

Redes Baseadas em Intenção: Análise de Abordagens e Taxonomia Hierárquica Multidimensional

Pedro I. S. de Souza¹, Helder Oliveira², Diego Kreutz³,
Nelio Cacho¹, Augusto Neto¹, Roger Immich¹

¹ Universidade Federal do Rio Grande do Norte (UFRN)

² Universidade de São Paulo (USP)

³ Universidade Federal do Pampa (Unipampa)

iuri.souza.072@ufrn.edu.br, helderoliveira@ime.usp.br,
diegokreutz@unipampa.edu.br, {neliocacho, augusto}@dimap.ufrn.br,
roger@imd.ufrn.br

Abstract. *Intention-Based Networks (IBNs) are emerging as a paradigm for the autonomous management of complex networks in the face of increasing demand for automation. In this context, there is an urgent need to consolidate experimental evidence that identifies patterns and research gaps. To this end, this work presents a multidimensional Systematic Mapping and proposes a taxonomy that structures the state of the art in IBNs. The results indicate the predominance of semi-autonomous solutions and a transition from approaches based on the use of NLP and LLMs in intention translation. Despite the advances, standardization, security, and intention translation remain challenges, highlighting gaps for the evolution of IBNs.*

Resumo. *Redes Baseadas em Intenção (IBN) emergem como um paradigma para o gerenciamento autônomo de redes complexas frente a crescente demanda por automação. Nesse contexto, urge a consolidação de evidências experimentais que identifique padrões e lacunas de pesquisa. Para tanto, este trabalho apresenta um Mapeamento Sistemático multidimensional e propõe uma taxonomia que estrutura o estado da arte em IBN. Os resultados indicam a predominância de soluções semiautônomas e uma transição de abordagens baseadas no uso de PLN e LLMs na tradução de intenções. Apesar dos avanços, a padronização, segurança e tradução de intenções persistem como desafios, evidenciando lacunas para a evolução das IBN.*

1. Introdução

As redes de telecomunicações tornaram-se significativamente mais complexas com o avanço de tecnologias promotoras da ubiquidade em sistemas computacionais, como 5G, Computação em Nuvem e Internet das Coisas (IoT) [Bittencourt et al. 2018], exigindo mecanismos mais eficientes de gerenciamento [Cesário et al. 2022]. No entanto, a configuração de redes ainda depende amplamente de processos manuais, sujeitos a erros, enquanto modelos de orquestração permanecem centrados em QoS, com suporte limitado à QoE [Sophocleous et al. 2022].

Nesse contexto, as Redes Baseadas em Intenção (IBN) emergem como uma abordagem para redes autônomas, permitindo a definição de objetivos em alto nível sem

especificação de implementação [Leivadeas and Falkner 2023]. Diferentemente de estudos semelhantes que se restringem a análises conceituais [Leivadeas and Falkner 2023, Clemm et al. 2022], este trabalho apresenta um mapeamento sistemático da literatura sobre IBNs, analisando características atuais de implementações com foco prático nas dimensões de aplicação, operação e avaliação, sejam em ambientes simulados ou em produção real. As IBN são aplicadas em diversos domínios, incluindo redes de acesso [Velasco et al. 2021, Ooi et al. 2022], data centers [Goścień 2023], redes ópticas [Christou 2022], IoT [Shi et al. 2021, Kanagarathinam et al. 2025], nuvem [Li et al. 2024, Gama et al. 2024], segurança [Lingga et al. 2024, Rivera et al. 2022] e redes empresariais [Huanga et al. 2022], além de *network slicing* em ambientes 5G/6G multidomínio [Khan et al. 2022, Silva et al. 2023].

A aquisição e tradução de intenções são etapas centrais, envolvendo a expressão de requisitos via *templates*, linguagem natural ou linguagens específicas, e sua conversão em políticas técnicas, incluindo mapeamento de QoE para métricas quantitativas [Wu et al. 2022, Immich et al. 2015] e modelos ECA. Esse processo é tipicamente iterativo, permitindo refinamento e resolução de conflitos [Karakaya et al. 2024, Hossain and Aljoby 2025]. IA e ML são importantes para *intent assurance*, apoiando detecção de anomalias, tomada de decisão e tradução de intenções via NLP [Hossain and Aljoby 2025, Asif et al. 2025, Silva et al. 2024].

O restante deste artigo é organizado da seguinte forma. Na Seção 2 é apresentado o processo metodológico e a taxonomia proposta está na Seção 3. A Seção 4 apresenta a caracterização de IBNs. Desafios e direcionamentos futuros são descritos na Seção 5. Por fim, a Seção 6 trás as considerações finais e conclusão do estudo.

2. Metodologia da pesquisa

A seleção de estudos foi realizada durante Fevereiro de 2026 utilizando o protocolo PICOC. A obtenção dos estudos nas bases de pesquisa foi obtida por meio da string “(“*Intent-based Network*” OR “*IBN*” OR “*Intent-based system*” OR “*Intent-defined system*” OR “*intent-driven networking*” OR “*Intent-based management*”) AND (“*Intent Fulfillment*” OR “*Intent Activation*” OR “*Intent Ingestion*” OR “*Intent Translation*” OR “*Intent Orchestration*” OR “*Orchestrate*” OR “*Machine Learning*” OR “*ML*”) AND (“*Interfaces*” OR “*API*” OR “*Application Programming Interface*” OR “*frameworks*” OR “*simulation*”)”

Foram formuladas as seguintes questões de pesquisa buscando obter uma visão qualitativa e quantitativa sobre as experimentações práticas em IBNs e as principais características, desafios, ferramentas e tecnologias utilizadas.

- RQ1. Qual o nível de autonomia alcançado nas experimentações com relação ao mecanismo de close-loop para garantia de intenções?
- RQ2. Quais são os domínios de aplicação onde as experimentações práticas com IBNs têm demonstrado maior sucesso?
- RQ3. Quais métricas são utilizadas na avaliação de experimentações em IBNs e como elas se relacionam com os objetivos e dinâmicas de controle adotadas?
- RQ4. Quais as principais técnicas e/ou ferramenta de tradução de intenções (IBN Tools) que são abordadas?
- RQ5. Quais algoritmos de ML são utilizados nos estudos?

A Tabela 1 exibe os Critérios de Inclusão (CI) e Exclusão (CE) utilizados para a pesquisa e validação dos estudos selecionados. Para os critérios de inclusão definidos, utilizou-se os estudos definidos como Estudos que incluam experimentos, simulações ou avaliações práticas das soluções propostas. Os demais critérios serviram como uma seleção para temáticas relevantes e que tendem a fomentar estudos futuros. A Figura 1 mostra a modelagem final do protocolo de busca e seleção dos artigos em bases de reconhecida relevância e prestígio nos domínios científico e tecnológico.

Tabela 1. Critérios de inclusão e exclusão do estudo

Critérios de Inclusão	Critérios de Exclusão
CI1. Apresenta proposta para a gestão de intenções CI2. Estudos que incluam experimentos, simulações ou avaliações práticas das soluções propostas CI3. Investiga ou propõe técnicas de orquestração da rede a partir de camadas de abstração CI4. Propõe estratégias de aceitação ou tradução de intenções	CE1. Estudos anteriores a 2020 CE2. Estudos fora da atividade fim da revisão CE3. Estudos duplicados CE4. Idiomas que fogem do inglês, espanhol e português CE5. Trabalhos conceituais, sem proposta implementável

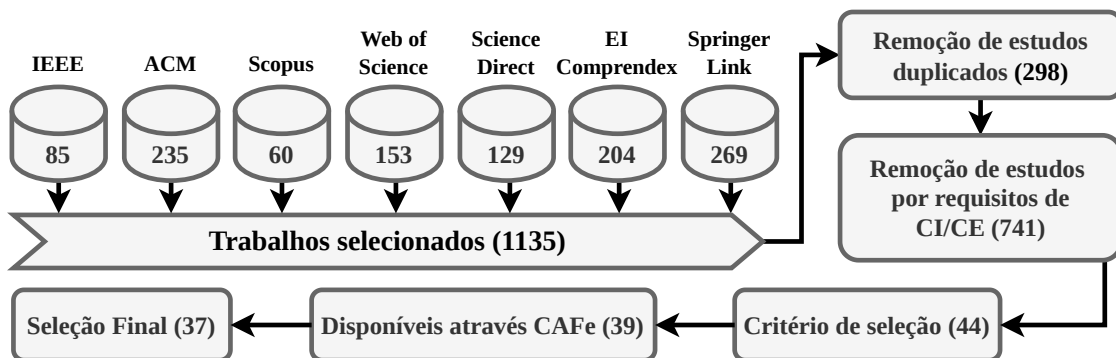


Figura 1. Fluxo de seleção dos estudos

Buscando aderência a Ciência Aberta (*Open Science*) foram compartilhados no GitHub¹ os dados brutos coletados e analisados para o desenvolvimento desta taxonomia, assim como as demais análises realizadas.

3. Taxonomia de Redes Baseadas em Intenção

No contexto das orquestrações de rede, as IBN representam uma evolução para um novo paradigma, uma vez que priorizam a tradução de intenções de alta nível de abstração em configurações de rede automatizadas e adaptáveis. Com isso, o desenvolvimento de uma taxonomia apresenta-se como um instrumento essencial para sistematizar os componentes, mecanismos e fluxos de trabalho, facilitando a análise comparativa e o avanço de pesquisas futuras.

A Figura 2 mostra a taxonomia proposta, construída a partir dos estudos selecionados neste trabalho, classificando os elementos centrais das IBN em domínios de aplicação, dimensões de abstração, aquisição e tradução das intenções, nível de autonomia da rede,

¹<https://github.com/ProfIuriSouza/MSL-em-Redes-IBN>

métricas de avaliação do desempenho, orquestração e execução, além dos objetivos dos estudos, oferecendo uma estrutura hierárquica e multidimensional que contribui para a padronização conceitual do campo.

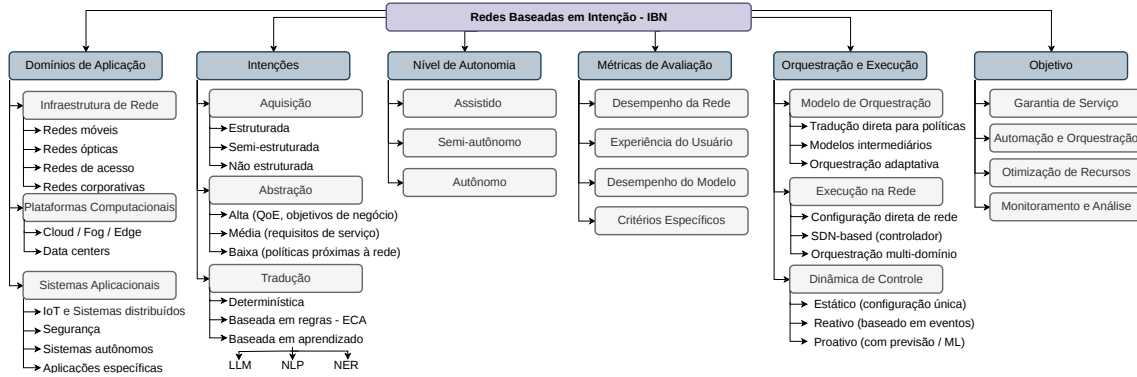


Figura 2. Taxonomia aplica às IBNs

A Figura 3 exibe a relação entre as principais características identificadas nos estudos. Observando os sistemas que focam na autonomia, percebe-se uma forte relação com o monitoramento proativo do estado da rede, através da análise de dados de telemetria, compondo o ciclo de *assurance*. Quando remete-se a aquisição e tradução das intenções, tais sistemas, inevitavelmente, remetem-se a um aquisição não estruturada, oferecendo alto nível de abstração diretamente ligada aos requisitos de experiência do usuário (QoE). Não distante, aplicações que investem nas intenções com menor abstração, com instruções mais próximas das políticas de rede, acabam utilizando aquisições estruturadas. Quanto a autonomia, interessante ressaltar um grupo de sistemas que, mesmo com aquisições de intenções conservadoras, investem fortemente na autonomia do sistema. O mapeamento indica que estes estudos direcionam-se para domínios de aplicação mais específicos como a garantia de sistemas autônomos e segurança.

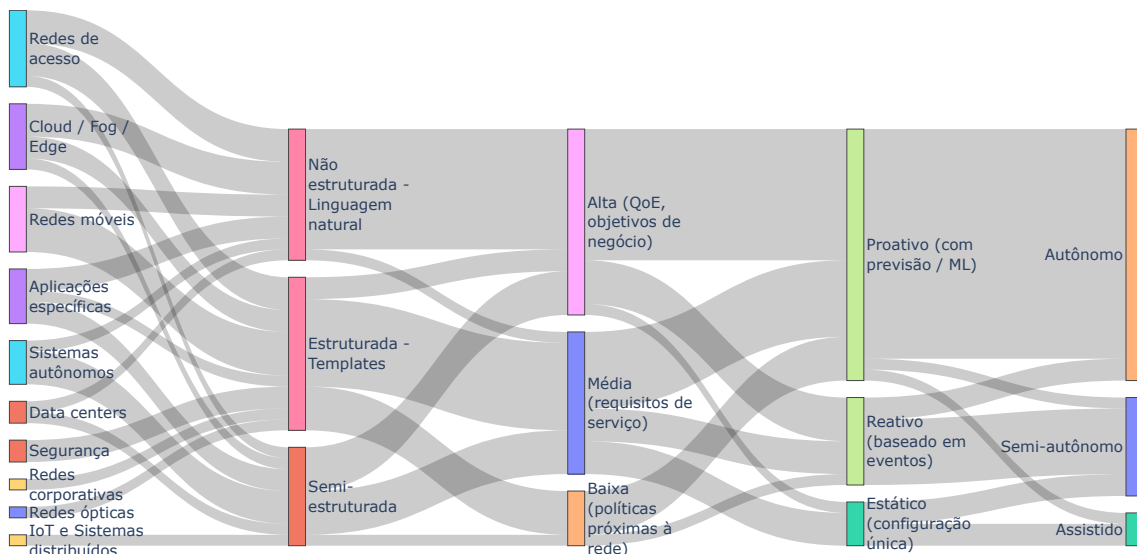


Figura 3. Características dos experimentos analisados em IBNs

Para exemplificação, o estudo [Khan et al. 2022] pode ser descrito conforme a

taxonomia apresentada. O trabalho foca em redes móveis (domínio de aplicação) e *network slicing*, fundamentando-se em padrões da GSMA, 3GPP e ETSI para viabilizar a automação e orquestração (objetivo) eficiente de recursos de nuvem e rede de transporte para serviços em infraestruturas 5G. A aquisição de intenções ocorre de forma estruturada por *templates*, onde o operador utiliza uma interface gráfica (GUI) com campos pré-definidos, utilizando modelos como o *Generic Slice Template (GST)* e *Network Slice Types (NEST)*. Esse método garante uma abstração de intenções de nível médio, focando nos requisitos de alto nível do serviço. A tradução de intenções é determinística, baseada em um diretório de catálogo que funciona como uma SSoT (*Single Source of Truth*). O modelo de orquestração utiliza a mediação por modelos intermediários, convertendo as intenções em *templates VNF* (*Virtual Network Function Descriptor*) para o orquestrador OSM (*OpenSource MANO*) e em informações semânticas para controladores SDN (execução na rede). O sistema utiliza modelos de ML (LSTM e RouteNet) para uma dinâmica de controle proativa, prevendo a utilização de recursos e *links* antes mesmo da ativação do serviço, o que classifica seu nível de autonomia como autônomo. Quanto às métricas de desempenho, o estudo combina métricas tradicionais de redes (como taxa de *bits* estável, *throughput* e perda de pacotes) com métricas de desempenho de modelos de ML, como *Mean Absolute Error (MAE)* e o *score R2*.

4. Caracterização de Redes Baseadas em Intenção

Esta seção apresenta uma caracterização das IBNs, abrangendo as dimensões de nível de autonomia dos sistemas, domínios de aplicação, métricas utilizadas para avaliação de desempenho, mecanismos de tradução de intenções e uso de técnicas de aprendizagem de máquina no gerenciamento da rede. Ao integrar essas perspectivas, busca-se identificar padrões, tendências e relações entre os diferentes elementos que compõem as soluções de IBN, contribuindo para uma compreensão mais estruturada do estado atual da área.

4.1. Qual o nível de autonomia alcançado nas experimentações com relação ao mecanismo de *close-loop* para garantia de intenções? (RQ1)

Dois *close-loop* são identificados de forma genérica nas IBNs. Um trata da aquisição, tradução e validação da intenção, nomeado de *intent fulfillment*. Outro direcionado a garantir as políticas de rede necessárias para atender a intenção, nomeado de *intent assurance*. Quanto ao primeiro *close-loop*, a aquisição da intenção costuma ser feita através de uma GUI [Khan et al. 2021a, Alam et al. 2024], *chatbots* [Meijer et al. 2022] ou outro meio de interação e podem permitir a inserção aberta de instruções, nestes casos com utilização de processamento de linguagem natural para a extração de *endpoints* [Yu et al. 2023, Martini et al. 2023], ou de forma mais restrita, através do preenchimento/seleção de parâmetros bem definidos [Beshley et al. 2022]. Uma vez coletados os *endpoints* e obtendo-se a intenção agora estruturada, um catálogo de políticas tende a ser acessado para se definir o que será feito na rede.

A nível de orquestração (segundo *close-loop*), os sistemas tendem a aplicar as políticas diretamente na rede, de forma adaptativa ou por meio de modelos intermediários. A Figura 4 mostra a relação destes modelos de orquestração com o nível de autonomia percebido. Destaca-se a maior porção de sistemas com alto nível de autonomia, 24 dos 37 analisados, e destes a maior quantidade com investimento em orquestrações

através de modelos intermediários, utilizando, por exemplo, agentes de aprendizado profundo com a finalidade de otimização na predição do estado da rede [Asif et al. 2025]. Como característica do *intent assurance*, o comportamento da rede passa a ser monitorado continuamente para garantir a validade das instruções passadas. No caso de um comportamento indesejável, pode ser gerado um alerta funcionando como *feedback* ao usuário/operador da rede para tomar uma nova decisão [Natarajan et al. 2025], caracterizando um cenário de semiautonomia, ou a adaptação proativa da rede em corrigir seus parâmetros [Asif et al. 2025, Khan et al. 2021b]. A Figura 5 exibe o levantamento destes cenários, indicando a relação entre as dinâmicas de controle com a autonomia promovida pelo sistema.




Figura 4. Modelo de Orquestração vs Nível de autonomia

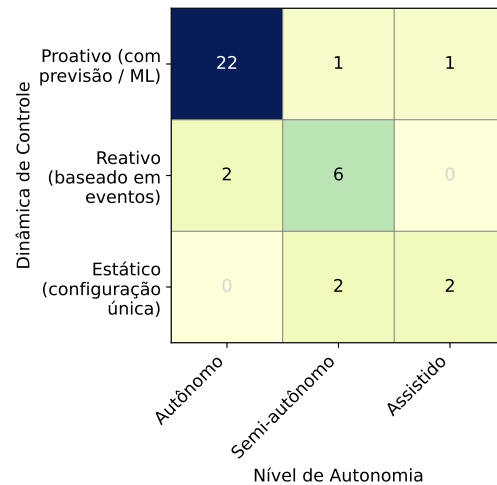


Figura 5. Dinâmica de Controle vs Nível de Autonomia

4.2. Quais são os domínios de aplicação onde as experimentações práticas com IBNs têm demonstrado maior sucesso? (RQ2)

Nota-se uma maior inserção da operação das IBNs onde há uma evidente separação entre quem usa e o que se opera na rede. Por exemplo, uso de IBNs para garantir serviços escaláveis em plataformas de *e-commerce* [Hurtado et al. 2023] ou em que gerenciamento de instruções executadas por robôs autônomos a partir de métricas de QoE partidas de usuários externos [Sophocleous et al. 2022]. Outra aplicação evidente é o que tange ao gerenciamento de dispositivos autônomos [Li et al. 2022].

A Figura 3 descreve em seu primeiro nó a disposição dos estudos por seus domínios de aplicação. Destacam-se as aplicações de serviços em nuvem [Li et al. 2024, Lingga et al. 2024, Wu et al. 2021], redes móveis 5G e 6G [Mehmood et al. 2024, Gupta et al. 2025] e redes de acesso [Asif et al. 2025, Huang et al. 2022, Beshley et al. 2022, Venkatesh et al. 2025]. Neste contexto, as intenções passam a serem parametrizadas por avaliação da própria rede, uma vez que um *feedback* ou interação de um usuário pode consumir tempo não disponível para a aplicação. O contexto de *networking slicing* [Andreazi et al. 2021] é muito comentado nos estudos também, mas compreende-se que essa seria uma arquitetura da rede e não diretamente o seu domínio de aplicação.

O objetivo pelo qual as IBNs tem sido utilizadas é um parâmetro importante para a compreensão do seu contexto atual. A Figura 6 demonstra essa evolução. A otimização de recursos e automação e orquestração têm se consolidado nos últimos anos como objetivos principais assim como a garantia de serviços. Vale destacar ainda o crescimento dos experimentos voltados ao uso de LLMs como parte integrante do processo de tradução e validação das intenções, inclusive com a comparação entre os desempenhos entre diferentes modelos de LLM [Asif et al. 2025]. A Figura 7 expõe esse crescimento. Os métodos de tradução de intenções baseados em aprendizagem, onde se encontra o processamento de linguagem natural em seu sentido amplo, tem concentrado a grande maioria dos experimentos nos dias atuais.




Figura 6. Objetivos de aplicação das IBNs ao longo dos anos




Figura 7. Tradução de intenções aplicados ao longo dos anos

4.3. Quais métricas são utilizadas na avaliação de experimentações em IBNs e como elas se relacionam com os objetivos e dinâmicas de controle adotadas? (RQ3)

A análise dos estudos levou a organização de quatro grupos de destaque: Métricas de Desempenho do Modelo de *Machine Learning* (MML), métricas tradicionais de desempenho de rede (*Key Performance Indicator* KPI), Critérios Específicos e particulares dos estudos (CPS) e, por fim, medidas de Qualidade de Experiências dos Usuários (QoE).

A Figura 8 exhibe a relação entre Objetivos e as Métricas encontradas nos trabalhos da literatura. É possível observar uma forte concentração de trabalhos que associam objetivos como Garantia de Serviço, Automação e Orquestração e Otimização de Recursos, respectivamente, às métricas de Desempenho da Rede, indicando uma predominância de abordagens orientadas à eficiência operacional e desempenho sistêmico. Métricas relacionadas à Experiência do Usuário e Critérios Específicos aparecem de forma mais esparsa e, frequentemente, sugerindo que aspectos qualitativos e contextuais ainda são subexplorados. Além disso, a métrica de Desempenho do Modelo surge em um subconjunto de trabalhos mais recentes, refletindo a incorporação de técnicas baseadas em aprendizado, porém ainda sem ampla integração com objetivos clássicos de rede.

A Figura 9 apresenta a relação das Dinâmicas de Controle e as Métricas associadas. Destaca-se a predominância de dinâmicas proativas (com previsão / ML) fortemente associadas ao Desempenho da Rede, reforçando a tendência de uso de técnicas preditivas para otimização contínua. Em contraste, abordagens Reativas e Estáticas aparecem menos conectadas a métricas diversificadas, limitando-se a cenários mais tradicionais. Adicionalmente, há uma lacuna na combinação de dinâmicas estáticas com métricas centradas no usuário, o que é esperado devido a estes serem mais utilizados em dinâmicas proativas. Esses resultados indicam que, embora haja avanços significativos na

automação inteligente e na otimização baseada em dados, ainda há espaço para modelos mais holísticos que considerem múltiplas dimensões de avaliação de forma integrada. Um outro ponto relevante é a utilização da métrica de Experiência do Usuário como parâmetro para adquirir intenções e avaliar a sua garantia [Beshley et al. 2022, Beshley et al. 2023, Sophocleous et al. 2022, Andrushchak et al. 2021]. É importante ressaltar que nesse tipo de métrica existe a necessidade de *feedback* do usuário/operador da rede, o que pode ser interpretado como uma fuga do *close-loop* de garantia, característica observada em sistemas semiautônomos e/ou assistidos.




Figura 8. Relação entre Objetivos e Métricas

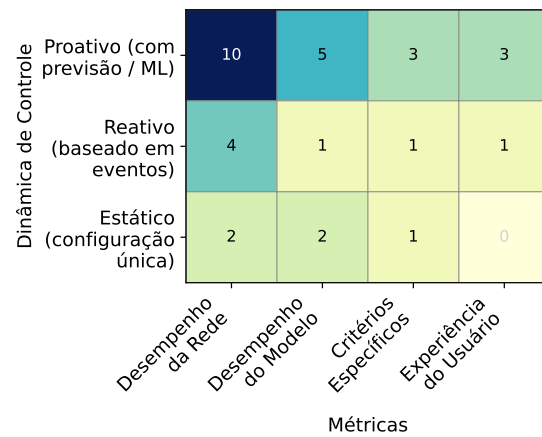


Figura 9. Relação entre Dinâmica de Controle e Métricas

4.4. Quais as principais técnicas e/ou ferramenta de tradução de intenções (IBN Tools) que são abordadas? (RQ4)

A aquisição de intenções em IBNs pode ser organizada em duas abordagens principais: discretizada e contínua. A abordagem discretizada baseia-se no uso de *templates*, que restringem e orientam as intenções submetidas [Beshley et al. 2022, Alcock et al. 2024]. Embora ofereça menor grau de liberdade ao usuário, essa estratégia aumenta a previsibilidade e a confiabilidade operacional, uma vez que as instruções são previamente estruturadas e facilmente mapeadas para políticas de rede definidas [Alam et al. 2024, Beshley et al. 2023].

Por outro lado, a abordagem contínua utiliza técnicas de NLP e LLM [Ma et al. 2025a, Yu et al. 2023], permitindo maior flexibilidade e abstração na expressão das intenções. Essa maior liberdade torna o modelo adequado inclusive para cenários multi-domínio [Hermosilla et al. 2025], embora introduza desafios adicionais na interpretação e validação das instruções. Nesse contexto, técnicas de ML podem ser empregadas para validar, complementar e estruturar automaticamente as intenções, inclusive convertendo descrições livres em *templates* intermediários antes da tradução em políticas de rede [Li et al. 2022]. Além disso, métodos como *Named Entity Recognition* (NER) auxiliam na identificação e extração de elementos relevantes, contribuindo para a definição precisa das instruções encaminhadas ao orquestrador da rede [Mehmood et al. 2023]. De forma geral, para implementação de projeto IBN deve-se definir um orquestrador da rede e uma forma de tradução de intenções adequadas

ao comando do orquestrador. Os padrões Nile [Meijer et al. 2022, Martini et al. 2023] e TOSCA [Khan et al. 2021a, Ma et al. 2025b] destacam-se entre os estudos analisados, enquanto o *OpenFlow* é utilizado para execução das configurações derivadas da tradução das intenções [Beshley et al. 2022, Venkatesh et al. 2025].

A Figura 10 apresenta a relação entre os métodos de Tradução de Intenções e os Objetivos. É possível ressaltar que a tradução de intenções determinística está amplamente associada a objetivos como Automação e Orquestração e Garantia de Serviço, podendo ainda ser considerada uma estratégia central para viabilizar maior autonomia e adaptabilidade. Em contraste, abordagens de tradução baseadas em aprendizado tendem a se concentrar em objetivos mais restritos, como Otimização de Recursos e Monitoramento e Análise, indicando que ainda existem áreas distintas para a sua aplicação.

A Figura 11 apresenta a relação entre a Tradução de Intenções e as Métricas. Observa-se uma predominância da abordagem Determinística associada à métrica de Desempenho da Rede, evidenciando que a tradução de intenções ainda está majoritariamente orientada à eficiência operacional e métricas tradicionais. Por outro lado, a tradução de intenções baseada em aprendizado, em destaque o uso de LLMs, apresenta crescimento recente, começando a se destacar na avaliação do desempenho da rede e principalmente no desempenho do modelo.

Esses resultados indicam que, apesar dos avanços na tradução de intenções, ainda há uma fragmentação entre os mecanismos de tradução, os objetivos pretendidos e as métricas utilizadas para avaliação, apontando oportunidades para modelos mais integrados e orientados a múltiplas dimensões.

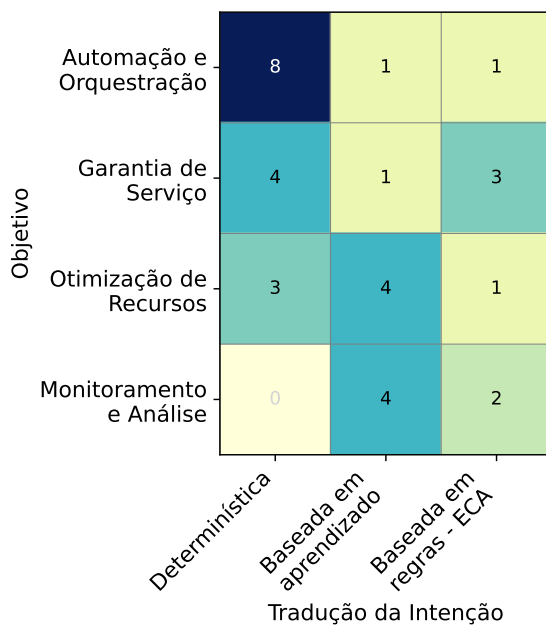


Figura 10. Relação entre Tradução da Intenção e Objetivos

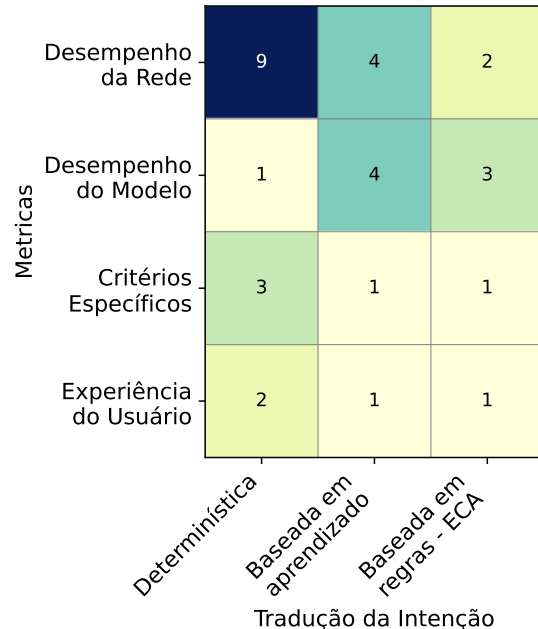


Figura 11. Relação entre Tradução da Intenção e Métricas

4.5. Quais algoritmos de ML são utilizados nos estudos? (RQ5)

A utilização dos algoritmos de ML está diretamente relacionada no propósito ao qual os estudos empregam a rede IBN. Se o foco está na aquisição de intenções, encontra-se o

uso massivo de algoritmo para processamento de linguagem natural e grandes modelos de linguagem (NLP/LLM) [Meijer et al. 2022]. A nível de orquestração, a aprendizagem de máquina apresenta-se na análise de tráfego para identificação de anomalias e para a decisão de melhores rotas [Huanga et al. 2022], destacando nestes contextos as *Neural Networks* (NN), modelos baseados em árvores de decisão (TBM) e algoritmos de vetor distância (DBA). Alguns estudos trouxeram algoritmos de otimização (OM) que não fazem uso de aprendizagem em seu funcionamento. Um grupo de estudos não evidenciou de forma clara quais métodos de ML eram empregados, sendo classificados como *Not Mentioned* (NM). Em alguns estudos, mais de um método foi utilizado, dessa forma foi quantificado a citação dos modelos.

A Figura 12 apresenta a relação entre Domínio e Técnica de ML, condicionada ao nível de autonomia. É possível observar que no cenário autônomo, existe uma concentração de maior densidade, indicando uma predominância de soluções maduras e orientadas à automação, com destaque para técnicas como NN e *Optimization Methods* (OM) distribuídas em múltiplos domínios, sugerindo maior generalização e aplicabilidade transversal. Em contraste, os cenários semiautônomo e assistido apresentam distribuições mais esparsas e heterogêneas, refletindo estágios intermediários de adoção tecnológica. Essa segmentação pode revelar uma transição progressiva de abordagens assistidas para totalmente autônomas. Assim, a análise evidencia indícios claros sobre maturidade tecnológica e oportunidades de pesquisa em direção a sistemas mais autônomos e adaptativos.

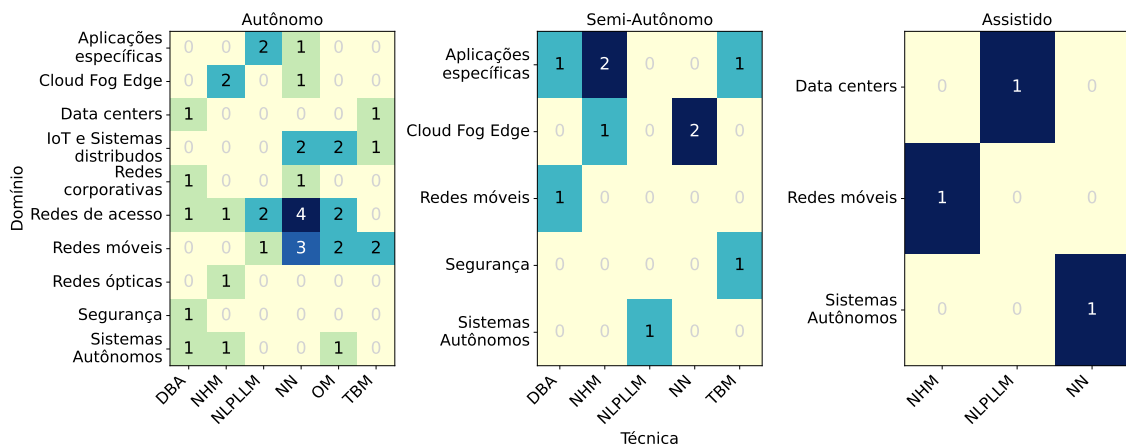


Figura 12. Utilização de algoritmos de ML nas experimentações práticas

5. Desafios e direcionamentos futuros

Embora o conceito das IBNs não seja novo, ganha relevância renovada diante das demandas atuais por automação e escalabilidade. O avanço em soluções de tradução de intenções robustas baseadas em mecanismos de aprendizagem, mesmo ganhando notoriedade nos últimos anos, ainda carece de maturidade e padronização dos processos, além de maior diversificação dos domínios de aplicação, sendo ainda pouco explorados em sistemas IoT, *data centers* e segurança, temáticas de grande relevância nos dias atuais. Fatores estes que tendem, inclusive, a expandirem a taxonomia proposta como no que tange, por exemplo, o uso de LLMs visando maior autonomia na gerência das redes, segmento este em expansão e com potenciais ramificações.

Questões como a validação das intenções, garantindo que elas sejam seguras, precisas e resistentes a manipulações maliciosas, emergem como desafios centrais, especialmente em cenários multidomínio e de grande escala. A integração com o paradigma *Zero Trust*, que pressupõe ausência de confiança inerente e exige verificação contínua de todas as entidades, pode ser vista como um direcionamento pavimentado, demandando mecanismos robustos de autenticação, autorização granular e auditoria em tempo real das intenções traduzidas.

Além do gerenciamento de conflitos entre intenções concorrentes, a otimização da tradução de intenções, interfaces intuitivas e segurança reforçada tem atraído crescente interesse acadêmico e industrial. Esses elementos posicionam as IBNs como pilar essencial para redes futuras, mas requerem avanços na validação confiável para mitigar riscos inerentes ao *Zero Trust*.

6. Considerações finais

As IBNs representam um paradigma essencial para o gerenciamento de redes complexas, oferecendo autonomia, adaptação e otimização a partir de intenções declarativas de alto nível, mas também oferecendo flexibilidade para serem adaptadas em quaisquer cenários onde a autonomia dos recursos de redes são desejáveis. Os resultados do estudo mostram que a autonomia nas IBNs é estruturada em ciclos de automação fechados na aquisição e tradução das intenções e na orquestração e monitoramento contínuo da rede. As métricas utilizadas para avaliação incluem tanto indicadores tradicionais de desempenho de rede quanto medidas de precisão de modelos de aprendizado de máquina, critérios específicos de estudos e parâmetros de QoE. A tradução das intenções se mostra uma etapa crítica. No campo dos algoritmos de aprendizado de máquina, observa-se o uso do NLP para interpretar intenções, bem como a aplicação de técnicas de análise de tráfego e detecção de anomalias, principalmente com redes neurais, árvores de decisão e algoritmos de vetor de distância.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. Este trabalho utilizou ferramentas de IA exclusivamente para aprimoramento textual, incluindo correção gramatical e melhorias de clareza e legibilidade. Todo o conteúdo técnico, ideias e contribuições são de inteira responsabilidade dos autores.

Referências

- Alam, S., Rivera, J. J. D., Sarwar, M. M. S., Muhammad, A., and Song, W.-C. (2024). Assuring Efficient Path Selection in an Intent-Based Networking System: A Graph Neural Networks and Deep Reinforcement Learning Approach. *Journal of Network and Systems Management*, 32:41. Publicado online: 3 de Abril de 2024.
- Alcock, P., Anand, R., Rotsos, C., and Race, N. (2024). Swift: Semantic web intent framework for intent translation.
- Andreazi, G. T., Estrella, J. C., Bruschi, S. M., Immich, R., Guidoni, D., Alves Pereira Júnior, L., and Meneguette, R. I. (2021). Mohripa—an architecture for hybrid resources management of private cloud environments. *Sensors*, 21(20).

- Andrushchak, V. S., Beshlei, M. I., and Maksymiuk, T. A. (2021). Intelligent traffic engineering for future intent-based software-defined transport network. In Klymash, M., Beshley, M., and Luntovskyy, A., editors, *Future Intent-Based Networking: On the QoS Robust and ...*, Lecture Notes in Electrical Engineering, pages 161–181. Springer, Cham.
- Asif, M., Khan, T. A., and Song, W.-C. (2025). R-ibn: A reinforcement learning-based intent-driven framework for end-to-end service orchestration and optimization. *Computer Networks*, 270:111564.
- Beshley, M., Kryvinska, N., and Beshley, H. (2023). Quality of service management method in a heterogeneous wireless network using Big Data technology and mobile QoE application. *Simulation Modelling Practice and Theory*, 127:102771.
- Beshley, M., Medvetskyi, M., Jun, S., Pryslupskyi, A., Bobalo, Y., and Beshley, H. (2022). Qoe-aware intelligent handover method for intent-based software-defined wireless network. In *2022 IEEE 16th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET)*, pages 534–538.
- Bittencourt, L., Immich, R., Sakellariou, R., Fonseca, N., Madeira, E., Curado, M., Villas, L., DaSilva, L., Lee, C., and Rana, O. (2018). The internet of things, fog and cloud continuum: Integration and challenges. *Internet of Things*, 3-4:134 – 155.
- Cesário, H., Girao, G., Riker, A., Dalmazo, B., and Immich, R. (2022). Arquitetura para gerenciamento de dispositivos através de assistentes virtuais comandados por voz. In *Anais do VI Workshop de Computação Urbana*, pages 1–14, Porto Alegre, RS, Brasil. SBC.
- Christou, F. (2022). Decentralized intent-driven coordination of multi-domain ip-optical networks. In *2022 18th International Conference on Network and Service Management (CNSM)*, pages 359–363.
- Clemm, A., Ciavaglia, L., Granville, L. Z., and Tantsura, J. (2022). Intent-Based Networking - Concepts and Definitions.
- Gama, E. S., Rodrigues-Filho, R., Madeira, E. R. M., Immich, R., and Bittencourt, L. F. (2024). Enabling adaptive video streaming via content steering on the edge-cloud continuum. In *2024 IEEE 8th International Conference on Fog and Edge Computing (ICFEC)*, pages 35–42.
- Goścień, R. (2023). Traffic-aware service relocation in software-defined and intent-based elastic optical networks. *Computer Networks*, 225:109660.
- Gupta, N., Das, D., K, T., Natarajan, U. M., Ravindran, S., Sharma, K., Bapat, J., and Das, D. (2025). A novel integrated architecture for intent based approach and zero touch networks. In *Proceedings of IEEE FNWF*.
- Hermosilla, A., Martinez-Julia, P., Lopez, D. R., and Skarmeta, A. F. (2025). Multi-domain network intent policy enforcement. *Computer Modeling in Engineering & Sciences*, 145(3):4280–4316.

- Hossain, M. K. and Aljoby, W. (2025). Netintent: Leveraging large language models for end-to-end intent-based sdn automation. *IEEE Open Journal of the Communications Society*.
- Huanga, M. V. B., Ortiz, R. I. H., and Marca, J. D. A. (2022). Design and development of an intent-based intelligent network using machine learning for qos provisioning. In *2022 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC)*, volume 6, pages 1–7.
- Hurtado, R., Torres, M., Pintado, B., and Muñoz, A. (2023). Development of an Intent-Based Network Incorporating Machine Learning for Service Assurance of E-Commerce Online Stores. In *Machine Learning for Networking (MLN 2022)*, pages 12–23. Springer Nature Switzerland AG.
- Immich, R., Borges, P., Cerqueira, E., and Curado, M. (2015). Qoe-driven video delivery improvement using packet loss prediction. *International Journal of Parallel, Emergent and Distributed Systems*, 30(6):478–493.
- Kanagarathinam, M. R., Kovvuri, J. R., Sandeep, I., and Godavarti, U. K. (2025). Intent-based l4s for ai-powered iot: A client-side implementation via ebpf.
- Karakaya, E., Ercetin, O., Ozkan, H., Karaca, M., Biyar, E. D., and Palaios, A. (2024). Online learning for autonomous management of intent-based 6g networks.
- Khan, T. A., Akbar, W., Muhammad, A., and Song, W.-C. (2022). Proactive intent policy activation: An ml-assisted resource forecasting approach. In *2022 23rd Asia-Pacific Network Operations and Management Symposium (APNOMS)*, pages 1–6.
- Khan, T. A., Mehmood, A., Ravera, J. J. D., Muhammad, A., Abbas, K., and Song, W.-C. (2021a). Intent-based Networking Platform An Automated Approach for Policy and Configuration of Next-Generation Networks. In *Proceedings of the 2021 ACM Symposium on Applied Computing (SAC '21)*, pages 1–10.
- Khan, T. A., Muhammad, A., Akbar, W., Mehmood, A., Rafiq, A., and Song, W. C. (2021b). Intent-based Networking Approach for Service Route and QoS control on KOREN SDI. In *2021 IEEE 7th International Conference on Network Softwarization (NetSoft)*, pages 24–30.
- Leivadeas, A. and Falkner, M. (2023). Autonomous network assurance in intent based networking: Vision and challenges. In *2023 32nd International Conference on Computer Communications and Networks (ICCCN)*, pages 1–10.
- Li, T., Yang, C., and Yang, L. (2022). Intent-Driven QoS-Aware Routing Management for Flying Ad hoc Networks. In *2022 International Wireless Communications and Mobile Computing (IWCMC)*, pages 1172–1177.
- Li, X., Cai, Y., Wu, R., and Tian, J. (2024). Cloud-Network Resource Scheduling for ONAP-Based IDN. In *Lecture Notes in Electrical Engineering (LNEE 1127)*, pages 39–52. Springer Nature Singapore Pte Ltd.
- Lingga, P., Jeong, J. P., and Dunbar, L. (2024). ICSC: Intent-Based Closed-Loop Security Control System for Cloud-Based Security Services. *IEEE Communications Magazine*.
- Ma, H., Ma, Y., and Wu, Y. (2025a). UINT: An intent-based adaptive routing architecture. *Computer Networks*, 257:110991.

- Ma, Y., Zhang, P., Li, H., Zhao, Y., Ai, Y., and Liu, H. (2025b). Intent fuel station: A rag-enhanced agent hub for realizing networking intents. In *2nd Workshop on Networks for AI Computing (NAIC '25)*. ACM.
- Martini, B., Gharbaoui, M., and Castoldi, P. (2023). Intent-based network slicing for SDN vertical services with assurance: Context, design and preliminary experiments. *Future Generation Computer Systems*, 142:101–116.
- Mehmood, K., Krlevska, K., and Palma, D. (2023). Knowledge Graph Embedding in Intent-Based Networking. In *2023 IEEE International Mediterranean Conference on Communications and Networking (MeditCom)*, pages 181–186.
- Mehmood, K., Krlevska, K., and Palma, D. (2024). Knowledge graph embedding in intent-based networking. In *2024 IEEE 10th International Conference on Network Softwarization (NetSoft)*, pages 13–18.
- Meijer, A.-R., Boldrini, L., Koning, R., Hesselman, C., Grosso, P., Bazo, R., Albalawi, A., and Bos, H. (2022). User-driven Path Control through Intent-Based Networking. In *Proceedings of the 2022 ACM/IEEE International Workshop on Network Dynamics (INDIS)*, pages 9–19.
- Natarajan, U. M., Diddigi, R. B., and Bapat, J. (2025). Rag-inspired intent-based solution for intelligent autonomous networks. IEEE.
- Ooi, S. E., Beuran, R., Tan, Y., Kuroda, T., Kuwahara, T., and Fujita, N. (2022). SecureWeaver: Intent-Driven Secure System Designer. In *Proceedings of the 2022 ACM Workshop on Secure and Trustworthy Cyber-Physical Systems (SaT-CPS '22)*, pages 1–10.
- Rivera, J. J. D., Khan, T. A., Akbar, W., Muhammad, A., Mehmood, A., and Song, W.-C. (2022). Automation of network anomaly detection and mitigation with the use of ibn: A deployment case on koren. Jeju, Republic of Korea. IEEE. Afiliação: Jeju National University [2].
- Shi, Z., Zeng, Y., and Wu, Z. (2021). Service Chain Orchestration Based on Deep Reinforcement Learning in Intent-Based IoT. In *Proceedings of the 9th International Conference on Computer Engineering and Networks, Advances in Intelligent Systems and Computing 1143*, pages 875–882. Springer Nature Singapore Pte Ltd.
- Silva, F. S. D., Bessa, A., Silva, S., Ferino, S., Paiva, P., Medeiros, M., Silva, L., Neto, J., Costa, K., Santos, C., Maciel, D., Silva, L., Inoue, A., Immich, R., Aranha, E., Martins, A., Sousa, V., Kulesza, U., Fernandes, M., Salvador, M., Pupio, G., Fontes, R., and Neto, A. (2023). Proactive ml-assisted and quality-driven slice application service management to keep qoe in 5g mobile networks. In *2023 IEEE Conference on Network Function Virtualization and Software Defined Networks (NFV-SDN)*, pages 182–184.
- Silva, F. S. D., Silva, S. N., da Silva, L. M., Bessa, A., Ferino, S., Paiva, P., Medeiros, M., Silva, L., Neto, J., Costa, K., Santos, C., Aranha, E., Martins, A., Kulesza, U., Immich, R., Neto, A. V., Fontes, R., Sousa, V., and Fernandes, M. A. (2024). MI-based inter-slice load balancing control for proactive offloading of virtual services. *Computer Networks*, 246:110422.

- Sophocleous, M., Lessi, C., Xu, Z., Špaňhel, J., Qiu, R., Lendinez, A., Chondroulis, I., and Belikaidis, I. (2022). AI-Driven Intent-Based Networking for 5G Enhanced Robot Autonomy. In Maglogiannis, I., Psannis, K. E., Cosmas, J. P., Kampouridis, M. P., and Iliadis, L., editors, *IFIP Advances in Information and Communication Technology (AIAI 2022 Workshops)*, pages 61–70. Springer Nature Switzerland AG.
- Velasco, L., Signorelli, M., De Dios, O. G., Papagianni, C., Bifulco, R., Olmos, J. J. V., Pryor, S., Carrozzo, G., Schulz-Zander, J., Bennis, M., Martinez, R., Cugini, F., Salvadori, C., Lefebvre, V., Valcarenghi, L., and Ruiz, M. (2021). End-to-End Intent-Based Networking. *IEEE Communications Magazine*, 59(10):106–112.
- Venkatesh, K., Krishnan, S. B., and Hussain, M. A. (2025). Enhancing end-user application performance with intention-based sdn in public networks.
- Wu, C., Horiuchi, S., Murase, K., Kikushima, H., and Tayama, K. (2021). Intent-driven cloud resource design framework to meet cloud performance requirements and its application to a cloud-sensor system. *Journal of Cloud Computing*, 10(1).
- Wu, C., Horiuchi, S., Murase, K., Kikushima, H., and Tayama, K. (2022). An Intent-driven DaaS Management Framework to Enhance User Quality of Experience. *ACM Transactions on Internet Technology*, 22(4):98:1–98:25.
- Yu, H., Rahimi, H., Janz, C., Wang, D., Yang, C., and Zhao, Y. (2023). A Comprehensive Framework for Intent-Based Networking, Standards-Based and Open-Source. In *NOMS 2023–2023 IEEE/IFIP Network Operations and Management Symposium*, pages 1–6.