مورد استفاده معرفی شده و سپس مراحل پیاده‌سازی، آموزش و ارزیابی مدل تشریح می‌شود.

#### ۳-۴-۱- منطقه مورد مطالعه

منطقه مورد مطالعه در این پژوهش شامل مناطق شهری ۲، ۵، ۹ و ۱۰ تهران است که هر یک به‌عنوان



شکل ۳: نمونه مورد مطالعه در تهران در چهار منطقه ۲، ۵، ۹ و ۱۰

جامع از ساختار ترافیکی چهار منطقه منتخب ارائه می‌دهد. این شبکه گسترده به‌گونه‌ای توزیع شده است که منطقه ۲ با ۲۰۰۷ قطعه بخش عمده‌ای از معابر

شبکه معابر مورد بررسی در این پژوهش مجموعاً شامل ۵۰۳۷ قطعه خیابان است که بر اساس داده‌های رسمی شبکه راه‌های شهری تهران استخراج شده و نمای

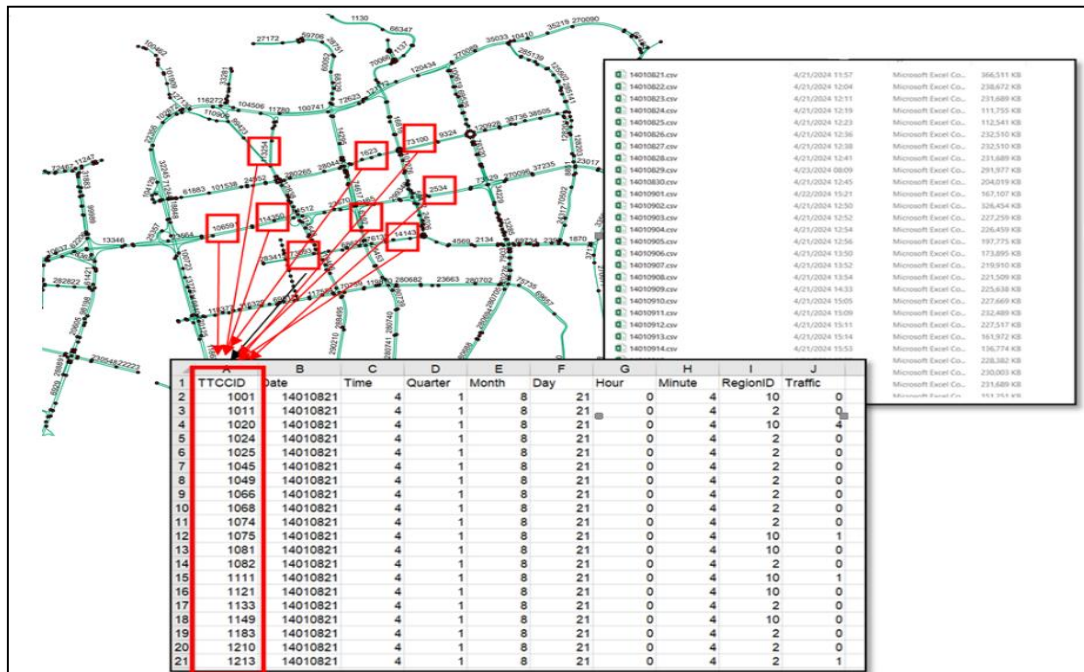
مکانی بوده و به‌عنوان واحد پایه تحلیل در نظر گرفته شده است.

برای هر قطعه خیابان با شناسه یکتای مکانی، وضعیت ترافیکی در بازه‌های زمانی ۱۵ دقیقه‌ای و طی یک دوره سه‌ماهه ثبت شده و به‌صورت کلاس‌های گسسته ترافیکی شامل جریان آزاد، نیمه‌سنگین، سنگین و تراکم شدید کدگذاری شده است. این ساختار داده‌ای، امکان ایجاد یک پایگاه داده مکانی-زمانی منظم را فراهم کرده است که در آن، هر نمونه شامل اطلاعات مکانی (ساختار شبکه و همسایگی‌ها) و زمانی (توالی وضعیت‌های ترافیکی) است.

به‌منظور آماده‌سازی داده‌ها برای مدل‌سازی، ابتدا شبکه معابر به گراف تبدیل شده و سپس با استفاده از برنامه‌نویسی، ماتریس‌های همسایگی مرتبه اول و دوم استخراج گردید. همچنین شاخص‌های مرکزیت برای هر قطعه خیابان محاسبه و به‌عنوان ویژگی‌های مکانی به داده‌های ورودی مدل افزوده شد.

شیرانی و محلی پرتردد را دربر می‌گیرد، منطقه ۵ با ۱۶۷۹ قطعه یکی از پهنه‌های توسعه‌یافته شهری با الگوی سفر متنوع را شامل می‌شود، منطقه ۹ با ۵۱۲ قطعه به‌عنوان یکی از مناطق کوچک‌تر اما راهبردی (به‌ویژه به دلیل وجود مسیرهای دسترسی فرودگاهی و بزرگراهی) شناخته می‌شود، و در نهایت منطقه ۱۰ با ۸۳۹ قطعه است. در کنار یکدیگر، این چهار منطقه یک زیرشبکه بزرگ‌مقیاس و واقع‌بینانه از تهران را تشکیل می‌دهند که به‌خوبی تنوع هندسی، عملکردی و ترافیکی شبکه شهری را پوشش می‌دهد و بستری مناسب برای تحلیل و پیش‌بینی مکانی-زمانی جریان ترافیک فراهم می‌سازد.

نقشه بزرگراه‌های مورد نظر در مناطق مورد مطالعه به همراه اطلاعات ترافیکی آنها، از سازمان کنترل ترافیک شهرداری تهران دریافت شده است (شکل ۴). این داده‌ها به‌صورت وکتوری و مبتنی بر شبکه رسمی بزرگراه‌ها و معابر اصلی شهر تهران ارائه شده‌اند. در این پایگاه داده، هر قطعه خیابان دارای یک شناسه یکتای



شکل ۴: داده‌های دریافت شده از سازمان کنترل ترافیک شهرداری تهران

به منظور ارزیابی منصفانه عملکرد مدل و جلوگیری از نشت اطلاعات<sup>۱</sup> زمانی، داده‌های مکانی - زمانی بر اساس ترتیب زمانی تقسیم‌بندی شدند.

داده‌ها شامل مشاهدات ۱۵ دقیقه‌ای در یک بازه زمانی سه‌ماهه بودند. این داده‌ها به صورت ترتیبی به سه بخش تقسیم شدند که شامل ۷۰ درصد ابتدایی بازه زمانی برای آموزش، ۱۰ درصد بعدی برای اعتبارسنجی و ۲۰ درصد انتهایی برای آزمون نهایی می‌باشد. در این تقسیم‌بندی، تمامی ۵۰۳۷ قطعه معبر در هر سه بخش حضور داشتند، اما ترتیب زمانی حفظ شد تا شرایط پیش‌بینی واقعی شبیه‌سازی شود. این رویکرد تقسیم‌بندی زمانی، با ماهیت پیش‌بینی مکانی - زمانی سازگار بوده و از انتقال ناخواسته اطلاعات آینده به مرحله آموزش جلوگیری می‌کند.

### ۳-۴-۲- اعتبارسنجی مدل

برای ارزیابی عملکرد مدل *Enhanced GNN-GRU* و سنجش میزان بهبود حاصل از به‌کارگیری ساختار مکانی تقویت‌شده، مجموعه‌ای از مدل‌های پایه و پرکاربرد در ادبیات پیش‌بینی سری‌های زمانی ترافیک انتخاب شده است. این مدل‌ها شامل *GRU*، *LSTM* و مدل ترکیبی *GRU-LSTM* می‌باشند که همراه با مدل *Enhanced GNN-GRU* در ادامه به‌طور خلاصه معرفی می‌شوند.

### ۳-۴-۲-۱- مدل شبکه‌های عصبی واحد بازگشتی

واحد بازگشتی (*GRU*) یکی از معماری‌های سبک و سریع شبکه‌های بازگشتی است که به دلیل تعداد پارامتر کم، توانایی مناسبی در یادگیری وابستگی‌های زمانی کوتاه‌مدت و میان‌مدت دارد. این مدل به‌عنوان روش مقایسه‌ای انتخاب شده زیرا در بسیاری از پژوهش‌های اخیر در حوزه پیش‌بینی ترافیک، به‌عنوان یک معماری پایه و محکم شناخته می‌شود و کارایی بالایی آن در مسائل سری زمانی اثبات شده است.

در گراف اشاره شده، هر تقاطع به عنوان یک گره و هر قطعه خیابان به عنوان یال تعریف می‌شود. با این حال، با توجه به توضیحات ارائه شده در بخش قبل، از آن‌جا که هدف پژوهش، مدل‌سازی و پیش‌بینی وضعیت ترافیک در سطح قطعه خیابان است، این مدل‌سازی نمی‌تواند واحد واقعی جریان را به‌طور مستقیم مورد تحلیل قرار دهد. از این رو، مشابه آنچه در مدل‌سازی شبکه‌های حمل‌ونقل توصیه شده است، گراف اولیه به گراف دوگان تبدیل شد؛ بدین ترتیب هر قطعه خیابان به‌عنوان یک گره و هر اتصال فیزیکی بین دو قطعه خیابان در محل تقاطع به‌عنوان یک یال مدل‌سازی می‌شود.

به‌منظور شکل‌دهی یک چارچوب جامع مکانی-زمانی، این شبکه ساختاری با مجموعه‌ای از داده‌های پویا تکمیل شد. وضعیت تاریخچه‌ای ترافیک برای تمامی ۵۰۳۷ قطعه خیابان از طریق کلاس‌های ترافیکی دریافت شده از سازمان کنترل ترافیک شهرداری تهران گردآوری شده است که شدت ترافیک را در چهار سطح دسته‌بندی می‌کند. همانطور که عنوان شد، این داده‌ها در بازه‌های ۱۵ دقیقه‌ای و برای یک دوره زمانی ۳ ماهه جمع‌آوری شده‌اند تا یک توالی زمانی ریزدانه و پایدار برای مدل‌سازی فراهم شود. ترکیب این داده‌ها یک چارچوب گسترده و چندبعدی ایجاد می‌کند که در آن وابستگی‌های مکانی (ساختار گراف و شاخص‌های ساختاری) و وابستگی‌های زمانی (توالی تاریخی وضعیت ترافیک)، به صورت یکپارچه وارد مدل می‌شوند. به منظور یکپارچه‌سازی داده‌های مکانی - زمانی، تطبیق با توپولوژی شبکه، پیش‌پردازش داده‌ها، ساخت دنباله‌های زمانی و آماده‌سازی داده‌ها برای مدل‌سازی مکانی - زمانی برنامه نویسی به زبان پایتون صورت گرفته و از کتابخانه‌های مربوط به یادگیری عمیق به منظور مدل‌سازی‌های مورد نیاز در این زبان استفاده شده است.

<sup>1</sup> Data Leakage

## ۳-۲-۴-۲- مدل حافظه طولانی کوتاه مدت

شبکه حافظه طولانی - کوتاه مدت (*LSTM*) یکی از رایج‌ترین معماری‌های شبکه‌های عصبی بازگشتی<sup>۱</sup> (*RNN*) برای یادگیری وابستگی‌های زمانی بلندمدت است و ساختار دروازه‌های آن امکان ذخیره‌سازی و به‌روزرسانی اطلاعات مهم در طول زمان را فراهم می‌کند. انتخاب *LSTM* به این دلیل است که اکثر مطالعات کلاسیک پیش‌بینی ترافیک از این معماری استفاده کرده‌اند و مقایسه با آن نشان می‌دهد مدل *Enhanced GNN-GRU* تا چه حد نسبت به روش‌های استاندارد یادگیری زمانی کارآمدتر است.

## ۳-۲-۴-۳- مدل ترکیبی شبکه‌های عصبی گرافی-واحد بازگشتی

مدل *GNN-GRU* یکی از مدل‌های ترکیبی شناخته‌شده در حوزه پیش‌بینی ترافیک است که برای ارزیابی عملکرد مدل *Enhanced GNN-GRU* به‌عنوان یک روش مقایسه‌ای استفاده می‌شود. در این مدل، *GNN* برای استخراج وابستگی‌های مکانی و ساختاری بین معابر به‌کار می‌رود و نمایش مکانی هر قطعه خیابان را تولید می‌کند. این مرحله به مدل اجازه می‌دهد تا ارتباطات شبکه‌ای و همسایگی‌ها را از ساختار گراف یاد بگیرد.

در ادامه، خروجی مکانی *GNN* وارد واحد *GRU* می‌شود تا الگوهای زمانی و پویایی جریان ترافیک در طول دوره‌های تاریخی را مدل‌سازی کند. *GRU* به‌دلیل ساختار ساده‌تر نسبت به *LSTM* و توانایی مناسب در یادگیری توالی‌های زمانی، یک انتخاب رایج برای پیش‌بینی سری‌های زمانی ترافیک است و امکان مقایسه مؤثر با مدل *Enhanced GNN-GRU* را فراهم می‌کند.

استفاده از *GNN-GRU* به‌عنوان مدل مقایسه‌ای از آن جهت اهمیت دارد که این مدل هم‌زمان وابستگی‌های

<sup>۱</sup> Recurrent Neural Network

مکانی را از طریق *GNN* و وابستگی‌های زمانی را از طریق *GRU* ترکیب می‌کند، اما فاقد تقویت‌های مکانی پیشرفته‌ای است که در مدل *Enhanced GNN-GRU* به کار گرفته شده است. بنابراین اختلاف عملکرد بین این مدل و مدل *Enhanced GNN-GRU* می‌تواند به‌طور مستقیم میزان تأثیر بهبودهای مکانی طراحی‌شده در این تحقیق را نشان دهد.

۳-۲-۴-۳- مدل *Enhanced GNN-GRU*

مدل پیشنهادی *Enhanced GNN-GRU* با تقویت مولفه مکانی و بهره‌گیری از ساختار گرافی برای استخراج وابستگی‌های ساختاری بین معابر عمل می‌کند. از طریق ادغام ویژگی‌های ساختاری، همسایگی چندمرتب‌ه‌ای و مدل‌سازی گراف دوگان، وابستگی‌های مکانی-ساختاری را قبل از ورود به لایه‌های *GRU* غنی‌سازی می‌کند. مقایسه این مدل با روش‌های پایه نشان می‌دهد که افزودن اطلاعات مکانی ساختاریافته و تقویت بعد مکانی و ساختاری تا چه حد می‌تواند دقت پیش‌بینی ترافیک را افزایش دهد و نقش شبکه معابر را در رفتار زمانی جریان ترافیک بهتر مدل‌سازی نماید.

## ۴- تحلیل نتایج

در این بخش، تحلیل پیاده‌سازی مدل *Enhanced GNN-GRU* و ارزیابی عملکرد آن در مقایسه با مجموعه‌ای از روش‌های پایه و ترکیبی ارائه می‌شود. تمام مراحل شامل آماده‌سازی داده‌ها، معیارهای ارزیابی، تحلیل نتایج و تفسیر خروجی‌ها تشریح شده است تا تصویری جامع از نحوه ایجاد و توسعه و ارزیابی کارایی مدل فراهم شود.

برای شروع، داده‌های مکانی، ترافیکی و زمانی مطابق روش تحقیق استخراج و پیش‌پردازش شدند. شبکه معابر در مناطق مورد مطالعه، پس از تبدیل به گراف دوگان، به‌همراه ماتریس‌های همسایگی مرتبه اول و دوم، شاخص‌های مرکزیت بینابینی، نزدیکی و درجه وزن‌دار، وضعیت ترافیکی، متغیرهای زمان، روز، هفته و ساعت در قالب مجموعه‌ای از ویژگی‌های نرمال‌سازی شده آماده ورود به مدل شدند. داده‌های

زمانی به کمک پنجره لغزان ساختاردهی شده و برای افق‌های پیش‌بینی ۱۵، ۳۰ و ۶۰ دقیقه‌ای آماده شدند. این داده‌ها سپس مبنای آموزش مدل‌های مختلف قرار گرفتند.

برای ایجاد شرایط منصفانه، تنظیمات اصلی همه مدل‌ها شامل نرخ یادگیری، نوع بهینه‌ساز، تعداد واحدهای پنهان، تعداد دوره‌های آموزشی و معیارهای خطا یکسان در نظر گرفته شد. در مدل *Enhanced GNN-GRU*، ماژول *GNN* با دو لایه کانولوشن گراف و یک لایه توجه<sup>۱</sup> برای ترکیب وابستگی‌های مرتبه اول و دوم طراحی شده است و خروجی آن به واحدهای *GRU* ارسال می‌شود. این ترکیب، زمینه‌ای فراهم می‌کند تا هم ساختار مکانی پیچیده شبکه و هم پویایی زمانی جریان ترافیک به‌طور هم‌زمان یاد گرفته شود.

به‌منظور ارزیابی اثربخشی مدل، مجموعه‌ای از روش‌های مقایسه‌ای انتخاب شد که به‌ترتیب شامل *GRU*، *LSTM*، مدل ترکیبی *GNN-GRU* در کنار مدل *Enhanced GNN-GRU* هستند. استفاده از این مدل‌ها از آن جهت اهمیت دارد که بتوان نقاط ضعف و قوت رویکرد پیشنهادی را در برابر طیفی از مدل‌های فاقد ساختار مکانی *GRU* و *LSTM* و مدل‌های مکانی-زمانی پایه *GNN-GRU* به‌صورت شفاف ارزیابی کرد. در این میان، مدل *Enhanced GNN-GRU* تنها مدلی است که علاوه بر ادغام *GNN* و *GRU*، ساختار مکانی را با تقویت همسایگی چندمرتبه‌ای، شاخص‌های مرکزیت و گراف دوگان غنی کرده و نمایشی بسیار دقیق‌تر از روابط شبکه‌ای فراهم کرده است. ارزیابی عملکرد مدل‌ها بر اساس دو معیار استاندارد شامل صحت<sup>۲</sup> (*ACC*)، امتیاز  $F_1$ <sup>۳</sup> انجام شد (جدول (۱)).

در جدول (۱)، عملکرد چهار مدل شامل *GRU*، اما نقطه اوج عملکرد زمانی مشاهده می‌شود که مدل *GNN-GRU* با یک لایه تقویت مکانی<sup>۴</sup> بهینه‌سازی شده و نسخه *Enhanced GNN-GRU* ارائه می‌شود. در این مدل، استفاده هم‌زمان گراف دوگان از همسایگی چندمرتبه‌ای و شاخص‌های ساختاری شبکه سبب شده وابستگی‌های مکانی نه فقط در سطح محلی، بلکه در قالب الگوهای گسترده‌تر شبکه‌ای نیز مدنظر قرار گیرند. این امر مستقیماً عملکرد مدل را در تمام افق‌های زمانی ارتقا داده است.

در مقابل، مدل *GNN-GRU* که در آن وابستگی‌های مکانی از طریق شبکه‌های عصبی گرافی لحاظ شده است، با بهبود قابل توجه معیارها همراه می‌شود. در این مدل، امتیاز  $F_1$  در افق ۱۵ دقیقه‌ای از ۰٫۵۴ (*GRU*) و ۰٫۶۰ (*LSTM*) به ۰٫۶۴ افزایش یافته و *ACC* نیز از حداکثر مقدار ۰٫۶۶ مدل‌های پایه به ۰٫۷۰ رسیده است. این اختلاف عملکرد بیانگر این واقعیت است که افزودن ساختار گرافی و مدل‌سازی روابط مکانی بین معابر، به‌صورت ذاتی قابلیت پیش‌بینی را افزایش می‌دهد؛ زیرا جریان ترافیک تنها تابع زمان نیست، بلکه به‌شدت تحت تأثیر ساختار مکانی شبکه و تعاملات بین قطعات معابر است.

در جدول (۱)، عملکرد چهار مدل شامل *GRU*،

<sup>1</sup> Attention

<sup>2</sup> Accuracy

<sup>3</sup> F1-Score

<sup>4</sup> Spatial Enhancement Layer

جدول ۱: مقایسه مدل‌های پایه با مدل *Enhanced GNN-GRU*

مدل مطالعه شده	ACC (15')	ACC (30')	ACC (60')	F1-score (15')	F1-score (30')	F1-score (60')
GRU	۰٫۶	۰٫۵۹	۰٫۵۵	۰٫۵۴	۰٫۵۷	۰٫۵
LSTM	۰٫۶۶	۰٫۶۳	۰٫۵۷	۰٫۶	۰٫۵۸	۰٫۵۳
GNN-GRU	۰٫۷۱	۰٫۶۸	۰٫۶۴	۰٫۶۴	۰٫۶	۰٫۵۷
Enhanced GNN-GRU	۰٫۷۶	۰٫۷۱	۰٫۶۹	۰٫۶۷	۰٫۶۳	۰٫۶

مکانی و ادغام ساختاری اطلاعات شبکه برمی‌گردد. نمودار مقایسه‌ای ترسیم شده که چهار مدل *GRU*، *LSTM*، *GNN-GRU* و *Enhanced GNN-GRU* را در سه افق زمانی ۱۵، ۳۰ و ۶۰ دقیقه به نمایش می‌گذارد، چند الگوی بسیار مهم را به‌طور بصری آشکار می‌کند (شکل (۵)).


نخستین نکته‌ای که در نگاه اول از شکل منحنی‌ها مشاهده می‌شود، پایین‌بودن پیوسته‌ی خط مربوط به *GRU* در تمام نقاط نمودار است. منحنی *GRU* در هر سه افق زمانی پایین‌ترین مقدار امتیاز  $F_1$  و  $ACC$  را نشان می‌دهد و کاملاً از سایر نمودارها جدا افتاده است؛ این موضوع به‌وضوح از نمودار مشخص است و بیانگر ضعف مدل در یادگیری ساختارهای پیچیده ترافیک است.

در نقطه مقابل، منحنی *LSTM* کمی بالاتر از *GRU* قرار گرفته، اما همچنان فاصله قابل توجهی با مدل‌های مکانی دارد. تغییرات این دو مدل در نمودار نشان می‌دهد که افزودن حافظه بلندمدت (*LSTM*) به‌تنهایی توانایی مدل‌سازی جریان مکانی-زمانی را ندارد و ستون‌های مربوط به این مدل نمایانگر ارتقای نسبتاً کمی نسبت به مدل *GRU* در سه افق زمانی مخصوصاً در افق‌های ۳۰ و ۶۰ دقیقه می‌باشد.

به‌طور مشخص، در افق ۱۵ دقیقه‌ای امتیاز  $F_1$  به ۰٫۶۷ و  $ACC$  به ۰٫۷۶ رسیده است؛ مقداری که نسبت به مدل *GNN-GRU* به ترتیب ۳ و ۵ درصد افزایش دارد. مهم‌تر از آن، در افق ۶۰ دقیقه که معمولاً دشوارترین حالت پیش‌بینی است، مدل تقویت‌شده همچنان امتیاز  $F_1$  را ۰٫۶ و  $ACC$  را ۰٫۶۹ ثبت کرده و بهترین پایداری زمانی را در بین تمام مدل‌ها نشان می‌دهد.

این روند نمایانگر یک اصل بنیادین در مدل‌سازی ترافیک است: هرچه مدل‌سازی مکانی کامل‌تر، ساخت یافته‌تر و شبکه‌محورتر باشد، مدل توانایی بیشتری در درک و پیش‌بینی صحیح دینامیک ترافیک خواهد داشت و می‌تواند با دقت، پایداری و تعمیم‌پذیری بالاتری عمل کند. در واقع، تقویت مؤلفه مکانی باعث می‌شود مدل بتواند الگوهای سرریز را بهتر شناسایی کند، تمایز دقیق‌تری میان کلاس‌های مختلف تراکم ترافیک برقرار سازد، در افق‌های زمانی بلند پایداری بیشتری نشان دهد و از تجمع خطاها در توالی پیش‌بینی شده جلوگیری کند؛ موضوعی که در نتایج مدل تقویت‌شده به‌وضوح قابل مشاهده است.

نتایج نشان می‌دهند که مدل *Enhanced GNN-GRU* نه تنها بهترین مدل جدول است، بلکه تنها مدلی است که توانسته در همه افق‌های زمانی دقت بالا و پایداری قابل توجه ارائه دهد؛ امری که مستقیماً به تقویت



شکل ۵: نمودار ترسیم شده برای چهار مدل مقایسه‌ای

بیشترین مقدار خود می‌رسد. این الگوی صعودی و فاصله گرفتن منحنی *Enhanced GNN-GRU* از سایر خطوط، نقش کلیدی تقویت مکانی را به صورت کاملاً بصری و قابل مشاهده اثبات می‌کند.

به عبارت دیگر، نمودار به صورت بسیار روشن نشان می‌دهد که:

۱- مدل‌های فاقد اطلاعات مکانی *GRU* و *LSTM* در همه نقاط نمودار پایین‌تر قرار دارند.

۲- مدل‌های مکانی *(GNN-GRU)* جهش قابل مشاهده‌ای ایجاد می‌کنند.

۳- مدل تقویت‌شده مکانی، بالاترین منحنی را دارد و فاصله آن با مدل‌های دیگر در افق‌های بلندتر بیشتر می‌شود.

این روند بصری نشان می‌دهد که هرچه غنای مکانی بیشتر باشد، مدل بهتر می‌تواند روابط شبکه‌ای، الگوهای سرریز، وابستگی میان معابر و پویایی‌های ساختاری جریان ترافیک را استخراج کند. افزایش فاصله نموداری بین مدل *Enhanced* و مدل‌های قبلی به طور مستقیم نشان‌دهنده پایداری بیشتر در افق‌های

بررسی نمودار همچنین نشان می‌دهد که با ورود مؤلفه مکانی، جهش قابل توجهی رخ می‌دهد. منحنی مدل *GNN-GRU* به صورت واضح (چه در امتیاز  $F_1$  و چه در  $ACC$ ) بالاتر از دو مدل پایه قرار گرفته و شکاف میان خطوط به خوبی قابل مشاهده است. این شکاف بصری نشان می‌دهد که مدل توانسته وابستگی‌های مکانی و اثرات شبکه‌ای را استخراج کند؛ به ویژه در افق ۶۰ دقیقه‌ای که فاصله میان *GNN-GRU* و مدل‌های صرفاً زمانی بیشتر می‌شود. این روند در نمودار به شکل افزایش فاصله عمودی میان منحنی‌ها کاملاً مشهود است.

اما برجسته‌ترین ویژگی نمودار، موقعیت بالاتر خط مربوط به مدل *Enhanced GNN-GRU* است. این منحنی در هر سه نقطه (۱۵، ۳۰ و ۶۰ دقیقه) در بالاترین سطح قرار دارد و هم امتیاز  $F_1$  و هم  $ACC$  را به صورت یکنواختی بهبود می‌دهد. در نمودار مشخص است که در افق ۱۵ دقیقه‌ای، هرچند اختلاف این مدل با *GNN-GRU* قابل توجه است، اما اختلاف در افق ۳۰ دقیقه‌ای بیشتر می‌شود و در افق ۶۰ دقیقه‌ای به

بلندمدت و کاهش خطای انباشته است.

به طور کلی، نتایج نشان می‌دهد که مدل *Enhanced GNN-GRU* در تمامی افق‌های پیش‌بینی عملکرد بهتری نسبت به مدل‌های پایه دارد، اما این بهبود در افق‌های زمانی بلندتر (به‌ویژه ۶۰ دقیقه) برجسته‌تر است. این رفتار بیانگر آن است که تقویت مکانی بیشترین تأثیر خود را در شرایطی نشان می‌دهد که وابستگی‌های غیرمستقیم و سرریز ترافیکی نقش پررنگ‌تری دارند. در حالی که مدل‌های مبتنی بر همسایگی مرتبه اول عمدتاً به واکنش‌های محلی محدود می‌شوند، مدل *Enhanced GNN-GRU* قادر است تأثیر مسیرهای واسط و نقش ساختاری معابر مرکزی را در پیش‌بینی لحاظ کند. از این رو، افزایش ۳ تا ۵ درصدی در شاخص‌های  $ACC$  و امتیاز  $F_1$ ، نشان‌دهنده ارتقای کیفی مدل در درک دینامیک شبکه‌ای ترافیک و کاهش خطاهای تجمعی در افق‌های پیش‌بینی بلندمدت است.

##### ۵- نتیجه‌گیری

این پژوهش با هدف ارتقای دقت، پایداری و تبیین‌پذیری پیش‌بینی وضعیت ترافیک شهری در مقیاس قطعه معبر، یک چارچوب یادگیری عمیق مکانی - زمانی مبتنی بر ادغام ساختاری شبکه‌های عصبی گراف و مدل‌های بازگشتی حافظه‌دار ارائه نمود. نوآوری اصلی تحقیق نه صرفاً در ترکیب *GNN* و *GRU*، بلکه در ارتقای سطح غنای توپولوژیک ورودی مدل نهفته است.

برخلاف رویکردهای متداول که نمایش مکانی را به همسایگی مرتبه اول یا گراف تقاطع‌محور محدود می‌کنند، در این مطالعه شبکه معابر با استفاده از گراف دوگان و با تمرکز بر قطعه خیابان به‌عنوان واحد بنیادی جریان ترافیک مدل‌سازی شد. این انتخاب ساختاری، امکان بازتاب مستقیم پدیده‌های انتشار جریان، سرریز تراکم و تعاملات غیرمحلی و سراسری میان معابر را فراهم می‌سازد. لحاظ کردن همسایگی مرتبه دوم، در کنار شاخص‌های ساختاری کلیدی شامل بینابینی،

نزدیکی و درجه وزن دار، موجب شد جایگاه عملکردی هر معبر در سازمان مکانی شبکه به‌صورت صریح در فرآیند یادگیری وارد شود. بدین ترتیب، مدل نه تنها روابط مجاورت مستقیم، بلکه نقش ساختاری معابر در هدایت و بازتوزیع جریان ترافیک را نیز فرا گرفت.

در بعد زمانی، استفاده از *GRU* امکان استخراج پویایی‌های کوتاه‌مدت و میان‌مدت را فراهم نمود و چارچوب نهایی توانست تعامل پیچیده میان ساختار شبکه و تغییرات زمانی را به‌صورت یکپارچه مدل‌سازی کند. تحلیل عملکرد مدل در افق‌های ۱۵، ۳۰ و ۶۰ دقیقه نشان داد که با افزایش افق پیش‌بینی، افت عملکرد تمامی مدل‌ها امری طبیعی است؛ با این حال، مدل *Enhanced GNN-GRU* افت ملایم‌تر و پایداری بیشتری را تجربه می‌کند. این موضوع بیانگر آن است که غنی‌سازی مکانی مدل، از انباشت خطا در پیش‌بینی‌های میان‌مدت جلوگیری کرده و قابلیت تعمیم مدل را تقویت می‌کند.

نتایج کمی نشان داد که چارچوب پیشنهادی *Enhanced GNN-GRU* در تمامی افق‌های زمانی و در هر دو شاخص  $ACC$  و امتیاز  $F_1$  عملکرد برتری نسبت به مدل‌های *GRU*، *LSTM* و نسخه پایه *GNN-GRU* دارد. اگرچه میزان بهبود عددی در بازه ۳ تا ۵ درصد قرار دارد، این افزایش به‌صورت سازگار در تمامی سناریوهای آزمایشی تکرار شده است که نشان‌دهنده پایداری اثر تقویت مکانی است. در مقیاس شبکه‌ای شامل بیش از پنج هزار قطعه معبر، چنین بهبودی می‌تواند منجر به کاهش قابل توجه خطاهای طبقه‌بندی در سطح شهری گردد و از منظر مدیریت ترافیک، دارای پیامد عملی معنادار باشد.

تحلیل رفتار مدل نشان می‌دهد که بیشترین بهبود در تفکیک کلاس‌های مرزی رخ داده است؛ جایی که مدل‌های صرفاً زمانی معمولاً دچار خطای طبقه‌بندی می‌شوند. این موضوع تأیید می‌کند که اطلاعات ساختاری شبکه در تشخیص الگوهای انتقال و انتشار ازدحام، نقش تعیین‌کننده دارد. بدین ترتیب، ارزش

هوشمند یا داده‌های رفتاری کاربران تلفیق شود. در نهایت، این پژوهش نشان می‌دهد که ارتقای هدفمند مدلسازی مکانی می‌تواند مسیر مؤثری برای بهبود عملکرد مدل‌های مکانی - زمانی باشد. ترکیب گراف دوگان، همسایگی چندمرتبه‌ای، شاخص‌های ساختاری و مدل‌سازی زمانی مبتنی بر GRU چارچوبی منسجم برای تحلیل و پیش‌بینی رفتار ترافیک در شبکه‌های شهری پیچیده فراهم می‌آورد و می‌تواند مبنایی برای توسعه نسل بعدی سامانه‌های پیش‌بینی ترافیک شهری هوشمند قرار گیرد. در مطالعات آتی، می‌توان ظرفیت‌های رویکرد پیشنهادی را از طریق توسعه مکانی شبکه و بهره‌گیری از اطلاعات مکمل گسترش داد. به‌طور خاص، ترکیب گراف دوگان با همسایگی‌های مرتبه بالاتر، نقش هر مولفه مکانی با بررسی جزء به جزء، شاخص‌های ساختاری پیشرفته‌تر شبکه و متغیرهای برون‌زا نظیر شرایط جوی، رخدادهای شهری و الگوهای تقاضای سفر می‌تواند به درک عمیق‌تر پویایی ترافیک و بهبود دقت پیش‌بینی منجر شود.

افزوده مدل *Enhanced GNN-GRU* صرفاً در افزایش عددی دقت خلاصه نمی‌شود، بلکه در ارتقای تبیین‌پذیری ساختاری و قابلیت تحلیل نقش توپولوژیک معابر نیز نمود می‌یابد.

از منظر نظری، یافته‌های این پژوهش بر این نکته تأکید دارند که کیفیت و چندمرتبه‌ای بودن مدلسازی مکانی، عامل تعیین‌کننده‌ای در موفقیت مدل‌های پیش‌بینی ترافیک است. مدل‌هایی که ساختار شبکه را به‌صورت ساده‌شده یا محدود به همسایگی مستقیم لحاظ می‌کنند، قادر به درک کامل منطق انتشار جریان نیستند. در مقابل، ادغام شاخص‌های توپولوژیک و روابط چندمرتبه‌ای، مدل را به سطحی از درک ساختاری ارتقا می‌دهد که امکان پیش‌بینی پایدارتر و قابل‌تعمیم‌تر را فراهم می‌سازد.

از منظر کاربردی، چارچوب پیشنهادی قابلیت استفاده در سامانه‌های مدیریت هوشمند ترافیک، تخصیص پویا منابع کنترلی، پیش‌بینی نقاط بحرانی بالقوه و پشتیبانی تصمیم‌گیری در مقیاس شبکه شهری را داراست. همچنین ساختار مدل این امکان را فراهم می‌کند که در آینده با داده‌های بلادرنگ، اطلاعات حسگرهای

## مراجع

- [1] J. N. Fadila, N. H. A. Wahab, A. Alshammari, A. Aqarni, A. Al-Dhaqm, and N. Aziz, "Comprehensive Review of Smart Urban Traffic Management in the Context of the Fourth Industrial Revolution," *IEEE Access*, vol. 12, pp. 196866–196886, 2024.
- [2] R. S. Koroth and V. Mohan C, "Real Time Traffic Congestion Prediction in Smart Cities," *International Research Journal on Advanced Engineering Hub (IRJAEH)*, vol. 3, pp. 4506–4515, 2025.
- [3] A. N. Tripathi and B. Sharma, "A Deep Review: Techniques, Findings and Limitations of Traffic Flow Prediction Using Machine Learning," in *Proceedings of the International Conference on Advances in Materials and Manufacturing*, Singapore, 2022.
- [4] F. Rempe, G. Huber, and K. Bogenberger, "Spatio-Temporal Congestion Patterns in Urban Traffic Networks," *Transportation Research Procedia*, vol. 15, pp. 513–524, 2016.
- [5] S. Rahmani, A. Baghbani, N. Bouguila, and Z. Patterson, "Graph Neural Networks for Intelligent Transportation Systems: A Survey," *IEEE Transactions on Intelligent Transportation Systems*, vol. 24, pp. 8846–8885, 2023.
- [6] C. Zhang and M. Lei, "A Survey on Spatio-Temporal Graph Neural Networks for Traffic Forecasting," in *Proc. IEEE International Conference on Data Mining Workshops (ICDMW)*, 2023.
- [7] X. Rao, H. Wang, L. Zhang, J. Li, S. Shang, and P. Han, "FOGS: First-Order Gradient

- Supervision with Learning-based Graph for Traffic Flow Forecasting,* in *Proceedings of the 31st International Joint Conference on Artificial Intelligence (IJCAI 2022)*, vol. 20, pp. 3926–3932, 2022.
- [8] R. Li, F. Zhang, T. Li, N. Zhang, and T. Zhang, “DMGAN: Dynamic Multi-Hop Graph Attention Network for Traffic Forecasting,” *IEEE Transactions on Knowledge and Data Engineering*, vol. 35, pp. 9088–9101, 2023.
- [9] H. F. Al-Selwi, A. A. Aziz, F. S. B. Abas, M. Y. Alias, et al., “Hybrid Spatiotemporal Graph Convolutional Network Enhanced with GRU for Traffic Forecasting,” in *Proc. 2025 Multimedia University Engineering Conference (MECON)*, 2025.
- [10] H. Chen, J. Huang, Y. Lu, and J. Huang, “Urban traffic flow prediction based on multi-spatio-temporal feature fusion,” *Neurocomputing*, vol. 638, pp. 130117, 2025.
- [11] W. Jiang, J. Luo, M. He, and W. Gu, “Graph Neural Network for Traffic Forecasting: The Research Progress,” *ISPRS International Journal of Geo-Information*, vol. 12, pp. 100, 2023.
- [12] Z. Xia, Y. Zhang, J. Yang, and L. Xie, “Dynamic spatial-temporal graph convolutional recurrent networks for traffic flow forecasting,” *Expert Systems with Applications*, vol. 237, pp. 121491, 2024.
- [13] M. Jiang and Z. Liu, “Traffic Flow Prediction Based on Dynamic Graph Spatial-Temporal Neural Network,” *Mathematics*, vol. 11, pp. 2528, 2023.
- [14] A. Sharma, A. Sharma, P. Nikashina, V. Gavrilenko, A. Tselykh, A. Bozhenyuk, M. Masud, and H. Meshref, “A Graph Neural Network (GNN)-Based Approach for Real-Time Estimation of Traffic Speed in Sustainable Smart Cities,” *Sustainability*, vol. 15, pp. 11893, 2023.
- [15] R. Xue, S. Zhao, and F. Han, “An Embedding-Driven Multi-Hop Spatio-Temporal Attention Network for Traffic Prediction,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 24, pp. 13192–13207, 2023.
- [16] Z. Teng et al., “Topology-Aware Road Extraction from Remote Sensing Images Using Deep Learning and Graph-Based Connectivity Refinement,” *ISPRS International Journal of Geo-Information*, vol. 15, pp. 208, 2026.
- [17] L. Peng, C. Li, W. Zhang, W. Yu, and T. Li, “Learning Dynamic and Multi-Scale Graph Structure for Traffic Demand Prediction,” *International Journal of Machine Learning and Cybernetics*, vol. 16, pp. 3177–3191, 2025.
- [18] A. Ali, R. Ali, M. Asad, L. Yang, T. Alsarhan, and X. Bai, “Exploiting attention-driven weather-aware multimodal spatio-temporal fusion for urban traffic flow prediction,” *Future Generation Computer Systems*, vol. 183, pp. 108559, 2026.
- [19] H. Wang, L. Zhang, R. Wu, and Y. Cen, “Spatio-temporal fusion of meteorological factors for multi-site PM2.5 prediction: A deep learning and time-variant graph approach,” *Environmental Research*, vol. 239, pp. 117286, 2023.
- [20] C. Huang, T. Guo, N. Yang, and C. Antoniou, “Augmenting Spatio-Temporal Dependencies for GNN-Based Short-Term Traffic Flow Prediction,” *Transportation Research Procedia*, vol. 95, pp. 592–599, 2026.
- [21] H. Zhong, J. Wang, C. Chen, J. Wang, D. Li, and K. Guo, “Weather interaction-aware spatio-temporal attention networks for urban traffic flow prediction,” *Buildings*, vol. 14, pp. 647, 2024.
- [22] S. Wang and P. Zhang, “Multi-level Temporal Feature Extraction and Cross-dimension Dynamic Interaction Network for Traffic Flow Prediction,” in *Proc. 2025 7th Int. Conf. Data-driven Optimization of Complex Systems (DOCS)*, 2025.
- [23] R. Liu, Z. He, and W. Sun, “Centrality-

- Enhanced Graph Learning for Large-Scale Transportation Networks,*” *Information Sciences*, vol. 660, p. 119890, 2024.
- [24] J. Kim, S. Park, and Y. Yoon, “Incorporating Graph Centrality into Spatial–Temporal Forecasting Models for Road Networks,” *Physica A: Statistical Mechanics and Its Applications*, vol. 627, p. 129240, 2023.
- [25] Y. Zhang, L. Wang, and Y. Chen, “Mixed-Graph Neural Networks for Dynamic Road-Segment Traffic Forecasting,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 26, pp. 3891–3905, 2025.
- [26] S. Li, J. Xu, and K. Zheng, “Graph-Based Traffic Forecasting with the Dynamics of Road Symmetry and Capacity Performance,” *Transportation Research Part C: Emerging Technologies*, vol. 158, p. 104380, 2024.
- [27] X. Sun, R. Xiong, D. Shen, and J. Luo, “Enhancing Network Traffic Prediction by Integrating Graph Transformer with a Temporal Model,” in *Proc. 9th Asia-Pacific Workshop on Networking*, 2025.
- [28] A. Concas, C. Fenu, L. Reichel, G. Rodriguez, and Y. Zhang, “Chained structure of directed graphs with applications to social and transportation networks,” *Applied Network Science*, vol. 7, pp. 64, 2022.
- [29] D. Zang, Z. Cui, Z. Wang, J. Lei, Y. Ding, C. Wei, and J. Zhang, “Geometric Algebra Multi-Order Graph Neural Network for Traffic Prediction,” *IEEE Transactions on Big Data*, vol. 11, pp. 1206–1220, 2024.
- [30] X. Liu, P. Luo, M. Rijal, M. Hu, and K. L. Chong, “Spatial Spillover Effects of Urban Agglomeration on Road Network with Industrial Co-Agglomeration,” *Land*, vol. 13, pp. 2097, 2024.
- [31] M. E. J. Newman, “Message Passing Methods on Complex Networks,” *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 479, pp. 20220774, 2023.
- [32] B. Zhang, S. Cheng, P. Wang, and F. Lu, “Inferring freeway traffic volume with spatial interaction enhanced betweenness centrality,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 129, pp. 103818, 2024.
- [33] X. Yang, L. Liu, Y. Li, and R. He, “Identifying critical links in urban traffic networks: A partial network scan algorithm,” *Kybernetes*, vol. 45, pp. 915–930, 2016.
- [34] Y. Zhang, W. Song, J. Sun, and P. Dai, “Accessibility measurement of highway transportation networks based on closeness-accessibility,” *PLOS ONE*, vol. 20, pp. 336928, 2025.
- [35] A. Chen, C. Yang, S. Kongsomsaksakul, and M. Lee, “Network-based Accessibility Measures for Vulnerability Analysis of Degradable Transportation Networks,” *Networks and Spatial Economics*, vol. 7, pp. 241–256, 2007.
- [36] M. Piraveenan and N. B. Saripada, “Transportation centrality: Quantifying the relative importance of nodes in transportation networks based on traffic modeling,” *IEEE Access*, vol. 11, pp. 142214–142234, 2023.
- [37] Y. Liu, L. Yu, and X. Mao, “Graph-Theory-Based Traffic Flow Assignment Model and Path Optimization for Urban Interchanges,” *Procedia Computer Science*, vol. 281, pp. 393–401, 2026.
- [38] H. Zhang, G. Lu, M. Zhan, and B. Zhang, “Semi-supervised classification of graph convolutional networks with Laplacian rank constraints,” *Neural Processing Letters*, vol. 54, pp. 2645–2656, 2022.
- [39] Z. Ye, Y. J. Kumar, G. O. Sing, F. Song, and J. Wang, “A comprehensive survey of graph neural networks for knowledge graphs,” *IEEE Access*, vol. 10, pp. 75729–75741, 2022.
- [40] J. Yan, H. Li, D. Zhang, et al., “A multi-feature spatial–temporal fusion network for

traffic flow prediction," *Scientific Reports*, vol. 14, pp. 14264, 2024.

- [41] S. Yang, H. Li, Y. Luo, J. Li, Y. Song, and T. Zhou, "Spatiotemporal adaptive fusion graph network for short-term traffic flow forecasting," *Mathematics*, vol. 10, pp. 1594, 2022.
- [42] K. Cho, B. van Merriënboer, D. Bahdanau, H. Schwenk, C. Gulcehre, and F. Bougares, "Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation," in *Proc. Conf. Empirical Methods in Natural Language Processing*, 2014.
- [43] Z. Chen, J. Lai, J. Zhu, W. Ma, L. Gan, and T. Xia, "Spatiotemporal-Enhanced Recurrent Neural Network for Network Traffic Prediction," in *Proc. IEEE Symp. Computers and Communications (ISCC)*, 2023.
- [44] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," in *Proc. Int. Conf. Learn. Representations (ICLR)*, 2015.
- [45] M. Fey and J. E. Lenssen, "Fast Graph Representation Learning with PyTorch Geometric," *arXiv preprint arXiv:1903.02428*, 2019.



## Spatiotemporal Traffic Prediction Using Graph Neural Network, Gated Recurrent Unit, with a Spatial Network Structure Approach

Fateme Noori Alamouti <sup>1\*</sup>, Mohammad Sadi Mesgari <sup>2</sup>

1- Phd student of Geospatial information system in Department of Geodesy and Geomatics Engineering , K. N. Toosi University of Technology  
2- Associate professor in Geospatial information system group , Department of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology

### Abstract

Optimal urban traffic management requires accurate and timely prediction of traffic conditions across the spatial-temporal scales, as congestion patterns within the urban road networks are governed by complex spatial interactions among the road segments as well as short- and long-term temporal dynamics. Therefore, the development of frameworks capable of concurrent capturing of the spatial and temporal dependencies plays a critical role in traffic forecasting and in supporting urban decision-making processes. In this study, a hybrid spatiotemporal framework that is based on Graph Neural Networks (GNN) and Gated Recurrent Units (GRU) is proposed for traffic state classification. The dataset consists of the road network of four urban districts of Tehran and the traffic conditions of 5,037 road segments recorded in 15-minute intervals over a three-month period. The road network is modeled as a directed graph and utilized as input to the graph neural network. To enhance the spatial modeling, in addition to the first-order adjacency matrix, the second-order neighborhood relationships and the key structural network measures—including betweenness centrality, closeness centrality, and weighted degree—are explicitly incorporated into the graph learning process.

The GNN extracts the spatial dependencies and structural interactions among road segments, and its output, together with the temporal sequences of the traffic states, is fed into the GRU to perform predictions over 15-, 30-, and 60-minute time horizons. The experimental results demonstrate that the proposed model (Enhanced GNN-GRU) consistently outperforms the baseline models, including GRU, LSTM, and the conventional GNN-GRU, across all of the prediction horizons. Specifically, the Enhanced GNN-GRU achieves an accuracy (ACC) of 0.76 and an F1-score of 0.67 for the 15-minute horizon, indicating a significant improvement over the baseline GNN-GRU model. This performance gain remains stable across longer forecasting horizons. The findings suggest that the explicit integration of the multi-order spatial dependencies and the structural network features substantially enhances the spatial representation learning, improves discrimination among different congestion levels, and increases prediction robustness over the extended time horizons, and it also highlights the critical role of road network topology in the urban traffic modeling and forecasting.

**Key words:** Traffic prediction, spatiotemporal models, network spatial structure, graph neural networks, recurrent units.

**Correspondence Address:** Geospatial information system Group, Department of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology, Tehran, Iran.

**Tel :** +98 9127893898

**Email:** Fateme.Noorialamooti@email.kntu.ac.ir