

Do Dado à Ação: Modelando Pragmatismo no contexto da Internet das Coisas

João Victor S. Coelho¹, Victor S. Cardel¹, Paulo H. L. Rettore²,
Daniela B. Claro¹, Bruno Santos¹

¹ Instituto de Computação
Universidade Federal da Bahia (UFBA) – Salvador – BA – Brasil

² Departamento de Ciência da Computação
Universidade Federal de Lavras (UFLA) – Lavras – MG – Brasil

{coelhoj, victor.cardel, dclaro, bruno.ps}@ufba.br,
rettore@dcc.ufmg.br

Abstract. *This paper proposes a mathematical model for pragmatic interoperability in device networks. By employing Reinforcement Learning (Q-Learning), the model infers goal-oriented actions under contextual uncertainty. In factory floor simulations, the algorithm outperformed human operation in terms of system stability and resource optimization. We argue that pragmatic interoperability between machines and humans can be achieved, demonstrating that well-structured formal modeling paves the way for advancements at this level of communication.*

Resumo. *Este artigo propõe uma modelagem matemática para a interoperabilidade pragmática na Internet das Coisas (IdC). Utilizando Aprendizado por Reforço (Q-Learning), o modelo infere ações orientadas a objetivos sob incerteza de contexto. Em simulações de chão de fábrica, o algoritmo superou a operação humana na estabilidade do sistema e na otimização de recursos. Argumentamos sobre a viabilidade da interoperabilidade pragmática entre máquina e humanos, evidenciando que uma modelagem formal bem estruturada pode ser o caminho para avanços neste nível de comunicação.*

1. Introdução

A comunicação entre dispositivos em redes de computadores possui a interoperabilidade sintática e semântica bem estabelecida, mas ainda enfrenta desafios significativos na interoperabilidade pragmática [Maciel et al. 2016]. Na Indústria 4.0, o crescimento exponencial de dispositivos Internet das Coisas (IdC) (alcançando mais de 75 bilhões de conexões globais e 80 zettabytes de dados em 2025¹) intensifica a dificuldade de interpretar a massiva quantidade de dados gerados por sensores industriais. Nesse contexto, modelos pragmáticos tornam-se essenciais para capturar intenções comunicativas e adequação contextual, promovendo decisões autônomas e eficientes em sistemas distribuídos.

Apesar dos avanços em protocolos IdC e IdC Industrial (IdCI), a literatura ainda apresenta lacunas na formalização do pragmatismo comunicativo [Muniz et al. 2019]. As

¹Dados da Statista disponível em: <https://www.statista.com/statistics/1183457/iot-connected-devices-worldwide/>

abordagens atuais focam principalmente nas camadas sintática (ex.: MQTT, CoAP) e semântica (ex.: ontologias como SSN), negligenciando aspectos como intenção, contexto e inferência adaptativa [Mane et al. 2026, Muniz et al. 2019]. Essa limitação reduz a autonomia de sistemas inteligentes, especialmente em cenários como vigilância universitária [Mane et al. 2026] e manufatura dinâmica, onde interpretações inadequadas causam falhas de segurança ou ineficiências operacionais [Figueiredo et al. 2025].

Este trabalho propõe uma modelagem pragmática formal para comunicações em IdC, ancorada na pragmática linguística e em técnicas computacionais de aprendizado. O arcabouço matemático estabelecido quantifica elementos como utilidade contextual e alinhamento intencional, integrando Aprendizado por Reforço para inferência adaptativa em tempo real. Assim este trabalho introduz um novo direcionamento para potencializar novas pesquisas no desenvolvimento de redes de dispositivos mais inteligentes

As principais contribuições deste artigo são: 1) Uma modelagem matemática inicial do pragmatismo para IdC, formalizando intenção, contexto e adequação; 2) Um simulador em Python (código aberto²) para troca de mensagens entre sensores e controladores industriais; 3) Uma abordagem de inferência pragmática via Aprendizado por Reforço (Q-learning), permitindo a adaptação dinâmica do comportamento comunicativo.

O restante do artigo segue assim: A Seç. 2 apresenta o contexto e literatura; a Seç. 3 detalha a modelagem da proposta. A Seç. 4 descreve o simulador e o algoritmo *Q-Learning* usados. A Seç. 5 discute resultados. Por fim, a Seç. 6 apresenta as conclusões.

2. Contextualização e Trabalhos relacionados

A interoperabilidade entre sistemas de informação e comunicação é essencial para integrar dados, serviços e processos [Maciel et al. 2024, Neiva et al. 2016]. Em ambientes cada vez mais distribuídos (governos digitais, redes de saúde e cadeias produtivas), essa capacidade aprimora a qualidade dos serviços, reduz redundâncias e favorece decisões baseadas em dados consistentes [Figueiredo et al. 2025].

Embora não há um consenso na literatura, aqui abordaremos a definição em que a interoperabilidade está organizada em níveis, iniciando no nível sintático através de protocolos, perpassando pelo nível semântico com a compreensão do significado das mensagens, e alcançando o nível pragmático, ressaltado no conhecimento e as intenções adquiridas [Santos et al. 2021, Lalli 2025, Figueiredo et al. 2025, Ribeiro et al. 2019, Neiva et al. 2016]. Essa distinção orienta o diagnóstico de falhas na comunicação e o planejamento de soluções que abrangem desde a modelagem (como é o caso deste artigo) até a padronização e a governança de informações comunicadas entre sistemas.

Segundo os autores em [Mane et al. 2021, Figueiredo et al. 2025], a **interoperabilidade sintática** busca padronizar a estrutura e o formato dos dados para garantir que as mensagens sejam corretamente trocadas entre sistemas. Já a **interoperabilidade semântica** assegura que o significado das informações seja compartilhado de forma consistente, por meio de ontologias, vocabulários ou esquemas de metadados. Por fim, a **interoperabilidade pragmática** refere-se à capacidade de uma comunicação gerar o comportamento esperado no sistema receptor, dados regras e fluxos de negócio compartilhados.

²Simulador disponível em: <https://github.com/vscardel/pragmatic-simulator>

Neste contexto, diversos trabalhos estão sendo propostos que possuem interseção com a abordagem aqui apresentada. Em [Holm et al. 2023], é proposto um modelo pragmático para agendamento em redes de sensores com Valor da Informação (VdI), integrando estimativas remotas e restrições temporais para múltiplos clientes com objetivos conflitantes. Diferentemente da modelagem matemática aqui proposta (focada em funções de intenção e contexto com *Q-learning*), o trabalho enfatiza otimização dinâmica multi-objetivo sem formalização explícita de aprendizado por reforço.

Em [Huttenbraucker et al. 2024], desenvolvem-se comunicações pragmáticas orientadas a metas em redes 6G, usando redes neurais para linguagens geradoras/interpretadoras sob canais com erros semânticos. Essa abordagem difere da proposta aqui, que integra aprendizado por reforço para inferência pragmática adaptativa em tempo real, aplicada a sensores IdC em planta industrial via simulação.

Os autores de [Milan et al. 2021] apresentam o RL-IoT, sistema que usa Aprendizado por Reforço para interagir autonomamente com dispositivos IdC desconhecidos, recuperando semântica de protocolos e controlando ações com poucas interações. Assim como nós, emprega RL, mas sem formalismo matemático em sua proposição.

3. Modelagem

O conceito de pragmatismo varia conforme o domínio de estudo que o aborda. Neste trabalho, interoperabilidade pragmática é definida como a intenção associada ao significado da informação/dado [Muniz et al. 2019, Figueiredo et al. 2025].

Inicialmente, no nível sintático, assume-se que os agentes compartilham um mesmo universo de mensagens. Seja M o conjunto de todas as mensagens possíveis. Dois agentes são sintaticamente interoperáveis se conseguem trocar elementos de M preservando sua estrutura e formato. No nível semântico, a interpretação de uma mensagem depende de um contexto operacional. Assim, sejam C o conjunto de contextos possíveis e \mathcal{I} o conjunto de interpretações. A semântica pode ser formalizada como a função:

$$\sigma : M \times C \rightarrow \mathcal{I}, \quad (1)$$

tal que, para uma mensagem $m \in M$ e um contexto $c \in C$, a interpretação $\sigma(m, c)$ é bem definida. A interoperabilidade semântica ocorre quando diferentes agentes produzem a mesma interpretação para um mesmo par (m, c) .

No nível pragmático, a interpretação por si só não é suficiente. É necessário considerar como essa interpretação induz ações orientadas a objetivos. Para isso, definimos: i) S como o conjunto de estados do sistema; ii) A como o conjunto de ações possíveis; iii) G como o conjunto de objetivos (ou intenções); iv) $U : S \times G \rightarrow \mathbb{R}$ como uma função de utilidade que mede o grau de satisfação de um objetivo em um estado.

A pragmática pode então ser formalizada como uma função de decisão:

$$\pi : M \times C \times S \times G \rightarrow A, \quad (2)$$

onde $\pi(m, c, s, g)$ representa a ação escolhida a partir de uma mensagem m , sob contexto c que pode ser incompleto, no estado s , visando ao objetivo g . A execução de uma ação induz uma transição de estados. Seja $T \subseteq S \times A \times S$ a relação de transição, tal que

$(s, a, s') \in T$ indica que a ação a leva o sistema do estado s ao estado s' . A correção pragmática pode então ser definida pela melhoria em relação ao objetivo:

$$(s, a, s') \in T \text{ com } a = \pi(m, c, s, g) \Rightarrow U(s', g) > U(s, g). \quad (3)$$

Ou seja, uma interação é pragmaticamente válida se a ação resultante contribui para o avanço do objetivo considerado. Finalmente, a interoperabilidade pragmática entre dois agentes k e j pode ser definida como a equivalência funcional de suas decisões:

$$\pi_k(m, c, s_k, g) \sim \pi_j(m, c, s_k, g), \quad (4)$$

onde \sim indica efeitos equivalentes nos objetivos: $U_k(s'_k, g) \approx U_j(s'_j, g)$.

Assim, mesmo que as ações executadas sejam distintas, os agentes são pragmaticamente interoperáveis se seus efeitos são compatíveis em relação aos objetivos compartilhados. Em síntese, o pragmatismo pode ser entendido como a propriedade segundo a qual o significado de uma informação é determinado pelos efeitos das ações que ela induz, relativamente a um conjunto de objetivos. Formalmente, isso pode ser expresso como:

$$\text{significado} \equiv \text{efeito operacional orientado a objetivos}. \quad (5)$$

4. Simulador

Simulamos um cenário industrial no qual sensores monitoram equipamentos (e.g., caldeiras) e enviam medições numéricas a um controlador central. Em um cenário ideal, o controlador possuiria uma base de conhecimento com as faixas de operação de cada sensor, permitindo mapear diretamente valores em estados (e.g., normal ou crítico). Contudo, assumimos um contexto mais realista, em que essa base não está disponível, exigindo a inferência do significado operacional das mensagens a partir de seus efeitos no sistema.




Figura 1. Cadeia de Markov para simulação dos estados dos sensores.

Modelamos uma planta composta por sensores que reportam periodicamente a temperatura de equipamentos. Cada sensor possui estados discretos (normal, degradado, crítico, falha), cuja dinâmica segue uma cadeia de Markov (Fig. 1). Além disso, cada sensor possui um peso de importância para a saúde global da planta. O sistema é composto por sensores, um controlador e um atuador responsável por executar ações de manutenção nos equipamentos. A manutenção consome tempo a depender da criticidade e, caso o equipamento esteja em falha, a ação é ineficaz, ainda assim incorrendo em custo temporal.

Seja $\mathcal{K} \subset \mathbb{N}$ o conjunto de sensores. Cada sensor $k \in \mathcal{K}$ é definido por: (a) estado $x_k(t) \in \mathcal{X} = \{0, 1, 2, 3\}$ (normal, degradado, crítico, falha); (b) peso $w_k \in \{0, 1, 2\}$; e (c) intervalo de amostragem $\Delta_k \in \mathbb{R}_{>0}$. A cada amostragem, o sensor gera uma

mensagem $m \in M \subset \mathbb{R}$ que é uma variável aleatória $m \sim \mathcal{N}(\mu_{x_k}, \sigma_{x_k}^2)$, com parâmetros dependentes do estado do sensor. A dinâmica é dada por uma matriz de transição P , tal que $\mathbb{P}(x_k(t+1) = x' \mid x_k(t) = x) = P_{x,x'}$.

O estado global da planta é definido por uma média ponderada:

$$s_p(t) = \frac{\sum_{k \in \mathcal{K}} \alpha(w_k) x_k(t)}{\sum_{k \in \mathcal{K}} \alpha(w_k)}, \quad (6)$$

onde α pondera a importância dos sensores. O estado completo é $s(t) = (s_p(t), n(t))$, com $n(t)$ sendo o número de equipes disponíveis, capturando o “problema atual” e a “capacidade de reação”. Por exemplo, se $s(t) = (0.2, 4)$ a planta está saudável e tem-se recursos para manutenções, deste modo, as decisões podem ser mais conservadoras. Quando $s(t) = (2.5, 0)$ a planta está em estado crítico e sem equipes de manutenção, assim mesmo decisões corretas não podem ser executadas por falta de recursos.

O controlador observa parcialmente o sistema por meio de um contexto $c = (k, m, n)$, omitindo informações como tipo e faixa de operação dos sensores. O conjunto de ações é $A = \{0, 1\}$, onde 0 denota não atuar e 1 agir para manutenção. Quando $a = 1$ e $n(t) > 0$, uma equipe é alocada; sensores em $x_k \in \{1, 2\}$ retornam a 0 após tempo de manutenção $\tau(x_k)$, enquanto sensores em falha ($x_k = 3$) não são recuperáveis. Quanto a objetivos, foram considerados $G = \{g_1, g_2\}$, onde g_1 minimiza $s_p(t)$ e g_2 maximiza $n(t)$, equilibrando desempenho da planta e uso de recursos.

4.1. Q-learning como função pragmática

A função pragmática $\pi : M \times C \times S \times G \rightarrow A$, definida na Seç. 3, é aproximada por um agente de aprendizado por reforço baseado em *Q-Learning*. O agente não observa o estado completo do sistema, mas sim uma representação reduzida $\tilde{s} = (i, m, n)$, composta pelo identificador do sensor, a medição recebida e o número de equipes disponíveis. Com base nisso, ele aprende uma função valor-ação $Q : \tilde{S} \times A \rightarrow \mathbb{R}$, que estima o retorno esperado ao executar uma ação a em um estado \tilde{s} . A política é obtida escolhendo a ação com maior valor estimado: $\pi(\tilde{s}) = \arg \max_{a \in A} Q(\tilde{s}, a)$, ou seja, o agente seleciona a ação que acredita trazer maior benefício futuro.

A atualização do Q-Learning é dada por:

$$Q(\tilde{s}, a) \leftarrow Q(\tilde{s}, a) + \alpha \left[r + \gamma \max_{a'} Q(\tilde{s}', a') - Q(\tilde{s}, a) \right], \quad (7)$$

onde o termo entre colchetes representa o erro de previsão (*temporal-difference*). Intuitivamente, o agente ajusta $Q(\tilde{s}, a)$ aproximando-o da soma entre a recompensa imediata r e o melhor retorno futuro estimado. O parâmetro α controla o quanto novas informações influenciam o aprendizado, enquanto γ pondera a importância de recompensas futuras. A recompensa r captura dois aspectos: a evolução do estado da planta e o uso de recursos. Ela é definida como:

$$r = \begin{cases} +\lambda_1 \Delta s_p^- \cdot f(n), & \text{se } s_p(t+1) < s_p(t), \\ -\lambda_2 \Delta s_p^+ \cdot g(n), & \text{caso contrário,} \end{cases} \quad (8)$$

onde Δs_p^- e Δs_p^+ representam, respectivamente, a melhora e a piora no estado global da planta. Assim, o agente é recompensado quando reduz $s_p(t)$ (melhora do sistema) e penalizado quando o estado piora.




Figura 2. Painel de Controle utilizado para a atuação do operador humano.

As funções $f(n)$ e $g(n)$ modulam a recompensa de acordo com a disponibilidade de equipes: decisões corretas são mais valorizadas quando há recursos disponíveis, enquanto decisões inadequadas são mais penalizadas em cenários com poucos recursos. Como o agente não observa diretamente informações fundamentais (ex.: faixas de operação dos sensores), ele deve inferir padrões a partir das interações com o ambiente. Dessa forma, o aprendizado da política π implementa, na prática, a inferência pragmática: mapear mensagens em ações eficazes sob informação incompleta.

5. Avaliação Experimental e Resultados

Para avaliar a eficácia do agente Q -Learning e estabelecer uma linha de base empírica para a interoperabilidade pragmática, comparamos seu desempenho ao de um operador humano, ambos atuando por 9 h. Para garantir equidade sob observabilidade parcial, o humano utilizou o painel de controle da Fig. 2.



Figura 3. Métricas de aprendizado do agente Q -Learning

Embora com pouco mais de um ano seja possível alcançar boa estabilidade, o agente foi treinado ao longo de 3 anos simulados (Fig. 3). Essa extensão justifica-se pelo crescimento contínuo da Q -Table, mesmo após estabilizadas as recompensas acumuladas e a taxa de manutenções desnecessárias por volta do primeiro ano de simulação.

A simulação operou com 50 sensores de diferentes níveis de criticidade, faixas de operação e intervalos de amostragem. A cada minuto, computou-se:

- 1) **Estado médio da planta:** índice de 0 a 3, onde valores menores indicam maior estabilidade;
- 2) **Tempo de reação:** intervalo médio entre a transição de um sensor/equipamento para o estado degradado ou crítico e a efetivação da decisão de manutenção;
- 3) **Evolução temporal de equipes:** análise longitudinal que evidencia a priorização da política adotada (preservação de recursos versus mitigação imediata de falhas);
- 4) **Manutenções desnecessárias:** percentual de despachos de equipes para equipamentos que operavam normalmente ou que já se encontravam em falha irreversível.

Os resultados apresentados na Fig. 4 revelam que as ações pragmáticas baseadas no Q -Learning mantiveram o estado global da planta mais saudável, justificado pelo tempo de reação significativamente mais rápido do computador para equipamentos degradados, (o Q -Learning não chegou a fazer manutenções críticas, por isso não pôde

ser comparado), contornando a fadiga inerente ao monitoramento humano prolongado. Observou-se também uma divergência clara na alocação de recursos: o algoritmo gerou 17,6% de ordens desnecessárias, contra 56,2% do humano, este excesso de despachos humanos explica-se por uma heurística de “inspeção visual” exploratória em momentos de incerteza, visível nas flutuações de disponibilidade entre 6 e 8 horas de simulação.

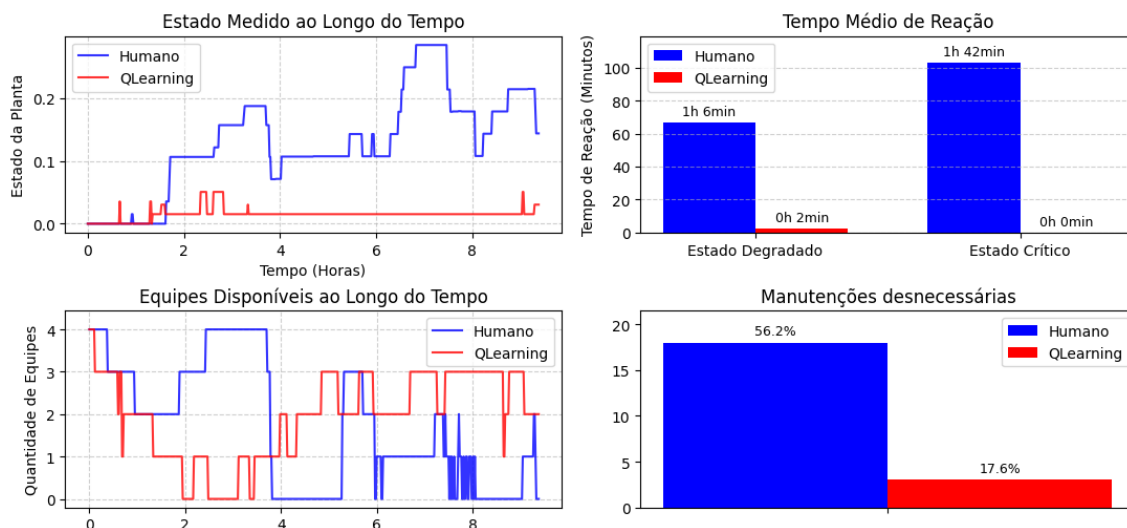


Figura 4. Métricas comparativas entre *Q-Learning* e Humano

Observa-se que, em termos de comportamento, a abordagem pragmática é bastante diferente do operador humano, embora ambos tenham os mesmos conjuntos de informações. Ainda podemos dizer que, a partir do nosso modelo proposto, computador e humano são, neste cenário, interoperáveis pragmaticamente, isto é, objetivam maximizar a saúde da planta ao passo que visam minimizar o uso de recursos (ações de manutenção), sendo o *Q-Learning* mais útil em termos gerais.

6. Conclusão

Neste trabalho, apresentamos uma modelagem matemática formal para interoperabilidade pragmática em redes IdC e IdCI na Indústria 4.0, a modelagem proposta apresenta-se como um bloco de mais alto nível acima dos níveis de interoperabilidade sintático e semântico já amplamente abordados. Avaliamos o modelo com uma simulação de chão de fábrica, comparando metodologicamente comportamentos pragmáticos quanto à tomada de decisão, de um humano e de um algoritmo de *Q-Learning* em condições de observabilidade comprometida. Os resultados apontam que o modelo é útil para representar interoperabilidade pragmática mesmo quando agentes têm conjuntos de ações diferentes. Trabalhos futuros incluem expandir a validação para outros contextos de comunicações em redes e aplicar o modelo teórico em um ambiente de testes real, a fim de consolidar a aplicabilidade da interoperabilidade pragmática.

Agradecimentos

Gostaríamos de agradecer ao CNPq, CAPES, FAPESB, FAPMIG, FAPESP CGI e aos auxílios 444077/2024-3, 407568/2025-5, 2018/23097-3, 2020/05182-3, TIC 002/2015.

Referências

- Figueiredo, R. D. C., Mane, B., Clavijo, D. R., Da Silva, S. R., Moraes, F. D. A., Nery, C., Magalhaes, A. P., Maciel, R. S., Claro, D. B., e Souza, M. V. D. S., et al. (2025). Towards a SoIS model for University Surveillance. In *IEEE/ACM 13th SESoS*. IEEE.
- Holm, J., Chiariotti, F., Kalør, A. E., Soret, B., Pedersen, T. B., and Popovski, P. (2023). Goal-oriented scheduling in sensor networks with application timing awareness. *IEEE Transactions on Communications*, 71(8):4513–4527.
- Huttenbraucker, T., Sana, M., and Strinati, E. C. (2024). Pragmatic goal-oriented communications under semantic-effectiveness channel errors. In *2024 IEEE 21st Consumer Communications & Networking Conference (CCNC)*, pages 683–689. IEEE.
- Lalli, G. (2025). Defining interoperability: a universal standard. *Journal of ICT Standardization*, 13(2):139–156.
- Maciel, R. S. P., David, J. M. N., Claro, D. B., and Braga, R. (2016). Full interoperability: Challenges and opportunities for future information systems. *Grand Research Challenges in Information Systems in Brazil*, 2026(2017):107–116.
- Maciel, R. S. P., Valle, P. H. D., Santos, K. S., and Nakagawa, E. Y. (2024). Systems interoperability types: A tertiary study. *ACM Computing Surveys*, 56(10):1–37.
- Mane, B., Magalhaes, A. P., Quinteiro, G., Maciel, R. S. P., and Claro, D. B. (2021). A domain specific language to provide middleware for interoperability among saas and daas/dbaas through a metamodel approach. In *Proceedings of the 23rd International Conference on Enterprise Information Systems - Volume 1: ICEIS*. SciTePress.
- Mane, B., Moraes Neto, F. H. d. A., Figueiredo, R. d. C., Nery, C., Clavijo, D. R., Silva, S. R. d., Claro, D. B., Ralha, C. G., Magalhaes, A. P., Maciel, R. S. P., Souza, M. V. d. S. e., Lima, G. M. d. A., Santos, B. P. d., Pita, R., Proenca, E., Jesus, L. E. N. d., and Jesus, I. P. d. J. M. d. (2026). CSIS Ecosystem: Impacts of Pragmatic Detection on a Campus Surveillance Case Study. In *Proceedings of the Brazilian Symposium on Information Systems (SBSI)*, Brazil. Sociedade Brasileira de Computação.
- Milan, G., Vassio, L., Drago, I., and Mellia, M. (2021). RL-IoT: reinforcement learning to interact with IoT devices. In *2021 IEEE International Conference on Omni-Layer Intelligent Systems (COINS)*, pages 1–6. IEEE.
- Muniz, M. H., David, J. M. N., Braga, R., Campos, F., and Stroele, V. (2019). Pragmatic interoperability in iot: a systematic mapping study. In *Proceedings of the 25th WebMedia*, page 73–80, New York, NY, USA. Association for Computing Machinery.
- Neiva, F. W., David, J. M. N., Braga, R., and Campos, F. (2016). Towards pragmatic interoperability to support collaboration: A systematic review and mapping of the literature. *Information and Software Technology*, 72:137–150.
- Ribeiro, E. L. F., Monteiro, E. L., Claro, D. B., and Maciel, R. S. P. (2019). A conceptual framework for pragmatic interoperability. In *Proceedings of the XV Brazilian Symposium on Information Systems*, pages 1–8.
- Santos, K. S., Pinheiro, L. L., and Maciel, R. S. (2021). Interoperability types classifications: A tertiary study. In *Anais do XVII Simpósio Brasileiro de Sistemas de Informação*, Porto Alegre, RS, Brasil. SBC.