

Otimização da Eficiência de Uso Dinâmico de Espectro em Caráter Secundário

Fernando Dias de Mello Silva, Leandro da Silva Pires, Fernanda Duarte Vilela Reis de Oliveira,
Pedro Henrique Cruz Caminha e Luís Henrique Maciel Kosmalski Costa

Resumo— O compartilhamento de espectro licenciado pode aumentar a eficiência de uso do espectro, mas prejudicar usuários primários. Assim, é necessário resolver um problema de otimização que ofereça configurações de equipamentos secundários maximizando a eficiência do espectro sem causar interferências indesejadas a usuários primários. Este trabalho propõe uma heurística de otimização baseada em Redes Neurais de Grafos, evitando a busca exaustiva por soluções ótimas. Os resultados mostram que a proposta obtém respostas melhores de maneira mais rápida do que outras encontradas na literatura.

Palavras-Chave— Compartilhamento de espectro, aprendizado de máquina, comunicações sem-fio.

Abstract— Licensed spectrum sharing can improve the spectrum usage efficiency, but also hinder the operation of primary users. To optimize spectrum usage efficiency while avoiding significant interference to the primary user equipment, it is necessary to solve an optimization problem that returns the optimal configuration of secondary equipment. Nevertheless, obtaining optimal solutions to this problem might not be practical. This paper proposes a heuristic based on Graph Neural Networks to obtain solutions for the secondary equipment configurations. Our results show that our proposal obtains better solutions in a shorter time than other methods from the literature.

Keywords— Spectrum sharing, machine learning, wireless communications.

I. INTRODUÇÃO

No contexto brasileiro, o espectro eletromagnético é considerado um bem público limitado, sendo administrado pelo órgão regulador Anatel (Agência Nacional de Telecomunicações) [4]. O regulador deve prezar pelo uso eficiente do espectro através de licenciamentos que dão o direito de uso do mesmo em uma determinada região, faixa de frequência e sob determinadas condições operacionais. usuário. Uma das métricas observadas pelo regulador é a eficiência de uso do espectro (EUE) [3], que avalia se o recurso de espectro é devidamente utilizado pelo usuário. Um usuário é uma entidade com direito de uso de uma fatia do espectro, podendo possuir

vários terminais transmissores e receptores, como empresas de telefonia móvel, por exemplo.

Licenças podem ser concedidas em caráter primário ou secundário. Um usuário que possui uma licença de caráter primário (incumbente) tem preferência de uso de determinada fatia do espectro. Um usuário pode adquirir uma licença de uso em caráter primário, mas não iniciar a operação imediatamente dentro de uma determinada região. Por isso, a fatia de recursos pode ser oferecida em caráter secundário [2] para usuários que desejam usufruir do espectro não utilizado. No entanto, a interferência causada ao usuário incumbente devido ao secundário deve estar abaixo de um limiar (a razão interferência/ruído ≤ -6 dB [2]). Portanto, é necessário alocar os diferentes recursos de espectro entre incumbentes e secundários, maximizando a EUE e respeitando os limites de interferência. Esse tipo de autorização secundária é dinâmica, já que o incumbente pode querer explorar uma região a qualquer momento e novos usuários secundários podem surgir. Assim, o processo de otimização deve ser dinâmico e se adaptar às mudanças de condição de operação dos incumbentes, além de maximizar a utilização de espectro e garantir a proteção entre usuários.

O uso de recursos computacionais por otimizadores tradicionais pode impossibilitar a alocação ótima entre usuários. Este trabalho investiga o uso de Redes Neurais em Grafos (GNN) como otimizadores heurísticos para o problema de EUE. A EUE é definida seguindo os critérios brasileiros e recomendações internacionais. É formulado um problema de otimização com múltiplos transmissores e receptores por usuário baseado na EUE que é utilizado como base para treinamento da GNN. Um processo de geração de problemas constrói uma base para o treinamento e teste do modelo, e uma etapa de validação garante que as respostas da GNN são viáveis. Pode-se observar que a GNN apresenta um aumento de 32% no encontro de soluções viáveis e possui uma diferença de 50% em relação ao otimizador tradicional, a menor diferença observada entre os outros solucionadores heurísticos testados.

Este trabalho tem como contribuições: um modelo de problema de alocação de recursos de rádio multi-usuário e multi-transceptor para a otimização de EUE, baseado em resoluções da Anatel e recomendações da UIT; a proposta de um otimizador baseado em GNNs, que após treinamento são capazes de retornar respostas viáveis quase ótimas para o problema mais rápido que otimizadores tradicionais.

II. TRABALHOS RELACIONADOS

Diversos trabalhos exploram o processo de otimização de uso de espectro no contexto de sistemas de acesso dinâmico

Fernando D. M. Silva, Fernanda D. V. R. Oliveira, Pedro H. C. Caminha, Luís H. M. K. Costa, Poli/COPPE, Universidade Federal do Rio de Janeiro (UFRJ), Rio de Janeiro - RJ, e-mail: fernandodias@gtg.ufrj.br, fernanda.dvro@poli.ufrj.br, cruz@gtg.ufrj.br, luish@gtg.ufrj.br; Leandro S. Pires, Gerência de Espectro, Órbita e Radiodifusão, Agência Nacional de Telecomunicações (Anatel), Rio de Janeiro - RJ, e-mail: leandrop@anatel.gov.br. Este trabalho contou com apoio técnico e fomento à pesquisa do Centro de Altos Estudos em Comunicações Digitais e Inovações Tecnológicas (Ceadi) da Anatel, por meio de Termo de Execução Descentralizada celebrado entre a Agência Reguladora e a Universidade Federal do Rio de Janeiro, no contexto do Projeto nº 4/2024 (53500.060216/2024-35), "Soluções de Inteligência Artificial (IA) voltadas à gestão do espectro". O trabalho foi parcialmente financiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) Finance Code 001.

(DSA). O trabalho [1] otimiza o intervalo de medida de tempo para minimizar o tempo de interferência entre usuário primário e secundário e assim maximizar a utilização de espectro. Em [17], é avaliado o uso do espectro no contexto de DSA em veículos aéreos não tripulados com base na probabilidade de sensoriamento de uso bem sucedido. Porém, esses trabalhos carecem de medidas padronizadas e alinhadas com as recomendações de agências reguladoras, além de otimizar métricas sob a perspectiva do usuário e não de forma global.

Alguns trabalhos fazem uso de GNNs no processo de otimização de recursos de rádio. O trabalho [8] avalia e observa a viabilidade de uso de GNNs treinadas para o problema de alocação de recursos de rádio em conjuntos de dados reais. O trabalho [11] demonstra o uso de GNNs no problema de maximização de capacidade dos usuários. O trabalho [7] utiliza a GNN para detectar o uso indevido de espectro do usuário secundário dadas medidas de interferência do primário. Todos esses trabalhos propõem estruturas próprias para representação dos transmissores e receptores, porém não consideram o problema de otimização proposto.

Diversas propostas de DSA fazem uso de redes neurais para resolução do problema, treinadas através de técnicas de aprendizado por reforço. Em [13] *Deep-Q learning* é utilizada para maximizar a relação sinal-interferência mais ruído entre transmissores e receptores de um usuário, restrito pelo nível de interferência nos usuários primários. O trabalho [10] modifica o processo de Deep-Q learning e considera o cenário multi usuário com probabilidade de erro de medida dos dispositivos. O trabalho de [14] mostra que o treinamento por algoritmos genéticos é comparável aos métodos de aprendizado por reforço para o treinamento de redes.

III. DEFINIÇÃO DO PROBLEMA

O objetivo do problema de otimização é maximizar a EUE de um conjunto de usuários. No problema, um usuário possui um ou mais pares de transmissores e receptores e deseja utilizar parte do espectro para comunicação. São definidos usuários incumbentes, que são os que têm preferência de uso, e secundários, que são os que utilizam o espectro de forma oportunística em regiões onde o incumbente não utiliza ou subutiliza sua fatia de recursos. A otimização consiste em maximizar a eficiência através dos parâmetros de operação dos secundários, sem modificar o estado de operação e sem causar uma interferência significativa nos incumbentes.

A. Eficiência de uso do espectro

A Anatel define critérios para a EUE na Resolução [3]. Essa resolução concorda com a recomendação da União Internacional de Telecomunicações (UIT) [15]. Na resolução, é definida a utilização do espectro por usuário, através da expressão: $U = B \cdot S \cdot T$, em que B é a largura de banda, S é o total de área afetada pela transmissão e T a porcentagem de tempo que um usuário transmite. A EUE é definida pela razão entre o total de informação transmitida pela utilização do espectro.

Em cenários cuja localização dos transmissores e receptores é bem definida (chamados ponto-ponto), o critério utilizado determina que a eficiência é medida como a razão entre a

distância em que a informação é transmitida vezes a vazão alcançada e a utilização do espectro. Um usuário que contenha múltiplos enlaces de comunicação calcula sua eficiência de uso de forma agregada com o uso da seguinte expressão:

$$EUE = \frac{\sum_i D_i \cdot C_i}{\sum_i S_i \cdot B_i} \text{ [bps/km.MHz]}, \quad (1)$$

onde i representa cada enlace de comunicação de um usuário e D_i é a distância entre o transmissor e receptor daquele enlace.

Idealmente, o valor de C_i representa a quantidade de informação transmitida. Como esse valor não pode ser estimado *a priori*, pode-se utilizar o valor de capacidade do canal, que é representada através do limite teórico da equação:

$$C_i = B_i \log_2 \left(1 + \frac{P_i}{N_0 B_i} \right) \text{ [bps]}. \quad (2)$$

Por último, o valor de área deve considerar a área tanto do transmissor e receptor, descontando o valor de área que é comum a ambos. Para simplificação do cálculo das áreas, a Resolução [3] assume que a área referente tanto ao transmissor quanto receptor são círculos e que a área da interseção é a área da lente formada pela interseção. A equação de perda de propagação utilizada em [3] é a equação de transmissão de Friis, com dois componentes para compensar a atenuação de gases e para difração (segundo recomendações UIT-R P.676 e UIT-R P.526 da UIT). Os valores padrão dados pela resolução são utilizados para fins de cálculo da área nesse trabalho.

B. Modelo de otimização

O problema de otimização pode ser formalizado da seguinte forma: Sejam $\mathcal{I}$ e $\mathcal{S}$ o conjunto de usuários incumbentes e secundários, respectivamente. Cada usuário u possui um espaço de configurações possíveis $\mathcal{K}_u$ no qual cada elemento $k_i^{[u]} = \{p_i^{[u]}, f_i^{[u]}, b_i^{[u]}\}$ contém um valor de potência p , frequência central f e largura de banda b que juntos compõem uma configuração atribuída ao usuário, compartilhada entre todos os seus equipamentos de rádio, separados entre transmissores $\mathcal{T}_u$ e receptores $\mathcal{R}_u$. O conjunto $\mathcal{K}_u$ pode não ser idêntico entre usuários devido às capacidades de hardware distintas. Define-se a função de interferência $I_{t \rightarrow r}$ que calcula qual o valor de interferência que um transmissor t causa no receptor r . Essa função pode ser 0 caso não tenha interferência devido à escolha de configurações de frequência diferentes, por exemplo. Assume-se que os incumbentes já possuem uma configuração válida entre eles, portanto as variáveis de otimização se limitam apenas aos secundários $\mathcal{S}$. Assim, esse problema segue a equação:

$$\max_{x_{u,k}} \sum_{u \in \mathcal{S}} \sum_{k \in \mathcal{K}_u} x_{u,k} \cdot EUE(k_u) \quad (3)$$

$$\text{sujeito a: } \sum_{u \in \mathcal{S}} \sum_{t \in \mathcal{T}_u} \sum_{k \in \mathcal{K}_u} x_{u,k} \cdot I_{t \rightarrow r}^{(k)} \leq I_r^{\max} \quad \forall r \in \mathcal{R}_{\mathcal{I}} \quad (4)$$

$$\sum_{k \in \mathcal{K}_u} x_{u,k} = 1 \quad \forall u \in \mathcal{S} \quad (5)$$

$$x_{t,k} \in \{0,1\} \quad (6)$$




Fig. 1. Exemplo da representação em grafos do problema. Três usuários com três cores distintas são representados através dos enlaces de pertencimento (pontilhados). Os enlaces de interferência são desenhados em vermelho e ligam o transmissor de um usuário ao receptor de outro.

No problema, a função objetivo (3) calcula a EUE da rede para uma resposta, como definida pela equação (1). As variáveis de decisão binárias $x_{u,k}$ em (6) definem se a configuração k é atribuída ao usuário u . A restrição em (5) garante que apenas uma configuração de todo conjunto $\mathcal{K}_u$ é escolhida por usuário. A restrição (4) define que o somatório das interferências de todos os transmissores $k \in \mathcal{T}_u$ de todos os usuários secundários $u \in \mathcal{S}$ não pode ultrapassar o limiar de interferência do usuário incumbente r , essa restrição é válida para todos os receptores de todos os incumbentes $\mathcal{R}_{\mathcal{I}}$.

Para o problema proposto, os múltiplos usuários devem concentrar todas as informações necessárias de seus transmissores e receptores para a formulação dos problemas. Para isso, modelos de consumo de espectro (SCM) como o IEEE 1900.5.2 [6] podem ser utilizados para caracterizar o conjunto de usuários cuja configuração será otimizada. O padrão define listas de configurações possíveis para clientes e representa valores como largura de banda, potência e frequências centrais e limiares de interferência disponíveis para aquele dispositivo. Além disso, o SCM define posição geográfica e como o cálculo de perda de propagação deve ser feito. Essa definição serve para representar modelos de perda de propagação diversos ou até mesmo medidos experimentalmente. Assim, o SCM pode ser utilizado para construir uma representação do problema que serve como entrada válida para o otimizador GNN.

C. Representação do problema em grafos

Para limitar o escopo de atuação do otimizador, o problema proposto considera os usuários estáticos e mantém as condições geográficas constantes. Assim, todos os transmissores e receptores envolvidos nos cálculos de eficiência de uso têm posição fixa e todos os pares de transmissores e receptores entre usuários diferentes tem o total de perda de propagação calculado apenas uma vez por problema. Nessas condições, o problema pode ser representado através de um grafo.

Define-se um grafo $\mathcal{G}$ que representa esse problema como um conjunto de vértices $v_i \in \mathcal{V}$ e de enlaces $e_{ij} \in \mathcal{E}$ que fazem a conexão entre o vértice i e o vértice j . Um exemplo dessa representação pode ser visto na Figura 1. Um usuário pode ter múltiplos vértices associados a ele, um para cada transmissor e receptor que o usuário possui. Para representação das informações relevantes do usuário, dois tipos de enlaces são definidos: de pertencimento e de interferência.

Os enlaces de pertencimento criam diversos subgrafos que conectam os diversos transmissores e receptores de um único usuário (representados na figura 1 como cores diferentes). A direção do enlace determina quais vértices atuam como transmissores ou receptores. Assim, esses enlaces indicam quais vértices devem possuir a mesma configuração.

Os enlaces de interferência conectam todos os transmissores de um usuário aos receptores dos outros usuários. Cada enlace representa a existência de um potencial de interferência entre esse par transmissor/receptor. O enlace é construído entre os vértices se o valor de perda de propagação entre esse par é menor que um limiar. Esse limite deve ser definido de modo que, mesmo na maior potência de transmissão do cliente, a intensidade da interferência é suficientemente pequena para não ser relevante no cálculo de interferência.

IV. GNN PARA OTIMIZAÇÃO DE EUE

Dada a forma de representação do problema, a GNN é um tipo de rede conveniente para a busca de soluções [16]. As GNNs são utilizadas em diversos contextos, como análise de redes de relacionamento, estruturas de proteínas e grafos de conhecimento [18]. A GNN possui a vantagem de ser invariante a permutações que alterem a ordem em que os vértices e enlaces são tratados, facilitando o processamento.

A arquitetura de uma GNN é detalhada no trabalho [16]. A GNN é uma rede neural cujas entradas são vetores de atributos atribuídos aos vértices e enlaces de um grafo. A GNN utiliza redes do tipo *Multi-Layer Perceptron* para calcular um espaço latente por vértice e por enlace. As diversas camadas atualizam os valores das próximas camadas através de “mensagens”, que agregam a informação do espaço latente do vértice da origem, do destino e o espaço latente do próprio enlace. Todas as mensagens de enlaces que entram em um vértice são somadas e utilizadas para atualizar o espaço latente desse vértice. A GNN utilizada nesse trabalho é a estrutura básica com compartilhamento de pesos entre camadas. Devido a definição bipartida do grafo, dois tipos distintos de mensagens são calculadas com MLPs separadas e agregadas.

A. Entradas e saídas da GNN

A entrada da GNN segue a estrutura de grafo definida na Seção III-C. As entradas do problema são representadas pelos vetores de atributos dos vértices e dos enlaces.

O vetor de atributos dos vértices codifica a configuração de um transmissor utilizando um vetor binário em que 1 representa que a configuração é permitida e 0 representa que a configuração não é permitida para aquele transmissor. Há duas sequências binárias de configuração: uma que define as soluções possíveis e outra que define a solução atual. A solução atual é 1 na configuração escolhida e 0 em todo o resto. Três configurações podem ser selecionadas: frequência central, largura de banda e potência (f, b, p) . A Figura 2 ilustra como a configuração de um transmissor é representada dada uma lista de configurações possíveis.

Para os enlaces de interferência, há duas entradas normalizadas: a função de perda de propagação do canal e o excedente de interferência do receptor acima do valor imposto pela restrição. A perda de propagação pode ser calculada por qualquer função desejada (Friis, *log-distance*, *ray-tracing*) e é válido desde que as condições do problema não mudem. Já os enlaces de pertencimento não possuem informação adicional em seus vetores de atributos. O método de solução com a GNN é apresentado na Seção IV-C.




Fig. 2. Exemplo de configuração de usuário, representação do conjunto global de configurações possíveis, conjunto do usuário e a solução atual como vetores binários de entrada da GNN.

A saída da GNN é calculada para um transmissor de usuário secundário, e retorna uma sugestão de configuração de potência, largura de banda e frequência central.

B. Método de treinamento

O processo de treinamento é baseado em algoritmos genéticos, inspirado no trabalho de Such *et al.* [14]. Para o treinamento, as operações utilizadas são torneio para seleção, *Two Point Crossover* para recombinação e a concatenação de número aleatório para mutação (devido à representação do indivíduo). Um indivíduo é representado como uma lista de inteiros $[z_1, z_2, \dots, z_n]$. O modelo é calculado segundo $\sum_n \delta \cdot RNG(z_i)$, onde RNG é uma função geradora de números aleatórios, que recebe uma semente z_i e gera uma sequência aleatória de mesmo tamanho do modelo. O valor de δ é um hiperparâmetro definido antes do processo de treinamento.

C. Cálculo de aptidão

A aptidão mede o desempenho das soluções produzidas pelo otimizador. A GNN possui um comportamento iterativo, tal que a resposta atual insatisfatória pode ser realimentada na GNN para que ela ofereça uma nova solução. O ciclo de uso da GNN consiste na entrada dos parâmetros do problema, a verificação da resposta e a realimentação, caso a resposta atual viole ao menos uma restrição. Durante o treinamento, esse processo é limitado a até 10 tentativas. Caso uma solução viável não seja encontrada, um valor negativo de aptidão é retornado, proporcional ao excesso de interferência. Assim, se uma resposta é encontrada, o valor da aptidão é calculado como o valor da função objetivo menos o número de tentativas multiplicado por um fator de penalização.

1) *Geração de problemas sintéticos*: Devido à estrutura de grafo do problema, uma abordagem trivial de sorteio aleatório de vértices e enlaces pode ser utilizada para gerar problemas. Porém, nos problemas gerados os vértices e enlaces podem ter valores irreais para a geometria Euclidiana. Isso resulta em uma chance alta de encontrar problemas triviais ou impossíveis. Por isso, um método de geração de problemas é desenvolvido para gerar problemas verossímeis.




Fig. 3. Exemplo de problema sintético através da construção de mapa de ruído Perlin e posicionamento dos transmissores e receptores no espaço.

O método começa definindo um mapa no qual o ruído de Perlin [12] desenha um número fixo de regiões aleatórias. A essas regiões são atribuídos diferentes coeficientes γ para uso com a função de perda de propagação log-distância $p = p_0 - 10\gamma \log_{10}(d/d_0)$. Assim, ao posicionar de forma aleatória os transmissores e receptores dos usuários, a reta entre possíveis pares de interferência é traçada e a equação linear por partes é calculada com base no comprimento da reta contida em cada uma das regiões. O valor de p_0 é calculado com base na mesma equação de Friis. Um exemplo do mapa formado com usuários posicionados pode ser visto na Figura 3.

V. AVALIAÇÃO DE DESEMPENHO

A busca de soluções por GNN é comparada com outros dois algoritmos da literatura descritos na Seção V-A. Para comparar os otimizadores com a proposta deste artigo, são gerados 100 problemas com o método descrito na Seção IV-C.1. Avaliam-se a qualidade da resposta encontrada e o tempo de execução. Para avaliar a resposta dos métodos, são feitas estatísticas sobre os valores da função objetivo retornados para todos os 100 experimentos. A média é calculada tanto para todos os 100 problemas quanto para apenas aqueles para os quais uma solução viável foi encontrada (“compatíveis”). Para a comparação temporal, são medidos os tempos de execução dos algoritmos em um computador com processador Intel(R) Core(TM) i9-10900 com 16 GB de RAM e sem GPU.

A faixa utilizada para o teste do modelo vai de 3.700 a 3.800 MHz, dedicada ao serviço limitado privado pela Anatel. Nessa faixa há 10 canais de 10 MHz de banda cada. Um canal pode ser identificado através da frequência central definida como $f_c[n] = 3705 + 10n$ MHz. A potência máxima definida por canal é de 67 dBm/10 MHz. Considera-se que a potência de transmissão pode assumir sete valores: 30, 35, 40, 45, 50, 55 e 60 dBm/10 MHz.

A. Outros otimizadores utilizados

Dado o conjunto de valores finitos de potência, o problema torna-se puramente combinatório e pode ser resolvido através do método de otimização não linear DIRECT-L [9]. Esse algoritmo faz inúmeras divisões e buscas no espaço de soluções até que o resultado ótimo seja encontrado. Porém, com o aumento da escala do problema, o tempo de processamento aumenta substancialmente, e uma resposta pode não ser dada em tempo viável. Outra desvantagem é que, em cenários mais realistas onde a potência pode assumir valores reais, esse método já não pode mais ser utilizado.

Dois otimizadores baseados em métodos heurísticos e probabilísticos são utilizados para prover respostas que se aproximam do valor ótimo em um tempo menor: busca aleatória e

TABELA I
RESULTADOS DOS ALGORITMOS NO CONJUNTO DE PROBLEMAS EUE.

Algoritmo	Compat.(%)	Média	Mediana	Desvio	Mínimo	Máximo	Média (Compatíveis)
Busca aleatória	4%	-223,44	-382,62	912,34	-788,56	5307,93	4019,24
Algoritmos Genéticos	65%	4707,23	5117,50	4160,27	-396,24	15976,44	7321,10
GNN (Proposta)	97%	5213,45	253,14	7014,54	-137,37	25023,56	10230,05
DIRECT-L (Referência)	100%	20707,39	20013,85	8428,46	2039,53	52086,97	20707,39

algoritmos genéticos. A busca aleatória consiste no sorteio de soluções candidatas aleatórias e na verificação do resultado, tal que o melhor valor é salvo ao longo da execução. Já nos algoritmos genéticos, cada indivíduo representa uma possível resposta do problema, na forma de um vetor de configurações. Esse processo é mais eficiente na busca de soluções do que o método aleatório em diversos problemas [5], e portanto foi selecionado como algoritmo heurístico neste trabalho.

B. Resultados

O desempenho dos otimizadores está mostrado na Tabela I. Pode-se observar que a proposta se sobressai tanto no número de soluções possíveis encontradas como também no valor médio encontrado na função objetivo. A compatibilidade apresenta um salto de 32% na taxa de dados compatíveis comparado ao algoritmo genético. Ao observar a média dos valores encontrados compatíveis, o modelo apresenta um desempenho aproximadamente 40% superior ao algoritmo genético.

TABELA II
TEMPO DE EXECUÇÃO [S] DOS ALGORITMOS DIRECT-L E A SOLUÇÃO PROPOSTA, PARA $|Z| = 10$.

Método	$ S = 10$, $ E = 380$	$ S = 100$, $ E = 11990$
BnB	$2,187 \pm 0,145$	$24,308 \pm 6,132$
GNN	$0,087 \pm 0,093$	$0,148 \pm 0,172$

Já os tempos de execução estão na Tabela II. Esses resultados mostram o desempenho superior em tempo de resposta da GNN em todos os casos. Essa tabela também mostra que o tempo de execução do DIRECT-L tem um aumento considerável em relação ao número total de enlaces de comparação, o que não acontece no caso da GNN. Isso ocorre porque a quantidade de execuções é diretamente proporcional ao número de arestas e enlaces, que cresce em ritmo polinomial.

VI. CONCLUSÕES

Este trabalho investiga a otimização de eficiência de uso do espectro com o uso de modelos de GNNs. A função de eficiência de uso do espectro é definida segundo as resoluções vigentes da Anatel e o problema de otimização é modelado para adaptar um problema de alocação de recursos de rádio com múltiplos usuários e múltiplos transceptores por usuário. Observa-se que o modelo de IA se apresenta como uma forma de resolução heurística superior aos métodos tradicionais, mas mantém o título de heurística devido à limitação da reposta da ferramenta em comparação com o otimizador tradicional.

Nos trabalhos futuros serão investigados novos modelos de IA e métodos de treinamento que considerem variáveis inteiras ou reais, como o valor de potência. Além disso, variações do processo de alocação de recursos podem considerar a inserção

incremental de usuários e a acurácia da resposta desse modelo pode ser comparada com o processo de otimização global.

REFERÊNCIAS

- [1] Mohsin Ali, Muhammad Naveed Yasir, Dost Muhammad Saqib Bhatti, and Haewoon Nam. Optimization of Spectrum Utilization Efficiency in Cognitive Radio Networks. *IEEE Wireless Communications Letters*, 12(3):426–430, March 2023.
- [2] ANATEL. Ato nº 17985, de 31 de dezembro de 2024.
- [3] ANATEL. Resolução nº 548, de 8 de novembro de 2010.
- [4] ANATEL. Resolução nº 779, de 28 de abril de 2025.
- [5] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan. A fast and elitist multiobjective genetic algorithm: Nsga-ii. *IEEE Transactions on Evolutionary Computation*, 6(2):182–197, 2002.
- [6] DySPAN Standards Committee. Ieee 1900.5.2-2024: IEEE Standard for Method for Modeling Spectrum Consumption, June 2025.
- [7] Chibuiem Ezemaduka and Alhussein A. Abouzeid. Spec-GNN: Spectrum Enforcement Through Graph Neural Networks in Dynamic Spectrum Access Systems. *IEEE Transactions on Cognitive Communications and Networking*, 12:2590–2602, 2026.
- [8] Santiago Fernández, Romina García Camargo, Mark Eisen, Alejandro Ribeiro, and Federico Larroca. On the Transferability of Graph Neural Networks for Resource Allocation in Wireless Networks. In *2024 IEEE URUCON*, pages 1–5, November 2024.
- [9] J.M. Gablonsky and C.T. Kelley. A Locally-Biased form of the DIRECT Algorithm. *Journal of Global Optimization*, 21(1):27–37, September 2001.
- [10] Amandeep Kaur, Jaismin Thakur, Mukul Thakur, Krishan Kumar, Arun Prakash, and Rajeev Tripathi. Deep Recurrent Reinforcement Learning-Based Distributed Dynamic Spectrum Access in Multichannel Wireless Networks With Imperfect Feedback. *IEEE Transactions on Cognitive Communications and Networking*, 9(2):281–292, April 2023.
- [11] Suiyuan Peng, Ruoqi Liu, and Yanqiu Liu. Deep Learning-Based Graph Neural Networks for Large-Scale Wireless Network Topology Optimization and Dynamic Resource Allocation. In *2025 7th International Conference on Machine Learning, Big Data and Business Intelligence (MLBDBI)*, pages 209–212, October 2025.
- [12] Ken Perlin. An image synthesizer. In *Proceedings of the 12th Annual Conference on Computer Graphics and Interactive Techniques, SIGGRAPH '85*, page 287–296, New York, NY, USA, 1985. Association for Computing Machinery.
- [13] Hao Song, Lingjia Liu, Jonathan Ashdown, and Yang Yi. A Deep Reinforcement Learning Framework for Spectrum Management in Dynamic Spectrum Access. *IEEE Internet of Things Journal*, 8(14):11208–11218, July 2021.
- [14] Felipe Petroski Such, Vashisht Madhavan, Edoardo Conti, Joel Lehman, Kenneth O. Stanley, and Jeff Clune. Deep neuroevolution: Genetic algorithms are a competitive alternative for training deep neural networks for reinforcement learning, 2018.
- [15] União Internacional de Telecomunicações. Recommendation ITU-R SM.1046-3: Definition of spectrum use and efficiency of a radio system. *SM Series Spectrum management*, 2017.
- [16] Isaac Ronald Ward, Jack Joyner, Casey Lickfold, Yulan Guo, and Mohammed Bennamoun. A Practical Tutorial on Graph Neural Networks, December 2021.
- [17] Hongwei Zhang, Xinyu Da, Hang Hu, Lei Ni, and Yu Pan. Spectrum efficiency optimization for uav-based cognitive radio network. *Mathematical Problems in Engineering*, 2020(1):2497542, 2020.
- [18] Jie Zhou, Ganqu Cui, Shengding Hu, Zhengyan Zhang, Cheng Yang, Zhiyuan Liu, Lifeng Wang, Changcheng Li, and Maosong Sun. Graph Neural Networks: A Review of Methods and Applications, October 2021.