

Predição de Volume de Tráfego de Rede a partir de uma Análise de Granularidade Temporal de Medição em Computação de Borda

Ismael S. F. de Castro¹, Maria C. M. M. Ferreira¹, Maria de L. Linhares¹,
Rafael L. Gomes¹

¹Universidade Estadual do Ceará (UECE)

{clara.mesquita, ismael.fonteles, malu.linhares, }@aluno.uece.br

{rafa.lopez}@uece.br

Abstract. *The increasing digitalization of urban spaces has amplified the importance of using prediction mechanisms based on data from connected infrastructures that support services such as communication, monitoring, sensing, and the operation of digital platforms. However, the quality of predictive results depends not only on the adopted model but also on fundamental methodological decisions, such as the choice of temporal granularity and the implementation of robust data preprocessing. Within this context, this work presents a mechanism focusing on a robust preprocessing pipeline to mitigate gaps and noise typical of sensors and telemetry failures in connected infrastructures. It investigates the impact of different temporal granularities on the predictive behavior of models, while emphasizing the importance of a consistent series cleaning and preparation process. The results, using real-world network data, indicate that hourly granularity offers the best balance between stability and absolute error reduction.*

Resumo. *A crescente digitalização dos espaços urbanos tem ampliado a importância do uso de mecanismos de predição baseados em dados oriundos de infraestruturas conectadas que dão suporte a serviços como comunicação, monitoramento, sensoriamento e operação de plataformas digitais. Entretanto, a qualidade dos resultados preditivos depende não apenas do modelo adotado, mas também de decisões metodológicas fundamentais, como a escolha da granularidade temporal e a realização de um pré-processamento robusto dos dados. Dentro deste contexto, este trabalho apresenta um mecanismo que foca em um pipeline de pré-processamento robusto para mitigar lacunas e ruídos típicos de sensores e falhas de telemetria em infraestruturas conectadas, investigando o impacto de diferentes granularidades temporais sobre o comportamento preditivo dos modelos, sem desconsiderar a importância de um processo consistente de limpeza e preparação das séries. Os resultados, usando dados de redes reais, indicam que a granularidade horária oferece o melhor equilíbrio entre estabilidade e redução de erro absoluto.*

1. Introdução

A crescente digitalização dos espaços urbanos e a expansão da Internet das Coisas (IoT) têm impulsionado a transição de arquiteturas de nuvem centralizadas para o paradigma da

Computação de Borda [Souza et al. 2024]. Nesse cenário, o processamento de dados e a execução de serviços ocorrem de forma descentralizada, aproximando a capacidade computacional dos usuários finais para garantir baixa latência e suporte a aplicações críticas, como monitoramento em tempo real e cidades inteligentes. Paralelamente, avanços recentes em paradigmas de redes têm introduzido níveis sem precedentes de programabilidade e controle para operadores, favorecendo a transição de abordagens reativas para modelos preditivos de gerenciamento [Nobre et al. 2025]. Em ambientes urbanos cada vez mais conectados, essa transformação é particularmente relevante, pois a natureza e a escala do crescimento impõem desafios significativos relacionados à escalabilidade, à Qualidade de Serviço (QoS) [Lopes Gomes and Roberto Mauro Madeira 2012], à Qualidade de Experiência (QoE) [Baganal-Krishna et al. 2024] e à privacidade [Santos et al. 2020].

Dentro desse contexto, a análise e a telemetria de dados tornam-se componentes centrais para o funcionamento de infraestruturas urbanas inteligentes. Entre as várias possibilidades analíticas, a predição de séries temporais associadas ao comportamento do tráfego em sistemas conectados destaca-se por seu potencial de apoiar decisões operacionais, planejamento de capacidade e adaptação dinâmica de recursos. Em particular, a predição de dados de tráfego permite antecipar tendências de uso a partir de observações históricas, favorecendo respostas mais eficientes diante de variações de demanda [Leoni et al. 2021, Gomes et al. 2014]. Esse potencial aplicado se estende a mecanismos orientados à QoS, nos quais a predição de métricas de rede pode apoiar decisões adaptativas em tempo de execução [Gomes et al. 2016, Santos and Almeida 2025], tornando-se relevante para aplicações urbanas baseadas em conectividade, serviços móveis e sensoriamento distribuído.

A literatura recente reforça ainda que a predição de tráfego não se limita à antecipação de volume, mas constitui um mecanismo de apoio a tarefas estratégicas como planejamento de capacidade, conservação de energia em estações-base, otimização da operação da rede e suporte à provisão de QoS. Em ambientes urbanos instrumentados, essas capacidades são particularmente valiosas por impactarem diretamente a continuidade e a confiabilidade de serviços digitais que compõem o ecossistema das cidades inteligentes. Nesse sentido, estudos em redes celulares e móveis indicam que a forma como os dados são representados ao longo do tempo interfere diretamente na utilidade prática da predição, o que reforça a necessidade de investigar, de maneira metodológica, o papel da granularidade temporal em cenários reais [Wang et al. 2024].

Entretanto, muitos trabalhos da área concentram-se principalmente na comparação de desempenho entre modelos [Ferreira et al. 2023, Koumar et al. 2025], dedicando menor atenção às etapas de pré-processamento e às decisões metodológicas associadas à preparação das séries temporais. Em aplicações reais de Computação Urbana, essa limitação é ainda mais sensível, uma vez que dados operacionais frequentemente apresentam lacunas, ruídos, inconsistências e irregularidades decorrentes de falhas de telemetria, sensores e sistemas de coleta. Nesses casos, simplesmente remover observações ausentes pode comprometer a qualidade analítica e reduzir a eficiência dos modelos [Zhu et al. 2024]. Por essa razão, a qualidade dos dados deve ser tratada como elemento central, e não periférico, em estudos de predição baseados em aprendizado de máquina [Zhu et al. 2024, Ferreira et al. 2024, Ferreira et al. 2025].

Entre as decisões de pré-processamento com maior impacto sobre tarefas predi-

tivas, destaca-se a definição da granularidade temporal. Em séries temporais, a granularidade corresponde à unidade fundamental de agregação dos dados e determina o nível de detalhe capturado ao longo do tempo. Essa escolha afeta diretamente a quantidade de informação disponível, a visibilidade de padrões sazonais, a presença de ruído e, consequentemente, o desempenho e a interpretabilidade dos modelos [Park et al. 2025]. Em aplicações urbanas orientadas por dados, essa questão torna-se ainda mais relevante, pois diferentes resoluções temporais podem ser mais adequadas para distintos objetivos, como monitoramento contínuo, resposta rápida a eventos, planejamento operacional ou análise agregada de comportamento.

A relevância da granularidade temporal tem sido amplamente reconhecida na literatura de aprendizado de máquina para séries temporais [Park et al. 2025, Yu et al. 2024, Shubo and Haipeng 2024]. Ainda assim, permanece a necessidade de estudos que investiguem, de forma mais controlada, como diferentes granularidades afetam efetivamente a modelagem preditiva em dados reais. Tal investigação é importante não apenas para identificar a resolução mais adequada em um dado contexto, mas também para fundamentar a eventual combinação de múltiplas granularidades em cenários mais complexos. Em outras palavras, compreender o papel da granularidade temporal é uma etapa metodológica essencial para tornar a predição mais robusta, interpretável e útil em sistemas conectados do mundo real.

Assim, a partir da análise de trabalhos anteriores voltados à predição com pré-processamento robusto [Zhu et al. 2024, Ferreira et al. 2024, Ferreira et al. 2025], emerge a necessidade de uma investigação metodológica específica sobre a influência da granularidade temporal na predição de dados. Essa necessidade é ainda mais evidente em cenários baseados em telemetria, nos quais a ocorrência de dados faltantes e irregularidades é natural. Considerando bases reais de tráfego, como a utilizada neste estudo [Koumar et al. 2024], observa-se que a escolha da granularidade ideal não deve ser tratada apenas como uma decisão operacional, mas como uma etapa estruturante do pipeline analítico e preditivo, com impacto direto sobre a qualidade final dos resultados.

Diante disso, este trabalho propõe um mecanismo de predição de tráfego baseado em uma análise aprofundada da granularidade temporal em séries de tráfego, combinada a um processo de pré-processamento robusto, tendo como objetivo reduzir vieses decorrentes de dados ruins ou variações não representativas da realidade monitorada e, assim, avaliar seus efeitos sobre a predição. Assim, a proposta deste trabalho pode ser aplicada como um motor de inteligência para a orquestração autônoma de recursos em infraestruturas sensíveis à latência. Ao identificar a granularidade temporal que melhor equilibra o detalhamento dos padrões de tráfego e a estabilidade preditiva, o modelo permite que nós de borda antecipem picos de demanda e realizem o escalonamento dinâmico de funções de rede de forma localizada [Brito et al. 2026]. Essa capacidade é fundamental para suportar serviços digitais essenciais nas cidades inteligentes, como o monitoramento de mobilidade e sensoriamento distribuído, onde o processamento próximo à fonte dos dados reduz o congestionamento do núcleo da rede e garante o cumprimento de requisitos estritos de QoS e QoE.

Para isso, utiliza-se a base *CESNET-TimeSeries24*, disponibilizada recentemente e composta por monitoramento de 40 semanas de mais de 270.000 endereços IP ativos da rede ISP *CESNET3* (*Czech Education and Science Network*) [Koumar et al. 2024]. Trata-

se de um conjunto de dados realista e de grande escala, com forte potencial para investigações metodológicas em predição e análise de séries de tráfego [Koumar et al. 2025, Liu et al. 2026, Feng et al. 2026]. A partir dessa base, são avaliados modelos recorrentes amplamente utilizados na literatura, nomeadamente LSTM, GRU e RNN, com o propósito de investigar como diferentes granularidades afetam o comportamento preditivo dessas arquiteturas.

Os experimentos foram organizados de forma a avaliar o desempenho dos modelos com métricas amplamente adotadas na literatura de predição, bem como observar de que modo a granularidade temporal afeta não apenas os valores finais das métricas agregadas, mas também a evolução do erro ao longo do horizonte de previsão. Para isso, foram definidas condições específicas e comparáveis para cada granularidade analisada, buscando preservar a equidade experimental e permitir uma análise metodológica consistente. O código utilizado no estudo está disponível publicamente no GitHub¹.

Dessa forma, o presente trabalho busca oferecer uma contribuição metodológica reprodutível e consultável para pesquisas em predição de séries temporais em infraestruturas conectadas, com potencial de diálogo com temas de Computação Urbana, como cidades inteligentes, infraestruturas de sensoriamento, monitoramento contínuo e análise de serviços digitais urbanos. O restante deste trabalho está organizado da seguinte forma. Na Seção 2, são discutidos os trabalhos relacionados. Na Seção 3, é detalhada a proposta do artigo. Na Seção 4, são apresentadas as configurações experimentais. Na Seção 5, são discutidos os resultados obtidos. Por fim, a Seção 6 apresenta as considerações finais e os trabalhos futuros.

2. Trabalhos Relacionados

A literatura de predição de tráfego de rede tem avançado em múltiplas direções, incluindo a comparação entre arquiteturas profundas, o uso de bases reais de monitoramento, a exploração de múltiplas granularidades temporais e a aplicação de modelos preditivos ao suporte de QoS e automação de redes. Ainda assim, permanecem lacunas relevantes quanto à compreensão isolada do papel da granularidade temporal sobre o desempenho preditivo. A análise a seguir evidencia trabalhos recentes relacionados ao tema deste trabalho para contextualização e clarificação do caráter inovador da proposta.

[Ferreira et al. 2023] apresentam uma revisão ampla dos principais métodos de predição de tráfego, cobrindo desde modelos estatísticos, como ARIMA e SARIMA, até redes neurais como RNN, LSTM e GRU, além de disponibilizarem uma base comparativa aberta para reprodução experimental. O trabalho é importante por sistematizar técnicas, métricas e estratégias de avaliação, mas seu foco está mais na comparação entre famílias de modelos do que na investigação específica do impacto da granularidade temporal como variável metodológica central.

Koumar et al. [Koumar et al. 2025] realizam uma avaliação comparativa de modelos profundos de previsão sobre o próprio CESNET-TimeSeries24, investigando janelas de treino e predição, níveis de agregação hierárquica e múltiplas métricas monitoradas. O estudo mostra que o desempenho depende fortemente das condições experimentais e que o nível de agregação influencia diretamente a previsibilidade das séries, com melhor

¹<https://github.com/LarcesUece/GRANULARITY-PREDICTION>

desempenho no nível institucional do que no nível de IP. Apesar desse avanço, a granularidade temporal aparece como uma dimensão entre várias outras, e não como o eixo principal da investigação; assim, o trabalho não isola nem discute em profundidade o efeito da resolução temporal sobre o pipeline preditivo em si.

Tabela 1. Comparação entre trabalhos relacionados e a proposta deste trabalho.

Trabalho	Foco principal	Granularidade temporal	Tipo de análise	Limitação em relação a este trabalho
[Ferreira et al. 2023]	Revisão e comparação de métodos de predição de tráfego	Não central	Comparação entre famílias de modelos	Não investiga a granularidade temporal como variável metodológica central
[Koumar et al. 2025]	Comparação de modelos profundos no CESNET-TimeSeries24	Considerada entre vários fatores	Avaliação comparativa multivariada	Não isola a granularidade temporal como eixo principal da investigação
[Bi and Wang 2024]	Fusão multi-granular com arquitetura híbrida GRU-BP	Múltiplas granularidades combinadas	Proposição de nova arquitetura	Foca na fusão de escalas, e não na comparação controlada do efeito de cada granularidade isoladamente
[Liu et al. 2026]	Avaliação de modelo fundacional em tráfego ISP	Múltiplas resoluções	Zero-shot e few-shot	Investiga generalização de foundation models, não o efeito controlado da granularidade em modelos clássicos e recorrentes
Este trabalho	Análise metodológica da influência da granularidade temporal na predição	10 min, 1 h e 1 dia	Comparação controlada entre granularidades com pré-processamento robusto	Foco central na granularidade temporal como variável de análise

Bi e Wang [Bi and Wang 2024] propõem uma abordagem multigranular em que previsões geradas por diferentes granularidades temporais são combinadas por uma arquitetura híbrida GRU-BP. Os autores mostram ganhos de acurácia e eficiência computacional ao fundir informações de múltiplas escalas temporais, indicando que a granularidade é um fator relevante para a modelagem do tráfego. Entretanto, o foco está na fusão de granularidades em uma nova arquitetura, e não em uma análise comparativa e controlada do efeito de cada granularidade isoladamente, tampouco em um cenário centrado em dados públicos e realistas de rede ISP.

Mais recentemente, [Liu et al. 2026] avaliam um modelo fundacional de séries temporais sobre o CESNET-TimeSeries24, em cenários *zero-shot* e *few-shot*, cobrindo múltiplos horizontes, níveis de agregação e resoluções temporais. O trabalho mostra o potencial de modelos pré-treinados para previsão de tráfego ISP com boa acurácia e baixa

latência de inferência. Contudo, seu objetivo central é avaliar a capacidade de generalização de modelos em dados de rede, e não construir uma base metodológica para entender, de forma controlada, como a granularidade temporal afeta o desempenho de modelos clássicos e recorrentes amplamente utilizados.

Diferentemente desses trabalhos, o presente estudo toma a granularidade temporal como variável central de análise. Em vez de priorizar a proposição de uma nova arquitetura ou uma comparação ampla entre muitos fatores experimentais, a proposta busca investigar, de forma controlada e reproduzível, como diferentes resoluções temporais alteram o comportamento preditivo em dados reais de tráfego. Dessa forma, podemos observar com maior clareza o papel da granularidade em tarefas ligadas a planejamento de capacidade, desempenho, QoS e gerenciamento autônomo de redes e serviços.

3. Proposta

Propõe-se, neste artigo, a análise do impacto da granularidade temporal [Park et al. 2025] sobre a predição de dados de tráfego de rede considerando especialmente *CESNET-TimeSeries24*, um conjunto de dados atualizado, realista e de referência que foi disponibilizado publicamente pensando em estudos de predição e detecção de anomalias em dados de tráfego de rede [Koumar et al. 2024]. Toda a metodologia do trabalho foi construída pensando em entender como a granularidade impacta métricas de erro, se esse impacto é consistente entre diferentes modelos, e, por fim, concluir se pode existir um equilíbrio entre detalhamento temporal e robustez preditiva.

A Figura 1 a seguir representa a visão geral da proposta, dividindo a metodologia em etapas para melhor visualização e entendimento mas que, na prática, caminham juntas para resolução de um problema e formulação de respostas.



Figura 1. Visão geral da proposta.

1. Escolha de um conjunto de dados real e de uma métrica de tráfego específica para estudo: *CESNET-TimeSeries24* [Koumar et al. 2024] foi escolhida por seu caráter inovador e diversidade de dados. Diferentemente de outras alternativas de monitoramento, pegar esse conjunto de dados, já disponibilizado publicamente, economiza o trabalho de toda a coleta de dados manual, como usando uma ferramenta de monitoramento da RNP, a MonIpê (Rede Brasileira para Educação e Pesquisa)² ou da Geant³. A ideia então foi escolher uma métrica que representasse bem o

²<https://pop-pb.rnp.br/monipe/>

³<https://network.geant.org/>

comportamento da rede, onde poderíamos ver bem elementos temporais da rede, como ciclicidade e tendência; dessa forma, a vazão definida por n_bytes (número de bytes) por intervalo de tempo foi a métrica escolhida para análise de tráfego de rede, por representar diretamente o volume de dados transferidos em cada intervalo de agregação.

2. Escolha de granularidades: no próprio processo de coleta de dados do *CESNET-TimeSeries24*, os dados de tráfego de rede foram agregados inicialmente em intervalos de 10 minutos, então, foram feitos os intervalos também de uma hora e de um dia de intervalos de agregação, pensando em casos em que 10 minutos seriam intervalos muito curtos, como é o caso de aplicação de detecção de anomalias [Koumar et al. 2024]. Nesse contexto, seguimos o estudo com base nessas granularidades pré-definidas.
3. Preparação das séries: para que a análise pudesse ser feita diretamente sobre o tráfego de redes, minimizando interferências decorrentes de inconsistências estruturais ou problemas de completude dos dados, foi realizado um processo de preparação das séries em múltiplas etapas. O fluxo robusto de processamento dos dados consistiu em, primeiramente, remover instituições com: (a) quantidade insuficiente de observações; (b) presença de valores nulos; (c) variância nula; (d) valores negativos e (e) séries com *outliers*, de modo a preservar apenas séries com comportamento minimamente estável e informativo para fins preditivos. Em seguida, os identificadores temporais foram convertidos para representações cronológicas explícitas, permitindo alinhar as bases diária, horária e de 10 minutos em uma mesma estrutura temporal. A partir disso, foi construída uma malha temporal completa por instituição e por dia, com reconstrução das combinações esperadas de hora e subintervalo, seguida de preenchimento de lacunas por propagação temporal dentro de cada grupo.
4. Janelamento e particionamento: para transformar o problema de previsão em um formato supervisionado, foi empregado um procedimento de janelamento deslizante, no qual segmentos passados da série foram utilizados como entrada e os valores subsequentes como alvo de predição. No caso da granularidade diária, adotou-se uma janela de 7 passos de entrada para prever 1 passo à frente; na granularidade horária, utilizaram-se 7 dias de histórico em resolução horária para prever as 24 horas seguintes; e, na granularidade de 10 minutos, foi considerada uma formulação preliminar para prever um dia à frente a partir de múltiplos dias de histórico em alta resolução.
5. Análise comparativa dos resultados: Os dados tratados foram submetidos a treinamento e teste nos modelos clássicos de IA: LSTM, GRU e RNN, e testes foram executados para que pudessem ser analisados os resultados de validação com as métricas RMSE, MAE e NRMSE. Para ir além, foi também analisado o comportamento do modelo no decorrer do tempo, com a análise de degradação por modelo em um horizonte horário (sendo possível, assim, a análise apenas para as granularidades horária e de 10 minutos). Dessa forma, foi possível validar, ou não, a hipótese central deste estudo, de que a granularidade temporal exerce influência significativa sobre a qualidade da predição, afetando a representação dos padrões de variação, sazonalidade e ruído presentes na série.

A metodologia de escolha e definição da granularidade, como foi feito o pré-processamento robusto que diferencia a proposta e como foi feita a predição em si são

detalhadas nas seções 3.1, 3.2, 3.3, respectivamente:

3.1. Configuração dos Dados

A configuração experimental dos dados parte da hipótese de que a granularidade temporal deve ser tratada como uma variável metodológica central da tarefa preditiva, e não apenas como uma escolha operacional de pré-processamento. Nessa direção, o estudo considera três resoluções temporais disponibilizadas pelo próprio *CESNET-TimeSeries24* [Koumar et al. 2024]: diária, horária e de 10 minutos. A literatura recente em previsão de séries temporais tem destacado que padrões relevantes podem emergir ou desaparecer conforme a resolução adotada, de modo que a análise da granularidade deixa de ser um detalhe técnico e passa a compor o próprio desenho experimental do problema.

No fluxo implementado, as séries são carregadas separadamente conforme a resolução temporal, sempre preservando o identificador da instituição e a ordenação dos índices temporais originais. A métrica selecionada para a modelagem é n_bytes , por representar diretamente o volume de tráfego agregado em cada intervalo. A organização das três bases em estruturas paralelas permite comparar granularidades distintas sob uma mesma variável de interesse e sobre o mesmo conjunto de instituições elegíveis.

3.2. Pré-processamento dos Dados

O pré-processamento foi concebido para reduzir interferências estruturais que poderiam comprometer a comparação entre granularidades. Inicialmente, as instituições passam por uma etapa de seleção baseada em critérios de qualidade da série, com remoção de casos com quantidade insuficiente de observações, presença de valores nulos, variância nula, valores negativos ou comportamento extremo segundo um critério robusto baseado em intervalo interquartil. Esse procedimento busca preservar apenas séries com comportamento minimamente informativo para fins preditivos e evitar que a análise de granularidade seja contaminada por sinais degenerados, patológicos ou estruturalmente incompletos.

Em seguida, as três bases são alinhadas temporalmente a partir das tabelas oficiais de tempo do conjunto de dados. Os identificadores temporais são convertidos em representações cronológicas explícitas, permitindo associar observações diárias, horárias e de 10 minutos a um mesmo identificador diário por instituição. A partir desse alinhamento, é construída uma malha temporal regular para a resolução fina, cobrindo todas as combinações esperadas de hora e subintervalo dentro de cada dia. As lacunas resultantes da ausência de medições são então preenchidas localmente por propagação temporal, sempre dentro do mesmo grupo temporal, evitando vazamento entre instituições distintas. Esse desenho é importante porque torna a comparação entre granularidades mais coerente e fornece uma base regularizada para o janelamento supervisionado posterior.

3.3. Predição dos Dados

A etapa de predição foi estruturada a partir de três arquiteturas recorrentes amplamente consolidadas na literatura de previsão temporal: RNN, LSTM e GRU. A escolha desses modelos decorre do fato de todos serem capazes de modelar dependências sequenciais, mas com diferentes mecanismos internos de memória e atualização de estado. Redes recorrentes simples fornecem uma linha de base importante para tarefas temporais, enquanto LSTMs foram introduzidas justamente para lidar melhor com dependências de

longo alcance, mitigando problemas de dissipação de gradiente em sequências extensas. Já as GRUs surgem como uma alternativa recorrente com mecanismo de portas mais compacto, frequentemente apresentando desempenho comparável ao de LSTMs em tarefas de modelagem sequencial.

Para tornar a tarefa compatível com aprendizado supervisionado, cada série institucional é transformada em amostras por meio de janelas deslizantes. Na granularidade diária, a formulação utiliza sete observações passadas para prever o próximo dia. Na granularidade horária, emprega-se uma janela correspondente a sete dias em resolução horária para prever as 24 horas subsequentes. Já na granularidade de 10 minutos, a formulação preserva a previsão de um dia à frente, mas com histórico e horizonte expressos na resolução fina, de modo que a janela incorpora subintervalos de dez minutos e o deslocamento entre amostras é ajustado para manter coerência com a estrutura temporal. Esse desenho busca garantir que a comparação entre granularidades não seja feita apenas sobre escalas distintas, mas sobre horizontes semanticamente compatíveis, todos associados à previsão do comportamento futuro de um dia de tráfego.

Após o janelamento, as séries são particionadas cronologicamente em treino, validação e teste, preservando a ordem temporal e impedindo vazamento de informação futura. No fluxo implementado, a separação efetiva é realizada em proporções de 60% para treino, 30% para validação e 10% para teste, sendo o ajuste dos modelos conduzido sobre o conjunto de treino e a seleção comparativa apoiada no conjunto de validação.

Por fim, adota-se uma técnica adaptada de normalização por instituição, adequada a um modelo generalista treinado sobre múltiplas séries com amplitudes muito distintas. Em vez de aplicar uma única transformação global, cada instituição é escalada individualmente com base apenas em seu subconjunto de treino, e a mesma transformação é então reaplicada aos conjuntos de validação e teste correspondentes. Essa escolha preserva o caráter comparativo entre instituições sem apagar a estrutura relativa interna de cada série, além de reduzir o viés causado por grandes diferenças de magnitude entre perfis de tráfego. Na prática, isso permite que um mesmo modelo seja exposto a padrões temporais de várias instituições em uma escala mais compatível, favorecendo o aprendizado do comportamento dinâmico sem depender de uma homogeneidade artificial entre séries originalmente heterogêneas.

4. Experimentos

Este trabalho investiga o impacto da granularidade temporal no desempenho da previsão de tráfego de rede utilizando o subconjunto de instituições do *CESNET-TimeSeries24*, uma base real coletada ao longo de 40 semanas na rede *CESNET3*. O estudo considera a métrica `n_bytes` como sinal univariado de volume de tráfego e explora três granularidades com o objetivo de analisar como diferentes níveis de agregação afetam a representação da série e a capacidade preditiva dos modelos. A escolha dos dados se justifica por seu caráter realista, pela disponibilização explícita de múltiplas granularidades e pela presença de lacunas e irregularidades típicas de dados operacionais, o que o torna particularmente adequado para uma análise metodológica orientada à qualidade da modelagem e à escolha da resolução temporal.

Os dados são inicialmente carregados separadamente para cada granularidade e organizados por instituição e ordem temporal. Em seguida, aplica-se uma etapa de fil-

tragem para remover instituições com poucas observações, valores nulos, variância nula, valores negativos ou comportamento extremo, de modo a reduzir o risco de comparações enviesadas por séries patológicas. Após essa seleção, as bases são alinhadas temporalmente com auxílio das tabelas oficiais do CESNET, permitindo associar observações de diferentes resoluções a uma mesma referência cronológica. Para as resoluções mais finas, lacunas internas são completadas estruturalmente e preenchidas localmente, preservando a regularidade da série antes da modelagem. A formulação preditiva é então construída com janelas deslizantes semanticamente comparáveis: na resolução diária, utilizam-se os sete dias anteriores para prever o dia seguinte; na horária, sete dias em horas para prever as próximas 24 horas; e, na granularidade de 10 minutos, os dois dias anteriores para prever o dia subsequente. Posteriormente, cada série é particionada cronologicamente em treino, validação e teste, nas proporções de 60%, 30% e 10%, respectivamente, com normalização independente por instituição ajustada apenas no conjunto de treino.

Na etapa de modelagem, são avaliadas três arquiteturas recorrentes amplamente empregadas em tarefas de previsão temporal: RNN, LSTM e GRU. A comparação entre essas arquiteturas busca verificar como diferentes mecanismos de memória e atualização de estado respondem às distintas resoluções temporais do tráfego. Para reduzir o viés associado a escolhas manuais de configuração, os modelos são submetidos a um processo sistemático de otimização de hiperparâmetros, tomando o NRMSE de validação como critério de seleção. Essa busca considera diferentes combinações relacionadas tanto à dinâmica de treinamento quanto à capacidade representacional dos modelos, incluindo tamanho de lote, número de épocas, taxa de *dropout* e número de unidades ocultas, além de variações complementares em profundidade e dimensionalidade interna quando aplicável. O desempenho final é avaliado com base em MAE, RMSE, NRMSE e SMAPE, permitindo analisar simultaneamente erro absoluto, sensibilidade a grandes desvios, comparabilidade entre séries de magnitudes distintas e erro relativo percentual. Com isso, o protocolo experimental fornece um cenário controlado para isolar o efeito da granularidade temporal sobre a aprendizagem e a robustez da predição em dados reais de tráfego de rede.

5. Resultados

Esta seção apresenta os resultados obtidos a partir dos experimentos realizados com o conjunto de dados *CESNET-TimeSeries24*, com foco na influência da granularidade temporal sobre o desempenho da predição. A análise considera tanto as métricas agregadas quanto o comportamento do erro ao longo do horizonte de previsão, permitindo uma avaliação mais completa da robustez dos modelos nas diferentes resoluções analisadas.

A Figura 2 apresenta a comparação entre as granularidades diária, horária e de 10 minutos para os modelos GRU, LSTM e RNN. De forma geral, observa-se que a granularidade horária apresentou os menores valores de RMSE em todos os modelos, indicando melhor desempenho em termos de erro absoluto. A granularidade de 10 minutos, por sua vez, apresentou os menores valores de NRMSE, sugerindo melhor desempenho relativo à escala da série. Já a granularidade diária obteve, de modo recorrente, os maiores erros, indicando que a agregação mais grossa reduz a capacidade de capturar padrões temporais relevantes para a tarefa preditiva.

Entre os modelos avaliados, a GRU apresentou os melhores resultados gerais, com

desempenho ligeiramente superior ao da LSTM na maior parte dos cenários. A RNN simples apresentou os maiores erros, tanto nas métricas agregadas quanto na análise de degradação, confirmando menor robustez frente às demais arquiteturas recorrentes.

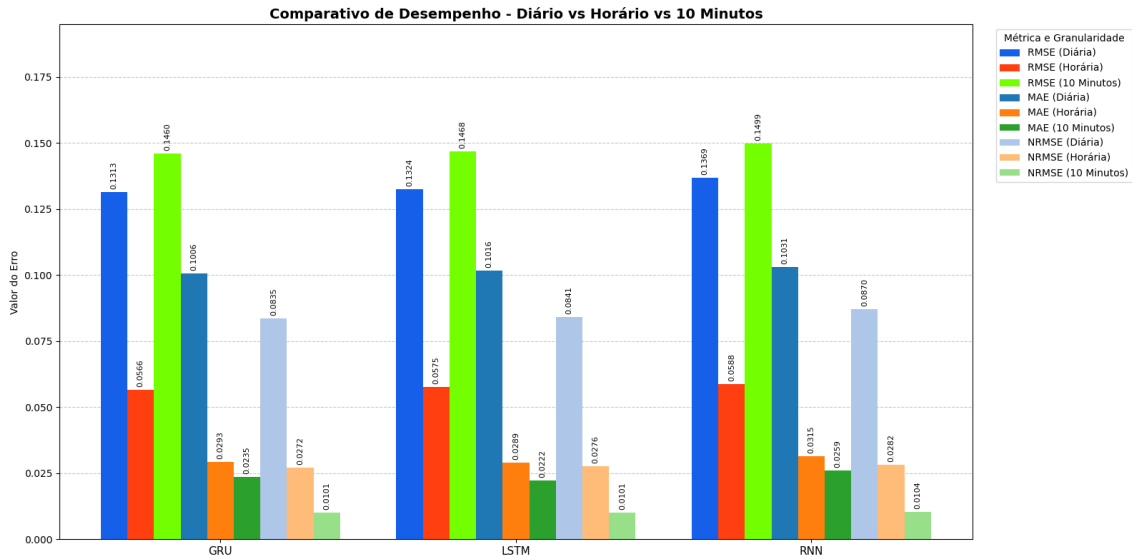


Figura 2. Comparativo de desempenho entre as granularidades diária, horária e de 10 minutos.

As Figuras 3 e 4 mostram as curvas de degradação para as granularidades horária e de 10 minutos. Na resolução horária, as curvas apresentam crescimento mais suave do erro ao longo do horizonte, indicando maior estabilidade preditiva. Nessa configuração, a GRU manteve o comportamento mais consistente, seguida pela LSTM, enquanto a RNN apresentou maior erro e maior instabilidade, sobretudo nos passos finais.

Na granularidade de 10 minutos, o comportamento foi mais oscilatório, com picos recorrentes ao longo do horizonte de previsão. Esse resultado indica maior sensibilidade a variações locais e maior dificuldade de modelagem nessa resolução mais fina. Ainda assim, GRU e LSTM mantiveram desempenho próximo entre si, enquanto a RNN novamente apresentou os piores resultados.

5.1. Discussão Final

Os resultados obtidos mostram que a granularidade temporal influencia diretamente o desempenho dos modelos e a estabilidade da predição ao longo do horizonte. De forma geral, a granularidade horária apresentou o melhor equilíbrio entre erro absoluto reduzido, estabilidade das curvas de degradação e consistência entre os modelos, o que a torna a alternativa mais robusta no cenário avaliado.

A granularidade de 10 minutos mostrou-se vantajosa do ponto de vista do erro relativo, preservando mais detalhes temporais da série. No entanto, essa maior riqueza de informação veio acompanhada de maior instabilidade, evidenciada pelas oscilações e pelos picos recorrentes observados nas curvas de degradação. Já a granularidade diária apresentou desempenho inferior, sugerindo que o aumento excessivo da agregação temporal compromete a representação da dinâmica do tráfego.

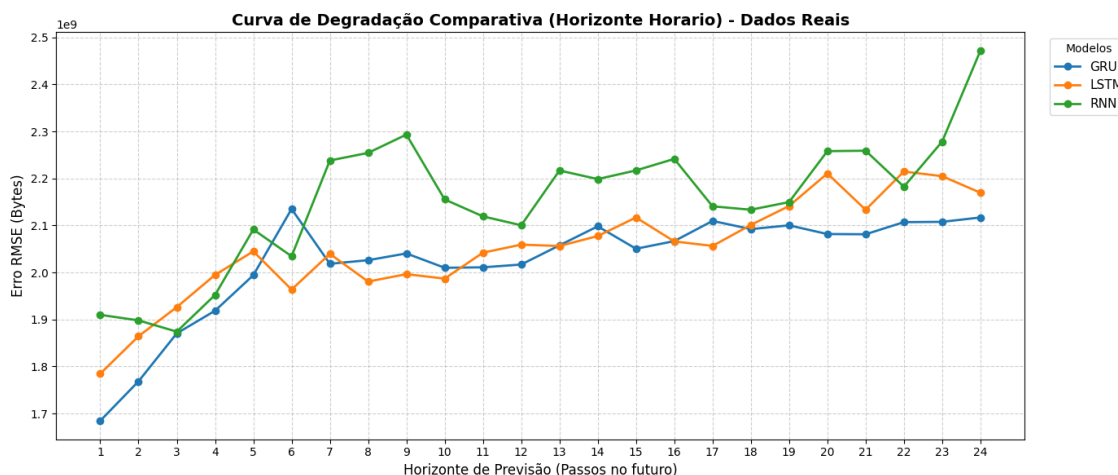


Figura 3. Curvas de degradação na granularidade horária para os diferentes modelos.




Figura 4. Curvas de degradação na granularidade de 10 minutos para os diferentes modelos.

6. Conclusão

Este trabalho apresentou uma abordagem robusta para predição de tráfego de rede com foco na análise do impacto da granularidade temporal sobre a qualidade preditiva em dados reais. A proposta foi construída a partir do conjunto de dados *CESNET-TimeSeries24*, considerando as resoluções diária, horária e de 10 minutos, com o objetivo de investigar, de forma controlada, como diferentes níveis de agregação influenciam a representação das séries e o desempenho de modelos recorrentes amplamente utilizados na literatura. Para isso, o estudo combinou um processo de pré-processamento robusto, um desenho experimental comparável entre granularidades e uma avaliação que considerou tanto métricas agregadas quanto o comportamento da degradação ao longo do horizonte de previsão.

Os resultados mostraram que a granularidade temporal exerce influência direta e relevante sobre a tarefa preditiva. De modo geral, observou-se que a granularidade horária apresentou o melhor equilíbrio entre estabilidade e desempenho absoluto, produzindo curvas de degradação mais suaves e menores valores de erro em termos absolutos. A granularidade de 10 minutos, por sua vez, apresentou maior riqueza temporal e bons resultados relativos, especialmente em termos normalizados, mas também revelou maior sensibilidade a oscilações locais e picos recorrentes de erro ao longo do horizonte. Já a granularidade diária se mostrou menos competitiva, indicando que níveis mais altos de agregação podem reduzir excessivamente a variabilidade útil do sinal para fins de predição. Em paralelo, entre os modelos avaliados, a GRU apresentou o comportamento mais consistente, seguida de perto pela LSTM, enquanto a RNN simples confirmou seu papel como *baseline* menos robusta frente à complexidade temporal do problema.

Dessa forma, a principal contribuição deste trabalho está em evidenciar que a granularidade temporal não deve ser tratada apenas como uma escolha operacional de pré-processamento, mas como uma variável metodológica central no desenho de pipelines de predição de tráfego de rede.

Como continuidade natural desta pesquisa, um caminho promissor consiste em explorar o uso conjunto de múltiplas granularidades dentro do mesmo processo preditivo, em vez de tratá-las apenas como alternativas excludentes. Nesse contexto, trabalhos futuros podem investigar o uso das granularidades diária, horária e de 10 minutos como *features* complementares, buscando enriquecer a representação da série com aspectos distintos capturados em cada escala temporal.

Agradecimentos

Pesquisa parcialmente financiada pelo CNPq (Processos 305946/2025-0 e 405940/2022-0) e Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 88887.954253/2024-00 e 88887.972043/2024-00.

Referências

- Baganal-Krishna, N., Lübben, R., Liotou, E., Katsaros, K. V., and Rizk, A. (2024). A federated learning approach to qos forecasting in cellular vehicular communications: Approaches and empirical evidence. *Computer Networks*, 242:110239.
- Bi, S. and Wang, H. (2024). Network traffic prediction based on the multi-time granularity gru-bp neural network. *IEEE Access*, 12:96997–97003.
- Brito, M. L. L., Ferreira, M. C. M., Portela, A. L. C., and Gomes, R. L. (2026). Ai-based estimation of bandwidth availability for data offloading in edge-cloud computing. *IEEE Networking Letters*, 8:69–73.
- Feng, W., Li, L., Zhou, H., Xie, B., Zhao, D., Zhang, Y., and Wang, F. (2026). Robust long-term spatial-temporal forecasting for dynamic networks: The mdetst model. *Mathematics*, 14(4).
- Ferreira, G. O., Ravazzi, C., Dabbene, F., Calafiore, G. C., and Fiore, M. (2023). Forecasting network traffic: A survey and tutorial with open-source comparative evaluation. *IEEE Access*, 11:6018–6044.
- Ferreira, M., Linhares, M., Araújo, T., and Gomes, R. (2025). Aplicando decomposição de valores singulares na predição de vazão de rede. In *Anais do XLIII Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*, pages 630–643, Porto Alegre, RS, Brasil. SBC.
- Ferreira, M. C., Ribeiro, S. E., Nobre, F. V., Linhares, M. L., Araújo, T. P., and Gomes, R. L. (2024). Mitigating measurement failures in throughput performance forecasting. In *2024 20th International Conference on Network and Service Management (CNSM)*, pages 1–7.
- Gomes, R. L., Bittencourt, L. F., and Madeira, E. R. (2014). A bandwidth-feasibility algorithm for reliable virtual network allocation. In *2014 IEEE 28th International Conference on Advanced Information Networking and Applications*, pages 504–511.

- Gomes, R. L., Bittencourt, L. F., Madeira, E. R., Cerqueira, E., and Gerla, M. (2016). Bandwidth-aware allocation of resilient virtual software defined networks. *Computer Networks*, 100:179–194.
- Koumar, J., Hynek, K., Čejka, T., and Šiška, P. (2024). Cesnet-timeseries24: Time series dataset for network traffic anomaly detection and forecasting.
- Koumar, J., Smoleň, T., Jeřábek, K., and Čejka, T. (2025). Comparative analysis of deep learning models for real-world isp network traffic forecasting.
- Leoni, G., Rosati, P., Lynn, T., Kelner, J., Sadok, D., and Endo, P. (2021). Predicting short-term mobile internet traffic from internet activity using recurrent neural networks. *International Journal of Network Management*, 32.
- Liu, F., Farkiani, B., and Crowley, P. (2026). Time-series foundation models for isp traffic forecasting.
- Lopes Gomes, R. and Roberto Mauro Madeira, E. (2012). A traffic classification agent for virtual networks based on qos classes. *IEEE Latin America Transactions*, 10(3):1734–1741.
- Nobre, F. V. J., Silva, D. d. S., Ferreira, M. C. M. M., Brito, M. L. M. L., de Araújo, T. P., and Gomes, R. L. (2025). Time-weighted correlation approach to identify high delay links in internet service providers. *Journal of Internet Services and Applications*, 16(1):419–430.
- Park, J., Kang, H., Han, S., and Kang, P. (2025). Granularity fusion transformer: Learning multi-granularity patterns for time-series forecasting. *Knowledge-Based Systems*, 320:113644.
- Santos, E. and Almeida, T. (2025). From statistics to deep learning: Forecasting mobile throughput. In *Anais do XIII Symposium on Knowledge Discovery, Mining and Learning*, pages 137–144, Porto Alegre, RS, Brasil. SBC.
- Santos, G. L., Rosati, P., Lynn, T., Kelner, J., Sadok, D., and Endo, P. T. (2020). Predicting short-term mobile internet traffic from internet activity using recurrent neural networks.
- Shubo, S. and Haipeng, H. (2024). Network traffic prediction based on the multi-time granularity gru-bp neural network. *IEEE Access*, 12:96997–97003.
- Souza, M. S., Ribeiro, S. E. S. B., Lima, V. C., Cardoso, F. J., and Gomes, R. L. (2024). Combining regular expressions and machine learning for sql injection detection in urban computing. *Journal of Internet Services and Applications*, 15(1):103–111.
- Wang, X., Wang, Z., Yang, K., Song, Z., Bian, C., Feng, J., and Deng, C. (2024). A survey on deep learning for cellular traffic prediction. *Intelligent Computing*, 3:0054.
- Yu, H., Wang, Z., Xie, Y., and Wang, G. (2024). A multi-granularity hierarchical network for long- and short-term forecasting on multivariate time series data. *Applied Soft Computing*, 157:111537.
- Zhu, Y., Jiang, B., Jin, H., Zhang, M., Gao, F., Huang, J., Lin, T., and Wang, X. (2024). Networked time-series prediction with incomplete data via generative adversarial network. *ACM Trans. Knowl. Discov. Data*, 18(5).