

MonitorIA – Radiomonitoragem do Serviço Móvel Pessoal por Crowdsensing

Guilherme A. Thomaz, João Pedro de S. Machado, Miguel Elias M. Campista e Marcello L. R. de Campos

Resumo— A radiomonitoragem envolve o mapeamento do uso das frequências, possibilitando, por exemplo, a desativação de estações clandestinas. O *crowdsensing* reduz o custo e aumenta a agilidade em comparação com os *drive tests*, mas as propostas atuais demandam alto uso de recursos dos celulares. Este artigo propõe o MonitorIA: um arcabouço que usa *smartphones* para mapear canais e identificar irregularidades por aprendizado de máquina. As contribuições incluem a avaliação de modelos de mapeamento de espectro em dados reais e o uso de métricas comparativas entre mapas para identificação de irregularidades. Os experimentos utilizam dados de diferentes aplicativos em modelos treinados com *ray tracing*, visando avaliar a capacidade de generalização. Os resultados indicam um erro de predição de potência até 30% menor do que o obtido com métodos estatísticos, usando menos de 4% das medidas. Ademais, a rede siamesa proposta identifica transmissões irregulares em diferentes posições, potências e frequências com acurácia acima de 92%.

Palavras-Chave— Crowdsensing, SMP, REM

Abstract— Radiomonitoring involves mapping frequency usage, enabling, for example, the deactivation of clandestine stations. *Crowdsensing* reduces costs and increases agility compared to *drive tests*, but current proposals demand high resource usage from mobile phones. This paper proposes MonitorIA: a framework that uses *smartphones* to map channels and identify irregularities through machine learning. The contributions include the evaluation of spectrum mapping models on real data and the use of comparative metrics between maps to identify irregularities. The experiments use data from different applications in models trained with *ray tracing*, aiming to evaluate the generalization capacity. The results indicate a power prediction error up to 30% lower than that obtained with statistical methods, using less than 4% of the measurements. Furthermore, the proposed Siamese network identifies irregular transmissions at different positions, powers, and frequencies with an accuracy above 92%.

Keywords— Crowdsensing, SMP, REM

Guilherme A. Thomaz, João Pedro de S. Machado, Miguel Elias M. Campista e Marcello L.R. de Campos, Programa de Engenharia Elétrica (PEE), Universidade Federal do Rio de Janeiro (UFRJ), Rio de Janeiro. E-mails: guiaraujo@gt.a.ufrj.br, joao.machado@smt.ufrj.br, miguel@gt.a.ufrj.br, campos@smt.ufrj.br.

Este trabalho contou com apoio técnico e fomento à pesquisa do Centro de Altos Estudos em Comunicações Digitais e Inovações Tecnológicas (Ceadi), da Agência Nacional de Telecomunicações (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”.

Este trabalho foi parcialmente financiado pelo Instituto Nacional de Ciência e Tecnologia (INCT) STREAM, com apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), processo no. 409179/2024-8, além dos projetos CNPq 310234/2025-5, 407304/2025-8, 408255/2023-4 e 405940/2022-0; Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) – Código de Financiamento 001 e 88887.954253/2024-00; FAPERJ E-26/200.438/2026 e E-26/210.778/2025; e da FAPESP 2023/00673-7 e 2023/00811-0.

I. INTRODUÇÃO

A gestão do espectro radioelétrico por agências reguladoras, como a Anatel no Brasil, garante o uso eficiente desse recurso escasso. Uma das atividades de gestão é a radiomonitoragem, que consiste no mapeamento do uso das faixas de frequência do espectro radioelétrico visando verificar se as transmissões ocorrem conforme as regulamentações vigentes e, quando necessário, identificar e desativar emissores não autorizados [1]. A importância dessa atividade aumentou nas últimas décadas graças à crescente dependência social e econômica das redes sem fio, que transformou o uso irregular do espectro em uma operação economicamente atrativa. Um exemplo é a operação de Estações Rádio-Base (ERBs) clandestinas em canais do Serviço Móvel Pessoal (SMP) para o disparo em massa de mensagens, impactando o acesso à Internet e o envio de alertas de emergência [2]. Como contramedida tradicional, equipes especializadas percorrem regiões de interesse (*Region of Interest* – ROI) em veículos equipados com instrumentos. Um grande volume de dados coletados permite a construção de Mapas de Ambiente de Rádio (*Radio Environment Map* – REM), que indicam a potência do sinal em cada canal e local no espaço. Entretanto, esses procedimentos de *drive-test* incorrem alto custo operacional e tempo de execução [1].

Com a ampliação do acesso da população aos *smartphones* com tecnologias móveis modernas, surge a oportunidade de distribuir o processo de coleta de dados espectrais entre os próprios usuários, por meio do *crowdsensing* [3]. Apesar dos esforços nessa direção, desafios relacionados à exigência de *hardware* complementar, à ausência de um formato padrão de dados, à falta de conformidade com regulamentos de privacidade e à demanda de recursos dos dispositivos limitam a escala das propostas existentes, tornando-as não aplicáveis às necessidades das agências reguladoras [3, 4, 5]. Pesquisas recentes avaliam o uso da Inteligência Artificial (IA) para construção de REMs a partir de conjuntos de dados (*datasets*) escassos [6, 7, 8, 9], mas há uma lacuna de trabalhos que avaliam o desempenho desses modelos com dados reais de *crowdsensing*, e, mais especificamente, com dados que consideram as particularidades do SMP no Brasil. Além disso, o uso do REM obtido por *crowdsourcing* para a detecção de transmissões irregulares (TXI) é ainda inexplorado na literatura.

Este trabalho propõe o MonitorIA, um arcabouço que combina *crowdsensing* e IA para mapeamento do uso do espectro do SMP. *Smartphones* Android dos usuários coletam uma pequena quantidade de amostras de potência em canais do SMP, reduzindo o consumo de bateria, processamento e rede.

Um modelo de Aprendizado de Máquina (*Machine Learning* – ML) utiliza os dados centralizados em nuvem para interpolar a potência em toda a região de interesse, construindo um REM a partir dessas amostras esparsas. Em seguida, o sistema avalia se há irregularidades no uso do espectro pela comparação desse REM com um REM de referência, construído por simulações computacionais com dados da operadora. Os dados coletados durante a pesquisa em ROIs na cidade do Rio de Janeiro com os aplicativos SigCap e G-NetTrack compõem uma base de dados para validar o modelo de interpolação [9]. As principais contribuições deste trabalho são:

- 1) a avaliação de modelos U-Net de interpolação de REM, treinados com dados de *ray tracing*, em dados reais de *crowdsensing* do SMP em 4G e 5G coletados pelos autores. Os resultados revelam um erro de predição de potência até 30% menor que o obtido com o tradicional método estatístico de Kriging a partir de menos de 4% das medidas;
- 2) a adoção de uma rede siamesa para diferenciação entre REMs e a comparação dessa abordagem com métricas analíticas. Após um treinamento com perda contrastiva, a rede aprende classificar a presença de irregularidades em diferentes posições, potências e frequências com acurácia superior a 92% em faixas inferiores a 10 GHz.

A Seção II explica as técnicas usadas nos trabalhos anteriores que serviram como base do MonitorIA. A Seção III detalha os processos de geração do *dataset*, mapeamento do espectro, identificação de TXI e cálculo de métricas. A Seção IV discute os resultados. Por fim, a Seção V conclui este trabalho e indica as direções futuras.

II. FUNDAMENTAÇÃO E TRABALHOS RELACIONADOS

Cada canal da rede celular, identificado pela ARFCN (*Absolute Radio-frequency Channel Number*), tem sua frequência de portadora e largura de banda (*bandwidth* – BW) [10]. No caso de TDD (*Time-Division Duplexing*), os canais de *uplink* e *downlink* se sobrepõem, enquanto no caso de FDD (*Frequency-Division Duplexing*), eles são separados. O processo de geração do REM de um canal divide uma ROI retangular em $N \times M$ blocos iguais para obter a potência de cada um deles. Formalmente, cada elemento $[i, j]$ de uma matriz de medidas esparsa $\mathbf{X}_{\text{med}} \in \mathbb{R}^{N \times M}$ revela a potência média medida no bloco $[i, j]$. Na ausência de medida, $\mathbf{X}_{\text{med}}[i, j] = 0$. Uma matriz binária de máscara $\mathbf{M} \in \mathbb{R}^{N \times M}$ vale 1 nos blocos com medidas. O modelo de geração de REM $\mathcal{G}$ estima uma matriz $\hat{\mathbf{X}} = \mathcal{G}(\mathbf{X}_{\text{med}}, \mathbf{M})$ usando as medidas $\mathbf{X}_{\text{med}}[i, j]$, onde $\mathbf{M}[i, j] = 1$. Apesar de trabalhos como o de Zeng *et al.*, que propõem o *crowdsensing* do espectro para acelerar a coleta de dados para identificação de anomalias no LTE, a dependência de *hardware* específico limita a escala de adoção [3]. O trabalho de Bastida avalia a qualidade do SMP usando aplicativos de celular, mas não coleta dados espectrais, tornando o mapeamento do espectro nestes canais uma lacuna de pesquisa [10].

A literatura implementa frequentemente o gerador de REM $\mathcal{G}$ com o método de Kriging. Todavia, a técnica assume estacionariedade na média, o que não ocorre devido à perda de




Fig. 1: Processos do MonitorIA, representados por retângulos numerados.

caminho (*Path Loss* – PL) do sinal em relação ao transmissor. Sato *et al.* treinam uma rede neural para estimar a PL e, em seguida, utilizam o Kriging para estimar a perda com média zero devido ao *shadowing* gerado por obstáculos [11]. Teganya *et al.* combinam dados gerados com um modelo de propagação (500 mil) com dados gerados por *ray tracing* (125 mil) para construir uma rede neural profunda com arquitetura *autoencoder*, baseada em redes neurais convolucionais (*Convolutional Neural Networks* – CNNs) [6]. Cada amostra $(\mathbf{X}, \mathbf{X}_{\text{med}}, \mathbf{M})$ é interpretada como 3 imagens 32×32 , e o objetivo é minimizar a Raiz do Erro Médio Quadrático (*Root Mean Squared Error* – RMSE) média entre os pontos de $\hat{\mathbf{X}}$ e $\mathbf{X}_{\text{med}}$. Locke *et al.* propõem modificações nas arquiteturas de *autoencoders* e U-Net, ambas baseadas em CNN, para geração de REMs [9]. Ainda assim, há um desafio aberto na literatura conhecido como Generalização Fora da Distribuição (*Out-of-Distribution* – OOD Generalization), no qual um modelo perde desempenho quando testado em dados novos, como os dados obtidos por *crowdsensing*.

Um processo de identificação de TXI compara o REM $\mathbf{X}_{\text{med}}$, construído com medidas em campo, com um REM de referência ($\mathbf{X}_{\text{ref}}$), simulado com dados detalhados da prestadora de serviços ou da agência reguladora. Essa comparação envolve o cálculo de uma métrica de discrepância $m(\mathbf{X}_{\text{med}}, \mathbf{X}_{\text{ref}})$ e a comparação com um limiar de decisão l . Katagiri *et al.* propõem um método para atualização dinâmica de REMs baseado no teste-*t* de Welch bloco a bloco sobre o mapa para inferir se o transmissor legítimo mudou de posição [12]. Zhen *et al.* atacam o mesmo problema combinando redes siamesas com mecanismos de atenção [13]. Infelizmente, os trabalhos de identificação de TXI se concentram mais na utilização de equipamentos de alto custo para análise de espectro e na execução de algoritmos computacionalmente custosos [3, 14].

O trabalho atual se diferencia dos anteriores ao investigar o uso de *crowdsensing* para o cenário brasileiro de radiomonitoragem do espectro do SMP. Outra contribuição é a avaliação do desempenho dos modelos de interpolação de REM treinados com dados de *ray tracing* quando testados com dados medidos em campo com aplicativos comerciais. Por fim, o trabalho




Fig. 2: Rede siamesa para comparação entre dois REMs. As camadas são representadas pelos retângulos coloridos, cujos detalhes são apresentados na legenda, à direita. A mesma rede é reutilizada para ambas as matrizes de entrada.

propõe a identificação de irregularidades pela diferenciação entre REMs, investigando métricas baseadas em RMSE e redes siamesas.

III. ARCABOUÇO MONITORIA

Esta seção descreve os processos do arcabouço proposto, resumidos na Figura 1.

A. Ambiente Real

O Processo (1) da Figura 1 envolve a coleta dos dados usando Android. Uma pesquisa dos autores identificou aplicativos de *smartphone* disponíveis no mercado com potencial de colaborar para o processo de radiomonitoragem. Os principais obstáculos encontrados foram: i) a indisponibilidade de recursos para IOS; ii) a falta de informações mais detalhadas na API do Android, como a largura de banda utilizada na transmissão, sendo necessário o uso da ARFCN para obter informações do canal; e iii) a inconsistência de formatos entre aplicativos, obrigando o desenvolvimento de programas para tradução. Os dois aplicativos escolhidos foram o SigCap e o G-NetTrack PRO, uma vez que são os únicos que oferecem dados de espectro em um formato que pode ser manipulado por *softwares* customizados.

O Processo (2) inclui a recepção dos dados exportados pelos aplicativos por um servidor Linux, no qual um programa em Python oferece estatísticas de ocupação do espectro. Em seguida, o servidor formata todos os dados em CSV (*Comma Separated Values*), armazenando em disco a potência em cada canal e em cada posição. Os processos seguintes são realizados para cada canal em cada ROI.

O Processo (3) transforma os dados contidos no CSV referentes a um determinado canal na ROI em matrizes $\mathbf{X}$ e $\mathbf{M}$, ambas 32×32 , que passam pelo modelo de geração de REM ($\mathcal{G}$). Os modelos avaliados neste artigo são: i) o algoritmo de Kriging; e ii) uma rede U-Net com *Skip Connections*, treinada em [9] com dados de ambientes *outdoor* simulados com *ray tracing*.

O Processo (4) calcula uma métrica de discrepância, que apresenta um valor significativamente maior quando há um transmissor irregular em campo ($\mathbf{X}_{med}$ e $\hat{\mathbf{X}}$) que não está previsto no mapa de referência ($\mathbf{X}_{ref}$). Caso a métrica supere um limiar, o processo alerta a possível presença de um TXI.

O Processo (5) testa o desempenho do modelo de geração de REM com os dados de *crowdsensing*. O erro total da interpolação dependeria do conhecimento da potência em

todos os blocos. Uma estratégia para contornar esse problema consiste em realizar a interpolação após a remoção de uma fração dos blocos conhecidos. Em seguida, é calculada a RMSE entre cada bloco removido e o seu valor calculado pela interpolação. Os experimentos reportam a média do RMSE entre estes blocos. A repetição do experimento múltiplas vezes para diferentes conjuntos de blocos removidos permite a estimação da incerteza de medição.

B. Ambiente Simulado

O Processo (6) usa o *software* fornecido em [6] gera a matriz de medições completa $\mathbf{X}$, usando *ray tracing*, e a matriz de máscara ($\mathbf{M}$), na qual uma fração aleatória de 5% dos 32×32 pontos valem 1 (simulando medições), enquanto os outros valem 0. Um segundo REM se diferencia do primeiro pela introdução de um TXI, gerando um *dataset* com mapas em diferentes frequências (f), valores de distância entre os transmissores (d_T) e diferença de potência entre o transmissor irregular e o regular (ΔP). Para cada configuração de parâmetros $p = (d_T, \Delta P, f)$, são gerados 20 pares de mapas (com e sem TXI), salvos como tensores em arquivos no formato *pickle*. Cada experimento em cada configuração é repetido 20 vezes para oferecer resultados com significância estatística.

O Processo (7) treina um modelo capaz de computar a métrica de discrepância m . Cada amostra é um par de imagens: um mapa de referência $\mathbf{X}_{ref}$ e um mapa interpolado $\hat{\mathbf{X}}$, a partir de $\mathbf{X}_{med}$, na mesma frequência. A classe é 1 se $\mathbf{X}_{med}$ inclui um TXI, e 0 caso contrário.

C. Métricas de Discrepância

Existem dois tipos de métrica de discrepância entre mapas propostos neste trabalho: analíticas e orientada a dados. A dependência do resultado de métricas analíticas de parâmetros como potência, frequência e distância entre transmissores regular e irregular dificulta o ajuste manual do limiar l . Já uma métrica orientada a dados é calculada pela saída de um modelo treinado para gerar valores próximos a 1 quando $\mathbf{X}_{med}$ tiver transmissor irregular e próximos a 0, caso contrário.

A Figura 2 apresenta uma rede siamesa para comparar dois REMs, interpretados como imagens 32×32 . Cada matriz passa por filtros convolucionais lineares, acompanhados de uma operação não linear (*Rectifier Linear Unit* – ReLU) e de redução de dimensionalidade (*pooling*). As camadas finais geram um vetor de *embeddings* $x \in \mathbb{R}^{64}$. A amostra j inclui os REMs a serem comparados e um rótulo binário y_j que

indica se eles são compatíveis (não há TXI). Sendo d_j a distância entre o par de vetores de *embeddings*, a função de perda contrastiva (*contrastive loss*) da amostra, $\mathcal{L}_j$, é d_j^2 se $y_j = 1$ e $-d_j^2$ se $y_j = 0$. Assim, a perda diminui quando a rede afasta imagens discrepantes e aproxima imagens similares. Na prática, é comum limitar a distância em $d_{max} = 1$ quando $y_j = 0$. O treinamento usa a descida do gradiente dos pesos na direção que minimiza a perda $\mathcal{L}$, utilizando o Adam com taxa de aprendizado 0,001. O *backpropagation* calcula o gradiente para cada *batch* de $N = 16$ amostras, em que a perda do *batch* é a média da perda de cada amostra: $\mathcal{L} = \left(\sum_{j=1}^N \mathcal{L}_j \right) / N$. Estratégias de regularização baseadas em normalização de *batch* e *dropout* evitam o *overfitting*.

O *dataset* gerado no Processo (6), contendo 220 amostras, é dividido em conjuntos de treino (80%) e validação (20%). Após 500 épocas de treinamento, a rede aprende a gerar valores elevados de d apenas quando o REM medido ($X_{med}[i,j]$) possui um transmissor irregular, ausente no REM de referência. Caso contrário, $d \approx 0$, de forma que a comparação com um limiar arbitrário ($l = 1$) permite obter uma inferência do rótulo $\tilde{y}$ de um par. A literatura em aprendizado profundo com imagens utiliza também a similaridade normalizada $S = \max(0, 1 - d)$, de forma que $d = 0 \implies S = 1$ e $d > 1 \implies S = 0$. As métricas de acurácia (A , taxa de acerto), precisão (P , taxa de positivos dentre as amostras classificadas como positivas), *recall* ou sensibilidade (R , taxa de positivos dentre as amostras com rótulo positivo) e *F1-score* ($F1 = 2 \cdot P \cdot R / (P + R)$) são avaliadas.

IV. EXPERIMENTOS E RESULTADOS

Os experimentos foram feitos em uma máquina virtual Debian 12 com 8 núcleos de CPU Xeon Gold 5416S, 32 GB de RAM e GPU NVIDIA A2. O processamento dos dados dos aplicativos SigCap e G-NetTrack e as técnicas de interpolação e discrepância entre os mapas foram programados em Python usando as bibliotecas Pandas, Kriging, Numpy e PyTorch. As implementações do simulador de propagação em mapas por *ray tracing* e da U-Net são reaproveitadas de [6] e [9]. O intervalo de confiança dos resultados é de 95%

A. REMs do Espectro SMP por Crowdsensing

O primeiro experimento avalia o erro das técnicas de interpolação por Kriging e U-Net nos dados obtidos por *crowdsensing* (Processo (5), Figura 1). A interpolação usa uma fração p dos pontos medidos, enquanto os outros pontos medidos são usados para calcular a RMSE média, $\epsilon_{med}(p)$. A Tabela I detalha a coleta em duas ROIs, bem como o canal selecionado em cada ROI para os experimentos. A Figura 3 ilustra a potência interpolada com todos os pontos medidos pelas cores amarela (valores maiores) e roxa (valores menores).

Os resultados na parte inferior da Tabela I indicam que a redução na fração de medidas utilizadas de $p = 25\%$ para $p = 5\%$ resulta em um aumento no erro. As medidas cobrem apenas 12,7% dos blocos. Assim, quando $p = 25\%$, são utilizados apenas $0,25 \cdot 0,127 \approx 4\%$ dos pontos do mapa. Nesse cenário, na ROI 1, a U-Net obteve um erro (0,64 dB)

TABELA I: Coletas com 1 dispositivo e RMSE média de interpolação com apenas 25% ou 5% dos pontos.

Dado	ROI 1 Outdoor (carro)	ROI 2 Indoor (a pé)
Tamanho da coleta	4896 amostras, 5h16min	989 amostras, 2h07min
Aplicativo	G-NetTrack	SigCap
Dimensões	3725m x 1362m	215m x 150m
ARFCN escolhido	635080 (5G TDD)	351 (4G FDD)
Freq. em MHz	3511,2	1955,1/2145,1
BW em MHz	900	60
Faixa de Potência	[-125,-66] dBm	[-136,-77]dBm
Blocos com medidas	12,7%	6,5%
$\epsilon_{med}(25\%)$ Kriging	0,094 $\pm$ 0,001dB	0,066 $\pm$ 0,001dB
$\epsilon_{med}(5\%)$ Kriging	0,136 $\pm$ 0,002dB	0,093 $\pm$ 0,002dB
$\epsilon_{med}(25\%)$ U-Net	0,064 $\pm$ 0,001dB	0,065 $\pm$ 0,001dB
$\epsilon_{med}(5\%)$ U-Net	0,116 $\pm$ 0,002dB	0,096 $\pm$ 0,002dB




Fig. 3: Potência interpolada nas ROIs 1 e 2 por Kriging. Os números indicam a potência média nos pontos medidos.

30% menor que o erro do Kriging (0,94 dBm). Entretanto, o erro da U-Net na ROI 2 empata com o do Kriging, por se tratar de um ambiente *indoor*. Esse resultado evidencia o desafio de generalização OOD, justificando a criação de *datasets* para treinamento que reflitam cenários heterogêneos.

B. Detecção de TXI por Discrepância entre REMs

O Experimento 2 compara as métricas de discrepância entre mapas propostas na Seção III-C: RMSE média em mdB = 10^{-3} dB (ϵ_{med}), distância entre *embeddings* (d) e similaridade normalizada entre *embeddings* (S), conforme o Processo (i) na Figura 1. A Tabela II apresenta, na sessão superior, a similaridade entre $\hat{\mathbf{X}}$, gerado pela interpolação com a U-Net em um ambiente sem TXI, e $\mathbf{X}_{ref}$. Assim, ϵ_{med} (primeira linha) é a RMSE introduzida apenas pela interpolação com a U-Net. O erro diminui com o aumento da frequência do canal (f) devido à maior atenuação da potência (PL). Para todo f , d (segunda linha) permanece próximo a 0 ou mesmo estatisticamente igual a 0, sugerindo que a rede siamesa corretamente aproxima REMs compatíveis. Analogamente, $S > 0,6$ (terceira linha), indicando alta similaridade entre $\hat{\mathbf{X}}$ e $\mathbf{X}_{ref}$.

A segunda sessão da Tabela II revela o efeito da introdução de um TXI a 50 m do transmissor regular e com a mesma potência. O valor de ϵ_{med} aumenta significativamente apenas para $f < 10$ GHz, de forma que, em altas frequências, a RMSE média não é uma boa métrica para revelar a presença de um TXI. Há ainda um segundo problema, relacionado à dificuldade de definição do limiar de classificação de TXI, l . Quando $l = 27$, muitos falsos negativos serão gerados em 2500 MHz, pois a RMSE na presença de TXI fica entre 24 e 34. Reduzindo para $l = 23$, por exemplo, apesar da sensibilidade para 2500 MHz aumentar, a precisão em 800 MHz será prejudicada. Em contrapartida, a introdução do TXI aumenta significativamente a métrica d e faz com que

$S \approx 0$, tornando as métricas orientadas a dados vantajosas em comparação com o mero cálculo analítico do erro.

Os resultados na terceira sessão da Tabela II se referem à classificação de TXI comparando d com $l = 1$. A acurácia em frequências menores, conforme indicado em **negrito**, é superior a 95%. Em 10 GHz, o TXI foi identificado em apenas 42% dos mapas. A potência nos pontos selecionados para interpolação é muito baixa nessa frequência, fazendo com que a U-Net interpole ruído. Assim, por melhor que seja o treinamento da rede siamesa, a sensibilidade do classificador é reduzida.

A redução do limiar para $l = 0,2$ (quarta sessão da Tabela II) elimina os falsos positivos em 10 GHz, mas reduz a precisão nessa frequência. Além disso, o desempenho de classificação nas bandas inferiores diminui, sugerindo que ajustes em l são insuficientes. Felizmente, canais nessa faixa não são utilizados pelos prestadores do SMP para cobertura em regiões amplas (centenas de metros) consideradas nos experimentos. Em bandas *mmWave*, por exemplo, um dispositivo que se afasta da ERB se conectará em outra ERB com maior potência. Assim, esses resultados revelam que o mapeamento do espectro nesses cenários requer o uso de REMs menores.

Enquanto os resultados anteriores consideram constantes os valores $d_T = 50$ m e $\Delta P = 0$ dB, a Tabela III resume o efeito da redução e do aumento de d_T e ΔP nas métricas de discrepância, mantendo fixos $f = 1500$ MHz e $l = 1$. A mudança na posição do TXI não influencia ϵ_{med} por se tratar de uma média da RMSE entre todos os pontos. Entretanto, os mapas se distanciam no espaço de *embeddings* à medida que os transmissores se afastam, revelando que a rede siamesa leva em consideração a posição relativa das medidas no mapa. O parâmetro d_T não influencia as métricas de classificação, de forma que a acurácia segue acima de 95%. A redução de ΔP para -6 dB representa uma potência do TXI quatro vezes menor, justificando a redução na RMSE média (ϵ_{med}). Nesse cenário, a irregularidade de transmissão se torna mais sutil, justificando a redução em d na saída da rede siamesa e da sensibilidade do modelo (87%). Em contrapartida, quando $\Delta P = 6$ dB, a potência do TXI é o quádruplo do transmissor regular, elevando as métricas de discrepância. Entretanto, um aumento da potência do TXI praticamente mascara o sinal do transmissor regular, resultando em uma precisão inferior (89%). Em ambos os casos, a acurácia se manteve em aproximadamente 92%, demonstrando que a robustez da estratégia proposta a diversos cenários de transmissão irregular.

V. CONCLUSÕES

Este trabalho desenvolve o MonitorIA para radiomonitoragem do serviço móvel pessoal por *crowdsensing*. Um modelo treinado com dados sintéticos mapeia a potência em blocos geográficos a partir de dados coletados por aplicativos em menos de 4% dos blocos com erro inferior a 0,120 dB. Outra contribuição é a classificação de transmissor irregular com o uso de redes siamesas, ultrapassando 92% de acurácia. Os trabalhos futuros incluem: i) quantificar o uso de recursos dos *smartphones*; ii) expandir a diversidade do conjunto de dados, incluindo ambientes *indoor* e faixas *mmWave*; e iii) realizar experimentos em campo em *testbed* controlado.

TABELA II: Influência de f na discrepância entre mapas e na classificação de TXI com limiar l .

Situação	Métrica	800 MHz	1500 MHz	2500 MHz	10000 MHz
Sem TXI	ϵ_{med}	25 ± 3	22 ± 2	18 ± 3	13 ± 2
	d	$0,5 \pm 0,4$	$0,2 \pm 0,4$	$0,6 \pm 0,2$	$0,2 \pm 0,2$
	S	$0,8 \pm 0,2$	$0,9 \pm 0,2$	$0,7 \pm 0,1$	$0,9 \pm 0,1$
Com TXI $d_T = 50$ m $\Delta P = 0$ dB	ϵ_{med}	57 ± 8	43 ± 5	29 ± 5	13 ± 2
	d	$7,5 \pm 2,1$	$6,1 \pm 1,9$	$4,5 \pm 1,8$	$1,1 \pm 0,9$
	S	$0,0 \pm 0,0$	$0,0 \pm 0,0$	$0,0 \pm 0,0$	$0,5 \pm 0,4$
Clas. $l = 1$	A	0,96	0,96	0,99	0,71
	P	0,93	0,92	1,00	0,92
	R	1,00	1,00	0,98	0,42
	$F1$	0,96	0,96	0,99	0,60
Clas. $l = 0,2$	A	0,61	0,85	0,51	0,70
	P	0,76	0,76	0,51	0,5
	R	1,00	1,00	1,00	1,00
	$F1$	0,86	0,87	0,67	0,67

TABELA III: Resumo das métricas de discrepância e classificação em função de d_T e ΔP ($l = 1$ e $f = 1500$ MHz).

Métrica	Fixo: $\Delta P = 0$ dB		Fixo: $d_T = 50$ m	
	0 m	100 m	-6 dB	6 dBm
ϵ_{med}	40 ± 3	40 ± 3	31 ± 3	70 ± 4
d	$5,5 \pm 2,6$	$7,5 \pm 2,6$	$3,6 \pm 2,0$	$9,7 \pm 1,8$
P	0,92	0,93	0,97	0,89
R	0,99	1,00	0,87	1,00

REFERÊNCIAS

- [1] International Telecommunications Union, *HANDBOOK National Spectrum Management*. Geneva: ITU, 2015.
- [2] Agência Nacional de Telecomunicações (Anatel), “Anatel desarticula estação clandestina de “ERB Fake” em São Paulo,” Mar. 2026.
- [3] Y. Zeng, B. Liu, Y. Li, D. Giustiniano, and S. Banerjee, “Sustainable Spectrum Crowdsensing,” *IEEE Transactions on Networking*, vol. 34, pp. 2954–2965, 2026.
- [4] E. Testi and A. Giorgetti, “Wireless network analytics for the new era of spectrum patrolling and monitoring,” *IEEE Wireless Communications*, vol. 31, pp. 230–236, Aug. 2024.
- [5] A. Ivanov, K. Tonchev, V. Poulkov, and A. Manolova, “Deep Learning for Reduced Sampling Spatial 3-D REM Reconstruction,” *IEEE Open Journal of the Communications Society*, vol. 5, pp. 1–12, 2024.
- [6] Y. Teganya and D. Romero, “Deep Completion Autoencoders for Radio Map Estimation,” *IEEE Transactions on Wireless Communications*, vol. 21, pp. 1710–1724, Mar. 2022.
- [7] A. Chaves-Villota and C. A. Viteri-Mera, “DeepREM: Deep-Learning-Based Radio Environment Map Estimation From Sparse Measurements,” *IEEE Access*, vol. 11, pp. 48697–48714, 2023.
- [8] B. K. Chowdappa and C. Botella, “Distributed Radio Map Reconstruction for 5G Automotive,” in *2018 IEEE Wireless Communications and Networking Conference (WCNC)*, Apr. 2018.
- [9] W. Locke, N. Lohmachev, Y. Huang, and X. Li, “Radio Map Estimation with Deep Dual Path Autoencoders and Skip Connection Learning,” in *2023 IEEE 34th Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC)*, pp. 1–6, Sept. 2023.
- [10] R. C. Bastida, “MEDIÇÃO DE DESEMPENHO DE SMP UTILIZANDO FUNÇÕES DO ANDROID,” trabalho de conclusão de curso, Universidade Federal do Espírito Santo (UFES).
- [11] K. Sato, K. Inage, and T. Fujii, “On the Performance of Neural Network Residual Kriging in Radio Environment Mapping,” *IEEE Access*, vol. 7, pp. 94557–94568, 2019.
- [12] K. Katagiri, K. Sato, K. Inage, and T. Fujii, “Dynamic Radio Map Using Statistical Hypothesis Testing,” *IEEE Transactions on Cognitive Communications and Networking*, vol. 7, pp. 752–766, Sept. 2021.
- [13] P. Zhen, B. Zhang, C. Xie, and D. Guo, “A radio environment map updating mechanism based on an attention mechanism and siamese neural networks,” *Sensors*, vol. 22, no. 18, 2022.
- [14] H. Kim, J. Kim, Y. Ji, and B. Kim, “Anomaly Detection for Wireless Cellular Communication Based on Synthetic Anomaly,” *IEEE Access*, vol. 13, pp. 112720–112730, 2025.