

Identificação das Causas de Situações de Alto Atraso em Provedores de Internet

Danielle S. Silva¹, Francisco V. J. Nobre¹, Maria C. Ferreira¹,
Ariel L. Portela¹, Thelmo P. Araújo¹, Rafael L. Gomes¹

¹Universidade Estadual do Ceará (UECE), Fortaleza, Ceará, Brasil.

{danielle.santos, valderlan.nobre, clara.mesquita,
ariel.portela}@aluno.uece.br, {thelmo.araujo, rafa.lopes}@uece.br

Resumo. *Provedores de Internet (ISPs) oferecem serviços de monitoramento de rede que incluem testes regulares de desempenho, sendo o atraso fim-a-fim uma informação crucial. Contudo, as ferramentas de monitoramento ainda precisam evoluir para abranger atividades mais complexas, como a detecção de situações de atraso alto. Dentro deste contexto, este trabalho apresenta um método para detectar situações de atraso alto em enlaces de comunicação na infraestrutura de rede utilizando um Score de Impacto proposto, baseado em técnicas de correlação de dados, sobre dados de ferramentas de monitoramento de rede. Os experimentos, utilizando dados reais da Rede Nacional de Ensino e Pesquisa (RNP), mostram que o método proposto é capaz de indicar os enlaces da rede que comprometem o atraso ponta a ponta.*

Abstract. *Internet Service Providers (ISPs) offer network monitoring services that include regular performance tests, with end-to-end delay being a critical piece of information they provide. Nevertheless, the monitoring tools still need to evolve to encompass more complex activities, such as high-delay detection. Within this context, this paper presents a method to detect high delays in communication links in the network infrastructure using the proposed Impact Score, based on data correlation techniques, over data from network monitoring tools. The experiments, using real data from the National Education and Research Network (RNP), show that the proposed method is capable of indicating the network links that compromise the end-to-end delay.*

1. Introdução

Na era moderna, é crucial para entidades como Provedores de Serviços de Internet (ISPs), empresas e instituições utilizarem serviços de monitoramento de rede para avaliar métricas de desempenho e dados. Isso envolve analisar aspectos como atraso, perda, taxa de transferência e outros [Gomes et al. 2020]. O atraso de ida e volta, que mede a latência de ponta a ponta para a transmissão de bits através da rede, pode informar decisões de gestão [Mok et al. 2021], como expandir a infraestrutura de rede, definir expectativas de Qualidade de Serviço (QoS), avaliar Acordos de Nível de Serviço (SLA) e analisar a demanda por recursos de rede [Moreira et al. 2021, Silveira et al. 2023].

Quando se trata de Qualidade de Serviço (QoS), a latência de ponta a ponta impacta a eficiência e eficácia. Altos atrasos podem causar baixa taxa de transmissão, congestionamento e até falhas no sistema, resultando em experiências ruins para o usuário e

diminuição da produtividade da rede e dos clientes [Portela et al. 2024]. Por outro lado, atrasos baixos e eficientes podem melhorar a experiência de rede do cliente, resultando em aumento da produtividade e desempenho geral do sistema. Portanto, é essencial monitorar e otimizar o desempenho do atraso para garantir um serviço de alta qualidade. Ao monitorar o desempenho do atraso, é possível manter um ambiente de rede ótimo e garantir variações na demanda da internet causadas pelo comportamento elástico, que afeta significativamente o desempenho do atraso. Esse comportamento ocorre quando os usuários finais acessam a internet de maneiras diferentes, dependendo de sua localização, levando a flutuações na demanda ao longo do dia [Gomes et al. 2020, da Silva et al. 2020]. Não lidar adequadamente com cenários elásticos pode resultar em interrupções no serviço, lentidão e desconexões, levando, em última instância, a violações dos requisitos do SLA [Portela et al. 2023]. Para manter métricas de QoS, é essencial considerar abordagens adaptáveis adaptadas ao comportamento elástico [Silveira et al. 2023] para garantir que o sistema esteja funcionando da melhor forma possível.

Apesar da importância das medições de rede, as ferramentas de monitoramento que realizam essas medições ainda precisam evoluir em vários aspectos, como a identificação de altos atrasos em links de comunicação na infraestrutura de rede. Esses cenários de alto atraso podem impactar os Provedores de Serviços de Internet (ISPs), levando a uma baixa qualidade de serviço em aplicativos de rede, bem como afetando a experiência do usuário em aplicativos como videoconferência, jogos online e comunicação em tempo real.

Assim, a identificação desses altos atrasos em links de comunicação beneficia os ISPs nos seguintes aspectos [Scarpitta et al. 2023, BinSahaq et al. 2022]: (I) Planejamento de Capacidade: a identificação permite que as organizações antecipem as demandas futuras e aloquem recursos de acordo, evitando congestionamentos na rede; (II) Monitoramento de Qualidade: a identificação permite que os ISPs meçam e rastreiem o desempenho da rede ao longo do tempo, garantindo que os SLAs sejam cumpridos; (III) Alocação de Recursos: a identificação permite que as organizações aloquem mais recursos para links críticos e reduzam gastos desnecessários em links subutilizados; e, (IV) Otimização de Desempenho: a identificação permite configurações de gerenciamento de rede mais eficientes (como decisões de roteamento, balanceamento de carga e alocação de recursos), evitando links de alto atraso e, conseqüentemente, reduzindo a latência de ponta a ponta.

Dentro deste contexto, este artigo apresenta um método para identificar altos atrasos em links de comunicação na infraestrutura de rede utilizando o Score de Impacto proposto sobre dados de ferramentas de monitoramento de rede. O Score de Impacto proposto aplica técnicas de correlação de dados, que quantificam e analisam a relação estatística ou associação entre duas ou mais variáveis em medidas de rede, ajudando a descobrir padrões, dependências e insights nos dados analisados. Para avaliar o método proposto, realizamos vários experimentos usando dados reais de medidas de rede do Serviço de Monitoramento da Rede Ipê (Monipê)¹, da Rede Nacional de Ensino e Pesquisa (RNP). Os resultados mostram que o método proposto é capaz de indicar os links de rede envolvidos em casos de alto atraso de ponta a ponta.

¹monipe-central.rnp.br

O restante deste artigo está organizado da seguinte forma: A Seção 2 apresenta os trabalhos relacionados existentes. A Seção 3 apresenta o mecanismo de identificação de causas de problemas de desempenho proposto, enquanto a Seção 4 descreve os resultados dos experimentos realizados. Por fim, a Seção 5 conclui o artigo e apresenta trabalhos futuros.

2. Trabalhos Relacionados

Esta seção descreve os principais trabalhos relacionados, e recentemente publicados pela comunidade científica, sobre correlação de dados no contexto de redes de computadores, incluindo aspectos de desempenho e qualidade de serviço. A Tabela 1 resume os trabalhos existentes na literatura, destacando as diferenças em relação a proposta, onde a coluna *Contexto* apresenta o ambiente em que o trabalho relacionado atua, enquanto a coluna *Abordagem* informa a estratégia aplicada e o objetivo do artigo, respectivamente.

Scarpitta et al. [Scarpitta et al. 2023] propõem uma solução para *Software-Defined Wide Area Networks* (SD-WANs) que utiliza o *Simple Two-way Active Measurement Protocol* (STAMP) para monitorar o atraso de um caminho *Segment Routing over IPv6* (SRv6) entre dois nós. Esta ferramenta de monitoramento provê insumos para soluções de gerenciamento de redes que usam dados de medição para dar suporte aos administradores de rede.

Arachchige et al. [Arachchige et al. 2023] realizaram um estudo, usando técnicas de correlação de dados, sobre as temperaturas atingidas em dispositivos usados para processar algoritmos blockchain e o consumo de energia de três algoritmos blockchain comumente usados, executados em microcontroladores de baixa potência no contexto de redes de sensores sem fio. Este estudo foi limitado apenas aos dados de temperatura do dispositivos que executam as ações no blockchain e consumo de energia destes dispositivos. Assim, apesar de aplicar técnicas de correlação, o contexto do trabalho é diferente da proposta deste artigo, mas mostra a importância da correlação de dados no processo de identificação de eventos e suporte a tomada de decisão.

Imran et al. [Imran et al. 2023] investigam o tempo para detectar um ataque em redes IoT baseadas no protocolo Transporte de telemetria de Enfileiramento de Mensagens (Message Queuing Telemetry Transport - MQTT). Os autores usam abordagens de aprendizado de máquina e propõe uma abordagem que aplica análise de correlação para reduzir o tempo de treinamento e teste desses algoritmos. Os autores concluem que a análise de correlação é significativamente benéfica no processo de engenharia de recursos, principalmente para determinar os recursos mais relevantes no conjunto de dados MQTT. Similarmente, Wang et al. [Wang et al. 2024] aplicam uma variação de uma Rede Neural Recorrente (*Recurrent Neural Network* - RNN) baseado em correlação de dados para determinar o tamanho do reservatório que corresponde a uma determinada tarefa de treinamento. A proposta dos autores utiliza a teoria da probabilidade e a teoria da informação para medir a correlação entre os neurônios da RNN, removendo dinamicamente os neurônios com baixa correlação e construindo uma matriz de características mais concisa. A proposta em questão foca em otimizar o treinamento e uso de variações de rede neurais, sem um contexto específico em si.

A partir do levantamento bibliográfico realizado, nota-se que nenhum artigo da literatura se concentrou no desenvolvimento de um mecanismo de identificação de causas

Tabela 1. Trabalhos Relacionados

| Referencias | Contexto | Abordagem |
|--|----------------------------------|---|
| Scarpitta et al. [Scarpitta et al. 2023] | SD-WANs | Monitoramento do atraso de comunicação em um caminho SRv6. |
| Imran et al. [Imran et al. 2023] | Detecção de Ataques em Redes IoT | Análise de correlação para reduzir o tempo de treinamento das técnicas de detecção. |
| Arachchige et al. [Arachchige et al. 2023] | Blockchain e IoT | Correlação de dados de temperatura e consumo de energia ao executar atividades de blockchain. |
| Wang et al. [Wang et al. 2024] | Otimização de RNNs | Teorias da probabilidade e da informação para medir a correlação de dados de treinamento. |
| Nossa Proposta | Situações de Alto Atraso. | Correlação de Dados de Medição de Rede. |

de problema de desempenho de rede que utilize dados de monitoramento de rede, que é o foco deste artigo. Nossa proposta realiza ações estatísticas para aprimorar o processo de detecção, criando um *Score* que facilita o processo de gerência de desempenho de rede.

3. Proposta

O método proposto para identificar altos atrasos em links de comunicação requer duas informações para realizar as identificações: atraso de ponta a ponta e o traceroute da comunicação de ponta a ponta (rastrear a rota que os pacotes de dados fazem ao viajar de um computador/dispositivo para outro). Em geral, o método proposto possui os seguintes passos: Coleta de Dados, Identificação de Alto Atraso, Cálculo da Matriz de Correlação e Cálculo do Score de Impacto. Uma visão geral dos passos realizados é apresentada na Figura 1.

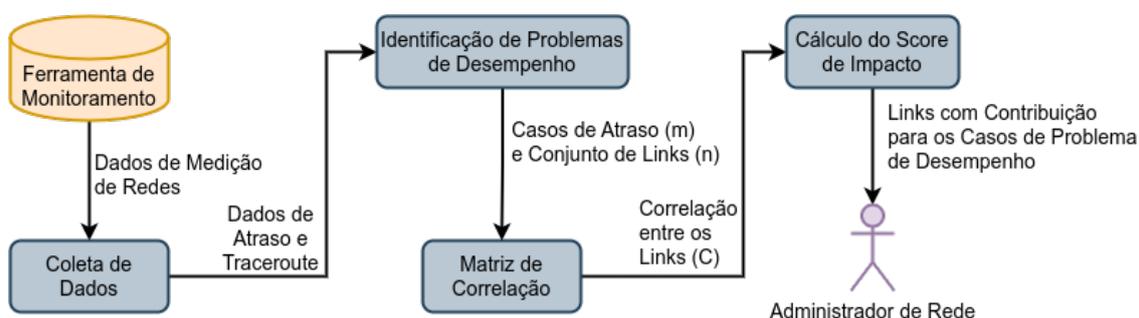


Figura 1. Visão Geral da Solução.

Inicialmente, os dados sobre a infraestrutura de rede são inseridos no método, onde esse processo de coleta de dados é realizado a cada minuto, obtendo todos os dados sobre o atraso de ponta a ponta e o traceroute (caminhos utilizados na comunicação). Ferramentas de medição e monitoramento de rede geram esses dados para apoiar o diagnóstico e a solução de problemas de desempenho de rede.

Após receber o conjunto de dados, o método busca por casos de medição com alto atraso, ou seja, atrasos de ponta a ponta superiores a $60ms$, uma vez que é um limite adequado para os serviços dos ISPs [Scarpitta et al. 2023, BinSahaq et al. 2022]. Em seguida, a partir dos dados do traceroute, o método seleciona os links que fazem parte dos caminhos desses casos de alto atraso. A partir desses passos, uma matriz M com m linhas e n colunas representa os m casos de atraso e o conjunto de n links de comunicação que fazem parte desses casos. A partir da matriz de dados inicial M , é calculada a matriz de correlação C e, a partir da matriz C , é calculado o Score de Impacto. Esses dois últimos passos são detalhados nas subseções seguintes.

3.1. Correlação de Dados

As técnicas de correlação de dados envolvem identificar e quantificar relações, dependências ou associações entre diferentes variáveis ou conjuntos de dados [Costa et al. 2021, Li et al. 2021]. Essas técnicas são comumente usadas em diversos campos, incluindo estatística, análise de dados, aprendizado de máquina e ciência de dados. O valor de correlação aumenta à medida que a relação entre as variáveis se torna mais forte. É importante lembrar que correlação não implica causalidade, o que significa que apenas porque duas variáveis estão correlacionadas não significa que uma cause a outra. A correlação de dados é útil para identificar relações entre variáveis na análise de dados, mas é necessário considerar outras informações e análises para estabelecer causalidade [Gottwalt et al. 2019].

Uma das técnicas de correlação de dados mais populares é o Coeficiente de Correlação de Pearson, frequentemente denotado como r . É uma medida estatística que quantifica a força e a direção da relação linear entre duas variáveis contínuas. Avalia o quão bem a relação entre duas variáveis pode ser descrita por uma linha reta. O coeficiente produz um valor entre -1 e 1 , onde: (i) $r = 1$ indica uma correlação linear positiva perfeita; (ii) $r = -1$ indica uma correlação linear negativa perfeita; e (iii) $r = 0$ indica nenhuma correlação linear. A correlação de Pearson é calculada usando a Equação 1. Na equação, x_i e y_i são pontos de dados das duas variáveis sendo correlacionadas, enquanto \bar{x} e \bar{y} são os valores médios das duas variáveis. Posteriormente, é gerada uma matriz de correlação, chamada C , onde $C_{i,j} = r(x, y)$.

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

Em relação às propriedades da correlação de Pearson [Pires and Mascarenhas 2023], seu valor varia entre -1 e 1 , onde -1 indica uma correlação negativa perfeita, 1 indica uma correlação positiva perfeita e 0 indica nenhuma correlação linear. Assim, $r > 0$ indica uma correlação positiva, ou seja, conforme uma variável aumenta, a outra tende a aumentar também. O caso de $r < 0$ indica uma correlação negativa, ou seja, conforme uma variável aumenta, a outra tende a diminuir. Já $r = 0$ indica nenhuma correlação linear, ou seja, as variáveis não estão linearmente relacionadas. Outras propriedades incluem simetria, o que significa que $r(x, y) = r(y, x)$, e linearidade, que mede relações lineares entre variáveis. Apesar disso, a correlação de Pearson é sensível a valores discrepantes, que podem influenciar desproporcionalmente o coeficiente [Kim et al. 2015].

3.2. Score de Impacto

Após o cálculo da matriz de correlação dos dados, é necessário extrair conhecimento sobre a situação atual da infraestrutura de rede. Para permitir a identificação de links de comunicação que afetam o atraso de ponta a ponta, projetamos o Score de Impacto, que representa o grau de responsabilidade de um link de comunicação em casos de alto atraso na infraestrutura de rede. O Score de Impacto é definido pela Equação 2, onde $[C_{i,j} > 0]$ é uma função que retorna 1 se $C_{i,j}$ for positivo (maior que 0) e 0 caso contrário. Assim, o Score de Impacto tem como objetivo agregar os valores de correlação de um link específico que faz parte dos caminhos nos casos de alto atraso, indicando um grau de responsabilidade pela situação atual.

$$ImpactScore(C) = \sum_{i=1}^m \sum_{j=1}^n (C_{ij} \cdot [C_{ij} > 0]) \quad (2)$$

Quanto mais forte for a relação entre os links, maior será o valor da correlação. Consequentemente, o Score de Impacto proposto foca em identificar o conjunto de links que têm uma correlação mais alta com outros links quando ocorre uma situação de alto atraso. Dessa forma, quanto maior o Score de Impacto, maior a chance deste link ser a raiz (ou uma delas) deste problema. É importante lembrar que correlação não implica causalidade, o que significa que apenas porque duas variáveis estão correlacionadas não significa que uma cause a outra. Portanto, o papel do Score de Impacto é crucial no processo de identificação de problemas de desempenho e melhoria da capacidade de gerenciamento dos ISPs.

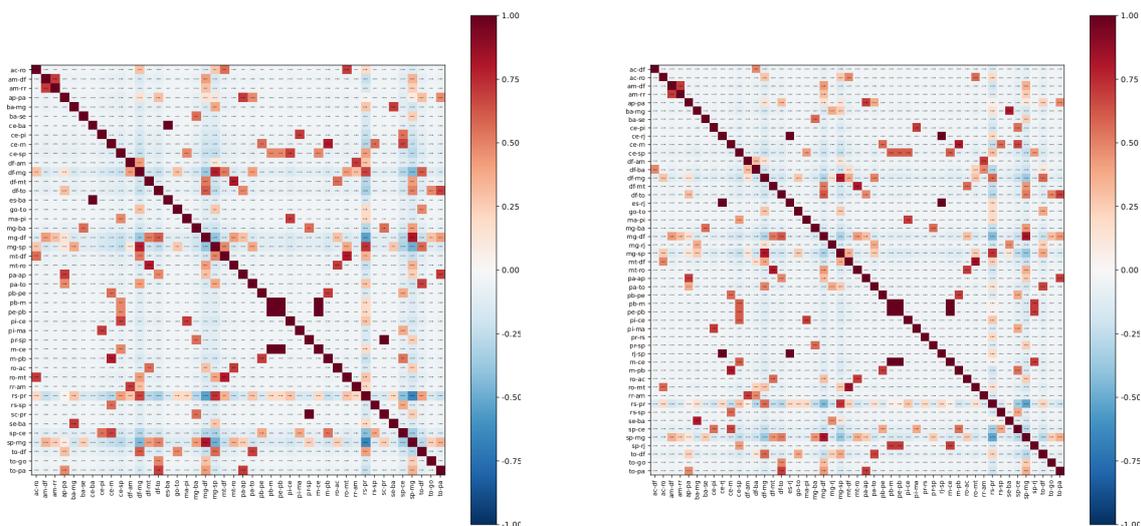
4. Resultados

Para realizar experimentos realistas, utilizamos os dados do serviço de monitoramento (MonIPÊ) da RNP², conforme mencionado anteriormente, que utiliza o padrão internacional de monitoramento perfSONAR³, onde as medições de taxa de transferência ocorrem a cada quatro horas, atraso a cada minuto e traceroute a cada dez minutos no dia. Vale ressaltar que a RNP possui pontos de comunicação em todos os 26 estados da República Federativa do Brasil, incluindo o Distrito Federal, e que esses pontos de comunicação têm comportamentos diferentes devido às suas particularidades. A Figura 3 fornece a visualização da infraestrutura de rede e suas características (nós, capacidade dos links, distribuição geográfica, entre outros).

Nos experimentos realizados, coletamos os dados em três momentos distintos: 22h36min, 22h37min e 22h38min do dia 28 de maio de 2023. Esses horários foram escolhidos devido aos horários com mais medidas de altos atrasos. Assim, as matrizes geradas têm tamanhos diferentes devido a diferentes quantidades de atrasos nos momentos escolhidos. A Figura 2 exibe as matrizes de correlação para esses casos. Os valores $C_{i,j}$ nas matrizes indicam o coeficiente de correlação entre os links usados em uma rota (linhas) e os links diretos (colunas) onde houve medições de alto atraso durante um determinado tempo. Como mencionado anteriormente, a Rede Ipê possui Pontos de Presença (PoPs)

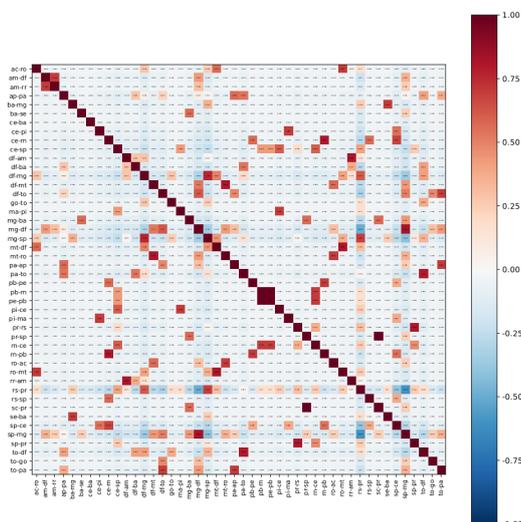
²www.rnp.br/en/ipe-network

³www.perfsonar.net



(a) Matriz de Correlação no Tempo 22:36h.

(b) Matriz de Correlação no Tempo 22:37h.



(c) Matriz de Correlação no Tempo 22:38h.

Figura 2. Resultados de Correlação

nas capitais de todos os estados do Brasil, incluindo o Distrito Federal, e a sigla dos estados de origem e destino indica os caminhos/links.

Embora a matriz de correlação possa oferecer informações valiosas sobre a possível causa do problema, utilizá-la como única fonte de análise pode não fornecer uma imagem relevante do desempenho entre os links e as possíveis fontes de atraso. Com as informações coletadas da matriz de correlação, os resultados na Figura 4 mostram os scores referentes aos links usados durante os períodos de alto atraso. Quanto maior o score, mais provável é que o link esteja contribuindo para o alto atraso na rota.

Ao adicionar as informações dos Scores de Impacto, é possível fornecer uma indicação melhor de qual dos links pode ser responsável por esses altos atrasos. Observando a Figura 4, após três minutos, encontramos os mesmos links com o maior Score de Impacto (df-mg, mg-sp, sp-mg e rs-pr), o que nos leva a concluir onde o problema

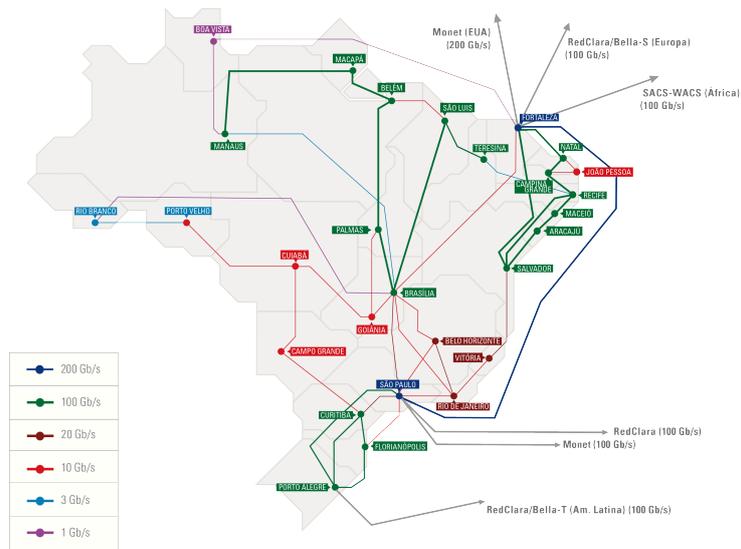
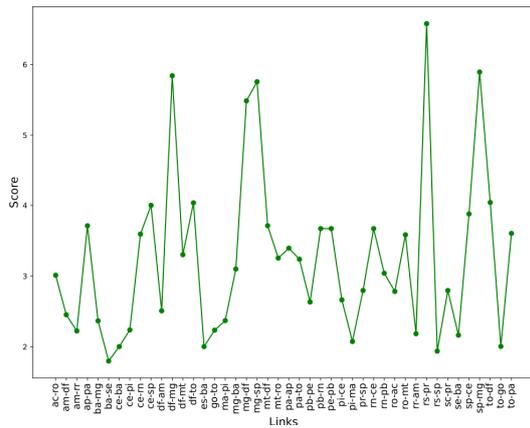
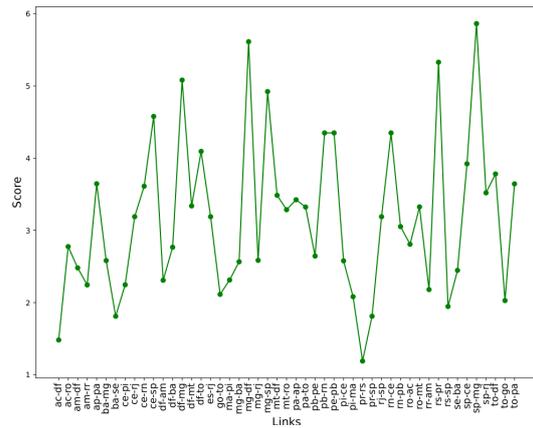


Figura 3. Rede Ipê da RNP.

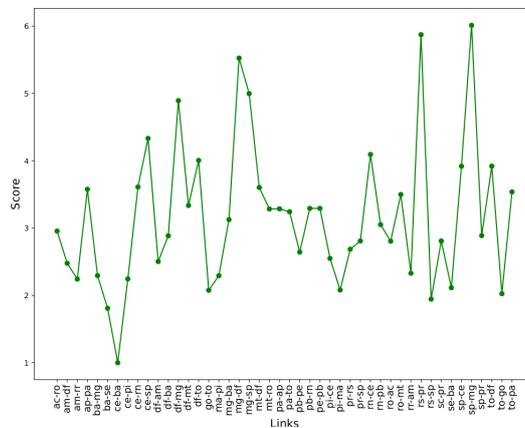
pode estar presente, indicando uma solução mais direcionada para esses casos.



(a) Score de Impacto no Tempo 22:36h.



(b) Score de Impacto no Tempo 22:37h.



(c) Score de Impacto no Tempo 22:38h.

Figura 4. Resultados do Score de Impacto

A partir da análise experimental realizada neste trabalho, concluímos que o método proposto traz uma grande vantagem para o gerenciamento de ISPs e desempenho de rede. Uma melhor identificação das possíveis causas de baixo desempenho de rede pode ajudar os gerentes de rede a otimizar o desempenho da rede, reduzir custos e melhorar a satisfação do usuário. Assim, nosso método permite que os gerentes de rede tomem decisões mais informadas e abordem proativamente problemas antes que impactem a rede ou seus usuários.

5. Conclusão

Muitas empresas e Provedores de Serviços de Internet (ISPs) atualmente oferecem serviços de monitoramento de rede, que envolvem a realização de testes de desempenho de rotina. Entre as informações cruciais que eles fornecem, o atraso de ponta a ponta se destaca. No entanto, ainda existe a necessidade contínua de evolução das ferramentas de monitoramento para lidar com tarefas mais complexas, como a detecção de altos atrasos.

Nesse contexto, este artigo apresenta um método para identificar atrasos elevados nos links de comunicação dentro da infraestrutura de rede. Essa metodologia se baseia no Score de Impacto proposto, que se fundamenta em técnicas de correlação de dados e utiliza dados provenientes de ferramentas de monitoramento de rede. Os experimentos conduzidos utilizando dados reais provenientes da Rede Nacional de Ensino e Pesquisa (RNP) demonstram a eficácia da abordagem proposta em identificar os links de rede que contribuem para o atraso de ponta a ponta geral.

Agradecimentos

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) do Brasil (*N^o* 303877/2021-9) e Rede Nacional de Pesquisa (RNP) através do Programa de Monitoramento de Redes (PMON 2023) e do Comitê Técnico de Ciência de Dados e Inteligência Artificial (CT-CDIA 2023) pelo apoio financeiro.

Referências

- Arachchige, K. G., Branch, P., and But, J. (2023). Evaluation of correlation between temperature of iot microcontroller devices and blockchain energy consumption in wireless sensor networks. *Sensors*, 23(14).
- BinSahaq, A., Sheltami, T., Mahmoud, A., and Nasser, N. (2022). Fast and efficient algorithm for delay-sensitive qos provisioning in sdn networks. *Wireless Networks*, pages 1–22.
- Costa, W. L., Portela, A. L., and Gomes, R. L. (2021). Features-aware ddos detection in heterogeneous smart environments based on fog and cloud computing. *International Journal of Communication Networks and Information Security*, 13(3):491–498.
- da Silva, G., Oliveira, D., Gomes, R. L., Bittencourt, L. F., and Madeira, E. R. M. (2020). Reliable network slices based on elastic network resource demand. In *NOMS 2020 - 2020 IEEE/IFIP Network Operations and Management Symposium*, pages 1–9.
- Gomes, R. L., Bittencourt, L. F., and Madeira, E. R. (2020). Reliability-aware network slicing in elastic demand scenarios. *IEEE Communications Magazine*, 58(10):29–34.

- Gottwalt, F., Chang, E., and Dillon, T. (2019). Corrcorr: A feature selection method for multivariate correlation network anomaly detection techniques. *Computers & Security*, 83:234–245.
- Imran, Zuhairi, M. F. A., Ali, S. M., Shahid, Z., Alam, M. M., and Su'ud, M. M. (2023). Improving reliability for detecting anomalies in the mqtt network by applying correlation analysis for feature selection using machine learning techniques. *Applied Sciences*, 13(11).
- Kim, Y., Kim, T.-H., and Ergün, T. (2015). The instability of the pearson correlation coefficient in the presence of coincidental outliers. *Finance Research Letters*, 13:243–257.
- Li, W., Wang, X., Zhang, Y., and Wu, Q. (2021). Traffic flow prediction over multi-sensor data correlation with graph convolution network. *Neurocomputing*, 427:50–63.
- Mok, R. K. P., Zou, H., Yang, R., Koch, T., Katz-Bassett, E., and Claffy, K. C. (2021). Measuring the network performance of google cloud platform. In *Proceedings of the 21st ACM Internet Measurement Conference, IMC '21*, page 54–61, New York, NY, USA. Association for Computing Machinery.
- Moreira, D. A., Marques, H. P., Costa, W. L., Celestino, J., Gomes, R. L., and Nogueira, M. (2021). Anomaly detection in smart environments using ai over fog and cloud computing. In *2021 IEEE 18th Annual Consumer Communications & Networking Conference (CCNC)*, pages 1–2. IEEE.
- Pires, S. and Mascarenhas, C. (2023). Cyber threat analysis using pearson and spearman correlation via exploratory data analysis. In *2023 Third International Conference on Secure Cyber Computing and Communication (ICSCCC)*, pages 257–262.
- Portela, A. L., Menezes, R. A., Costa, W. L., Silveira, M. M., Bittecourt, L. F., and Gomes, R. L. (2023). Detection of iot devices and network anomalies based on anonymized network traffic. In *NOMS 2023-2023 IEEE/IFIP Network Operations and Management Symposium*, pages 1–6.
- Portela, A. L. C., Ribeiro, S. E. S. B., Menezes, R. A., de Araujo, T., and Gomes, R. L. (2024). T-for: An adaptable forecasting model for throughput performance. *IEEE Transactions on Network and Service Management*, pages 1–1.
- Scarpitta, C., Sidoretti, G., Mayer, A., Salsano, S., Abdelsalam, A., and Filsfils, C. (2023). High performance delay monitoring for srv6 based sd-wans. *IEEE Transactions on Network and Service Management*, pages 1–1.
- Silveira, M. M., Portela, A. L., Menezes, R. A., Souza, M. S., Silva, D. S., Mesquita, M. C., and Gomes, R. L. (2023). Data protection based on searchable encryption and anonymization techniques. In *NOMS 2023-2023 IEEE/IFIP Network Operations and Management Symposium*, pages 1–5.
- Wang, B., Lun, S., Li, M., and Lu, X. (2024). Echo state network structure optimization algorithm based on correlation analysis. *Applied Soft Computing*, 152:111214.