# GREEN NETWORKING EM REDES 6G: UMA REVISÃO SISTEMÁTICA SOBRE A OTIMIZAÇÃO DE BEAMFORMING VIA MACHINE LEARNING

**Miguel Rodrigo Alfonzo Olmedo[1], Arthur de Arruda Cortez Martins[1], Rafael Zanuncio Ortiz do Nascimento[1], Tiago França Blanco [1], Frederico Silva Moreira[1]**

[1]*Universidade Federal de Mato Grosso do Sul, Campo Grande, Brasil*
(miguel.olmedo@ufms.br)

Resumo: Este trabalho analisa a evolução da eficiência energética em redes 6G, destacando o *Machine Learning* na otimização do *Beamforming* para otimizar o direcionamento de sinais e reduzir o consumo de energia (*Green Networking*). Discutem-se tecnologias como Superfícies Inteligentes Reconfiguráveis (RIS), e os desafios para viabilizar redes verdes e autônomas. Ao final, propõe-se um modelo conceitual de arquitetura para elevar a sustentabilidade operacional e a eficiência nas comunicações futuras

*Palavras-chave*: *Green Networking*; *Beamforming*; *Machine Learning*; 6G

## INTRODUÇÃO

O desenvolvimento de uma nova rede de comunicações representa um avanço na transmissão de dados. Nesse sentido, a rede 6G apresenta baixa latência, largura de banda na faixa de terahertz e alta taxa de transmissão. Portanto, o 6G promove o surgimento de novos serviços, como comunicação quântica, cirurgias remotas e interface cérebro-computador (Alhashimi *et al*., 2025).

Para atender essas novas demandas, a rede 6G necessita de uma infraestrutura que seja capaz de gerenciar a mobilidade, reduzir o consumo de energia e otimizar o espectro das ondas transmitidas (Alhashimi *et al*., 2025). Dessa maneira, a integração do *Machine Learning* (ML) ao 6G é essencial para o gerenciamento de recursos e o aprendizado em tempo real de sistemas autônomos.

Conforme Rekkas *et al*. (2021), *Machine Learning* é um sistema computacional que concede à máquina a capacidade de aprender e evoluir autonomamente, sem que seja necessário intervir no aprendizado. Após o *treinamento*, o algoritmo é colocado para realizar tarefas muito repetitivas ou com um enorme fluxo de dados sem que haja problemas.

*O Machine Learning* é dividido em alguns subconjuntos (Rekkas et al., 2021):

- *Supervised Learning:* É um modelo de *Machine Learning* que aprende com um banco de dados rotulados;

- *Reinforced Learning:* Este modelo funciona tal qual uma criança aprendendo, com base em punições quando comete erros e gratificações quando acerta;

- *Federated Learning:* É um modelo que busca aprender em múltiplos dispositivos ou servidores sem que os dados brutos precisem sair do local de origem;

- *Deep Learning:* Este modelo é baseado em redes neurais artificiais imitando um cérebro humano, para facilitar no processamento de dados, reconhecer padrões e tomar decisões;

- *Deep Reinforcement Learning* (DRL): Esse modelo aplica os algoritmos de *Deep Learning* ao *Reinforcement Learning.* Dessa maneira, ele usa o método de aprendizagem com base em gratificações do *Reinforced Learning* e a estrutura que imita o cérebro humano do *Deep Learning*;

O *Beamforming* é uma das técnicas responsáveis pela otimização do consumo de energia e eficiência espectral. Contudo, o seu desempenho é limitado por algoritmos complexos e sistemas dinâmicos (Selvaperumal *et al*., 2025). Dessa maneira, a aplicação do *Machine Learning* é imprescindível para controlar o *Beamforming* da maneira mais eficiente possível.

É possível associar o *Beamforming* ao *Deep Reinforcement Learning*. Essa é uma abordagem promissora, pois o *Beamforming* apresenta desempenho limitado devido à necessidade de uma grande quantidade de cálculos e de informações precisas. O DRL tem a capacidade de administrar quantidades massivas de informação e resolver

cálculos complexos em pouco tempo, ao associar os dois é possível resolver os principais problemas de funcionamento do *Beamforming* sem que haja um desperdício gigantesco de recursos (Yu *et al.*, 2022).

O método de desdobramento de algoritmos consiste em desdobrar um algoritmo iterativo específico dentro de uma rede profunda e agregar finitas camadas. Esse método converge a um resultado mais rápido do que algoritmos de limiarização suave iterativa (ISTA), aumentando, dessa forma, a capacidade computacional (Shi *et al*., 2023).

As Redes Neurais em Grafos (*Graph Neural Networks*, GNN) aplicam a estrutura de grafos em redes neurais para explorar suas propriedades. Conforme Shi *et al*. (2023), nesse tipo de rede neural, o aprendizado é otimizado por meio da permutação dos nós, obtendo-se diferentes saídas.

A invariância à permutação ocorre quando a saída não depende da ordem dos nós, enquanto a equivariância à permutação ocorre quando o resultado é alterado de acordo com a ordem da permutação dos nós. No *Beamforming*, essa técnica é aplicada considerando os RIS e as antenas como nós de um grafo, e os enlaces de comunicação entre eles como arestas (Shi *et al*., 2023).

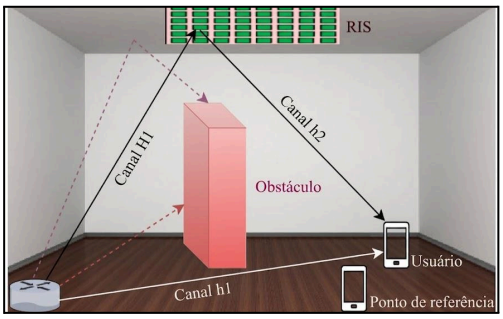



Figura 1. Sistema de comunicação interno com RIS.
Fonte: Adaptado de Faisal e Choi, 2022.

O *RIS* (*Reconfigurable Intelligent Surfaces)* é uma tecnologia inovadora que funciona a partir de painéis planos cobertos por uma camada de metamateriais chamados *meta-atoms,* que tem a capacidade de interferir em ondas eletromagnéticas e redirecionar sinais de rádio em tempo real (Dhote; Sharma; Singh, 2023). Para melhorar o sinal da onda, controles de sinais são transmitidos por estações de base para um controlador *RIS* (Faisal e Choi, 2022).

De acordo com Zhu *et al*. (2024) e Dhote, Sharma e Singh (2023), a RIS é considerada uma tecnologia fundamental para o desenvolvimento das redes 6G, apresentando características relevantes, como a baixa necessidade de potência elétrica e a compatibilidade com essa nova geração de redes. Além disso, possui menor custo energético e de *hardware* em comparação com outros métodos, tornando-se uma alternativa promissora para melhorar a qualidade da comunicação.

Diante desse contexto, este trabalho tem como objetivo analisar o estado da arte da aplicação de algoritmos de *Machine Learning* no controle dinâmico de *Beamforming* em redes 6G, com o foco na redução do consumo energético e na consolidação do *Green Networking*. Busca-se compreender como a integração dessas tecnologias, aliada ao uso de RIS, contribui para a eficiência operacional da infraestrutura e para a sustentabilidade das redes de próxima geração.

## MATERIAL E MÉTODOS

Para alcançar os objetivos propostos neste trabalho, foi adotada uma abordagem qualitativa e exploratória, com foco na revisão bibliográfica e análise documental. O estudo baseou-se em artigos encontrados em bases de dados científicas como IEEE Xplore, ScienceDirect, Google Acadêmico e SPECS.

A revisão da literatura permitiu identificar os principais marcos tecnológicos e as tendências de mercado para a próxima geração de redes móveis, bem como os avanços em algoritmos de inteligência artificial aplicados à otimização de recursos. Foram priorizados estudos publicados nos últimos cinco anos, visando garantir a qualidade técnica necessária para a análise do estado da arte do 6G e das tecnologias emergentes.

A análise dos dados coletados foi realizada de forma descritiva e crítica, buscando correlacionar as inovações no controle de sinais com os impactos diretos na redução do consumo energético da infraestrutura de rede. Foram considerados aspectos fundamentais como a interoperabilidade de sistemas, a redução de latência, a segurança da informação e a viabilidade sustentável para a consolidação do *Green Networking*.

## RESULTADOS E DISCUSSÃO

### *1.* O Paradigma da Eficiência Energética e o *Green Networking*

As Redes 6G são projetadas para suportar taxas de pico de até 1 Tbps, latência inferior a 0,1 ms e uma densidade de conectividade superior a 10 milhões de dispositivos por quilômetro quadrado (Alhashimi *et al*., 2025).

Embora o 4G ainda seja suficiente para a maior parte das atividades cotidianas dos usuários, sua taxa de pico de dados é aproximadamente dez vezes menor que a do 5G. Diante das demandas impostas pelas novas tecnologias, o 4G torna-se progressivamente insuficiente para aplicações de alta exigência, principalmente devido à sua maior latência.

O 5G representou um salto qualitativo significativo, alcançando taxas de pico de 10 Gbps, latência de 10 ms e eficiência espectral de 30 bps/Hz. O 6G, por sua vez, projeta uma ruptura ainda mais profunda, com taxa de pico de 1 Tbps, latência inferior a 1 ms e eficiência espectral de 100 bps/Hz, conforme apresentado na Tabela 1, que sintetiza numericamente essa ruptura geracional.

Cada salto geracional representa não apenas uma evolução quantitativa, mas também uma redefinição das exigências impostas à infraestrutura energética das redes. É justamente nesse aspecto que o 6G se diferencia de seus antecessores de maneira mais abrangente.

Tabela 1. Comparação das redes 4G, 5G e 6G.

| Tecnologia | 4G | 5G | 6G |
|---|---|---|---|
| Taxa de dados de pico | 1 Gbps | 10 Gbps | 1Tbps |
| Frequência | 6 GHz | 3-300 GHz | 1000 GHz |
| Latência | 100 ms | 10 ms | <1 ms |
| Suporte a mobilidade | 350 km | Até 500 km/h | Até 1000 km/h |
| Eficiência espectral | 15 bps/Hz | 30 bps/Hz | 100 bps/Hz |
| Confiabilidade | 99.9 | 99,9999% | 99,99999% |

Os dados da Tabela 1 os 5G e 6G são os fornecidos por Rekkas *et al*., (2021). Enquanto a rede 4G por Banafaa *et al*., (2022).

Segundo Banafaa *et al*. (2022), essas metas exigem que a eficiência energética seja tratada não como um requisito secundário, mas como uma dimensão nativa do projeto. Dessa forma, os autores propõem que o 6G passe a incorporar seis dimensões fundamentais de design: as três tradicionais (espectro, eficiência espectral e reuso espacial), acrescidas das dimensões de dados, computação e energia (Figura 2).

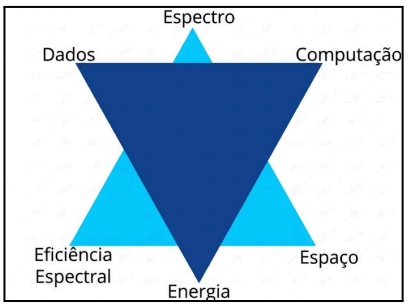



Figura 2. Dimensões fundamentais para o *design* de sistemas 6G.
Fonte: Adaptado de Viswanathan e Mogensen, 2020.

A adoção de práticas de *Green Networking*, é, portanto, fundamental. A meta declarada para o 6G é alcançar uma eficiência energética mais de dez vezes superior à do 5G, viabilizando redes autônomas sustentáveis paras as demandas da Internet das Coisas (IoT) (Shi *et al*., 2023).

## *2.* A otimização de *Beamforming* via *Machine Learning*

Os algoritmos clássicos de otimização matemática para *Beamforming* como WMMSE (*Weighted Minimum Mean-Square Error*) e *Branch-and-Bound* (BB), exibem uma complexidade computacional da ordem $O(n^3)$ e dependem de modelos de canal perfeitamente precisos (Shi *et al*., 2023). Para superar essa complexibilidade, a literatura propõe a adoção de técnicas de *Machine Learning,* que podem ser estruturadas em três paradigmas fundamentais.

### 2.1 Desdobramento de Algoritmos

A técnica de desdobramento de algoritmos converte interações clássicas em camadas de redes neurais com parâmetros treináveis. Shi *et al.* (2023) demonstram que a rede IAIDNN derivada do desdobramento do WMMSE reduz sua complexidade computacional de $O(n^3)$ para $O(n^{2,73})$, mantendo o desempenho equivalente ao algoritmo original, porém com latência significativamente menor.

### 2.2 Redes Neurais em Grafos (GNN)

Ainda segundo Shi *et al*. (2023), a topologia de redes sem fio pode ser naturalmente representada como um grafo, no qual os dispositivos correspondem aos nós e os canais de comunicação às arestas. Os autores demonstram que GNNs projetadas com propriedades de invariância e equivariância à permutação conseguem generalizar para redes de escala arbitrária, mesmo quando treinadas em cenários menores, reduzindo o erro de generalização e o número de amostras de treinamento necessárias em $O(n)$ e $O(n^2)$, respectivamente, em comparação com MLPs genéricas.

Aplicadas à otimização de *Beamforming* em sistemas com RIS, as GNNs realizam o mapeamento direto dos pilotos recebidos para matrizes de *Beamforming* na estação-base e para os padrões de reflexão das superfícies inteligentes.

2.3 *Deep Reinforcement Learning* (DRL)

Em ambientes de rede dinâmicos e desprovidos de modelos matemáticos tratáveis, o Aprendizado por Reforço Profundo (DRL) desponta como uma solução, permitindo que agentes autônomos aprendam políticas de alocação de *Beamforming* e espectro por interação com o ambiente.

Segundo Rekkas *et al*. (2021), a aplicação de modelos DRL para a maximização da relação sinal-ruído (SNR) em sistemas RIS atinge um desempenho muito próximo ao limite teórico superior do SNR recebido, reduzindo simultaneamente o consumo de tempo computacional.

## 3. Superfícies Inteligentes Reconfiguráveis (RIS)

As Superfícies Inteligentes Reconfiguráveis (RIS) representam uma das inovações mais inovadoras para a consolidação de redes sem fio ecologicamente eficientes (*Green Networking*). Rekkas *et al*. (2021) as caracterizam como superfícies compostas por elementos passivos de baixo custo, capazes de refletir sinais com ajustes de fase controlados via *software*.

Por dispensarem amplificadores de potência dedicados e procedimentos complexos de radiofrequência (RF) para sua operação direta, além de serem imunes à autointerferência, as RIS apresentam eficiência energética superior à das tecnologias convencionais de transmissão.

A sinergia entre *Machine Learning* e a infraestrutura das RIS é que o fato viabiliza o controle dinâmico dos sinais em tempo real. De acordo com Shi *et al*. (2023), As Redes Neurais de Grafos (GNNs), quando aplicadas a sistemas assistidos por RIS, são capazes de mapear diretamente os pilotos recebidos para as matrizes de *Beamforming* na estação base e para os padrões de reflexão nas superfícies.

Contudo, um desafio técnico crítico destacado na literatura reside no custo de aquisição da informação de Estado do Canal (CSI). Rekkas *et al*. (2021) advertem que a natureza passiva das RIS torna a estimação e o intercâmbio da CSI tarefas não triviais, exigindo um *overhead* de treinamento considerável que pode mitigar os ganhos energéticos do sistema. Consequentemente, a superação dessa limitação prática emerge como uma diretriz prioritária para pesquisas futuras.

Viswanathan e Mogensen (2020) destacam que o controle ótimo dessas metassuperfícies puramente por otimização analítica baseada em modelos pode se provar intratável na prática. Assim, a aplicação de técnicas avançadas de *Machine Learning* com ênfase em GNNs e Aprendizado por Reforço Hierárquico será fundamental para a resolução desses problemas não lineares complexos na era da rede 6G.

## 4. Desafios de Implementação e Tecnologias futuras

Ferreira *et al*. (2025), em seu estudo sobre os possíveis riscos e desafios da sexta geração de redes móveis, discute as implicações sociais, éticas e territoriais da hiperconectividade proporcionada pelo 6G. As principais preocupações decorrem do potencial de coleta massiva de dados, possibilitando que a rede seja utilizada como instrumento de vigilância sistemática.

Os autores também abordam a questão sob uma perspectiva socioeconômica, destacando a possibilidade de intensificação das desigualdades urbanas preexistentes. Nesse contexto, ressaltam a importância de análises aprofundadas sobre modelos regulatórios de caráter técnico, ético e ambiental, especialmente durante estudos empíricos relacionados aos impactos das redes 6G em territórios vulneráveis.

Com base em Gustavsson et al. (2021), sabe-se que a implementação do 5G introduziu novas técnicas de MIMO (*Multiple-Input Multiple-Output*), enquanto as projeções para o 6G apontam para uma arquitetura de MIMO massivamente distribuída, capaz de explorar frequências submilimétricas. Embora as faixas submilimétricas tendam a ser fragmentadas, bandas de frequência em torno de 70 GHz ainda apresentam ampla disponibilidade espectral.

A implementação de sistemas MIMO, especialmente do tipo LS-D-MIMO (*Large-Scale Distributed* MIMO), requer uma distribuição massiva de antenas. Gustavsson *et al*. (2021) afirmam que o desempenho teórico, por si só, não é suficiente para garantir o sucesso comercial dessa tecnologia, sendo necessárias novas abordagens de distribuição para tornar sua implementação viável.

Além disso, o próprio processo de sincronização do MIMO distribuído requer aproximadamente 50% mais sinais piloto em comparação ao MIMO co-localizado (Gustavsson *et al*., 2021). Dessa forma, o sistema demanda a adoção de estratégias de processamento mais sofisticadas.

Shi *et al*., (2023) abordam problemas de recuperação de sinal devido às técnicas de processamento em larga escala de sinais em redes 6G, como *big data*, IoT massiva, e redes de acesso massivas. Tal procedimento de recuperação de dados sofre com a imperfeição dos dados coletados, a diversidade de padrões e a alta complexidade computacional.

Na questão de detecção de dados, os autores afirmam que as técnicas tradicionais de detecção apresentam uma forte dependência entre complexidade e confiabilidade, resultando em uma infraestrutura incapaz de atender os sistemas massivos MIMO requerido pela rede 6G.

Dessa maneira, receptores baseados em aprendizado de máquina (ML) e *Algorithm Unrolling* têm sido estudados para a implementação de abordagens como DetNet, OAMPNet, MMNet e CMDNet.

## 5. Proposta de Modelo Conceitual de Arquitetura Autônoma

Como síntese desta revisão e com base nas evidências apresentadas na literatura, propõe-se um modelo conceitual de arquitetura autônoma para redes 6G voltadas ao *Green Networking* (Figura 3). O modelo não reproduz integralmente nenhuma arquitetura específica da literatura, mas articula, de forma integrada, componentes individuais encontrados em Viswanathan e Mogensen (2020), Shi *et al*. (2023) e Rekkas *et al*. (2021).

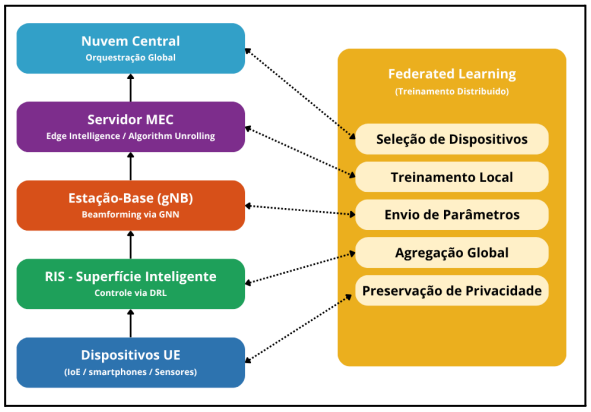



Figura 3. Modelo conceitual de arquitetura autônoma para *Green Networking* em Redes 6G.
Fonte: Autoria própria.

No modelo apresentado, podem ser identificadas as camadas da infraestrutura das redes 6G, desde a base, composta pelos dispositivos conectados à internet, até o servidor central de processamento de dados.

Na base da arquitetura encontram-se os dispositivos dos usuários. Nesta camada, o foco primordial é a preservação de privacidade. De acordo com Shi *et al*., (2023), o uso de Aprendizado Federado (*Federated Learning* – FL) permite que os dispositivos participem no treino do modelo global sem compartilhar seus dados brutos, o que minimiza drasticamente o custo de comunicação e protege a privacidade do usuário final.

As Superfícies Inteligentes Reconfiguráveis (RIS), integradas com a etapa de Agregação Global, otimizam o ambiente de propagação. Como apontado por Rekkas *et al*., (2021), o controle de RIS via DRL permite maximizar a relação sinal-ruído (SNR) e assegurar a integridade dos parâmetros do modelo de inteligência artificial (IA) que estão a ser agregados.

A Estação-Base (gNB), operando com rádio inteligente nativo, faz a ponte para o envio de parâmetros. Segundo Viswanathan e Mogensen (2020), a transição de IA como um adendo para uma base nativa do *design* da interface aérea permite que a gNB se auto-otimize. Em vez de gerenciar o tráfego convencional de dados, a gNB concentra-se na transmissão eficiente dos pesos e gradientes dos modelos de IA, utilizando técnicas avançadas de *Beamforming* para reduzir o desperdício de potência de transmissão.

O servidor MEC (*Multi-access Edge Computing*) viabiliza a *Edge Intelligence*. Nessa camada, ocorre a coordenação do treinamento local e a aplicação de técnicas de *Algorithm Unrolling*. Viswanathan e Mogensen (2020) destacam que o uso de computação local, porém separada dos dispositivos, constitui uma abordagem inovadora e essencial para o desenvolvimento das redes 6G.

Conforme Viswanathan e Mogensen (2020), a evolução para o 6G exige a alocação distribuída de funções que se estendem até o dispositivo final. A Figura 4 ilustra essa mudança de paradigma, demonstrando uma arquitetura com conectividade multi-percurso e descentralização de serviços.

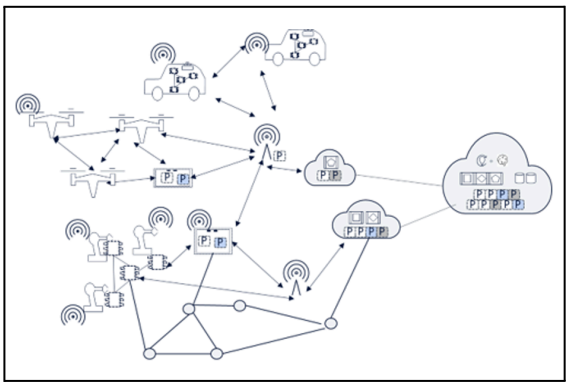


Figura 4. Arquitetura 6G com sub-redes, conectividade multi-percurso e alocação distribuída de funções estendida até o dispositivo.
Fonte: Viswanathan e Mogensen (2020).

No topo da hierarquia, a Nuvem Central realiza a orquestração de alto nível, com foco na Seleção de Dispositivos. Conforme a visão de Shi *et al*. (2023), este processo de seleção é crucial para a escalabilidade da "inteligência conectada", onde a nuvem identifica os nós mais aptos a participar da rodada de treino, baseando-se em critérios de eficiência e confiabilidade. Essa gestão centralizada viabiliza que a execução de serviços seja dividida dinamicamente entre a nuvem e os dispositivos da borda, garantindo que os serviços operem sem

interrupções e de forma resiliente, mesmo sob condições de conectividade limitada (Viswanathan; Mogensen, 2020).

## CONCLUSÃO

A presente revisão sistemática demonstrou que a convergência entre *Machine Learning* e as redes de sexta geração (6G) representa não apenas uma evolução tecnológica progressiva, mas uma transformação estrutural na forma como as redes de comunicação sem fio são concebidas, operadas e otimizadas. A análise da literatura evidenciou que os algoritmos clássicos de otimização, como WMMSE e *Branch-and-Bound,* tornam-se computacionalmente inviáveis diante da escala e da dinamicidade impostas pelo 6G, cedendo espaço a paradigmas de ML que oferecem desempenho superior com complexidade computacional significativamente reduzida.

Entre as técnicas investigadas, o Desdobramento de Algoritmos (*Algorithm Unrolling)* destacou-se pela capacidade de preservar a interpretabilidade e as garantias teóricas dos algoritmos clássicos enquanto reduz sua complexidade de $O(n^3)$ para $O(n^{2,73})$. As Redes Neurais em Grafos (GNN) demonstraram escalabilidade e generalização superiores para problemas de alocação de recursos em topologias de rede complexas, explorando a estrutura natural de grafo das redes sem fio. O *Deep Reinforcement Learning*, por sua vez, mostrou-se indispensável para ambientes dinâmicos e aleatórios, onde modelos matemáticos precisos são indisponíveis, permitindo que agentes autônomos aprendam políticas de *beamforming* e alocação de espectro por interação direta com o ambiente.

As Superfícies Inteligentes Reconfiguráveis (RIS) emergiram como tecnologia habilitadora central para o *Green Networking*, oferecendo controle passivo e energeticamente eficiente da propagação de sinais. Sua integração com algoritmos de ML, especialmente GNNs e DRL viabiliza o controle dinâmico em tempo real dos padrões de reflexão, potencializando os ganhos de eficiência energética e espectral. Contudo, o custo de aquisição de CSI em sistemas passivos permanece como um dos principais obstáculos técnicos a serem superados.

No âmbito dos desafios de implementação, o *Federated Learning* consolidou-se como resposta aos problemas de privacidade e distribuição de dados, permitindo o treinamento colaborativo de modelos de IA sem a centralização de dados sensíveis. Paralelamente, questões sociotécnicas relevantes foram identificadas, incluindo os riscos de vigilância sistemática, o aprofundamento de desigualdades socioeconômicas e a necessidade de marcos regulatórios robustos de caráter técnico, ético e ambiental, conforme apontado por Ferreira et al., (2025).

Através do modelo conceitual pode-se compreender visualmente a interação das tecnologias entre si, aplicando o método de *Federated Learning* com foco na preservação dos dados coletados pelos dispositivos. Juntamente com as tecnologias RIS, Estação-Base (gNB), Servidor Mec e pôr fim a Nuvem Central, a rede 6G se mostra possível e viável.

Conclui-se que o *Green Networking* em redes 6G não é uma meta desejável, mas um requisito de engenharia alcançável por meio da incorporação sistemática de ML ao controle de *Beamforming* e à gestão de recursos da infraestrutura. As evidências apresentadas apontam para um futuro próximo em que redes de comunicação operarão com autonomia crescente, consumo energético drasticamente reduzido e capacidade de adaptação em tempo real a ambientes heterogêneos e dinâmicos. Para que essa visão se concretize, pesquisas futuras devem endereçar prioritariamente: (i) a escalabilidade do Federated Learning para o contexto de IoT; (ii) a redução do overhead de CSI em sistemas com RIS; (iii) o desenvolvimento de arquiteturas de ML de baixa complexidade para dispositivos de borda (*edge*) com recursos limitados; e (iv) a formulação de modelos regulatórios que garantam que os benefícios do 6G sejam distribuídos de forma equitativa e socialmente responsável.

## AGRADECIMENTOS

À Universidade Federal de Mato Grosso do Sul -UFMS/MEC – Brasil, por ofertar ensino público, gratuito e de qualidade. E ao curso de Engenharia Elétrica por todo o suporte durante esta jornada.

## REFERÊNCIAS

ALHASHIMI, Hayder Faeq; HINDIA, Mhd Nour; DIMYATI, Kaharudin; HANAFI, Effariza Binti; ALDEN, Feras Zen; Alden; QAMAR, Faizan; NGUYEN, Quang Ngoc. *Survey on AI-Enabled Resource Management for 6G Heterogeneous Networks: Recent Research, Challenges, and Future Trends*. Computers, Materials and Continua, v. 83, n. 3, p. 3585–3622, 2025. Disponível em: https://www.sciencedirect.com/org/science/article/pii/S1546221825004382. Acesso em: 18/04/2026.

BANAFAA, Mohammed; SHAYEA, Ibraheem; DIN, Jafri; AZMI, Marwan Hadri; ALASHBI, Abdulaziz; DARADKEH, Yousef Ibrahim; ALHAMMADI, Abdulraqeb. *6G Mobile Communication Technology: Requirements, Targets, Applications, Challenges, Advantages, and Opportunities*. Alexandria Engineering Journal, v. 64, p. 245–274, 2022. Disponível em:

https://www.sciencedirect.com/science/article/pii/S111001682200549X. Acesso em: 15/04/2026.

DHOTE, Chandresh; SHARMA, Prabhat Kumar; SINGH, Anamika. *Graphene-Based Reconfigurable Intelligent Surface for 6G Wireless Communication*. 2023 IEEE Microwaves, Antennas, and Propagation Conference (MAPCON), Ahmedabad, India, pp. 1-6, 2023. Disponível em: https://ieeexplore.ieee.org/document/10463993. Acesso em: 22/04/2026.

FAISAL, K. M.; CHOI, W. *Machine Learning Approaches for Reconfigurable Intelligent Surfaces: A Survey*. IEEE Access, v. 10, p. 27343–27367, 2022. Disponível em: https://ieeexplore.ieee.org/document/9729826. Acesso em: 23/04/2026.

FERREIRA, Rodolfo de Lyra; SOUZA, Caroline Ferreira de; BRITO, Maria do Socorro da Cruz; CAJE, Mariza Santos; CABANÊZ, Paula Alvarez. *Tecnologia 6G: perspectivas futuras para a era da hiperconectividade*. Interference Journal, v. 11, n. 2, p. 6974–6993, 2025. Disponível em: 13/05/2026.

GUSTAVSSON, Ulf; RESEARCH, Ericsson; FRENGER, Pål; FAGER, Christian; ERIKSSON, Thomas; ZIRATH, Herbert; DIELACHER, Franz. *Implementation Challenges and Opportunities in Beyond-5G and 6G Communication*. IEEE Journal of Microwaves, v. 1, n. 1, p. 86–100, 2021. Disponível em: 16/05/2026.

REKKAS, Vasileios P.; SOTIROUDIS, Sotirios; SARIGIANNIDIS, Panagiotis; WAN, Shaohua; KARAGIANNIDIS, George K.; GOUDOS, Sotirios K. *Machine Learning in Beyond 5G/6G Networks-State-of-the-Art and Future Trends*. Electronics, v. 10, n. 22, p. 2786, 2021. Disponível em: 12/04/2026.

SELVAPERUMAL, P.; PRATHIK, A.; SURAT, Pyari Atti; TEJA SREE, B.; GOPINATH, D.; SHILPA, Jain. *Energy-Efficient Beamforming for 6G mmWave Networks using Deep Swarm Intelligence*. 4ª Conferência Internacional sobre Mecanismos Inovadores para Aplicações Industriais (ICIMIA), Tirupur, Índia, pp. 720-726, 2025. Disponível em: https://ieeexplore.ieee.org/document/11200559. Acesso em: 12/04/2026.

SHI, Yandong; LIAN, Li Xiang; YUANMING, Shi; WANG, Zixin; ZHOU, Yong; FU, Liqun. *Machine Learning for Large-Scale Optimization in 6G Wireless Networks*. IEEE Communications Surveys & Tutorials, v. 25, n. 4, p. 2088–2132, 2023. Disponível em: https://ieeexplore.ieee.org/document/10198239. Acesso em: 20/04/2026.

VISWANATHAN, Harish; MOGENSEN, Preben E. *Communications in the 6G Era*. IEEE Access, v. 8, p. 57063–57074, 2020. Disponível em: https://ieeexplore.ieee.org/document/9040431. Acesso em: 15/05/2026.

YU, Huihan; XIAO, Yang; WU, Jiawei; ELE, Zilong; LIU, Fang; LIU, Jun. *Deep Reinforcement Learning Based Beamforming for Throughput Maximization in Ultra-Dense Networks*. 2022 IEEE Wireless Communications and Networking Conference (WCNC) , Austin, TX, EUA, pp. 1021-1026, 2022. Disponível em: https://ieeexplore.ieee.org/document/9771887. Acesso em: 19/04/2026.