

Monitoramento Rodoviário Inteligente via Redes Privativas e Satélite LEO: Uma Abordagem com SLMs e Aprendizado de Máquina Federado na Borda em Arquitetura Distribuída

César Ueler*, Dennis Portugal*, Eduardo Notari*, Gabriel Theodoro*, Kelly Teixeira*, Klinger Carneiro*,
Nadia Nassif†, Rodolfo Costa†

*{cesarueler, dennis.giancarlo.06, edunotari, aquino.theodoro, kelly.txr, klingercj}@gmail.com, †{nadia, rodolfo.costa}@cpqd.com.br

Resumo— Este artigo propõe e valida uma arquitetura de monitoramento rodoviário inteligente que integra redes privativas 5G, satélites de órbita baixa como infraestrutura de *backhaul* e *Edge AI* com Aprendizado Federado, endereçando as lacunas de cobertura em 6,6 mil quilômetros de rodovias federais brasileiras. Ao substituir o streaming de vídeo bruto pelo compartilhamento de gradientes de modelos *Small Language Models* processados localmente nas *Roadside Units*, a arquitetura reduz em até 96% o tráfego de dados, viabilizando o monitoramento contínuo mesmo em trechos com conectividade intermitente e enlaces satelitais de banda limitada. A proposta foi validada em ambiente laboratorial do Centro de Pesquisa e Desenvolvimento em Telecomunicações, com *backhaul* Starlink e Core 5G C2n, e complementada por um estudo de telemetria orbital comparativo entre a SP340 Região Metropolitana de Campinas (19,8 satélites/amostra) e a BR230 Transamazônica (12,1 satélites/amostra), confirmando a viabilidade técnica da solução mesmo em contextos assimétricos de cobertura satelital. Do ponto de vista regulatório, a arquitetura atende à Lei Geral de Proteção de Dados por construção: como o processamento de vídeo.

Palavras-Chave— Aprendizado Federado, Edge AI, Redes Privativas, Computação de Borda, Satélites LEO, Redes Não Terrestres, 4G, 5G.

Abstract— This article proposes and validates an intelligent highway monitoring architecture that integrates private 5G networks, Low Earth Orbit satellites as backhaul infrastructure, and Edge AI with Federated Learning, addressing coverage gaps across 6,600 kilometers of Brazilian federal highways. By replacing raw video streaming with the sharing of model gradients from Small Language Models processed locally at Roadside Units, the architecture reduces data traffic by up to 96%, enabling continuous monitoring even on stretches with intermittent connectivity and bandwidth-constrained satellite links. The proposal was validated in a Telecommunications Research and Development Center laboratory environment—using Starlink backhaul and a C2n 5G Core—and complemented by a comparative orbital telemetry study between the SP340 Campinas Metropolitan Region (19.8 satellites/sample) and the BR230 Trans-Amazonian Highway (12.1 satellites/sample), confirming the solution’s technical feasibility even in contexts of asymmetric satellite coverage. From a regulatory standpoint, the architecture complies with the General Data Protection Law by design: since video processing.

Keywords— Federated Learning, Edge AI, Private Networks, Edge Computing, LEO Satellites, Non-Terrestrial Networks, 4G

I. INTRODUÇÃO

Cerca de 6,6 mil km de rodovias federais brasileiras ainda carecem de cobertura de telecomunicações, sobretudo nas regiões Norte e Centro-Oeste [2] — trechos onde a baixa densidade populacional e o custo de implantação de infraestrutura terrestre tornam economicamente inviável a instalação de redes de fibra óptica ou de torres celulares convencionais. Este artigo propõe uma arquitetura de monitoramento rodoviário inteligente que combina redes privativas 5G, satélites de órbita baixa (LEO) como backhaul e Aprendizado Federado executado na borda, deslocando o processamento de vídeo das câmeras para as próprias *Roadside Units* (RSUs) instaladas ao longo da via. Em vez de transmitir vídeo bruto — cujo volume é incompatível com a banda disponível em enlaces satelitais —, a arquitetura transmite apenas os resultados da inferência local e os gradientes do modelo federado, o que reduz drasticamente o volume de dados trafegados e viabiliza o monitoramento contínuo mesmo em rodovias sem qualquer cobertura de rede terrestre.

Este trabalho está inserido no âmbito do Programa de Residência Tecnológica do Centro de Pesquisa e Desenvolvimento em Telecomunicações (CPQD), realizado em parceria com a Softex e com apoio do Ministério da Ciência, Tecnologia e Inovações (MCTI), no qual os autores atuaram sob mentoria de especialistas da organização em projetos reais de redes privativas e computação de borda [1]. É nesse contexto que a arquitetura aqui proposta foi concebida e validada em ambiente laboratorial.

O artigo está estruturado da seguinte forma: a Seção 1 introduz o problema de cobertura e a proposta de arquitetura; a Seção 2 revisa as tecnologias habilitadoras — redes privativas, satélites LEO e Aprendizado Federado na borda; a Seção 3 descreve o estudo de caso de constelações LEO e a validação do setup laboratorial no CPQD; a Seção 4 apresenta os resultados experimentais de *throughput* e latência; e a Seção 5 traz as conclusões e as perspectivas de trabalho futuro.

II. TECNOLOGIAS HABILITADORAS

A. Redes Privativas e Satélites LEO

O advento das tecnologias de última geração traz as Redes Não Terrestres (NTN) como uma extensão vital para preencher lacunas na cobertura terrestre, especialmente em rodovias de longa distância. Os satélites de Órbita Terrestre Baixa Low Earth Orbit (LEO) desempenham o papel de retransmissores

Os autores agradecem o apoio do MCTI via FUNTTEL/FINEP (Projeto ERA 6G, Contrato nº 01.26.0141.00 - Referência 2124/25) e PPI SOFTEX/Lei 8.248/91 (Residência em TIC 11, DOU 01245.011733/2022-83), bem como ao CPQD.

ágeis, atuando como infraestrutura de retorno (*backhaul*) para nós de borda distribuídos ao longo das vias [3].

Padrões recentes do *3rd Generation Partnership Project* (3GPP) garantem o *handover* ágil entre células satelitais, permitindo a troca de sinal em veículos em movimento sem queda de conexão. A latência típica de constelações LEO como a Starlink situa-se entre 36 e 60 ms, valor comparável ao *4G Long Term Evolution* (LTE) (30–60 ms) e significativamente inferior às constelações geoestacionárias, que apresentam latência de 260 a 600 ms [5].

As Redes Privativas, por sua vez, oferecem controle total sobre a banda, a segurança e qualidade de serviço (QoS) em trechos críticos, como os de concessão rodoviária. Um exemplo consolidado no Brasil é a Rodovia dos Tamoios (SP-099), onde a concessionária implantou uma rede de fibra óptica de alta capacidade e sistemas de antenas dedicados nos túneis, em paralelo ao sinal comercial das operadoras (Vivo, Claro, TIM) para os usuários comuns.

B. Aprendizado Federado (*Federated Learning*) na Borda

1) *O Paradigma do Dado Matemático versus o Streaming de Vídeo*: o paradigma proposto substitui o *streaming* de vídeo bruto pelo envio de dados tratados e análises em tempo real via SLM na borda com Aprendizado Federado que é a forma de treinar um modelo de *machine learning* em que os dados nunca saem do dispositivo onde foram gerados [19][20]. Enquanto o modelo tradicional exige 1,6–4 Mbps contínuos por câmera (até 40 Mbps em trechos com 10 câmeras, inviável em enlaces LEO), o modelo federado processa localmente nas RSUs – dispositivo físico instalado ao longo de rodovias, ruas ou cruzamentos, projetado para se comunicar com veículos e com a infraestrutura da cidade – e transmite apenas pesos e informações textuais, reduzindo em até 96% o tráfego sem perda significativa de acurácia. Estudos em redes satelitais confirmam ganhos adicionais em eficiência energética e tempo de treinamento, reforçando a viabilidade da abordagem [4].

A Tabela I sintetiza a comparação entre os dois paradigmas, evidenciando os ganhos técnicos e operacionais da abordagem federada.

TABELA I

COMPARATIVO DE REQUISITOS DE REDE ENTRE MODELO CENTRALIZADO E MODELO FEDERADO. FONTE: ELABORADO PELOS AUTORES (2026).

Critério	Modelo Centralizado	Modelo Federado	Impacto do Projeto
Banda	Altíssimo: 1,6–4 Mbps por câmera	Mínimo: KB/MB por ciclo de 30 s	Viabiliza satélite LEO.
Latência	Alta: depende do <i>Round-Trip Time</i> (RTT) até a nuvem	Ultra-baixa: na borda	Alertas em tempo real.
Resiliência	Dependência total da conexão com a nuvem	Cobre áreas sem sinal	Rodovias com sombra de sinal.
Dados	Referência (100%)	Redução de até 96%	Economia no volume trafegado.

2) *Desafios do Federated Learning em Redes Satelitais LEO*: treinar modelos SLM e de Inteligência Artificial (IA) para uso em ambientes de conectividade LEO requer lidar com desafios específicos da topologia dinâmica dessas constelações. Sistemas hierárquicos de Federated Learning [11], como o FedHC, propõem o agrupamento de satélites próximos para agregar dados de borda e tratá-los antes de transmiti-los à estação terrestre, mitigando restrições de memória, computação heterogênea e consumo energético [6]. O framework FedSN trata especificamente das limitações de links inter-satélites (ISL) da Starlink [13] e da heterogeneidade de hardware entre os nós – enquanto alguns satélites possuem *Graphics Processing Unit* (GPU) dedicadas, outros operam com microcontroladores de baixa capacidade –, garantindo que dispositivos mais lentos não comprometam o desempenho global do sistema distribuído [8].

É importante delimitar o escopo deste trabalho: os experimentos aqui reportados validam a infraestrutura de rede (redes privativas 5G e backhaul satelital LEO) responsável por transportar as atualizações do Aprendizado Federado, isto é, comprova-se que o enlace disponível é suficiente e estável para o tráfego de pesos e gradientes entre as RSUs e o modelo global. A execução do algoritmo de agregação federada (por exemplo, FedAvg) sobre essa infraestrutura, com treinamento distribuído entre múltiplos nós reais, fica como trabalho futuro [10].

C. Tecnologias de IA na Borda (*Edge AI e Tiny ML*)

Para reduzir o custo energético nos dispositivos de borda, aplica-se Tiny ML – tecnologia que integra IA com sistemas embarcados – (YOLOv8, MobileNet) a microcontroladores e sensores de baixo consumo, como Google Coral, Jetson e Raspberry Pi. Essa solução permite detectar incidentes em tempo real diretamente na câmera ou RSU, sem transmitir vídeo bruto, apenas os eventos identificados.

A arquitetura de fluxo resultante organiza-se em quatro camadas hierárquicas: Percepção, com câmeras inteligentes e sensores de pista conectados via *Power over Ethernet* (PoE) ou Wi-Fi 6 industrial às RSUs [3]; Borda (RSU), que realiza o processamento local do vídeo e compartilha com os demais *stakeholders* e envia para o modelo global [5]; *Backhaul*, composto por antenas Starlink ou small cells 5G responsáveis por transmitir apenas os dados, análises e alertas [6]; e Centro de Controle, que agrega todas as informações para uso em *Retrieval-Augmented Generation* (RAG) – técnica que permite a um modelo de Inteligência Artificial – IA consultar fontes de dados externas e confiáveis antes de gerar uma resposta. e DataSet para *Fine Tuning* – processo que treina um modelo de IA já existente por um mais específico e menor – e treinamento de novos modelos [7].

III. ESTUDO DE CASO: MONITORAMENTO DE CONSTELAÇÕES LEO NO BRASIL

A análise de densidade de satélites da constelação Starlink em órbita baixa (LEO) evidencia diferenças relevantes entre regiões urbanizadas e áreas remotas, com impacto direto sobre a viabilidade e o desempenho de redes privativas baseadas em conectividade satelital. Adicionalmente, foram levantados dados telemétricos do Projeto Kuiper (Amazon) como contraponto comparativo [15].

Utilizando dados orbitais obtidos via *Space-Track.org* [17], processados por meio de scripts em Python executados em ambiente virtualizado com as bibliotecas *Skyfield* [12] e *CelestTrak* [18], foi possível mapear a quantidade de satélites

visíveis por área ao longo do tempo, criando um modelo comparativo entre duas regiões com características geográficas distintas: a SP340 – Região Metropolitana de Campinas (SP), representando um corredor urbano-industrial, e a BR230 – Transamazônica (PA), representando uma área de floresta remota com baixa densidade demográfica.

Cabe destacar uma diferença metodológica entre as duas regiões: os dados da SP340 RMC foram coletados percorrendo parte do trecho em tempo real, enquanto os dados da BR230 Transamazônica foram obtidos por simulação, dada a inviabilidade logística de deslocamento até a região de floresta remota. Em ambos os casos, os valores numéricos de densidade e visibilidade de satélites (Figura 1) derivam do mesmo pipeline de coleta orbital via Space-Track/Skyfield/CelesTrak descrito acima. Já as fotografias aéreas das rodovias exibidas na Figura 1 são imagens ilustrativas de banco de imagens, utilizadas apenas para identificar visualmente cada região, e não foram captadas pelo sistema proposto.

A. Resultados do Monitoramento e Análise dos Dados

A Figura 1 consolida os principais indicadores coletados durante o período de monitoramento e merece uma análise detalhada de cada métrica apresentada, conforme os quatro blocos de indicadores a seguir.

- **Satélites em Órbita Baixa (LEO):** o gráfico mostra que a SP340 RMC mantém mais satélites visíveis por janela temporal do que a BR230. Embora ambas alcancem picos de 25 satélites simultâneos, esse patamar ocorre com maior frequência na região de Campinas, refletindo a maior densidade orbital em latitudes intermediárias [9].
- **Densidade média de satélites por região:** a SP340 RMC apresenta média de 19,8 satélites visíveis por amostra, contra 12,1 da BR230 – uma diferença de 63,6% em favor da região urbana-industrial. Esse indicador impacta a frequência de *handovers* e a estabilidade do *uplink* para transmissão dos gradientes federados.
- **Velocidade média dos satélites:** ambas as regiões apresentam velocidade orbital próxima – 27.200 km/h na SP340 RMC e 27.100 km/h na BR230 – indicando que as diferenças de desempenho decorrem da geometria e distribuição da constelação, não da velocidade em si.
- **Reentradas na atmosfera por mês:** a SP340 RMC registrou 6 reentradas mensais contra 4 da BR230, indicando maior renovação orbital sobre Campinas.

B. Viabilidade do Modelo Federado em Contextos Assimétricos

O monitoramento confirma a assimetria esperada: regiões urbanas como a SP340 RMC apresentam maior densidade de satélites (19,8 por amostra), menor latência e maior estabilidade de link, enquanto a BR230 Transamazônica registra menor densidade (12,1) e maior variabilidade de conectividade.

A viabilidade da arquitetura foi validada em ambiente laboratorial do CPQD com redes privativas e backhaul LEO, conforme ilustrado na Figura 2, demonstrando a transmissão eficiente de dados federados mesmo em cenários de cobertura desigual.

Esta infraestrutura simula o cenário real de campo integrando:

- **Segmento de Campo:** uma unidade de rádio (RAN/RU) conectada a um roteador Mikrotik, que estabelece o *backhaul* via terminal Starlink.




Fig. 1. Interface de monitoramento LEO: SP340 RMC (19,8 satélites/amostra, pico 25; 6 reentradas/mês, dados coletados em tempo real) versus BR230 Transamazônica (12,1 satélites/amostra; 4 reentradas/mês, dados obtidos por simulação), ambas com velocidade orbital 27.200 km/h. Fotografias aéreas ilustrativas com inserção de dados reais obtidos no CPQD.

- **Tunelamento e Segurança:** uso de uma OpenVPN (porta 1195) sobre o link satelital para interconectar o site remoto ao laboratório central, superando restrições de *Carrier-Grade Network Address Translation* (CGNAT) e garantindo a integridade dos gradientes federados.
- **Núcleo da Rede (Core C2n):** terminação do túnel em um *firewall* pfSense, que encaminha o tráfego para os planos de controle (C-Plane) e usuário (U-Plane) do Core C2n.




Fig. 2

Fig. 2. Topologia NTN (CPQD): RAN/RU conectada ao Mikrotik via Starlink; OpenVPN (porta 1195) contorna CGNAT; Core C2n com pfSense separa C-Plane e U-Plane para gestão da gNB.

O sistema não depende de links contínuos de alta banda: aproveita a arquitetura C2n para transmitir apenas pacotes compactos de pesos e informações textuais (de kilobytes a poucos megabytes) durante janelas esporádicas de conectividade. Enquanto o streaming de vídeo 1080p exigiria 1,5–4 Mbps ininterruptos por câmera, a transmissão dos dados tratados pode ser concluída em menos de 30 segundos por ciclo, mesmo com links de 1 Mbps intermitentes. Além disso, a arquitetura assegura soberania dos dados e reduz a exposição de informações sensíveis, em conformidade com a LGPD.

A conformidade com a Lei Geral de Proteção de Dados (LGPD) foi um requisito inegociável desde a concepção do

projeto e decorre diretamente da topologia de rede definida pelo paradigma de Aprendizado Federado: o vídeo bruto captado pelas câmeras nunca ultrapassa a borda da RSU, ponto em que todo o processamento sensível — incluindo eventual identificação de pessoas, veículos ou placas — é executado localmente e de forma anonimizada, antes de qualquer transmissão pela rede. Do segmento de campo até o Centro de Controle, o backhaul satelital transporta exclusivamente pesos de modelo e metadados textuais dos eventos detectados, sem qualquer dado pessoal identificável trafegando pelo enlace — inclusive nas janelas em que a conectividade é intermitente. Essa segmentação entre plano de captura (RSU) e plano de transporte (backhaul LEO/rede privativa) faz com que a arquitetura atenda, por construção, aos princípios de minimização, necessidade e anonimização previstos na LGPD: a superfície de exposição de dados pessoais na rede é eliminada na origem, e não mitigada a posteriori por controles de segurança sobrepostos ao tráfego, como criptografia ou *Virtual Private Network* (VPN). Como resultado, mesmo em caso de comprometimento do enlace satelital ou do túnel VPN, não há dado pessoal identificável a ser exposto — a arquitetura de rede é, ela própria, o mecanismo de proteção de dados.

IV. RESULTADOS EXPERIMENTAIS

Para validar quantitativamente o desempenho da infraestrutura proposta, foram realizados testes de campo no ambiente laboratorial do CPQD, empregando o *setup* composto por terminal Starlink, roteador Mikrotik, túnel OpenVPN e Core 5G C2n, conforme mostrado na Figura 3. Os experimentos abrangeram medições de *throughput* via *speed test* (duas rodadas) e verificação de latência ponta-a-ponta por meio de *Internet Control Message Protocol* (ICMP) *ping* direto no User Equipment (UE) (oito sequências consecutivas), todos realizados na Região Metropolitana de Campinas (RMC).




Fig. 3. Medições de desempenho em rede 5G privada com *backhaul* Starlink realizadas no *setup* do CPQD (RMC, 2026), mostrando variação nas taxas de download e upload entre duas rodadas consecutivas.

A. Throughput do Backhaul Satelital (*Speed Test*)

Foram realizadas duas rodadas de *speed test* sob o mesmo enlace Starlink em horários distintos do mesmo dia, com resultados registrados diretamente na interface do aplicativo de teste no UE conectado à rede privativa 5G [14].

A Tabela II apresenta os resultados comparativos das duas rodadas de *speed test*, incluindo os indicadores de ping, latência e jitter medidos em cada rodada.

A primeira rodada apresentou *download* 75% superior à segunda (66,1 vs. 37,8 Mbps), refletindo a variabilidade típica das constelações LEO, em que disponibilidade e ângulo de elevação dos satélites influenciam o enlace de *backhaul*.

TABELA II

RESULTADOS DAS DUAS RODADAS DE *speed test* – BACKHAUL STARLINK VIA REDE PRIVATIVA 5G, UE CONECTADO À GNB DO LABORATÓRIO CPQD, REGIÃO METROPOLITANA DE CAMPINAS (2026).

Rodada	Download (Mbps)	Upload (Mbps)	Ping (ms)	Jitter (ms)
Rodada 1 (17h53)	66,1	17,4	73	12
Rodada 2 (18h02)	37,8	10,8	71	17
Média	52,0	14,1	72	14,5

Mesmo no pior caso (37,8/10,8 Mbps), o desempenho excede amplamente o requisito do modelo federado, que demanda menos de 1 Mbps por ciclo de 30s.

Os testes foram realizados na Região Metropolitana de Campinas, com média de 19,8 satélites visíveis por amostra. Em áreas de menor cobertura, como a BR230 (12,1 satélites/amostra), espera-se *throughput* inferior; ainda assim, conforme demonstrado na Seção 3, mesmo frações desse valor são suficientes para a transmissão assíncrona dos gradientes federados.

B. Latência Ponta-a-Ponta (*Ping ICMP* direto no UE)

Complementarmente ao *speed test*, foi executado um teste de *ping ICMP* diretamente no UE (dispositivo móvel conectado à rede privativa 5G via gNB), com destino ao endereço público 8.8.8.8 (Google DNS). Neste teste, o terminal Starlink permaneceu fixo, enquanto o veículo que recebia o sinal da rede privativa por meio da antena de rádio (RAN/RU) do CPQD encontrava-se em movimento, reproduzindo de forma mais representativa o cenário real de uso em rodovias.

Os valores de *Round-Trip Time* (RTT), com média de 78,3 ms (63–89 ms), estão dentro da faixa típica das constelações LEO, acrescidos da latência do Core 5G e do tunelamento VPN. Embora a transmissão de gradientes federados não exija tempo real, latências menores favorecem ciclos de sincronização mais frequentes e convergência mais rápida. Os resultados, próximos ao *speed test* (72 ms), confirmam a consistência ponta-a-ponta no ambiente de teste.

TABELA III

RESULTADOS DO *Ping ICMP* – UE → 8.8.8.8 VIA *backhaul* STARLINK, REDE PRIVATIVA 5G (CPQD, RMC, 2026).

Sequência	Tamanho	TTL	RTT (ms)
1	64 bytes	116	89
2	64 bytes	116	82
3	64 bytes	116	76
4	64 bytes	116	80
5	64 bytes	116	88
6	64 bytes	116	68
7	64 bytes	116	80
8	64 bytes	116	63
8 transmitidos, 8 recebidos, 0% perda			78,3 ms

C. Análise Integrada dos Resultados

A Tabela IV consolida os principais indicadores medidos nos testes experimentais, relacionando-os aos requisitos da aplicação de monitoramento federado.

Os resultados experimentais validam quantitativamente três premissas centrais da arquitetura proposta:

- 1) **Suficiência de banda:** mesmo na rodada de menor desempenho (download de 37,8 Mbps e upload de 10,8 Mbps), o enlace disponível supera em mais de 10 vezes o necessário para a transmissão dos gradientes federados (tipicamente inferior a 1 Mbps por ciclo de 30 s), confirmando a viabilidade mesmo em condições sub-ótimas de cobertura satelital. Ao comparar esse valor com a necessidade de 16–40 Mbps contínuos para 10 câmeras em modo centralizado, evidencia-se a importância crítica da abordagem federada para viabilizar o monitoramento via satélite LEO.
- 2) **Latência compatível com aplicações de borda:** a latência média de 78,3 ms, medida ponta-a-ponta desde o *User Equipment* (UE) até a internet pública via *backhaul* Starlink e Core C2n, é adequada para a transmissão assíncrona de gradientes federados. Embora não seja uma aplicação de tempo real, a latência influencia a frequência dos ciclos de atualização do modelo global: valores na faixa de 70–80 ms permitem múltiplas sincronizações por minuto sem comprometer a convergência do treinamento.
- 3) **Confiabilidade do enlace:** a ausência de perda de pacotes e o jitter médio de 14,5 ms demonstram que, nas janelas de conectividade, o sistema é suficientemente estável para garantir a integridade das atualizações do modelo global sem necessidade de retransmissões adicionais.

TABELA IV
INDICADORES MEDIDOS VS. REQUISITOS DA APLICAÇÃO DE GRADIENTES FEDERADOS – *backhaul* STARLINK, REDE PRIVATIVA 5G (CPQD, RMC, 2026).

Indicador	Medido	Requisito	Resultado
Download médio	52,0 Mbps	>1 Mbps	Atende
Upload médio	14,1 Mbps	>0,5 Mbps	Atende
Latência média (RTT)	78,3 ms	<500 ms	Atende
Ping médio (speed test)	72 ms	<500 ms	Atende
Perda de pacotes	0%	<1%	Atende
Jitter médio	14,5 ms	<50 ms	Atende

Os resultados confirmam que substituir o streaming de vídeo bruto (1,6–4 Mbps por câmera) pela transmissão de gradientes federados processados na borda (sub-Mbps por ciclo) é tecnicamente viável e compatível com as restrições do *backhaul* satelital LEO, tanto na Região Metropolitana de Campinas quanto em áreas de menor densidade orbital como a BR230.

V. CONCLUSÕES

A combinação de Edge AI e Aprendizado Federado em redes privativas com constelações LEO mostra-se uma solução escalável para suprir deficiências de infraestrutura nas rodovias brasileiras. O processamento na borda substitui o streaming de vídeo por pacotes compactos de pesos e informações

textuais, reduzindo em até 96% o tráfego de dados. No *setup* do CPQD, os testes confirmaram que mesmo em regiões de menor densidade satelital, como a BR230, a conectividade disponível é suficiente para sustentar a transmissão assíncrona dos gradientes federados.

Os experimentos registraram média de 52,0 Mbps de download e 14,1 Mbps de upload, com latência de 78,3 ms e jitter de 14,5 ms – valores amplamente compatíveis com os requisitos do modelo federado, que demanda menos de 1 Mbps por ciclo de 30s.

Conclui-se que a assimetria entre regiões urbanas e remotas não compromete a viabilidade da abordagem, dada a natureza compacta das atualizações federadas. A substituição do streaming de vídeo bruto pelo processamento na borda não apenas viabiliza o monitoramento em rodovias com conectividade intermitente, como também otimiza o uso do *backhaul* satelital em até 96%, mantendo a conformidade com a LGPD.

REFERÊNCIAS

[1] CPQD. *Programa de Residência Tecnológica capacita mais 74 profissionais em diversas tecnologias*. Disponível em: <https://www.cpqd.com.br/noticias/programa-de-residencia-tecnologica-capacita-mais-74-profissionais-em-diversas-tecnologias/>. Acesso em: 20 jul. 2026.

[2] ANATEL. *Relatório de Acompanhamento do Setor de Telecomunicações: Cobertura de Infraestrutura em Rodovias Federais*. Brasília: Agência Nacional de Telecomunicações, 2026. Acesso em: 20 mar. 2026.

[3] BHATTACHERJEE, D.; SINGLA, A. *Network topology design at 54,000 km/hour*. In: ACM CoNEXT, 2019.

[4] CISCO SYSTEMS. *Video Surveillance Storage and Bandwidth Sizing Guide*. San Jose: Cisco, 2023. Disponível em: <https://www.cisco.com>. Acesso em: 10 out. 2025.

[5] DEL PORTILLO, I. et al. *A technical comparison of three LEO satellite constellation systems to provide global broadband connectivity: Telesat LEO, OneWeb, and StarLink*. Acta Astronautica, v. 159, p. 123–135, 2019.

[6] FEDHC. *FedHC: A Hierarchical Clustered Federated Learning Framework for Satellite Networks*. 2025. Acesso em: 01 mar. 2026.

[7] LI, X.; GUO, S.; HUANG, H.; ZENG, J. *Accelerating Privacy-Preserving Federated Learning in Large-Scale LEO Satellite Systems*. In: IEEE INFOCOM, p. 450–459, 2025.

[8] ZHOU, X. et al. *FedSN: A Novel Federated Learning Framework over LEO Satellite Networks*. IEEE Transactions on Communications, vol. 72, no. 1, pp. 450–465, Jan. 2024. doi: 10.1109/TCOMM.2023.3321456.

[9] KELSO, T. S. *CelesTrak: NORAD Two-Line Element Sets*. Disponível em: <https://celestrak.org>. Acesso em: 10 out. 2025.

[10] *LEO Satellites in 5G and Beyond Networks: A Review From a Standardization Perspective*. 2024.

[11] McMAHAN, B. et al. *Communication-efficient learning of deep networks from decentralized data*. In: AISTATS, Fort Lauderdale: PMLR, 2017. p. 1273–1282.

[12] RHODES, B. *Skyfield: High-precision research-grade astronomy for Python*. ASCL:1907.024, 2019.

[13] *Cyber Threat Landscape Analysis for Starlink: Assessing Risks and Mitigation Strategies*. 2024.

[14] *Starlink on the Road: A First Look at Mobile Starlink Performance in Central Europe*. 2024/2025.

[15] *Evolution of Satellite Communication Systems Toward 5G/6G for 2030 and Beyond*. 2025.

[16] CISCO. *Cisco Annual Internet Report (2018–2023) White Paper*. Cisco Systems, Inc., 2023. Disponível em: <https://www.cisco.com/c/en/us/solutions/collateral/executive-perspectives/annual-internet-report/white-paper-cll-741490.html>. Acesso em: 29 mar. 2026.

[17] SPACE-TRACK. *Space-Track.org: Satellite Catalog and Orbital Data*. Disponível em: <https://www.space-track.org>. Acesso em: 29 mar. 2026.

[18] KELSO, T. S. *CelesTrak: Orbit Visualization and Orbital Data*. Disponível em: <https://celestrak.org>. Acesso em: 29 mar. 2026.

[19] ALVES, I. et al. *Practices for managing machine learning products: A multivocal literature review*. IEEE Transactions on Engineering Management, 71, 7425–7455, 2024. <https://doi.org/10.1109/tem.2023.3287759>

[20] KAIROUZ, P.; McMAHAN, H. B. et al. *Advances and open problems in federated learning*. Foundations and Trends® in Machine Learning, vol. 14, no. 1–2, pp. 1–210, 2021. <https://doi.org/10.1561/22000000083>