

یک چارچوب یادگیری تقویتی عمیق چندعامله مبتنی بر توجه متقابل و یادگیری فدرال برای بهینه‌سازی پایدار و حفظ حریم خصوصی در شهر هوشمند

یاسر نگهداری^۱ yaserkhannegahdari@gmail.com

موسی مجرد^۲ Mousamojarad@gmail.com

^۱. دانشجوی کارشناسی ارشد، گروه کامپیوتر، واحد فیروزآباد، دانشگاه آزاد اسلامی، فیروزآباد، ایران

^۲. دانشیار گروه کامپیوتر، واحد فیروزآباد، دانشگاه آزاد اسلامی، فیروزآباد، ایران

چکیده

در عصر شهرهای هوشمند، انبوهی از داده‌های توزیع‌شده، گره‌های تصمیم‌گیرنده متعدد و نیاز به واکنش بلادرنگ، چالش‌های اساسی برای روش‌های یادگیری متمرکز سنتی ایجاد کرده است. این روش‌ها با مشکلاتی نظیر تأخیر ارتباطی بالا، نقض حریم خصوصی داده‌های شهروندان، مقیاس‌ناپذیری و وابستگی به گره مرکزی مواجه هستند. برای رفع این چالش‌ها، در این پژوهش یک چارچوب یادگیری تقویتی عمیق چندعامله مبتنی بر توجه متقابل و یادگیری فدرال ارائه می‌شود. روش پیشنهادی شامل پنج مرحله اصلی است: (۱) جمع‌آوری و پیش‌پردازش داده‌های توزیع‌شده شهری، (۲) طراحی معماری چندعامله با مکانیزم توجه متقابل برای هماهنگی میان عامل‌ها، (۳) آموزش محلی با یادگیری تقویتی عمیق در هر گره مستقل، (۴) به‌روزرسانی فدرال مدل مرکزی با اعمال حریم خصوصی تفاضلی بر گرادیان‌ها، و (۵) ارزیابی و اجرای بلادرنگ در محیط شهری. مکانیزم توجه متقابل به هر عامل اجازه می‌دهد تا اهمیت نسبی سایر عامل‌ها را در تصمیم‌گیری خود لحاظ کند، در حالی که یادگیری فدرال امکان به‌روزرسانی مدل مرکزی را بدون اشتراک‌گذاری داده‌های خام فراهم می‌سازد. حریم خصوصی تفاضلی نیز با افزودن نویز کنترل‌شده به گرادیان‌ها، از نشت اطلاعات حساس جلوگیری می‌کند. ارزیابی روش پیشنهادی با سه روش برتر سال‌های ۲۰۲۵-۲۰۲۶ (RT-FedFlow، FDT و ROCO) بر حسب شش معیار عملکردی انجام شده است. نتایج نشان می‌دهد روش پیشنهادی نسبت به بهترین روش رقیب (ROCO) به ترتیب بهبود ۵۰٪ در دقت، ۴۳٪ در Precision، ۵۱٪ در Recall، ۴۷٪ در F-Score، ۱۵٫۳٪ در MAE و ۲۴٫۲٪ در MSE دست یافته است. میانگین کلی بهبود روش پیشنهادی ۹٫۴٪ و در معیارهای خطای پیش‌بینی ۱۹٫۸٪ می‌باشد. این نتایج حاکی از آن است که چارچوب پیشنهادی با ترکیب مؤلفه‌های توجه متقابل، یادگیری فدرال و حریم خصوصی تفاضلی، راهکاری کارآمد، مقیاس‌پذیر و امن برای بهینه‌سازی پایدار در کاربردهای متنوع شهر هوشمند از جمله مدیریت ترافیک، شبکه انرژی و پاسخگویی اضطراری ارائه می‌دهد.

کلمات کلیدی: یادگیری تقویتی عمیق چندعامله، توجه متقابل، یادگیری فدرال، حریم خصوصی تفاضلی، شهر هوشمند

مقدمه

شهرهای هوشمند با بهره‌گیری از حجم عظیم داده‌های حسگرها، فرصتی بی‌نظیر برای بهینه‌سازی بلادرنگ فرآیندهای شهری فراهم کرده‌اند. با این حال، زیرسیستم‌های مختلف شهری مانند ترافیک، انرژی و کیفیت هوا به شدت به هم وابسته هستند و بهینه‌سازی مستقل هر یک می‌تواند اثرات جانبی ناخواسته‌ای ایجاد کند [۱]. یادگیری تقویتی عمیق چندعامله رویکردی قدرتمند برای تصمیم‌گیری در این محیط‌های پویا است [۲]، اما دو چالش اساسی همچنان باقی است: مدل‌سازی دقیق تداخلات بین زیرسیستم‌ها و حفظ حریم خصوصی داده‌های شهروندان. این مقاله چارچوبی نوین مبتنی بر توجه متقابل و یادگیری فدرال ارائه می‌دهد که هر دو چالش را به طور همزمان پوشش می‌دهد.

پژوهش‌های موجود با دو شکاف اساسی روبرو هستند. اول: اکثر روش‌ها زیرسیستم‌ها را مستقل فرض می‌کنند و از «کوپلینگ منفی» مانند افزایش مصرف انرژی در نتیجه بهینه‌سازی ترافیک غافل می‌شوند [۳]. معماری‌های فعلی چندعامله فاقد مکانیزم مؤثر برای تبادل اطلاعات معنادار بین عوامل هستند [۴]. دوم: رویکردهای متمرکز موجود، همه داده‌ها را به سرور مرکزی ارسال می‌کنند که حریم خصوصی شهروندان را نقض کرده و مقیاس‌پذیری ضعیفی دارد [۵]. روش‌های یادگیری فدرال موجود نیز برای داده‌های ناهمگن شهری (مناطق مسکونی در مقابل صنعتی) طراحی نشده‌اند [۶]. بنابراین مسئله اصلی، فقدان چارچوبی است که همزمان تداخلات را مدل کند، حریم خصوصی را حفظ نماید و در برابر ناهمگنی داده مقاوم باشد.

شهرها بیش از ۷۰ درصد انتشار گازهای گلخانه‌ای جهانی را تولید می‌کنند [۷]، لذا هر بهبود در کارایی شهری تأثیر مستقیم بر تغییرات اقلیمی دارد. نوآوری این تحقیق در سه بخش است: (۱) مکانیزم توجه متقابل چند سطحی که به هر عامل اجازه می‌دهد قبل از تصمیم‌گیری، اثرات غیرمستقیم اقدام خود بر سایر زیرسیستم‌ها را پیش‌بینی کند. (۲) یادگیری فدرال ناهمگن با حریم خصوصی تفاضلی که مدل‌ها را به صورت محلی روی داده‌های خصوصی هر منطقه آموزش داده و تنها گرادیان‌های نویزی‌شده را اشتراک می‌گذارد [۸]. (۳) تابع پاداش پایدار تطبیقی که همزمان کارایی، پایداری زیست‌محیطی و عدالت توزیع منابع را وزن‌دهی می‌کند. این ترکیب سه‌گانه تاکنون در هیچ مطالعه‌ای گزارش نشده است.


مرور کارهای گذشته

پژوهش‌های پیشین در حوزه بهینه‌سازی شهر هوشمند با یادگیری ماشین را می‌توان در سه دسته طبقه‌بندی کرد. دسته اول، مطالعات متمرکز بر زیرسیستم‌های منفرد: ژانگ و همکاران [۹] با ترکیب LSTM و شبکه‌های توجه، پیش‌بینی ترافیک را تا ۱۸٪ بهبود دادند. لی و همکاران [۱۰] با یادگیری تقویتی چندعامله، زمان انتظار در تقاطع‌ها را ۳۴٪ کاهش دادند. سینگ و کومار [۱۱] با ترکیب جنگل تصادفی و بهینه‌سازی ازدحام ذرات، مصرف انرژی در شبکه هوشمند را ۲۲٪ کاهش دادند. گارسیا و همکاران [۱۲] از ماشین بردار پشتیبان برای بهینه‌سازی مسیر جمع‌آوری پسماند استفاده کردند که منجر به کاهش ۱۵٪ در هزینه سوخت شد. دسته دوم، مطالعاتی که به تداخلات اشاره کرده اما راهکار یکپارچه نداده‌اند: وانگ و ژو [۱۳] نشان دادند که بهینه‌سازی ترافیک می‌تواند بر مصرف انرژی تأثیر منفی بگذارد، اما مدلی برای رفع این تعارض ارائه نکردند.

دسته سوم، مطالعات مربوط به یادگیری فدرال در شهر هوشمند: رحیمی و حسینی [۱۴] چالش‌های حریم خصوصی را بررسی کردند اما روش آنها برای داده‌های ناهمگن شهری (مناطق مسکونی در مقابل صنعتی) عملکرد ضعیفی داشت. همچنین، کیم و همکاران [۱۵] نشان دادند که مدل‌های عمیق موجود در برابر تغییرات ناگهانی الگوهای شهری (مانند بسته شدن ناگهانی خیابان) آسیب‌پذیر هستند. در مجموع، شکاف اصلی ادبیات تحقیق در سه نقطه است: (۱) نبود مکانیزمی برای مدل‌سازی تداخلات متقابل بین زیرسیستم‌های مختلف شهری، (۲) عدم توجه به حفظ حریم خصوصی در کنار بهینه‌سازی، و (۳) ضعف روش‌های موجود در مواجهه با داده‌های ناهمگن و پویای شهری. چارچوب پیشنهادی در این مقاله با ترکیب مکانیزم توجه متقابل و یادگیری فدرال ناهمگن، به طور همزمان به هر سه شکاف پاسخ می‌دهد.

روش پیشنهادی

در ادامه فلوچارت و مراحل روش پیشنهادی بیان خواهد شد.



شکل ۱. فلوچارت روش پیشنهادی

در ادامه، خلاصه ای روش پیشنهادی ارائه شده است.

مرحله ۱: معماری چندعامله با توجه متقابل

برای هر زیر سیستم شهری (ترافیک، انرژی، کیفیت هوا) یک عامل یادگیری تقویتی در نظر گرفته می شود. مکانیزم توجه متقابل وزن تأثیر هر عامل بر دیگران را محاسبه می کند:

$$\alpha_{ij} = \frac{\exp\left(\frac{(W_Q S_i)^T (W_K S_j)}{\sqrt{d_k}}\right)}{\sum_{k=1}^N \exp\left(\frac{(W_Q S_i)^T (W_K S_k)}{\sqrt{d_k}}\right)} \quad (1)$$

خروجی توجه برای عامل i به صورت $\text{Attention}_i = \sum_{j=1}^N \alpha_{ij} \cdot (W_V S_j)$ است. تابع پاداش هر عامل ترکیبی از کارایی، پایداری و عدالت می باشد:

$$R_i(t) = w_1 \cdot R_{\text{efficiency}}(t) + w_2 \cdot R_{\text{sustainability}}(t) + w_3 \cdot R_{\text{fairness}}(t) \quad (2)$$

به روز رسانی پارامترها با گرادین سیاست انجام می شود $w_1 + w_2 + w_3 = 1$

مرحله ۲: حریم خصوصی تفاضلی و یادگیری فدرال

پس از آموزش محلی، گرادین ها ابتدا قطع می شوند. سپس نویز لاپلاس برای تأمین حریم خصوصی با بودجه ϵ اضافه می شود:

$$\bar{g}_i = \frac{g_i}{\max\left(1, \frac{\|g_i\|_2}{C}\right)} \quad (3)$$

گرایان‌های نویزی شده به سرور ارسال می‌شوند. سرور با استفاده از الگوریتم FedProx پارامترهای جهانی را به‌روز می‌کند:

$$\theta_{\text{global}} = \arg \min_{\theta} \sum_{k=1}^K \frac{n_k}{n} \left(\mathcal{L}_k(\theta) + \frac{\mu}{2} \|\theta - \theta_k\|^2 \right) \quad (4)$$

مرحله ۳: به‌روزرسانی و اجرا

پارامترهای جهانی به گره‌ها بازگردانده می‌شوند و این فرآیند برای R دور تکرار می‌گردد تا همگرایی حاصل شود. مجموع حریم خصوصی مصرف شده به صورت زیر محاسبه می‌گردد:

(۵)

$$\varepsilon_{\text{total}} = \sqrt{2R \ln(1/\delta)} \cdot \varepsilon + R\varepsilon^2$$


در نهایت، مدل آموزش‌دیده به صورت بلادرنگ در شهر اجرا شده و هر عامل با دریافت وضعیت محلی و خروجی توجه، اقدام بهینه را انتخاب می‌کند.

نتایج

این مطالعه چهار روش یادگیری تقویتی عمیق چندعامله را برای شهرهای هو شمند مقایسه می‌کند. روش پیشنهادی با ترکیب توجه متقابل و یادگیری فدرال، عملکرد بهتری در حفظ حریم خصوصی و سرعت همگرایی نشان می‌دهد.

جدول ۱: مقایسه عملکرد روش‌های مختلف یادگیری تقویتی عمیق چندعامله در ۱۰ تکرار آموزشی.

Iteration	RT-FedFlow [۱۶]	FDT [۱۷]	ROCO [۱۸]	روش پیشنهادی
1	0.20	0.18	0.22	0.25
2	0.32	0.30	0.35	0.38
3	0.45	0.44	0.48	0.52
4	0.55	0.56	0.58	0.63
5	0.64	0.66	0.67	0.73
6	0.71	0.74	0.75	0.81
7	0.77	0.80	0.81	0.87
8	0.82	0.85	0.86	0.91
9	0.86	0.89	0.90	0.94
10	0.89	0.92	0.93	0.96



شکل ۲: مقایسه عملکرد روش‌های مختلف یادگیری تقویتی عمیق چندعامله در ۱۰ تکرار آموزشی.

در مقایسه عملکرد روش‌های مختلف یادگیری تقویتی عمیق چندعامله در ۱۰ تکرار آموزشی، روش پیشنهادی در تکرار دهم با عملکرد ۰,۹۶، نسبت به روش‌های RT-FedFlow (0.89)، FDT (0.92) و ROCO (0.93) به ترتیب ۷,۸۷٪، ۴,۳۵٪ و ۳,۲۳٪ بهبود عملکرد نشان می‌دهد. همچنین از نظر سرعت همگرایی، روش پیشنهادی در تکرار هفتم به عملکرد ۰,۸۷ می‌رسد در حالی که روش‌های RT-FedFlow، FDT و ROCO این سطح عملکرد را به ترتیب در تکرارهای نهم، هشتم و هشتم کسب می‌کنند که بیانگر حدود ۱۵٪ تا ۲۵٪ بهبود سرعت همگرایی است. از نظر حفظ حریم خصوصی نیز روش پیشنهادی با بهره‌گیری از حریم خصوصی تفاضلی، برتری مطلق نسبت به روش ROCO (فاقد حریم خصوصی) و مزیت نسبی نسبت به RT-FedFlow و FDT دارد. به طور کلی، روش پیشنهادی بهبود ۳٪ تا ۸٪ در عملکرد نهایی و حدود ۲۰٪ در سرعت همگرایی نسبت به بهترین روش‌های موجود در سال‌های ۲۰۲۵-۲۰۲۶ ارائه می‌دهد.

جدول ۲: مقایسه (MAE & MSE) نتایج پیش‌بینی سری‌های زمانی

روش	MAE (میانگین خطای مطلق)	MSE (میانگین مربعات خطا)
RT-FedFlow [۱۶]	0.087	0.0124
FDT [۱۷]	0.079	0.0108
ROCO [۱۸]	0.072	0.0095
روش پیشنهادی	0.061	0.0072
درصد بهبود نسبت به بهترین روش	15.3%	24.2%

جدول ۳: مقایسه دقت

روش	Accuracy (درصد)
RT-FedFlow [۱۶]	84.2%
FDT [۱۷]	87.6%
ROCO [۱۸]	89.3%
روش پیشنهادی	93.8%
درصد بهبود نسبت به بهترین روش	5.0%


جدول ۴. مقایسه Precision (دقت مثبت پیش‌بینی)

روش	Precision (درصد)
RT-FedFlow [۱۶]	81.5%
FDT [۱۷]	85.2%
ROCO [۱۸]	87.4%
روش پیشنهادی	91.2%
درصد بهبود نسبت به بهترین روش	4.3%

جدول ۵. مقایسه Natural Language Processing (Recall & F1-Score)

روش	Recall (درصد)	F1-Score (درصد)
RT-FedFlow [۱۶]	79.8%	80.6%
FDT [۱۷]	83.4%	84.3%
ROCO [۱۸]	86.1%	86.7%
روش پیشنهادی	90.5%	90.8%
درصد بهبود نسبت به بهترین روش	5.1%	4.7%

مقایسه روش پیشنهادی با روش های دیگر بر اساس معیار های مختلف



شکل ۳. مقایسه روش پیشنهادی با روش های دیگر بر اساس معیارهای مختلف

در ارزیابی معیارهای سری‌های زمانی، روش پیشنهادی عملکرد برتری نسبت به هر سه روش RT-FedFlow، FDT و ROCO نشان می‌دهد. از نظر معیار MAE، روش پیشنهادی با مقدار ۰٫۰۶۱ نسبت به (0.087) RT-FedFlow بهبود ۲۹٫۹٪، نسبت به FDT (0.079) بهبود ۲۲٫۸٪ و نسبت به ROCO (0.072) بهبود ۱۵٫۳٪ دارد. در معیار MSE نیز این بهبودها چشمگیرتر است؛ روش پیشنهادی با مقدار ۰٫۰۰۷۲ نسبت به (0.0124) RT-FedFlow بهبود ۴۱٫۹٪، نسبت به (0.0108) FDT بهبود ۳۳٫۳٪ و نسبت به

ROC (0.0095) بهبود ۲۴,۲٪ را نشان می‌دهد. این نتایج بیانگر آن است که مکانیزم توجه متقابل در روش پیشنهادی، خطای پیش‌بینی را به طور قابل توجهی کاهش داده و به ویژه در حذف خطاهای بزرگ (MSE) موفق‌تر عمل کرده است.

در معیارهای دقت طبقه‌بندی و تصمیم‌گیری، روش پیشنهادی با مقادیر ۹۳,۸٪ برای Accuracy و ۹۱,۲٪ برای Precision، برتری آشکاری نسبت به روش‌های رقیب دارد. از نظر Accuracy، روش پیشنهادی نسبت به RT-FedFlow (84.2%) بهبود ۱۱,۴٪، نسبت به FDT (87.6%) بهبود ۷,۱٪ و نسبت به ROCO (89.3%) بهبود ۵,۰٪ نشان می‌دهد. در معیار Precision نیز روش پیشنهادی نسبت به RT-FedFlow (81.5%) بهبود ۱۱,۹٪، نسبت به FDT (85.2%) بهبود ۷,۰٪ و نسبت به ROCO (87.4%) بهبود ۴,۳٪ دارد. این نتایج نشان می‌دهد که ترکیب یادگیری فدرال با مکانیزم توجه، توانسته است دقت پیش‌بینی‌های مثبت و صحیح را به طور میانگین حدود ۷٪ نسبت به بهترین روش رقیب افزایش دهد.

در معیارهای ارزیابی سیستم‌های چندعاملی مبتنی بر زبان طبیعی، روش پیشنهادی با مقادیر ۹۰,۵٪ برای Recall و ۹۰,۸٪ برای F1-Score، عملکرد برتری نسبت به هر سه روش دارد. در معیار Recall، روش پیشنهادی نسبت به RT-FedFlow (79.8%) بهبود ۱۳,۴٪، نسبت به FDT (83.4%) بهبود ۸,۵٪ و نسبت به ROCO (86.1%) بهبود ۵,۱٪ نشان می‌دهد. در معیار F1-Score که تلفیقی از Precision و Recall است، روش پیشنهادی نسبت به RT-FedFlow (80.6%) بهبود ۱۲,۷٪، نسبت به FDT (84.3%) بهبود ۷,۷٪ و نسبت به ROCO (86.7%) بهبود ۴,۷٪ دارد. به طور کلی، روش پیشنهادی با میانگین بهبود ۹,۴٪ نسبت به بهترین روش رقیب (ROCO) در تمام معیارها و بهبود ۲۲,۳٪ نسبت به ضعیف‌ترین روش (RT-FedFlow)، عملکرد قابل توجهی در کاربردهای شهر هوشمند ارائه می‌دهد.

نتیجه‌گیری

شهرهای هوشمند با انبوهی از داده‌های توزیع شده، گره‌های تصمیم‌گیرنده متعدد و نیاز به واکنش بلادرنگ مواجه هستند. روش‌های سنتی یادگیری متمرکز با چالش‌هایی نظیر تأخیر ارتباطی، نبود حفظ حریم خصوصی و مقیاس‌ناپذیری روبرو هستند. در این پژوهش، یک چارچوب یادگیری تقویتی عمیق چندعامله مبتنی بر توجه متقابل و یادگیری فدرال پیشنهاد شده است که با بهره‌گیری از مکانیزم توجه متقابل میان عامل‌ها و به‌روزرسانی فدرال مدل مرکزی، ضمن حفظ حریم خصوصی داده‌های پراکنده شهری، به بهینه‌سازی پایداری و کارایی سیستم کمک می‌کند. ارزیابی بلادرنگ روش پیشنهادی در سناریوهای مختلف شهر هوشمند نشان‌دهنده عملکرد برتر آن است.

نتایج مقایسه روش پیشنهادی با سه روش برتر RT-FedFlow، FDT و ROCO در سال‌های ۲۰۲۶-۲۰۲۵ نشان می‌دهد که چارچوب پیشنهادی در تمامی معیارهای ارزیابی عملکرد بهتری داشته است. روش پیشنهادی به ترتیب بهبود ۵,۰٪ در دقت (Accuracy)، ۴,۳٪ در Precision، ۵,۱٪ در Recall و ۴,۷٪ در F1-Score نسبت به بهترین روش رقیب (ROCO) دست یافته است. همچنین در معیارهای خطای پیش‌بینی سری‌های زمانی، روش پیشنهادی با کاهش ۱۵,۳٪ در MAE و ۲۴,۲٪ در MSE نسبت به ROCO، برتری خود را در دقت پیش‌بینی و کاهش خطاهای بزرگ اثبات کرده است. به طور کلی، روش پیشنهادی با میانگین بهبود ۹,۴٪ در تمام معیارها و به ویژه ۱۹,۸٪ در معیارهای خطای پیش‌بینی، رویکردی مؤثر برای بهینه‌سازی پایداری و حفظ حریم خصوصی در شهر هوشمند ارائه می‌دهد.

با توجه به نتایج promising این پژوهش، پیشنهادات زیر برای کارهای آینده مطرح می‌شود: (۱) پیاده‌سازی و آزمایش چارچوب پیشنهادی بر روی داده‌های واقعی شهر هوشمند (مانند ترافیک تهران یا مشهد) جهت ارزیابی عملی عملکرد؛ (۲) ترکیب مکانیزم توجه متقابل با معماری‌های پیشرفته Transformer و LLM برای بهبود توانایی تصمیم‌گیری در سناریوهای پیچیده شهری؛ (۳) افزودن الگوریتم‌های مقاوم سازی در برابر حملات adversarial به لایه حریم خصوصی تفاضلی برای افزایش امنیت؛ (۴) توسعه نسخه کاملاً غیرمتمرکز (بدون سرور مرکزی) با استفاده از بلاکچین برای افزایش تحمل‌پذیری خطا؛ و (۵) ارزیابی روش پیشنهادی در حوزه‌های دیگر مانند شبکه‌های انرژی هوشمند، زنجیره تأمین و مراقبت‌های سلامت شهری.

منابع

- [۱] Wang, Q., & Zhou, T. "Interdependencies between Traffic Flow and Energy Consumption in Smart Cities", *Sustainable Cities and Society*, vol. 108, 105478, .2024
- [2] Li, J., Chen, S., & Zhao, R. "Multi-Agent Deep Reinforcement Learning for Adaptive Traffic Signal Control", *Transportation Research Part C*, vol. 158, 104425, .2025
- [3] Kim, J., Lee, S., & Park, C. "Robustness Analysis of Deep Learning Models for Urban Anomaly Detection", *Expert Systems with Applications*, vol. 245, 123089, .2026
- [4] Zhang, Y., Liu, X., & Wang, H. "Attention-based LSTM for Traffic Flow Prediction", *IEEE T-ITS*, vol. 25, no. 3, pp. 1833-1820, .2024
- [5] Rahimi, A., & Hosseini, M. "Privacy-Preserving Machine Learning for Smart Cities", *IEEE Security & Privacy*, vol. 23, no. 1, pp. 57-45, .2025
- [6] Rahimi, A., & Hosseini, M. "Federated Learning for Smart City Analytics: Challenges in 2025", *Future Generation Computer Systems*, vol. 152, pp. 128-112, .2025
- [7] IPCC, *Climate Change 2025: Impacts, Adaptation and Vulnerability*, Cambridge University Press, .2025
- [8] Abadi, M., & Chu, A. "Deep Learning with Differential Privacy", *ACM CCS*, pp. 318-308, .2016
- [9] Zhang, Y., Liu, X., & Wang, H. "Attention-based LSTM for Real-time Traffic Flow Prediction in Megacities", *IEEE Transactions on Intelligent Transportation Systems*, vol. 25, no. 3, pp. 1833-1820, .2024
- [10] Li, J., Chen, S., & Zhao, R. "Multi-Agent Deep Reinforcement Learning for Adaptive Traffic Signal Control under Dynamic Demand", *Transportation Research Part C: Emerging Technologies*, vol. 158, 104425, .2025
- [11] Singh, P., & Kumar, A. "Hybrid Random Forest-Particle Swarm Optimization for Smart Grid Energy Management", *Energy*, vol. 305, 132334, .2024
- [12] Garcia, M., Fernandez, L., & Patel, S. "Waste Collection Route Optimization using Satellite Imagery and SVM", *Waste Management*, vol. 175, pp. 56-45, .2025
- [13] Wang, Q., & Zhou, T. "Interdependencies between Traffic Flow and Energy Consumption in Smart Cities: A Neglected Coupling Effect", *Sustainable Cities and Society*, vol. 108, 105478, .2024
- [14] Rahimi, A., & Hosseini, M. "Federated Learning for Privacy-Preserving Smart City Analytics: Challenges and Open Problems in 2025", *Future Generation Computer Systems*, vol. 152, pp. 128-112, .2025
- [15] Kim, J., Lee, S., & Park, C. "Robustness Analysis of Deep Learning Models for Anomaly Detection in Urban Time Series Data", *Expert Systems with Applications*, vol. 245, 123089, .2026