

NEO: Aprendizado Federado com Meta-Aprendizado Dinâmico para Redes Veiculares

Carnot Braun¹, Rafael O. Jarczewski¹,
Joahannes B. D. da Costa², Allan M. de Souza¹

¹Instituto de Computação (IC)

Universidade Estadual de Campinas (UNICAMP), Campinas, Brasil

²Instituto de Ciência e Tecnologia (ICT)

Universidade Federal de São Paulo (UNIFESP), São José dos Campos, Brasil

{c255785, r200219}@dac.unicamp.br, joahannes.costa@unifesp.br,
allanms@unicamp.br

Resumo. As Redes Veiculares Ad Hoc (VANETs) permitem a comunicação direta entre veículos e a infraestrutura, contribuindo para a segurança e a eficiência do tráfego. No entanto, desafios como a alta mobilidade e as restrições computacionais dificultam a aplicação de técnicas de Aprendizado de Máquina (ML) nesse contexto. O Aprendizado Federado (FL) possibilita o treinamento distribuído de modelos preservando a privacidade dos dados, mas frequentemente exige um grande número de rodadas de comunicação para atingir uma boa convergência. Nesse sentido, este trabalho propõe uma abordagem adaptativa de Meta-Aprendizado Federado, baseada em Redes Convolucionais de Grafos (GCNs), para a previsão de tendências de velocidade em VANETs. A solução ajusta dinamicamente a intensidade do Meta-Aprendizado, otimizando a eficiência do treinamento e reduzindo a sobrecarga computacional. Resultados experimentais indicam que a abordagem reduz o erro preditivo em 5% e diminui o tempo de treinamento em 8%, quando comparada a outras abordagens do estado da arte, demonstrando-se uma alternativa viável para aplicações em VANETs com restrições de recursos.

Abstract. Vehicular Ad Hoc Networks (VANETs) enable direct communication between vehicles and infrastructure, contributing to traffic safety and efficiency. However, challenges such as high mobility and computational constraints hinder the application of Machine Learning (ML) techniques in this context. Federated Learning (FL) allows for the distributed training of models while preserving data privacy, but it often requires a large number of communication rounds to achieve good convergence. In this regard, this work proposes an adaptive Federated Meta-Learning approach based on Graph Convolutional Networks (GCNs) for predicting speed trends in VANETs. The proposed solution dynamically adjusts the intensity of Meta-Learning, optimizing training efficiency and reducing computational overhead. Experimental results indicate that the approach reduces prediction error by 5% and decreases training time by 8% when compared to other state-of-the-art methods, making it a viable alternative for resource-constrained VANET applications.

1. Introdução

As Redes Veiculares, ou *Vehicular Ad Hoc Networks* (VANETs) em inglês, possibilitam a comunicação entre veículos, bem como entre veículos e outras entidades, como infraestruturas de comunicação e semáforos inteligentes, por exemplo [de Souza et al. 2020].

Esse tipo de comunicação objetiva aprimorar a segurança viária, a eficiência do tráfego e proporcionar melhores experiências para os usuários [Al-shareeda et al. 2021]. No entanto, as características dinâmicas das VANETs, como a alta mobilidade dos nós, a rápida variação da topologia da rede, a intermitência das conexões e a restrição de recursos computacionais, tornam desafiadora a implementação de soluções eficientes baseadas em Aprendizado de Máquina, *Machine Learning (ML)* em inglês, nesse cenário [Tan et al. 2022].

Uma alternativa para implementar ML nas VANETs é utilizando o Aprendizado Federado (*Federated Learning (FL)*). O FL possibilita que veículos e infraestruturas colaborem no treinamento de modelos de ML sem a necessidade de compartilhar dados locais, garantindo assim a privacidade dos usuários [Wen et al. 2023, Souza et al. 2023]. Em um cenário veicular, o FL permite a colaboração entre os dispositivos distribuídos, melhorando a robustez e a generalização dos modelos de previsão ou detecção a partir de dados locais naturalmente heterogêneos. Porém, embora o FL se apresente como uma alternativa promissora para ambientes com alta mobilidade e limitações de comunicação, ele não resolve todas as questões complexas associadas às VANETs.

Embora o FL forneça uma plataforma para colaboração entre dispositivos, ele não consegue compreender totalmente a complexidade das VANETs, que envolvem variações rápidas e frequentes nos padrões de tráfego, falhas em sensores e a necessidade de adaptações rápidas e localizadas. O que se busca, portanto, é não apenas uma solução que distribua o treinamento, mas que também permita uma adaptação dinâmica aos desafios do ambiente, sem um consumo excessivo de recursos [He et al. 2022, de Souza et al. 2024]. Neste contexto, a modelagem baseada em grafos surge como uma abordagem para capturar e explorar as interações espaciais e temporais nas VANETs [Nayomi and Jyothsna 2024]. Especificamente as Redes Neurais Convolucionais de Grafos, ou *Graph Convolutional Networks (GCNs)* em inglês, são adequadas para modelar as relações entre veículos e infraestrutura, representando-os como nós em um grafo, enquanto as interações entre eles são modeladas por arestas. Essa abordagem é essencial para tarefas como previsão de velocidade ou fluxo de veículos, permitindo que o modelo entenda as dependências espaciais e temporais entre os veículos e os elementos de infraestrutura [Wu et al. 2021, Yu et al. 2018, Fei and Ling 2023].

No mesmo sentido, o Meta-Aprendizado (*Meta-Learning*) surge como uma solução promissora para enfrentar a necessidade de um aprendizado mais eficiente e com uma adaptação rápida em cenários como as VANETs. O *Meta-Learning* permite que os modelos aprendam a aprender, ou seja, buscam acelerar o processo de aprendizado, permitindo que os modelos se adaptem rapidamente a novas tarefas com um número reduzido de atualizações. O *Model-Agnostic Meta Learning (MAML)* e sua variante, *First-Order Model-Agnostic Meta Learning (FOMAML)*, são técnicas amplamente utilizadas nesse contexto. O FOMAML, por exemplo, simplifica o processo de cálculo de gradientes ao ignorar os gradientes de segunda ordem, tornando-o mais eficiente em termos computacionais e menos custoso em relação ao tempo de processamento, especialmente em cenários com a necessidade de aproveitar-se o tempo de conexão disponível para aprendizado, como os encontrados em dispositivos veiculares [Finn et al. 2017, Rajeswaran et al. 2019].

A combinação de FL com *Meta-Learning* oferece uma estratégia para lidar a adaptação de modelos de ML às condições dinâmicas das VANETs. No entanto, o uso de *Meta-Learning* pode ser custoso em termos de tempo de treinamento, o que pode agravar

ainda mais os desafios do FL em cenários com recursos limitados. Como abordado em trabalhos recentes [Chen et al. 2019, Chellapandi et al. 2024], a sobrecarga associada ao *Meta-Learning* pode ser um fator limitante, uma vez que o tempo adicional que o processo de aprendizado inicial toma ao adicionar-se uma camada a mais no treinamento.

Considerando aspectos discutidos acima, este trabalho introduz um mecanismo adaptativo e dinâmico que utiliza o *Meta-Learning* Federado com GCNs para a previsão de tendências de velocidade em VANETs, chamado **NEO** (*Nonstationary Environment Optimization*), o que reflete a proposta de adaptação dinâmica das amostras de aprendizado e a busca por se ajustar a cenários veiculares não estacionários. O NEO ajusta dinamicamente o nível de exploração dos dados locais (denominados meta-conjuntos, ou *meta-subsets* em inglês), ou seja, a quantidade de dados utilizada para o pré-treinamento inicial, durante cada rodada de treinamento, baseada no impacto da perda observada.

Os *meta-subsets* são importantes, visto que, como eles representam a quantidade de amostras utilizadas para o treinamento, a quantidade delas pode representar um grau de importância diferente para cada cenário, dada essa dinâmica de tráfego e características. Então, conseguir variar o quanto está sendo utilizado pode garantir aprendizados mais eficientes, tal qual, ao estudar para uma prova mais fácil, o aluno apenas revisa os assuntos, ao invés de estudar tudo desde a base. Tal estratégia garante que o modelo possa se especializar de forma eficiente em diferentes cenários de tráfego, sem sobrecarregar os dispositivos veiculares, ao utilizar quantidade de amostra não necessárias, ou seja, sem consumir um tempo maior que o necessário. Em situações que exigem maior capacidade adaptativa, como mudanças bruscas no fluxo de tráfego ou falhas de sensores, o sistema aumenta a intensidade do *Meta-Learning*. Por outro lado, em cenários com complexidade menores ou até mais simples, para o cenário veicular, momentos do dia em que o fluxo e a dinâmica dos carros é simples, ou seja, quando o modelo já apresenta bom desempenho, o sistema reduz o esforço computacional, equilibrando a adaptabilidade com a eficiência.

A principal contribuição desta proposta reside na implementação de um ajuste dinâmico do *meta-subset* a cada rodada de treinamento. Isso promove um aprendizado mais eficiente sem comprometer a precisão do modelo, ao contrário de abordagens tradicionais que utilizam *Meta-Learning* de forma fixa [You et al. 2024, Li and Wang 2022]. Nos experimentos realizados, foi utilizada a base de dados PEMS11, composta por informações coletadas por sensores instalados em vias urbanas. Esses sensores registram dados veiculares em determinadas ruas, que foram agrupadas em Unidades de Beira de Estrada, ou *Roadside Units (RSUs)* em inglês, com base em sua proximidade geográfica. Nesse contexto, o NEO demonstrou uma redução significativa no *RMSE*, e uma aceleração na convergência do modelo, com menor tempo de treinamento em comparação ao *baseline* (FL-LSTMGC tradicional) e ao FOMAML. Todos os resultados foram obtidos por meio de simulações, utilizando dados reais de tráfego, replicando condições de VANETs e analisando o impacto das abordagens comparadas.

O restante deste trabalho está organizado da seguinte forma. A Seção 2 revisa os principais trabalhos que integram GCN, *Meta-Learning* e FL no contexto de VANETs, destacando os desafios abordados e suas limitações. A Seção 3 apresenta em detalhes o NEO, descrevendo sua arquitetura, mecanismos de controle adaptativo e o fluxo de *Meta-Learning* Federado. A Seção 4 descreve e detalha os experimentos realizados para avaliar o desempenho, bem como apresenta uma discussão acerca dos resultados obtidos e os benefícios práticos da abordagem proposta. Por fim, a Seção 5 apresenta a conclusão e discute as limitações do estudo, além de direcionar para pesquisas futuras.

2. Trabalhos Relacionados

Esta seção apresenta inicialmente trabalhos que integram FL e GCNs no contexto da previsão de tráfego, destacando os desafios de escalabilidade e o elevado número de rodadas de comunicação necessárias para alcançar a convergência em cenários de larga escala. Em seguida, são discutidas pesquisas que incorporam *Meta-Learning* ao FL com GCNs, evidenciando seu potencial de adaptação a ambientes heterogêneos. Por fim, exploram-se estratégias que, de maneira análoga ao NEO, investigam ajustes dinâmicos de recursos e intensidade de aprendizagem – ou seja, a modulação dos hiperparâmetros do *Meta-Learning* – voltadas a cenários veiculares caracterizados por restrições de conectividade e capacidade computacional.

A combinação de FL e GCNs tem sido aplicada em diversos trabalhos de previsão de tráfego, dado que a modelagem em grafos permite capturar eficientemente as correlações espaciais e topológicas dos dados. Por exemplo, em [Wang et al. 2022, Qi et al. 2023], usuários de diferentes regiões participam do treinamento federado de um modelo GCN para prever fluxo de veículos, preservando a privacidade de seus dados locais. Embora esses estudos mostrem avanços significativos, observa-se que a obtenção de acurácia satisfatória pode demandar um grande número de rodadas de comunicação, sobretudo em cenários amplos e com maior heterogeneidade estatística. Esse fator motiva o desenvolvimento de estratégias que acelerem o processo de convergência e reduzam a sobrecarga de troca de parâmetros entre clientes e servidor em ambientes veiculares altamente dinâmicos.

Nos últimos anos, algumas pesquisas buscaram adicionar *Meta-Learning* ao contexto de FL com GCNs, com vistas a enfrentar tanto a heterogeneidade estatística quanto a adaptação rápida a novos nós ou regiões. Em [Li and Wang 2022], por exemplo, explora-se um modelo de *Meta-Learning* para previsão espaço-temporal com FL, evidenciando melhorias na adaptação dos nós a diferentes distribuições de dados. Já o trabalho de [Lee et al. 2023] propõe um mecanismo de geração de hiperparâmetros por *Meta-Learning*, visando ajustar estratégias de personalização para cada cliente, aliando a computação distribuída à flexibilidade de aprendizado por meta-modelos. Apesar desses avanços, ainda há oportunidades de explorar o balanceamento entre custo computacional e poder adaptativo, sobretudo quando os recursos computacionais variam de forma dinâmica no tempo ou entre veículos.

Alguns trabalhos focam em estratégias que ajustam dinamicamente a intensidade de aprendizado local ou a quantidade de recursos computacionais empregados, a fim de melhorar o desempenho em ambientes de conectividade e recursos limitados. Em [Feng et al. 2024], por exemplo, discute-se a necessidade de se adaptar a carga computacional durante o processo federado conforme a flutuação de tráfego ou falhas de sensores, apontando a relevância de ajustar o grau de participação dos nós no treinamento. Os trabalhos de [You et al. 2024] e [Li et al. 2024] sugerem mecanismos de atenção e ajustes dinâmicos de parâmetros para que cada nó (ou cliente) possa adequar o nível de personalização de acordo com sua complexidade local ou mudança repentina em padrões de tráfego, mas não abordam integralmente o aspecto do controle adaptativo federado e *meta-learning* de forma conjunta. Além disso, surgem propostas que variam a frequência de atualização local em função do histórico de perdas ou disponibilidade de recursos, evitando sobrecargas de processamento em nós com limitação de poder de computação ou restrições de conectividade.

Com base na análise do estado da arte, é possível observar que os trabalhos que

integram FL e GCNs no contexto de previsão de tráfego, em sua maioria, não abordam de forma eficaz os desafios relacionados à escalabilidade e ao elevado número de rodadas de comunicação necessárias para alcançar a convergência em cenários de larga escala. Algumas pesquisas mais recentes buscam mitigar essas limitações ao incorporar técnicas de *Meta-Learning* ao FL com GCNs, evidenciando maior capacidade de adaptação a ambientes heterogêneos. No entanto, essas abordagens ainda tendem a empregar configurações estáticas de aprendizagem, sem considerar a variabilidade do contexto veicular. Diferentemente dessas abordagens, nossa proposta explora precisamente o aspecto de ajustar dinamicamente o esforço de *Meta-Learning* federado com GCNs, com base na qualidade do aprendizado, levando em conta a perda local ou a variação do tráfego, mantendo, ao mesmo tempo, a escalabilidade e a eficiência computacional.

3. Proposta

O principal objetivo do NEO é oferecer uma estratégia eficaz e adaptativa para FL em VANETs atrelado ao *Meta-Learning*, garantindo um equilíbrio entre desempenho preditivo e custo computacional. Para isso, o NEO visa implementar um mecanismo adaptativo e dinâmico que ajusta continuamente a intensidade do aprendizado local para cada cliente. Nas próximas subseções, os principais componentes do NEO serão detalhados.

3.1. Definição do Problema

As VANETs possibilitam que veículos e infraestruturas fixas compartilhem dados para aprimorar a segurança e a eficiência do tráfego. No entanto, implementar FL nessas redes enfrenta desafios como alta mobilidade dos nós, conexões intermitentes, heterogeneidade dos dados locais e ineficiência na utilização dos recursos das RSUs [Valente et al. 2023]. Assim, torna-se fundamental desenvolver estratégias que reduzam o tempo necessário para a convergência do treinamento federado, tanto em termos de tempo de processamento quanto da taxa de convergência da perda.

Na proposta apresentada, introduzimos uma camada de pré-aprendizado via meta-learning, realizada no início de cada rodada, que ajusta os pesos iniciais dos modelos. Esse ajuste inicial permite que, ao incorporar novas tarefas, os modelos atinjam um estado mais próximo da convergência, reduzindo o número de rodadas necessárias e, consequentemente, o tempo total de processamento.

Nosso cenário é composto por $r_i \in R = \{r_1, r_2, \dots, r_m\}$ onde r representa uma RSU, cada uma possui um conjunto de dados d_i composto por uma tupla (x_i, y_i) , onde x_i representa os dados de fluxo e quantidade de veículos para RSU e y_i é a velocidade média dos carros ou seja, $D = \cup_{i \in R} d_i$. Sabendo que cada RSU possui um modelo w_i , podemos definir nosso modelo global w_g da seguinte forma.

$$w_g = \sum_{i=1}^{|R|} \frac{|d_i|}{|D|} w_i \quad (1)$$

Assim, o objetivo principal é minimizar a seguinte função objetivo $F(w_g)$

$$\min F(w_g) \text{ onde } F(w_g) = \sum_{i=0}^R \frac{|d_i|}{|D|} \mathcal{L}(w_g; x_i, y_i) \quad (2)$$

onde \mathcal{L} representa a função de perda do modelo para os dados da RSU.

Em suma, a definição do problema consiste em ajustar previamente os pesos dos modelos por meio do meta-learning, de forma que clientes com dados mais complexos consigam convergir para uma perda aceitável em menos rodadas, minimizando o tempo de processamento necessário para alcançar a convergência global, como é demonstrado na próxima subseção, que o NEO, visa resolver tais desafios.

3.2. Aprendizado Federado com *Meta-Learning* Dinâmico

O FL com *Meta-Learning* pode ser desafiador, especialmente quanto ao ajuste dinâmico da intensidade do aprendizado local. O *Meta-Learning* tradicional, exemplificado pelas abordagens MAML[Finn et al. 2017] e FOMAML[Nichol et al. 2018], opera em dois *loops* de treinamento: no *inner loop*, o modelo é treinado localmente com os dados do cliente para se adaptar rapidamente a novas tarefas; no *outer loop*, as atualizações locais de pesos são agregadas para ajustar globalmente os parâmetros iniciais. O MAML considera derivadas de segunda ordem para otimizar esse processo, buscando uma inicialização que minimize o esforço de adaptação, enquanto o FOMAML simplifica esse cálculo ao aproximar o meta-gradiente apenas pelas derivadas de primeira ordem, reduzindo significativamente o custo computacional sem comprometer substancialmente a eficiência de adaptação. A nossa proposta depende fortemente do FOMAML para balancear desempenho e sobrecarga de cálculo, aproveitando sua abordagem de primeira ordem para ajustar de forma dinâmica a intensidade do aprendizado local em cada cliente.

Além disso, cada treinamento de *Meta-Learning* possui um pequeno conjunto de dados da base tradicional, denominado *meta-subset*, que é a parte do treinamento destinada ao *Meta-Learning* e que se subdivide em conjuntos de suporte e *query*. Dessa forma, o cliente executa primeiramente o *Meta-Learning* com o *meta-subset* selecionado, ajustando os pesos do modelo de maneira adaptativa antes de proceder com o treinamento tradicional. Esse ajuste dinâmico visa melhorar a eficiência do aprendizado, equilibrando a precisão do modelo com o custo computacional.

Contudo, em vez de realizar uma atualização abrupta nos pesos durante o *outer loop*, como na abordagem clássica do FOMAML, o NEO faz um ajuste gradual nos pesos, ponderando-os por um fator de ponderação Ω_i , dado pela relação entre o tamanho do *meta-subset* utilizado por cada cliente ($|s_i|$) e o tamanho máximo permitido $|\mathcal{M}|$. Essa ponderação gradual permite uma atualização mais suave e proporcional dos pesos, ajustando o esforço computacional de cada cliente conforme seu desempenho de aprendizado. Como resultado, o processo de aprendizado se torna mais eficiente, evitando sobrecarga e permitindo que a adaptação do modelo seja feita de maneira mais equilibrada. A ponderação é obtida conforme Equação 3:

$$\Omega_i = \frac{|s_i|}{|\mathcal{M}|} \quad (3)$$

Além disso, diferente das outras abordagens, o NEO propõe a *seleção dinâmica do tamanho do meta-subset*. Nesse mecanismo, a quantidade de dados utilizados por cada cliente no treinamento é ajustada com base na métrica de desempenho local (como a perda). Clientes com desempenho superior passam a utilizar subconjuntos menores de dados, enquanto aqueles com desempenho inferior fazem uso de subconjuntos maiores, permitindo uma adaptação mais eficaz aos dados locais.

3.3. Visão Geral do NEO

A Figura 1 apresenta a arquitetura geral do NEO. O sistema é composto por um **servidor central**, responsável pela agregação dos pesos globais e pelo ajuste dinâmico do tamanho do *meta-subset* ($|s_k|$), e por diversas **RSUs** distribuídas, que atuam como clientes. Cada RSU emprega modelos baseados em GCNs e um mecanismo de *Meta-Learning* adaptativo para o treinamento local.

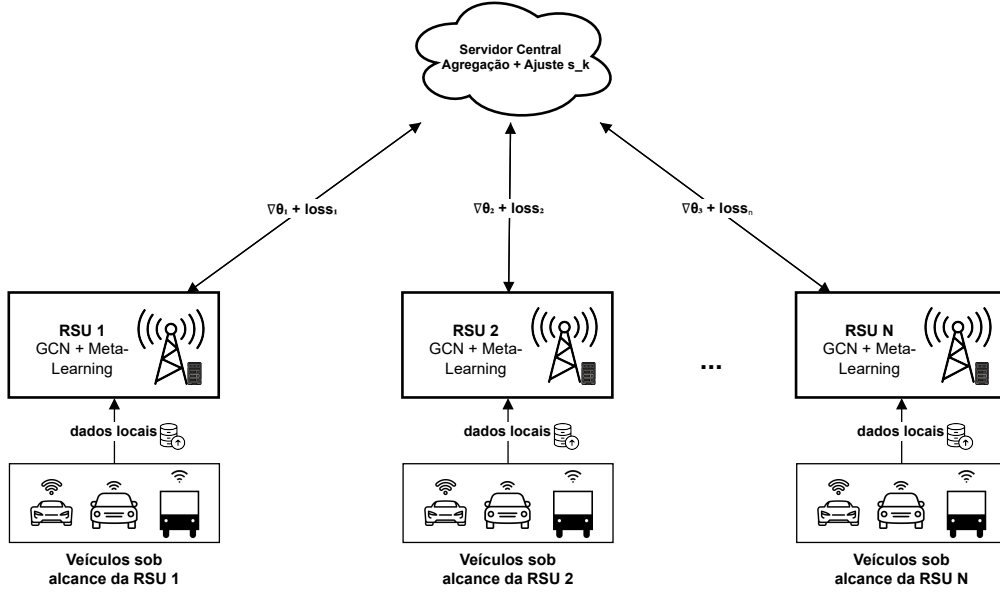


Figura 1. Overview da arquitetura do sistema proposto com *meta-learning* federado adaptativo.

Cada cliente coleta dados continuamente dos veículos em sua área de cobertura, tais como velocidade, direção, fluxo e estado do tráfego. Em cada rodada federada, ciclo de comunicação no qual o servidor envia o modelo global atualizado aos clientes, os clientes realizam o treinamento local com seus dados e enviam de volta seus pesos e perdas locais. Durante esse processo, o servidor envia aos clientes os parâmetros globais do modelo θ e o valor atualizado do *meta-subset* $|s_k|$. Os clientes treinam com o algoritmo de *Meta-Learning* localmente com um subconjunto de dados do tamanho definido (\mathcal{D}_{meta}), aplicam a ponderação pelo fator Ω_i , e seguem para a etapa tradicional de treinamento com seus pesos já atualizados, e depois retornam os pesos e perdas locais ao servidor.

Assim, esse processo de *feedback* contínuo permite ao servidor ajustar o esforço de pré-aprendizado na rodada seguinte, levando em conta o desempenho agregado das RSUs e, assim, balanceando o custo computacional com a taxa de convergência. Dessa forma, o NEO atenua o tempo excessivo que o *Meta-Learning* tradicional costuma introduzir, ao mesmo tempo em que mantém uma rápida convergência do modelo. Em particular, a **seleção dinâmica do *meta-subset*** e a **ponderação gradual dos pesos** são cruciais para alcançar eficiência e desempenho em cenários de FL em VANETs.

O Algoritmo 1 detalha o processo executado no servidor. O servidor coordena o processo federado distribuindo os parâmetros globais θ_t e controlando dinamicamente o tamanho do *meta-subset* $|s_i|$ para cada cliente. Cada cliente recebe o modelo global juntamente com o valor s_i , que determina a quantidade de dados que ele deverá utilizar

para o *Meta-Learning* (Linha 5). Esse procedimento é o que diferencia o NEO do FL tradicional: o *Meta-Learning* é executado no início de cada rodada (antes do treinamento local tradicional), ajustando os pesos do modelo com base em um subconjunto dos dados locais. Após esse passo inicial, o cliente realiza o treinamento tradicional utilizando o modelo já ajustado, o que significa que o esforço adaptativo é computado separadamente e antecipadamente. O servidor, então, agrega os pesos ponderados e atualiza o modelo global (Linha 9). A estratégia de ajuste, baseada na comparação entre a média das perdas atuais e a rodada anterior, permite aumentar ou reduzir $|s_i|$, conferindo maior ou menor influência ao cliente conforme seu desempenho (Linhas 10 a 14).

O Algoritmo 2 detalha os passos realizados pelos clientes no NEO. Cada cliente recebe o modelo global θ_t e o valor $|s_i|$ do servidor, determinando a quantidade de dados que será utilizada para o *Meta-Learning* (Linha 1). Na linha 2, o cliente seleciona exatamente $|s_i|$ amostras de seu conjunto local para formar o subconjunto \mathcal{D}_{meta} . O procedimento de meta-learning (linha 3) ocorre antes do treinamento tradicional, ajustando os pesos do modelo local com base nesse subconjunto e preparando o modelo para o treinamento posterior. Após o meta-learning, o cliente calcula os pesos e a perda local (linha 4) e envia essas informações para o servidor (linha 5), de forma que o impacto do esforço adaptativo possa ser considerado na atualização global. Esse fluxo distingue-se do FL tradicional, pois o meta-learning, que ajusta os pesos antes do treinamento completo, é executado a cada rodada, garantindo que o modelo local seja refinado de acordo com a quantidade de dados definida dinamicamente.

Algorithm 1 Servidor - FL com Meta-Learning Adaptativo

```

1: Input: Parâmetros iniciais do modelo global  $\theta$ , tamanho inicial do meta-subset  $s_i$ 
2: Output: Modelo global  $\theta$ 
3: Inicializar last_loss_mean  $\leftarrow$  None
4: for cada rodada de treinamento  $t$  do
5:   for cada cliente  $i$  do
6:     Enviar  $\theta_t$  e  $s_i$  ao cliente  $i$ 
7:   for cada cliente  $i$  do
8:     Receber  $\nabla\theta_i$  e perda local  $l_i$ 
9:   Calcular  $\mathcal{M} \leftarrow \max_i(|s_i|)$ 
10:  Atualizar modelo:  $\theta_{t+1} = \theta_t - \eta \cdot \sum_i \left( \frac{|s_i|}{\mathcal{M}} \cdot \nabla\theta_i \right)$ 
11:  Calcular média de perdas  $loss\_mean = \frac{1}{N} \sum_i l_i$ 
12:  if  $loss\_mean > 1.10 \cdot last\_loss\_mean$  then
13:    Aumentar  $|s_i|$  (até limite)
14:  else if  $loss\_mean < threshold\_loss$  then
15:    Reduzir  $|s_i|$  (até limite)
16:  Atualizar last_loss_mean  $\leftarrow loss\_mean$ 

```

De maneira geral, o NEO apresenta uma abordagem inovadora ao integrar o *Meta-Learning* adaptativo no fluxo tradicional do FL, ajustando dinamicamente o esforço de cada cliente e proporcionando um equilíbrio entre desempenho preditivo e eficiência computacional.

4. Avaliação de Desempenho

Esta seção descreve a metodologia e as métricas utilizadas para avaliar a eficiência do NEO em comparação com outras abordagens do estado da arte de FL. Além disso, apre-

Algorithm 2 Cliente - Meta-Learning Adaptativo com Ponderação

- 1: **Input:** Modelo global θ_t , valor de $|s_i|$ recebido do servidor
 - 2: Selecionar $\mathcal{D}_{meta} \subseteq \mathcal{D}_{local}$ com $|\mathcal{D}_{meta}| = |s_i|$
 - 3: Executar meta-learning local sobre \mathcal{D}_{meta}
 - 4: Calcular pesos $\nabla\theta_i$ e perda local l_i sobre o *meta-subset*
 - 5: Enviar $\nabla\theta_i$ e l_i ao servidor
 - 6: **Output:** Peso local e perda local
-

senta e discute os resultados obtidos. A análise abrange a eficácia do método dinâmico de *Meta-Learning* proposto, bem como sua eficiência em termos de tempo de treinamento e desempenho preditivo.

4.1. Metodologia

Para a avaliação de desempenho, o NEO foi comparado a duas outras abordagens, a saber: FL-LSTMGC e FOMAML. A solução *baseline* corresponde ao FL-LSTMGC tradicional [Yu et al. 2018], que utiliza uma arquitetura básica de FL com LSTMGC sem qualquer adaptação ou *Meta-Learning*. Esse modelo emprega duas camadas LSTM (*Long Short-Term Memory*), cada uma com 24 unidades, seguidas por uma camada densa que ajusta a saída ao número de nós do grafo, mantendo a integridade dimensional por meio de agregação média e concatenação. A abordagem FOMAML integra o *Meta-Learning* de primeira ordem ao treinamento federado tradicional, visando aprimorar a adaptação do modelo em ambientes dinâmicos, embora sem oferecer um controle adaptativo.

Além disso, cada RSU (representando um cliente no processo federado) possui seu próprio grafo local, que é utilizado para modelar as interações espaciais entre os veículos na área de cobertura da RSU. Em nosso estudo, a delimitação geográfica de cada RSU foi determinada por meio de um agrupamento das coordenadas dos pontos de coleta utilizando o algoritmo *K-Means*. Assim, cada RSU representa uma zona definida pela proximidade geográfica dos dados. Devido à distribuição das vias, constatou-se que uma das RSUs precisou abranger uma área maior para incluir todos os pontos de coleta correspondentes, resultando em um raio efetivo superior aos demais.

A estrutura do grafo global é composta pelas interações entre essas RSUs, sendo as conexões entre elas modeladas por meio de GCNs. A base de dados utilizada nos experimentos é a PEMS11 [California Department of Transportation (Caltrans) 2025], amplamente empregada em tarefas de previsão de tráfego. Os dados originais foram pré-processados e segmentados geograficamente para representar o cenário veicular distribuído. Para isso, utilizamos metadados com as coordenadas de cada estação de coleta, permitindo aplicar o algoritmo *K-Means* para agrupar os pontos em 10 zonas distintas, cada uma correspondendo a uma RSU.

A segmentação foi conduzida como se segue. Inicialmente, os dados de tráfego foram processados em blocos, com as coordenadas extraídas e armazenadas. Em seguida, o algoritmo *K-Means* agrupou todas as coordenadas com base em sua proximidade geográfica, formando 10 *clusters*. Após a clusterização, os dados de cada grupo foram salvos em arquivos separados, representando as diferentes RSUs utilizadas no treinamento federado.

A Figura 2 ilustra a segmentação realizada. Cada ponto representa uma medição de velocidade média, colorida de acordo com sua intensidade, enquanto os círculos deli-




Figura 2. Dispersão geográfica das medições de velocidade média com divisão em zonas de cobertura por RSU.

mitam as zonas geográficas associadas a cada RSU. Essa representação evidencia a heterogeneidade espacial e de tráfego, mostrando que os limites das RSUs variam conforme a dispersão dos dados. Cada RSU atua, assim, como um nó de aprendizado local, capturando o comportamento do tráfego em sua região específica. A modelagem local por meio de GCNs possibilita a extração de padrões espaciais relevantes em cada zona, enquanto a coordenação global via FL consolida um modelo robusto e generalizável para todo o sistema veicular.

As métricas consideradas para avaliação de desempenho foram o MSE (*Mean Squared Error*) e o MAE (*Mean Absolute Error*). O MSE reflete a diferença quadrática média entre as previsões e os valores reais, enquanto o MAE mensura a diferença média absoluta, sendo menos sensível a *outliers*. O treinamento conta com a técnica de *Early Stopping (EA)*, a qual interrompe o processo assim que a convergência é atingida. Embora a abordagem proposta inclua uma etapa adicional de *Meta-Learning*, os experimentos demonstraram que o EA acelera a convergência, resultando em um tempo total de processamento inferior ao observado no *baseline*. Quando o EA é desabilitado, o tempo de treinamento do NEO torna-se superior ao do *baseline*, porém ainda permanece inferior ao do FOMAML. Isso evidencia que o ganho temporal proporcionado pelo NEO está diretamente relacionado à sua capacidade de acelerar o processo de convergência durante o treinamento.

4.2. Resultados

A Figura 3 apresenta a evolução da perda (*loss*) em relação ao tempo de treinamento total para as abordagens consideradas. O NEO apresentou uma redução mais rápida da perda ao longo das rodadas em comparação com o FOMAML, ao atingir a convergência desde a rodada 13 enquanto o FOMAML atinge na rodada 40, considerando 50 rodadas. Isso confirma que a estratégia de *Meta-Learning* dinâmico proposta acelera a convergência do modelo, mantendo a precisão. A capacidade de ajustar dinamicamente o *meta-subset* de cada cliente, considerando seu desempenho local, facilita essa aceleração, tornando o processo de aprendizado mais eficiente.

A Figura 4 apresenta o tempo de treinamento total das abordagens considera-

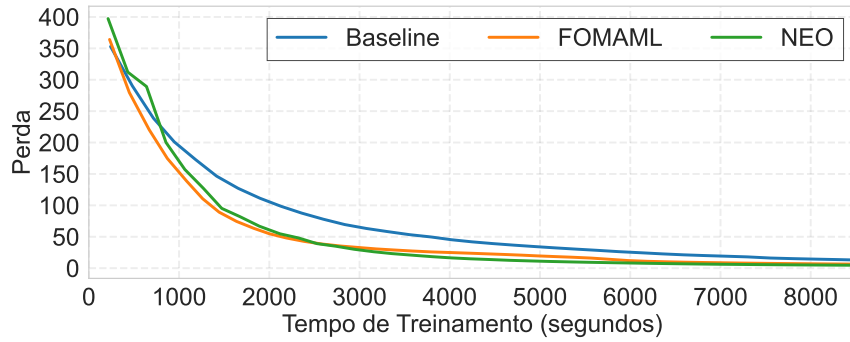


Figura 3. Evolução da perda (*loss*) por rodada para as abordagens comparadas: Baseline, FOMAML e NEO.

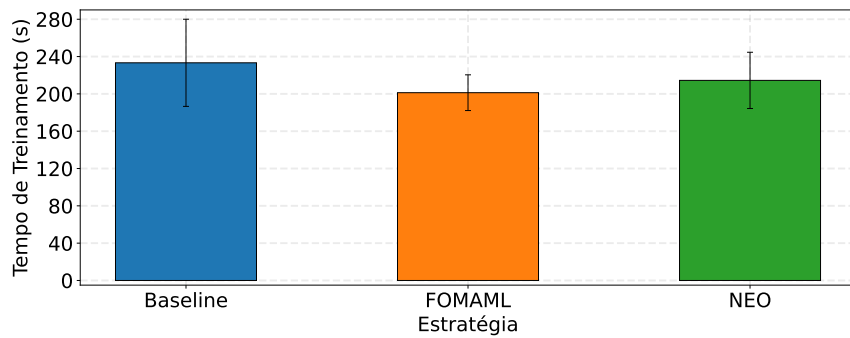


Figura 4. Resultados de tempo de treinamento médio para as abordagens consideradas.

das. Pode-se notar que apesar do tempo da proposta não superar o do FOMAML (que por sempre usar um tamanho padrão de *meta-subset* não possui variância no tempo de processamento), em totalidade, ele ainda sim consegue superar o tempo do *baseline*, atrelado ao fato, de que apesar de NEO envolver uma etapa extra de *Meta-Learning*, ainda assim é uma abordagem que atinge a convergência em um menor tempo. O comportamento de NEO demonstra um processo de aprendizado mais eficiente, que requer menos tempo total de treinamento para alcançar uma perda baixa em comparação ao *baseline* e FOMAML. Esse comportamento é um reflexo direto da personalização adaptativa da exploração local proposta pela NEO, que ajusta o *meta-subset* de forma dinâmica, acelerando a convergência.

De maneira geral, os resultados indicam que a NEO favorece um equilíbrio entre a redução da perda e a eficiência temporal, tornando-se uma abordagem promissora para redes veiculares com restrições computacionais. A proposta reduziu a perda com menos rodadas de treinamento em comparação com o FOMAML em 5%, ao mesmo tempo em que apresentou um tempo de treinamento total inferior ao do *baseline*, em cerca de 8%, devido ao ajuste dinâmico do *meta-subset*. Esse comportamento sugere que uma abordagem adaptativa pode contribuir para otimizar o processo de aprendizado, reduzindo o custo computacional sem comprometer a evolução do modelo.

A Figura 5 apresenta os valores de RMSE (*Root Mean Square Error*) para cada RSUs, comparando o desempenho das abordagens. Com ela, podemos perceber que o desempenho das estratégias varia conforme as características locais de cada RSU. Em RSUs como a 2 e a 14, por exemplo, a estratégia NEO apresenta valores significativa-

mente menores de RMSE, sugerindo que o ajuste dinâmico do *meta-learning* melhora a previsão nessas regiões. Por outro lado, em RSUs 4, 5, 6 e 10, a abordagem FOMAML obtém os melhores resultados, enquanto na RSU 9 o modelo tradicional (baseline) supera as demais. Essa variação indica que a eficácia do método de *meta-learning* adaptativo depende fortemente da heterogeneidade dos dados locais e das condições específicas de cada RSU, reforçando a necessidade de um mecanismo de ajuste dinâmico para equilibrar a precisão preditiva e o custo computacional em ambientes veiculares.

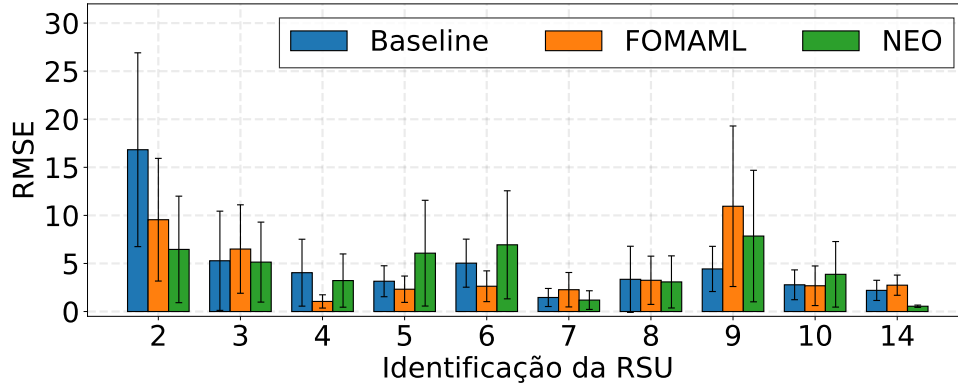


Figura 5. Resultados de *Root Mean Square Error (RMSE)* médio (com desvio padrão) por *Roadside Unit (RSU)* para as estratégias consideradas.

Os experimentos indicam que, em condições controladas, a NEO alcançou um equilíbrio satisfatório entre tempo de processamento e desempenho preditivo. Embora os ganhos não sejam expressivos em valores absolutos, o objetivo principal era demonstrar que a perda converge em um tempo menor que o baseline e, sobretudo, antes do FOMAML, este que foi escolhido pela sua eficiência computacional. Os cenários avaliados abrangem operações em ambientes veiculares urbanos, com variações de fluxo em horários de pico e fora de pico, bem como aplicações em rodovias de tráfego intenso, onde a capacidade de convergir rapidamente é essencial. Esses resultados reforçam a viabilidade da abordagem para cenários veiculares, nos quais otimizar o trade-off entre qualidade de modelo e custo computacional é fundamental.

5. Conclusão

Este artigo propôs uma abordagem inovadora de *Meta-Learning* federado adaptativo para otimizar o aprendizado em VANETs. A principal inovação da proposta é a adaptação dinâmica do tamanho do *meta-subset*, o que permite uma exploração local mais eficiente dos dados, equilibrando custo computacional e desempenho preditivo. Os experimentos demonstraram que a abordagem oferece ganhos em eficiência temporal e desempenho preditivo. Comparada a outras abordagens do estado da arte, a proposta foi capaz de reduzir a perda (*loss*) de forma mais rápida e com bom tempo de treinamento, além de ponderar corretamente o emprego da convergência do *Meta-Learning*. A personalização adaptativa do *meta-subset* permitiu uma convergência mais eficiente, confirmando que a adaptação local pode acelerar o processo de aprendizado em ambientes federados.

Como trabalhos futuros, pretende-se incluir a integração de técnicas avançadas de FL, como a seleção de clientes conforme sua necessidade ou disponibilidade de recursos, para lidar com cenários ainda mais dinâmicos e desafiadores. Além disso, a aplicação da proposta em outros contextos de redes de comunicação, como Rede 5G e Internet das

Coisas (IoT), pode ampliar o impacto da solução, explorando diferentes tipos de conectividade e padrões de dados em tempo real.

6. Agradecimentos

Este projeto foi apoiado pelo Ministério da Ciência, Tecnologia e Inovações, com recursos da Lei nº 8.248, de 23 de outubro de 1991, no âmbito do PPI-SOFTEX, coordenado pela Softex e publicado Arquitetura Cognitiva (Fase 3), DOU 01245.003479/2024-10. Este trabalho foi parcialmente patrocinado pelo projeto #23/00673-7, Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), CNPq projeto #405940/2022-0 e CAPES projeto #88887.954253/2024-00 e FAEPEX/PIND UNICAMP projeto #519.287

Referências

- Al-shareeda, M. A., Alazzawi, M. A., Anbar, M., Manickam, S., and Al-Ani, A. K. (2021). A comprehensive survey on vehicular ad hoc networks (vanets). In *2021 International Conference on Advanced Computer Applications (ACA)*, pages 156–160.
- California Department of Transportation (Caltrans) (2025). PeMS data source. <https://dot.ca.gov/programs/traffic-operations/mpr/pems-source>. Acesso em: 31 mar. 2025.
- Chellapandi, V. P., Yuan, L., Brinton, C. G., Żak, S. H., and Wang, Z. (2024). Federated learning for connected and automated vehicles: A survey of existing approaches and challenges. *IEEE Transactions on Intelligent Vehicles*, 9(1):119–137.
- Chen, F., Luo, M., Dong, Z., Li, Z., and He, X. (2019). Federated meta-learning with fast convergence and efficient communication.
- de Souza, A. M., Braun, T., Botega, L. C., Villas, L. A., and Loureiro, A. A. F. (2020). Safe and sound: Driver safety-aware vehicle re-routing based on spatiotemporal information. *IEEE Transactions on Intelligent Transportation Systems*, 21(9):3973–3989.
- de Souza, A. M., Maciel, F., da Costa, J. B., Bittencourt, L. F., Cerqueira, E., Loureiro, A. A., and Villas, L. A. (2024). Adaptive client selection with personalization for communication efficient federated learning. *Ad Hoc Networks*, 157:103462.
- Fei, X. and Ling, Q. (2023). Attention-based global and local spatial-temporal graph convolutional network for vehicle emission prediction. *Neurocomputing*, 521:41–55.
- Feng, X., Sun, H., Liu, S., Guo, J., and Zheng, H. (2024). Federated meta-learning on graph for traffic flow prediction. *IEEE Transactions on Vehicular Technology*, 73(12):19526–19538.
- Finn, C., Abbeel, P., and Levine, S. (2017). Model-agnostic meta-learning for fast adaptation of deep networks.
- He, Y., Wang, Y., Lin, Q., and Li, J. (2022). Meta-hierarchical reinforcement learning (mhrl)-based dynamic resource allocation for dynamic vehicular networks. *IEEE Transactions on Vehicular Technology*, 71(4):3495–3506.
- Lee, R., Kim, M., Li, D., Qiu, X., Hospedales, T., Huzár, F., and Lane, N. D. (2023). Fedl2p: Federated learning to personalize.
- Li, N., Zhao, S., Feng, Y., and Han, F. (2024). Mgsta : Meta learning based graph convolutional stacked temporal attention neural network for traffic flow forecasting. In *2024 International Joint Conference on Neural Networks (IJCNN)*, pages 1–8.

- Li, W. and Wang, S. (2022). Federated meta-learning for spatial-temporal prediction. *Neural Computing and Applications*, 34(13):10355–10374.
- Nayomi, B. D. and Jyothsna, V. (2024). A comprehensive survey on deep learning for enhanced node position prediction in vehicular ad-hoc networks. In *2024 4th International Conference on Ubiquitous Computing and Intelligent Information Systems (ICUIS)*, pages 602–609.
- Nichol, A., Achiam, J., and Schulman, J. (2018). On first-order meta-learning algorithms.
- Qi, T., Chen, L., Li, G., Li, Y., and Wang, C. (2023). Fedagcn: A traffic flow prediction framework based on federated learning and asynchronous graph convolutional network. *Applied Soft Computing*, 138:110175.
- Rajeswaran, A., Finn, C., Kakade, S., and Levine, S. (2019). Meta-learning with implicit gradients.
- Souza, A., Bittencourt, L., Cerqueira, E., Loureiro, A., and Villas, L. (2023). Dispositivos, eu escolho vocês: Seleção de clientes adaptativa para comunicação eficiente em aprendizado federado. In *Anais do XLI Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*, pages 1–14, Porto Alegre, RS, Brasil. SBC.
- Tan, K., Bremner, D., Le Kernec, J., Zhang, L., and Imran, M. (2022). Machine learning in vehicular networking: An overview. *Digital Communications and Networks*, 8(1):18–24.
- Valente, R., Senna, C., Rito, P., and Sargento, S. (2023). Embedded federated learning for vanet environments. *Applied Sciences*, 13(4).
- Wang, H., Zhang, R., Cheng, X., and Yang, L. (2022). Federated spatio-temporal traffic flow prediction based on graph convolutional network. In *2022 14th International Conference on Wireless Communications and Signal Processing (WCSP)*, pages 221–225.
- Wen, J., Zhang, Z., Lan, Y., Cui, Z., Cai, J., and Zhang, W. (2023). A survey on federated learning: challenges and applications. *International Journal of Machine Learning and Cybernetics*, 14(2):513–535.
- Wu, Z., Pan, S., Chen, F., Long, G., Zhang, C., and Yu, P. S. (2021). A comprehensive survey on graph neural networks. *IEEE Transactions on Neural Networks and Learning Systems*, 32(1):4–24.
- You, L., Chen, Q., Qu, H., Zhu, R., Yan, J., Santi, P., and Ratti, C. (2024). Fmgcn: Federated meta learning-augmented graph convolutional network for ev charging demand forecasting. *IEEE Internet of Things Journal*, 11(14):24452–24466.
- Yu, B., Yin, H., and Zhu, Z. (2018). Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting. In *Proceedings of the 27th International Joint Conference on Artificial Intelligence (IJCAI)*.