

ADAPTAR: Agregação Dinâmica para Análise e Predição de Tráfego e Anomalias em Rede

Denner Ayres¹, Abreu Quevedo¹, Giancarlo Lucca¹,
Graçaliz Dimuro¹, Bruno L. Dalmazo¹

¹ Centro de Ciências Computacionais (C3)
Universidade Federal do Rio Grande (FURG)
Rio Grande – RS – Brasil

{dennerayres, abreu-rg, giancarlo.lucca, gracalizdimuro, dalmazo}@furg.br

Abstract. *The increasing complexity of network traffic requires efficient methods for prediction and anomaly detection in dynamic and unsupervised scenarios. This work proposes ADAPTAR, an approach based on temporal aggregation operators for time series analysis. Moving average models are evaluated using the Mean Absolute Error (MAE), followed by the investigation of the Choquet Integral and its parametrization through power measures. Anomaly detection is performed using a threshold-based mechanism applied to prediction errors. Experiments conducted on the CIC-IDS2017 dataset indicate that the Choquet-based approach achieves competitive performance compared to traditional methods.*

Resumo. *A crescente complexidade do tráfego em redes de computadores exige métodos eficientes para predição e detecção de anomalias em cenários dinâmicos e não supervisionados. Este trabalho propõe a abordagem ADAPTAR, baseada em operadores de agregação temporal para análise de séries temporais. Modelos de médias móveis são avaliados com base no erro absoluto médio (MAE), seguidos pela investigação da Integral de Choquet e sua parametrização por medidas de potência. A detecção é realizada por meio de um mecanismo baseado em limiar aplicado aos erros de previsão. Experimentos com o conjunto CIC-IDS2017 indicam que a abordagem baseada na Integral de Choquet apresenta desempenho competitivo em relação aos métodos tradicionais.*

1. Introdução

As redes de computadores sustentam serviços essenciais da sociedade contemporânea, possibilitando comunicação, acesso à informação e o funcionamento de sistemas distribuídos [Dalmazo et al. 2017]. Com o crescimento do volume de dados e da interconexão entre dispositivos, o tráfego de rede tornou-se mais dinâmico e complexo, ampliando a ocorrência de comportamentos anômalos e a necessidade de mecanismos eficazes de monitoramento. Nesse contexto, garantir a segurança e a confiabilidade das infraestruturas de rede torna-se fundamental [Reglitz 2020].

Entre as abordagens utilizadas para detecção de anomalias em séries temporais de tráfego, destacam-se modelos baseados em médias móveis, como *Simple Moving Average*

(SMA), *Weighted Moving Average* (WMA), *Exponential Moving Average* (EMA) e *Poisson Moving Average* (PMA) amplamente empregados devido à sua simplicidade e baixo custo computacional [Dalmazo et al. 2018, Dalmazo et al. 2017]. Esses métodos são particularmente adequados para aplicações em tempo real e, em muitos casos, apresentam desempenho competitivo em tarefas de detecção [Schmidl et al. 2022]. No entanto, tais modelos assumem relações essencialmente lineares entre as observações, o que pode limitar sua capacidade de representar padrões mais complexos no tráfego de rede.

Como alternativa, operadores de agregação não lineares, como a Integral de Choquet, têm sido explorados na modelagem de dependências entre variáveis, permitindo capturar interações mais complexas em séries temporais [Choquet 1954, Grabisch and Labreuche 2010]. Essa abordagem utiliza medidas de capacidade para representar relações entre os dados, sendo especialmente adequada para cenários incertos e dinâmicos [Zeufack et al. 2021, Santo et al. 2023]. Estudos recentes também investigam extensões e parametrizações dessas integrais com o objetivo de aprimorar a modelagem de dados complexos [Karczmarek et al. 2023, Dimuro et al. 2020].

Neste contexto, abordagens baseadas em operadores fuzzy e técnicas híbridas têm sido propostas para lidar com a incerteza dos dados, incluindo combinações com aprendizado profundo [Novaes et al. 2020, Brandão Lent et al. 2022]. Em particular, trabalhos recentes de Ayres *et al.* [Ayres et al. 2024b, Ayres et al. 2024a] indicam que a Integral de Choquet, especialmente quando combinada com medidas de potência, pode alcançar desempenho competitivo na predição de tráfego e detecção de anomalias, sem necessidade de treinamento supervisionado. Apesar dos avanços, ainda há uma lacuna na integração sistemática de diferentes operadores de agregação em um mesmo arcabouço experimental, o que dificulta a análise comparativa de seu impacto na predição de tráfego e na detecção de anomalias.

Diante desse cenário, este trabalho propõe a abordagem **ADAPTAR** (*Agregação Dinâmica para Análise e Predição de Tráfego e Anomalias em Rede*), uma arquitetura modular voltada à análise de séries temporais de tráfego de rede. A proposta integra e compara operadores de agregação lineares e não lineares em um ambiente não supervisionado, priorizando simplicidade computacional, interpretabilidade e aplicabilidade em tempo real, sem depender de treinamento supervisionado ou arquiteturas profundas de alto custo computacional.

Este trabalho está organizado da seguinte forma. A Seção 2 apresenta os trabalhos relacionados. A Seção 3 descreve a arquitetura proposta ADAPTAR. A Seção 4 apresenta a avaliação experimental e a análise dos resultados. Por fim, a Seção 5 apresenta as considerações finais e trabalhos futuros.

2. Trabalhos Relacionados

A detecção de anomalias em redes de computadores tem sido amplamente investigada sob diferentes perspectivas, incluindo métodos estatísticos, técnicas baseadas em aprendizado de máquina e abordagens fundamentadas em lógica fuzzy e operadores de agregação.

Modelos baseados em análise de séries temporais têm sido amplamente utilizados nesse contexto. Schmidl *et al.* [Schmidl et al. 2022] avaliaram mais de 70 algoritmos de detecção de anomalias, indicando que métodos simples, como médias móveis, podem

apresentar desempenho competitivo considerando custo computacional e robustez. Modelos como SMA, WMA e EMA são amplamente empregados em cenários em tempo real devido à sua simplicidade [Dalmazo et al. 2018, Dalmazo et al. 2017], embora assumam relações lineares que podem limitar a representação de padrões mais complexos.

Abordagens baseadas em lógica fuzzy também têm sido exploradas para lidar com incerteza e imprecisão nos dados de tráfego [Conceição da Costa et al. 2027]. Yuan *et al.* [Yuan et al. 2023] propuseram um método baseado em densidade *fuzzy-rough* para detecção de anomalias, enquanto Novaes *et al.* [Novaes et al. 2020] e Lent *et al.* [Brandão Lent et al. 2022] investigaram modelos híbridos combinando aprendizado profundo e lógica fuzzy. Apesar dos bons resultados, essas abordagens geralmente demandam maior custo computacional e dependem de dados rotulados.

No contexto de operadores de agregação fuzzy, a Integral de Choquet tem sido amplamente utilizada para modelar dependências entre variáveis [Choquet 1954, Grabisch and Labreuche 2010]. Extensões recentes buscam ampliar sua flexibilidade e capacidade de modelagem, incluindo generalizações baseadas em quadratura numérica [Karczmarek et al. 2023] e variações voltadas à representação de relações mais complexas em processos de agregação [Dimuro et al. 2020, Amorim et al. 2025].

Aplicações dessas técnicas na análise de tráfego de rede também têm sido investigadas. Ayres *et al.* compararam modelos de médias móveis com a Integral de Choquet para detecção de anomalias, mostrando que a Integral de Choquet pode alcançar desempenho competitivo sem necessidade de treinamento supervisionado [Ayres et al. 2024b, Quevedo et al. 2025]. Em trabalho complementar, Ayres *et al.* [Ayres et al. 2024a] exploraram a parametrização da integral por medidas de potência, indicando que a adaptação dos pesos pode influenciar tanto a qualidade da previsão quanto a sensibilidade na detecção de anomalias.

De modo geral, métodos baseados em médias móveis se destacam pela simplicidade e eficiência computacional, enquanto abordagens de aprendizado profundo oferecem maior capacidade de modelagem, porém com maior complexidade e dependência de dados rotulados. Nesse contexto, operadores não lineares, como a Integral de Choquet, surgem como uma alternativa promissora ao combinar flexibilidade de modelagem com menor necessidade de treinamento supervisionado, especialmente em cenários dinâmicos e incertos.

3. ADAPTAR: Agregação Dinâmica para Análise e Predição de Tráfego e Anomalias em Rede

Esta seção apresenta a abordagem proposta, denominada **ADAPTAR** (*Agregação Dinâmica para Análise e Predição de Tráfego e Anomalias em Rede*). A arquitetura é estruturada como um arcabouço modular para análise de séries temporais de tráfego de rede, com foco na predição de comportamento e detecção de anomalias em cenários não supervisionados.

A Figura 1 apresenta uma visão geral da abordagem, destacando as principais etapas do fluxo de processamento, desde o pré-processamento dos dados até a geração de alertas de anomalias.

A abordagem organiza o processamento em um fluxo sequencial composto por




Figura 1. Vista geral da abordagem ADAPTAR com sete etapas.

etapas interdependentes. Inicialmente, os dados de tráfego são coletados e convertidos em séries temporais, permitindo representar a evolução do comportamento da rede ao longo do tempo. Nessa etapa, são realizadas operações de limpeza, padronização e alinhamento temporal, garantindo consistência nas entradas utilizadas pelos modelos.

Na etapa de modelagem, a série temporal é analisada por operadores de agregação aplicados sobre janelas deslizantes, visando capturar o comportamento recente do tráfego. Modelos baseados em médias móveis, como SMA, WMA e EMA, são utilizados como referência devido à sua simplicidade e eficiência computacional. Entretanto, por assumirem relações lineares entre as observações, esses modelos podem apresentar limitações na representação de padrões mais complexos do tráfego de rede.

Para superar essa limitação, a abordagem incorpora operadores de agregação não lineares, em especial a Integral de Choquet, conforme a Equação 1. Seja $x = (x_1, \dots, x_n)$ um vetor ordenado tal que $0 \leq x_{(1)} \leq \dots \leq x_{(n)}$, a Integral de Choquet discreta é definida como:

$$C_m(x) = \sum_{i=1}^n (x_{(i)} - x_{(i-1)}) \cdot m(A_{(i)}), \quad (1)$$

em que $x_{(0)} = 0$, $A_{(i)}$ representa o subconjunto dos maiores elementos a partir da posição i , e m é uma medida de capacidade responsável por modelar a importância dos subconjuntos. Essa formulação permite capturar interações não lineares entre os dados, aumentando

a flexibilidade na modelagem de padrões temporais.

A partir dos valores agregados, é realizada a previsão do próximo ponto da série temporal, representando o comportamento esperado da rede em condições normais. O valor predito $\hat{y}_t$ no instante t é obtido por meio da combinação ponderada dos elementos da janela deslizante de tamanho n , conforme o operador de agregação empregado. A qualidade das previsões é avaliada por meio do erro absoluto médio (*Mean Absolute Error* – MAE), utilizado como métrica para comparação entre diferentes estratégias de agregação.

3.1. Metodologia de Detecção por Threshold

A detecção de anomalias é conduzida a partir da análise dos resíduos de previsão, definidos pela diferença entre os valores previstos e os valores observados. O mecanismo de detecção é fundamentado em dois parâmetros essenciais: o erro e o incremento.

O erro, conforme a Equação 2, representa uma medida relativa entre o valor previsto $\hat{y}_t$ e o valor real observado y_t , sendo expresso como:

$$E = \left| \frac{y_t - \hat{y}_t}{\hat{y}_t} \right| \times 100, \quad (2)$$

em que y_t é o valor observado no instante t e $\hat{y}_t$ é o valor predito. Quando E ultrapassa um limiar percentual, o sistema registra a ocorrência de um **alarme**, indicando desvio em relação ao comportamento esperado. O threshold foi definido empiricamente a partir da análise dos resíduos de predição, buscando equilibrar sensibilidade e redução de falsos positivos. Optou-se por um limiar fixo para manter comparabilidade entre os operadores avaliados no arcabouço ADAPTAR.

O incremento está relacionado à persistência dos alarmes ao longo do tempo, sendo definido como uma sequência contínua de alarmes consecutivos. Quando essa sequência atinge um número mínimo estabelecido, o sistema a classifica como um ataque. Assim, enquanto o erro mede a magnitude de uma anomalia pontual, o incremento avalia sua persistência na identificação de eventos maliciosos.

Essa abordagem apresenta duas vantagens práticas relevantes: variações isoladas são tratadas como flutuações naturais do tráfego, reduzindo falsos positivos, enquanto o mecanismo opera de forma não supervisionada, sem necessidade de dados rotulados ou treinamento prévio, tornando-o aplicável em cenários dinâmicos e em tempo real.

A principal característica da abordagem ADAPTAR consiste na integração de diferentes operadores de agregação em um único arcabouço experimental, permitindo analisar e comparar estratégias lineares e não lineares sob o mesmo fluxo de processamento, mantendo aplicabilidade em cenários dinâmicos sem dependência de treinamento supervisionado.

4. Avaliação Experimental

Esta seção apresenta a avaliação experimental conduzida para analisar o desempenho das estratégias de agregação propostas, com foco na qualidade da predição de tráfego e na detecção de anomalias em séries temporais.

Os experimentos foram realizados utilizando o conjunto CIC-IDS2017¹, amplamente utilizado na literatura de detecção de intrusões devido à diversidade de ataques, disponibilidade pública e padronização experimental, favorecendo reprodutibilidade e comparabilidade entre diferentes abordagens [Xu and Liu 2025, Baek et al. 2025]. No contexto deste trabalho, sua utilização também se justifica pela natureza modular do arcabouço ADAPTAR, permitindo avaliar e comparar operadores de agregação sob um mesmo fluxo experimental.

A partir desse conjunto, foram construídas séries temporais representando métricas de tráfego de rede. Inicialmente, modelos baseados em médias móveis, incluindo SMA, WMA, EMA e PMA, foram avaliados na tarefa de predição do próximo valor da série temporal utilizando o erro absoluto médio (*Mean Absolute Error* – MAE) como métrica de comparação.

A Figura 2 apresenta a comparação do erro de predição entre os modelos avaliados. Observa-se que o modelo PMA (Poisson Moving Average) apresenta o menor MAE entre as abordagens analisadas, sendo adotado como referência entre os métodos baseados em agregação linear.




Figura 2. Comparação do erro de predição entre modelos de médias móveis.

Com base nesse resultado, foi realizada a comparação entre a abordagem baseada em médias móveis e a Integral de Choquet no contexto da detecção de anomalias. A detecção foi conduzida a partir da análise dos resíduos de previsão, utilizando um mecanismo baseado em *threshold*, no qual desvios entre valores previstos e observados indicam possíveis comportamentos anômalos.

O desempenho dos modelos foi avaliado por meio de matrizes de confusão, conforme apresentado na Tabela 1. Observa-se que ambas as abordagens apresentam comportamento semelhante na identificação de eventos anômalos. No entanto, a aborda-

¹<https://www.unb.ca/cic/datasets/ids-2017.html>

gem baseada na Integral de Choquet apresenta maior capacidade de identificar eventos anômalos, evidenciada pelo aumento no número de instâncias corretamente classificadas como anômalas.

Tabela 1. Matrizes de confusão para os modelos avaliados.

Modelo	Classe	Prev. Normal	Prev. Anômalo
PMA	Normal	7183	9535
	Anômalo	11816	8378
Choquet	Normal	7183	9535
	Anômalo	12826	8001

Além da análise por matriz de confusão, foram avaliadas as quantidades de alarmes gerados e ataques detectados por cada abordagem, conforme apresentado na Tabela 2. O termo *Dataset* refere-se à aplicação direta do mecanismo de detecção sobre os dados originais, sem utilização de modelos de predição, sendo utilizado como baseline.

Tabela 2. Quantidade de alarmes e ataques detectados.

Modelo	Alertas	Ataques
<i>Dataset</i>	16.718	7.183
PMA	20.194	11.816
Choquet	20.827	12.826

Os resultados indicam que modelos de predição aumentam a capacidade de detecção em relação ao baseline. A abordagem com Integral de Choquet apresenta desempenho semelhante ao PMA, com valores próximos de alarmes e ataques detectados. Apesar de identificar ligeiramente mais ataques, esse resultado deve ser analisado com cautela devido à parametrização ainda não consolidada. Ainda assim, a técnica demonstra potencial para aprimoramentos em aplicações de detecção de anomalias em séries temporais.

Além disso, foi investigado o uso da Integral de Choquet parametrizada por medidas de potência como mecanismo de adaptação dinâmica dos pesos na janela temporal. Nesse contexto, o parâmetro q é definido a partir de funções aplicadas ao vetor de entrada $v = (v_1, \dots, v_n)$, permitindo ajustar a distribuição de pesos conforme diferentes características dos dados.

A medida de potência é definida conforme a Equação 3:

$$m(A_i) = \left(\frac{|A_i|}{n} \right)^q, \quad (3)$$

onde $|A_i|$ representa a cardinalidade do subconjunto A_i , n é o tamanho da janela, e q controla a distribuição dos pesos. As funções utilizadas para definir o parâmetro q são apresentadas na Tabela 3, permitindo explorar diferentes estratégias de ponderação.

A Figura 3 apresenta o comportamento do erro médio absoluto para diferentes funções utilizadas na definição das medidas de potência, enquanto a Figura 4 compara o desempenho das abordagens PMA, Integral de Choquet e Choquet parametrizada.

Tabela 3. Funções utilizadas para o parâmetro q

ID	Função
(a)	$T_{Max}(v) = \max\{v\}$
(b)	$T_{Min}(v) = \min\{v\}$
(c)	$T_{Prod}(v) = \prod_{i=1}^n v_i$
(d)	$T_{Med}(v) = \frac{1}{n} \sum_{i=1}^n v_i$
(e)	$T_{MH}(v) = \frac{1}{\sum_{i=1}^n \frac{1}{v_i}}$
(f)	$T_{MG}(v) = \sqrt[n]{\prod_{i=1}^n v_i}$
(g)	$T_{Moda}(v) = \operatorname{argmax}_v f(v)$
(h)	$T_{Mediana}(v) = \begin{cases} v_{(\frac{n+1}{2})}, & n \text{ ímpar} \\ \frac{v_{(\frac{n}{2})} + v_{(\frac{n}{2}+1)}}{2}, & n \text{ par} \end{cases}$

Os resultados indicam que diferentes funções de agregação influenciam diretamente a qualidade da predição, sendo observadas variações no MAE conforme a estratégia adotada. De forma geral, a abordagem baseada na Integral de Choquet parametrizada apresenta desempenho competitivo, com tendência de redução do erro em diferentes configurações.

No contexto da detecção de anomalias, a parametrização da Integral de Choquet permite ajustar a sensibilidade do modelo, influenciando tanto a quantidade de alarmes quanto a identificação de ataques, evidenciando o potencial de operadores de agregação não lineares em cenários dinâmicos e não supervisionados.

5. Considerações Finais

Este trabalho investigou a predição de tráfego de rede e a detecção de anomalias a partir de diferentes estratégias de agregação aplicadas a séries temporais. Foram comparados modelos clássicos de médias móveis (SMA, WMA, EMA e PMA) com abordagens baseadas na Integral de Choquet, analisando seu impacto tanto na qualidade da previsão quanto no desempenho do módulo de detecção de anomalias do arcabouço proposto.

Os resultados experimentais indicam que abordagens baseadas na Integral de Choquet apresentam desempenho competitivo em relação aos modelos tradicionais de médias móveis, além de oferecer maior flexibilidade na modelagem de dependências temporais não lineares no tráfego de rede. A parametrização da integral por meio de medidas de potência mostrou-se particularmente promissora, permitindo ajustar dinamicamente a distribuição de pesos na janela temporal e contribuindo para a redução do erro absoluto médio (MAE), bem como para o aumento da sensibilidade na detecção de anomalias baseada em *threshold*.

Como principais contribuições deste trabalho, destacam-se: (i) a proposição de um arcabouço modular para análise de séries temporais de tráfego de rede, permitindo integrar e comparar diferentes operadores de agregação; (ii) a análise comparativa entre modelos lineares e não lineares no contexto de predição e detecção de anomalias; e (iii) a investigação do uso de medidas de potência como mecanismo adaptativo para ajuste dinâmico dos pesos na Integral de Choquet.

Como trabalhos futuros, pretende-se ampliar o arcabouço ADAPTAR por meio da investigação de estratégias adaptativas para definição automática de *thresholds*, au-




Figura 3. Erro médio absoluto das funções utilizadas na definição das medidas de potência.




Figura 4. Comparação do erro médio absoluto entre PMA, Integral de Choquet e Choquet parametrizada.

mentando a robustez em cenários sujeitos a mudanças dinâmicas no comportamento do tráfego (*concept drift*). Além disso, busca-se expandir a avaliação experimental com diferentes conjuntos de dados e métricas complementares de detecção, incluindo análises mais detalhadas sobre falsos positivos e sensibilidade dos operadores de agregação.

Outra direção promissora consiste na integração do arcabouço com métodos estatísticos e técnicas de aprendizado de máquina, mantendo o foco em cenários não supervisionados e em tempo real. Dessa forma, o ADAPTAR pode evoluir como uma plataforma modular para análise comparativa de operadores de agregação aplicados à previsão de tráfego e detecção de anomalias em redes de computadores.

Agradecimentos

Os autores gostariam de agradecer as agências de fomento brasileiras pelo financiamento: CAPES e FAPERGS (25/2551-0002584-2, 24/2551-0001396-2, 24/2551-0000723-7); CNPq (318141/2025-6).

Referências

- Amorim, M., Lucca, G., Dalmazo, B. L., Marco-Detchart, C., and Dimuro, G. P. (2025). Generalizations of choquet-like integrals by restricted dissimilarity functions applied to multi-channel edge detection problems. *Applied Sciences*, 15(24).
- Ayres, D., Quevedo, A., Dimuro, G., Lucca, G., and Dalmazo, B. (2024a). Detecção de anomalias de rede utilizando integrais de choquet através de medidas de potência. In *Anais da XXI Escola Regional de Redes de Computadores*, pages 129–134, Porto Alegre, RS, Brasil. SBC.
- Ayres, D., Quevedo, A., Lucca, G., Dimuro, G., and Dalmazo, B. (2024b). Comparando médias móveis com integral de choquet para detectar anomalias no tráfego de redes. In *Anais Estendidos do XXIV Simpósio Brasileiro de Segurança da Informação e de Sistemas Computacionais*, pages 353–357, Porto Alegre, RS, Brasil. SBC.
- Baek, M.-S., Jung, Y.-A., and Song, H.-K. (2025). A two-stage deep learning-based framework for high-accuracy network intrusion detection. In *2025 16th International Conference on Information and Communication Technology Convergence (ICTC)*, pages 641–642.
- Brandão Lent, D. M., Novaes, M. P., Carvalho, L. F., Lloret, J., Rodrigues, J. J. P. C., and Proença, M. L. (2022). A gated recurrent unit deep learning model to detect and mitigate distributed denial of service and portscan attacks. *IEEE Access*, 10:73229–73242.
- Choquet, G. (1953–1954). Theory of capacities. *Annales de l'Institut Fourier*, 5:131–295.
- Conceição da Costa, B., Lucca, G., de Souza Oliveira, L., Berri, R., Immich, R., Borges, E., Pinto, R. F., Cardoso, F. C., and Dalmazo, B. L. (2027). Adversarial detection in eeg-based bcis: A comparative study of classical and neuro-fuzzy approaches. In Gervasi, O., Murgante, B., Garau, C., Rocha, A. M. A., Faginas Lago, M. N., Taniar, D., and Karaca, Y., editors, *Computational Science and Its Applications – ICCSA 2026*, pages 173–184, Cham. Springer Nature Switzerland.
- Dalmazo, B. L., Vilela, J. P., and Curado, M. (2017). Performance analysis of network traffic predictors in the cloud. *Journal of Network and Systems Management*, 25:290–320.
- Dalmazo, B. L., Vilela, J. P., and Curado, M. (2018). Triple-similarity mechanism for alarm management in the cloud. *Computers & Security*, 78:33–42.
- Dimuro, G. P., Lucca, G., Bedregal, B., Mesiar, R., Sanz, J. A., Lin, C.-T., and Bustince, H. (2020). Generalized cf1f2-integrals: From choquet-like aggregation to ordered directionally monotone functions. *Fuzzy Sets and Systems*, 378:44–67. Theme : Aggregation Operations.
- Grabisch, M. and Labreuche, C. (2010). A decade of application of the choquet and sugeno integrals in multi-criteria decision aid. *Annals of Operations Research*, 175(1):247–286.
- Karczmarek, P., Dolecki, M., Powroznik, P., Łagodowski, Z. A., Gregosiewicz, A., Łukasz Gałka, Pedrycz, W., Czerwinski, D., and Jonak, K. (2023). Quadrature-inspired generalized choquet integral in an application to classification problems. *IEEE Access*, 11:124676–124689.

- Novaes, M. P., Carvalho, L. F., Lloret, J., and Proença, M. L. (2020). Long short-term memory and fuzzy logic for anomaly detection and mitigation in software-defined network environment. *IEEE Access*, 8:83765–83781.
- Quevedo, A., Ayres, D., Dimuro, G., Riker, A., Lucca, G., and Dalmazo, B. L. (2025). Optimizing big data traffic prediction using generalizations of choquet integral with adaptive weighting. In *ICC 2025 - IEEE International Conference on Communications*, pages 4872–4877.
- Reglitz, M. (2020). The human right to free internet access. *Journal of Applied Philosophy*, 37(2):314–331.
- Santo, Y., Immich, R., Dalmazo, B. L., and Riker, A. (2023). Fault detection on the edge and adaptive communication for state of alert in industrial internet of things. *Sensors*, 23(7).
- Schmidl, S., Wenig, P., and Papenbrock, T. (2022). Anomaly detection in time series: a comprehensive evaluation. *Proc. VLDB Endow.*, 15(9):1779–1797.
- Xu, Z. and Liu, Y. (2025). Robust anomaly detection in network traffic: Evaluating machine learning models on cicids2017.
- Yuan, Z., Chen, B., Liu, J., Chen, H., Peng, D., and Li, P. (2023). Anomaly detection based on weighted fuzzy-rough density. *Applied Soft Computing*, 134:109995.
- Zeufack, V., Kim, D., Seo, D., and Lee, A. (2021). An unsupervised anomaly detection framework for detecting anomalies in real time through network system’s log files analysis. *High-Confidence Computing*, 1(2):100030.