

Metaheurísticas na Otimização de Modelos para Predição da Cobertura Celular

**Gustavo José da Silva Castro¹, Victor F. Mota¹,
Marconi Arruda Pereira¹, Carolina Ribeiro Xavier¹**

¹Programa de Pós Graduação em Ciência da Computação –
Universidade Federal de São João del-Rei (UFSJ)
CEP 36.301-360 – São João del-Rei – MG – Brasil.

gustavojdscastro@gmail.com, vitorfmota@outlook.com

{carolinaxavier, marconi}@ufsj.edu.br

Abstract. Cellular connectivity relies on the presence of transmission towers, whose location influences signal quality. To assist in determining these locations, models are developed to estimate signal coverage. The accuracy of these predictions depends on the proper selection of model parameters.

This study employs metaheuristics to adjust the parameters of a signal prediction model, comparing Genetic Algorithms (GA) and Differential Evolution (DE). The model was implemented in Python, followed by parameter calibration. The experiments demonstrated that both techniques contributed to reducing the error in cellular coverage prediction.

Resumo. A conectividade por meio da telefonia celular depende da presença de torres de transmissão, cuja localização influencia a qualidade do sinal. Para auxiliar na definição desses locais, são desenvolvidos modelos que estimam a cobertura do sinal. A precisão dessas previsões está relacionada à escolha adequada dos parâmetros do modelo.

Este estudo usa metaheurísticas para ajustar os parâmetros de um modelo de predição de sinal, comparando os Algoritmos Genéticos (AG) e a Evolução Diferencial (ED). A implementação do modelo foi realizada em Python, seguida da calibração dos parâmetros. Os experimentos mostraram que ambas as técnicas contribuíram para a redução do erro na predição da cobertura celular.

1. Introdução

Nos dias de hoje, a conectividade tem um papel importante no desenvolvimento econômico e social. O acesso a tecnologias de comunicação, como internet, sinal celular e televisão, é necessário para a inclusão digital e a melhoria da qualidade de vida das populações [do Amaral and Bohadana 2008].

No entanto, oferecer cobertura eficiente em países extensos e com geografia variada pode ser desafiador. Modelos de predição de cobertura celular ajudam a lidar com essas dificuldades, mas sua precisão depende da configuração adequada dos parâmetros.

Parâmetros mal ajustados podem levar a previsões imprecisas, resultando em áreas sem cobertura ou superposição excessiva de sinais. Para melhorar a precisão das previsões, técnicas metaheurísticas, como Algoritmos Genéticos [Holland 1992] e Evolução Diferencial [Price 2013], vêm sendo aplicadas na otimização desses modelos.

Este trabalho busca otimizar os parâmetros do modelo de predição de cobertura celular proposto em [Mota 2024] utilizando metaheurísticas. Garantindo que o modelo forneça estimativas mais confiáveis de acordo com a localização das torres de transmissão.

2. Modelo de Predição de Cobertura Celular

Os modelos de predição de cobertura celular são utilizados no planejamento e na otimização de redes de telecomunicações. Eles permitem estimar a qualidade do sinal em diferentes áreas, considerando fatores como potência de transmissão, características do ambiente (como edificações, vegetação e outros obstáculos) e a topografia do terreno.

2.1. Modelo de Predição Utilizado

A otimização neste trabalho é aplicada ao modelo de predição proposto em [Mota 2024], no qual o nível de sinal recebido, RX_{MP} , é calculado conforme a Equação 1. As variáveis utilizadas no modelo estão listadas na Tabela 1.

O ajuste do modelo envolve quatro parâmetros: VA (Análise de Visibilidade), que indica se há linha de visada direta entre a Estação Rádio Base (ERB) e o terminal móvel; DP (Densidade Populacional), ajustado conforme o tipo de área urbana; K , uma constante que representa a intensidade do sinal em setores específicos, conforme o diagrama de irradiação da antena; e M , uma margem de calibração do modelo. Como a constante K não foi considerada na implementação, seu valor foi fixado em 1.

$$RX_{MP} = (P_{TX} - L_{TX}) * VA - (DP * L_{EL}(freq, dist) * K) - M, \\ L_{EL}(freq, dist) = 32,4 + 20 * \log_{10}\left(\frac{dist}{1000}\right) + 20 * \log_{10}(freq) \quad (1)$$

Variável	Descrição
RX_{MP}	Nível de sinal recebido.
P_{TX}	Potência de transmissão de acordo com a ERB.
L_{TX}	Perdas totais do sinal conforme as características da instalação dos equipamentos.
VA	Análise de Visibilidade da ERB. Valor varia entre 0 e 1.
DP	Densidade Populacional. Valor varia entre 1 e 2.
L_{EL}	Aplicação da fórmula da equação da perda no Espaço Livre.
$freq$	Frequência de operação da ERB.
$dist$	Distância do ponto/pixel da ERB.
K	Constante que identifica se a região está no setor com maior intensidade de sinal.
M	Margem de calibração do Modelo. Valor varia entre 0 e 40.

Tabela 1. Descrição das Variáveis do Modelo de Predição

2.2. Medições de sinal em campo

Para otimizar o modelo, é importante contar com referências confiáveis para comparação. Por isso, foram utilizadas medições de sinal da rede 4G da operadora TIM, coletadas em [Mota 2024], na cidade de São João del Rei - MG. Esses dados serviram como base para validar as estimativas do modelo.

A Figura 1 apresenta a distribuição dos níveis de sinal coletado em cada ponto, utilizando o software QGIS [Moyroud and Portet 2018]. A coleta foi realizada em um trajeto percorrido de carro com o auxílio do aplicativo G-NET-TRACK. Os níveis de sinal são representados em cores, onde sinais mais fortes (acima de -70 dBm) aparecem em vermelho, enquanto sinais mais fracos (abaixo de -130 dBm) tendem para o azul escuro ou preto, indicando ausência de sinal.

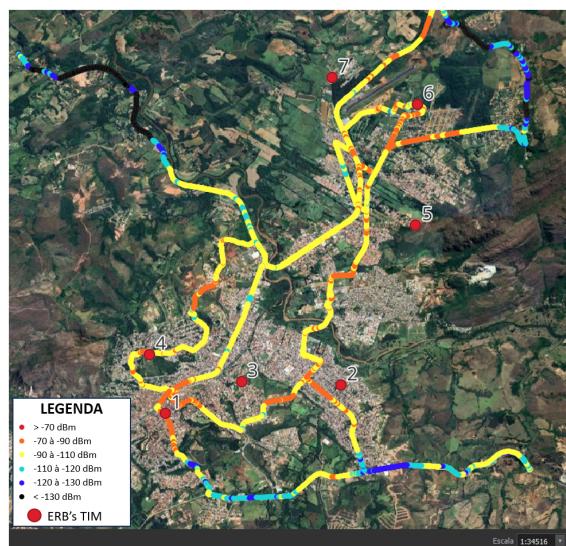


Figura 1. Mapa com intensidade de sinal coletado em campo. FONTE: [Mota 2024]

As características das amostras coletadas estão ilustradas na Figura 2. Em relação à distância, a maioria das medições foi feita a mais de 1 km das ERBs. Quanto à visibilidade, grande parte das amostras apresentava linha de visada direta com a ERB. Já na densidade populacional, as medições se concentraram em duas faixas: áreas com menos de 300 hab./km² e regiões com população entre 300 e 3.000 hab./km².

data coleta	# amostras	distância		visibilidade		densidade populacional			
		< 1km	> 1km	0	1	<300	300 à 3000	3000 à 10000	>10000
22/08/2023	1.608	868	740	1	1.607	298	745	460	105
28/05/2024	3.213	820	2.393	1.083	2.130	1.724	934	444	111
TOTAL	4.821	1.688	3.133	1.084	3.737	2.022	1.679	904	216

Figura 2. Caracterização das amostras de sinal coletado em campo. FONTE: [Mota 2024]

3. Metodologia

3.1. Metaheurísticas

Duas metaheurísticas foram selecionadas para otimizar os parâmetros do modelo de predição de cobertura celular. Para isso, foi necessário implementá-las e testar diferentes configurações de parâmetros, a fim de identificar o melhor conjunto para a otimização. O processo de teste consistiu na combinação de diferentes valores de parâmetros, gerando múltiplos conjuntos de teste, cada um executado 10 vezes para garantir a confiabilidade dos resultados. Além disso, o conjunto de parâmetros escolhido foi executado 100 vezes para garantir que temos um resultado final robusto.

A implementação foi feita em Python, com foco na eficiência, devido ao alto custo computacional da avaliação dos indivíduos no modelo preditivo. Para reduzir esse impacto, foi adotado o uso de multiprocessamento por meio da biblioteca *concurrent.futures*, permitindo a execução simultânea de várias avaliações e melhorando o tempo de processamento.

3.1.1. Algoritmo Genético

Os Algoritmos Genéticos são metaheurísticas baseadas em população para busca e otimização estocástica, inspiradas nos princípios da evolução e seleção natural [Cavalcante 2010].

Os indivíduos da população representam possíveis soluções para o Modelo de Predição. Cada um é definido como um dicionário contendo sete parâmetros com valores percentuais, correspondentes aos componentes do modelo preditivo: 'va_0', 'va_1', 'dp_1', 'dp_2', 'dp_3' e 'dp_4', cujos valores variam no intervalo [0, 1], e 'm_', que assume valores entre [0, 40]. Além disso, cada indivíduo possui um *fitness*, representado pelo erro da predição calculado pelo modelo.

3.1.2. Evolução Diferencial

Proposto em [Storn and Price 1997], o algoritmo foi desenvolvido com o objetivo de alcançar resultados superiores por meio de uma abordagem diferente dos Algoritmos Genéticos e das Estratégias de Evolução. Trata-se de uma técnica estocástica de busca direta que utiliza diferenças entre vetores para modificar os indivíduos da população, resultando em um algoritmo robusto, de rápida convergência, fácil de implementar e com poucas variáveis de controle [Oliveira et al. 2006].

Os vetores (indivíduos) são armazenados em um dicionário que contém uma lista de coordenadas, onde cada coordenada representa um dos parâmetros do Modelo de Predição com valores percentuais. Além disso, cada indivíduo possui um valor de *fitness*, que corresponde ao erro da predição calculado pelo modelo.

3.2. Implementação do Modelo

O modelo de predição foi implementado em Python, utilizando a biblioteca Rasterio [Gillies 2019], que oferece ferramentas para manipulação de dados *raster*. A implementação seguiu uma nova abordagem [da Silva Castro 2025], na qual o sinal medido é representado e utilizado por área (*raster*), diferindo do método empregado em [Mota 2024], que utiliza o sinal medido em pontos.

Essa diferença pode ser observada na Figura 3, onde, à esquerda, a medição é realizada por pontos, totalizando 4.821 pontos, enquanto, à direita, é feita por áreas, resultando em 2.264 *pixels*, cada um representando uma região de 30x30 metros. A redução no número de pontos ocorre porque vários pontos são agrupados dentro de um único *pixel*.

Dada a nova abordagem, a precisão da predição passa a possuir uma diferença quando são usados os valores dos parâmetros da dissertação [Mota 2024] e do artigo

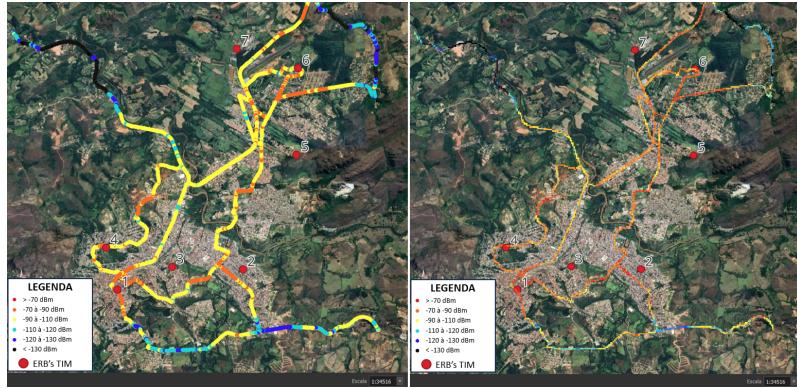


Figura 3. Comparação entre a medição do sinal por pontos(à esquerda) e por área(à direita). Fonte: Elaborado pelo autor (baseado em [da Silva Castro 2025])

[Mota et al. 2023]. Os parâmetros de cada trabalho e seus respectivos erros na abordagem de predição por ponto são apresentados na Tabela 2.

	Artigo	Dissertação
VA_0	0,700	0,237
VA_1	0,850	0,616
DP_1	1,060	1,357
DP_2	1,260	1,364
DP_3	1,360	1,463
DP_4	1,420	1,655
M	20,0	6,798
Erro por Pontos	40,44	20,08
Erro por Área	37,11	25,63

Tabela 2. Parâmetros adquiridos em trabalhos passados e seu erro em cada abordagem de predição. Fonte: [Mota 2024]

Antes de executar o modelo, é necessário garantir que os *rasters* utilizados na análise — como visibilidade, densidade populacional, distância até a ERB e medições do sinal real — tenham o mesmo tamanho e referência geoespacial, ou seja, compartilhem o mesmo SRC (Sistema de Referência de Coordenadas). Para isso, a função `reproject()` da biblioteca Rasterio foi utilizada. Esses *rasters* foram originalmente criados em [Mota 2024] e reutilizados neste estudo.

O modelo recebe os *rasters* ajustados, um indivíduo contendo os parâmetros do modelo e uma porcentagem de penalidade associada às regras violadas, que será incorporada ao resultado da predição. Em seguida, define-se a frequência de operação e a potência de transmissão da ERB, cria-se uma matriz para armazenar os valores previstos e, para cada *pixel* nos *rasters* (representando uma posição na matriz), aplica-se a equação 1. O valor correspondente na matriz é então atualizado com o resultado da equação.

Após o processamento de todos os *pixels*, o modelo calcula a raiz do erro quadrático médio (RMSE) da predição, comparando os valores estimados com as medições reais do sinal. Por fim, retorna o erro final com a penalidade incorporada.

4. Resultados e Discussões

Nesta seção, são apresentados os resultados obtidos a partir da otimização dos parâmetros do modelo de predição de cobertura celular utilizando o Algoritmo Genético e a Evolução Diferencial. Para cada abordagem, são exibidos os melhores parâmetros encontrados, bem como a predição da cobertura celular gerada com esses valores. A análise desses resultados permite comparar o desempenho das metaheurísticas e avaliar a precisão das previsões geradas pelo modelo.

A melhor solução encontrada pelo Algoritmo Genético é apresentada na Tabela 3. Com esses valores, foi gerada a predição da cobertura celular para a cidade de São João del Rei, ilustrada na Figura 4.

VA_0	VA_1	DP_1	DP_2	DP_3	DP_4	M	<i>Fitness</i>
0,049	0,418	1,099	1,130	1,174	1,273	23,183	24,306

Tabela 3. Parâmetros do modelo de predição e *Fitness* obtidos na melhor execução do AG.

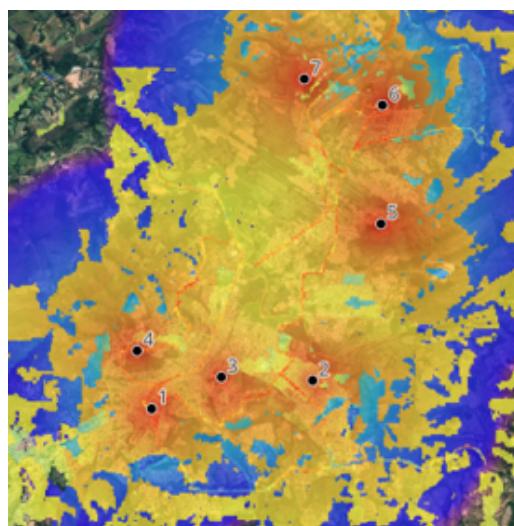


Figura 4. Predição da cobertura celular gerada pela melhor solução obtida com o AG. Fonte: Elaborado pelo autor (baseado em [da Silva Castro 2025])

Da mesma forma, a melhor solução encontrada pelo algoritmo de Evolução Diferencial é apresentada na Tabela 4. A predição correspondente da cobertura celular para São João del Rei pode ser observada na Figura 5.

VA_0	VA_1	DP_1	DP_2	DP_3	DP_4	M	<i>Fitness</i>
0,054	0,338	1,049	1,059	1,090	1,300	25,113	24,112

Tabela 4. Melhores Parâmetros do modelo de predição e *Fitness* obtidos na otimização com o ED.

4.1. Análise Comparativa dos Resultados Obtidos

Os testes realizados para ajuste dos parâmetros dos algoritmos de otimização e as execuções finais resultaram em soluções para o modelo, que serão analisadas em conjunto com aquelas obtidas em trabalhos anteriores, cujos parâmetros estão apresentados

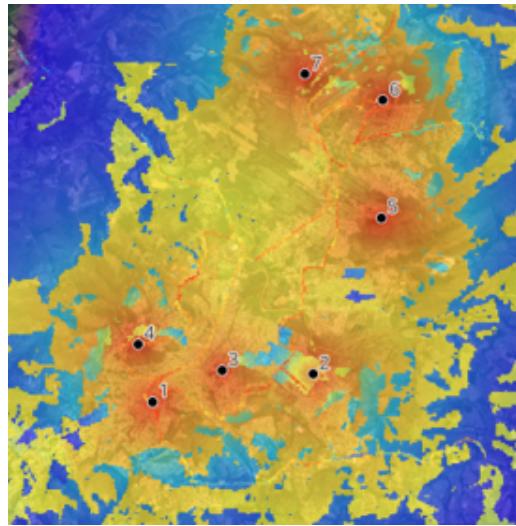


Figura 5. Predição da cobertura celular gerada pela melhor solução obtida com o ED. Fonte: Elaborado pelo autor (baseado em [da Silva Castro 2025])

na Tabela 5. Com base nessas soluções, foi possível comparar visualmente as previsões de cobertura para a cidade de São João del Rei, conforme ilustrado na Figura 6.

A análise dessa comparação indica que o modelo otimizado pelo ED apresentou maior precisão em regiões próximas às ERBs, em um raio de até 3000 metros. Em contrapartida, as previsões obtidas pelo AG e pelo modelo em [Mota 2024] mostraram melhor desempenho na estimativa do sinal em distâncias superiores a 3000 metros. Além disso, verificou-se que o modelo otimizado pelo ED tendeu a indicar cobertura, ainda que de forma fraca, em áreas onde não há sinal.

	Artigo	Dissertação	AG	ED
VA_0	0,700	0,237	0,049	0,054
VA_1	0,850	0,616	0,418	0,338
DP_1	1,060	1,357	1,099	1,049
DP_2	1,260	1,364	1,130	1,059
DP_3	1,360	1,463	1,174	1,090
DP_4	1,420	1,655	1,273	1,300
M	20,0	6,798	23,183	25,113
RMSE	37,110	25,630	24,306	24,112

Tabela 5. Parâmetros e RMSE adquiridos em trabalhos passados e pelos algoritmos de otimização. Fonte: Elaborado pelo autor (baseado em [da Silva Castro 2025]) e [Mota 2024]

Também é possível avaliar o desempenho do modelo conforme a visibilidade da ERB, a densidade populacional e a distância. A Figura 7 apresenta essa análise, onde o RMSE das soluções é representado por pontos, enquanto as faixas de visibilidade são indicadas por duas barras distintas. Além disso, o tamanho das barras corresponde à quantidade de *pixels* em cada faixa de visibilidade. Nota-se que o RMSE melhora à medida que a quantidade de *pixels* aumenta e que as soluções otimizadas se aproximam dos trabalhos anteriores na faixa sem visibilidade, superando-os na faixa com visibilidade.

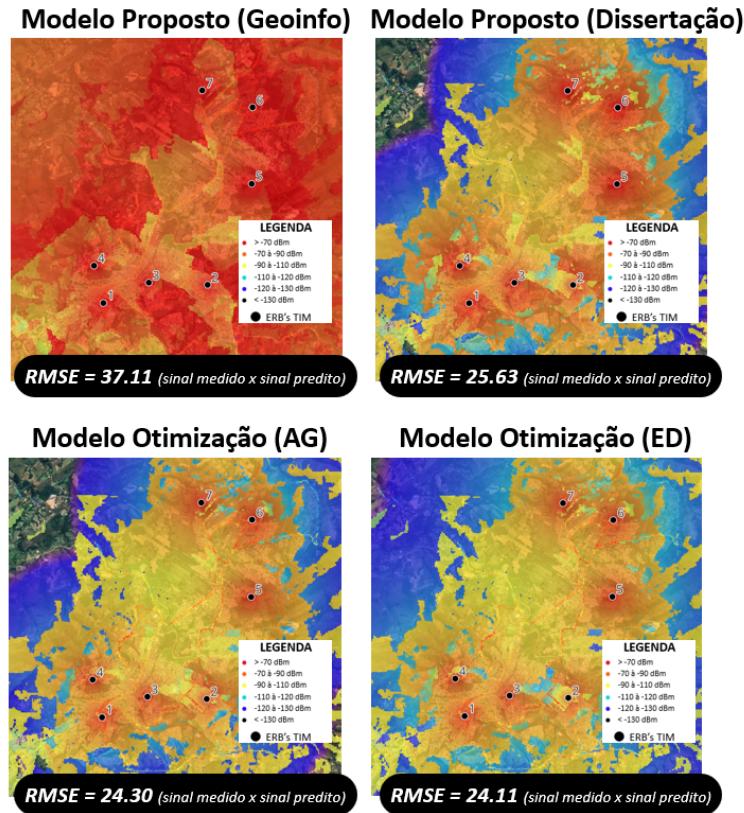


Figura 6. Comparação da cobertura de sinal na cidade de São João del Rei, predita com os parâmetros obtidos nos diferentes trabalhos. Fonte: Elaborado pelo autor (baseado em [da Silva Castro 2025])

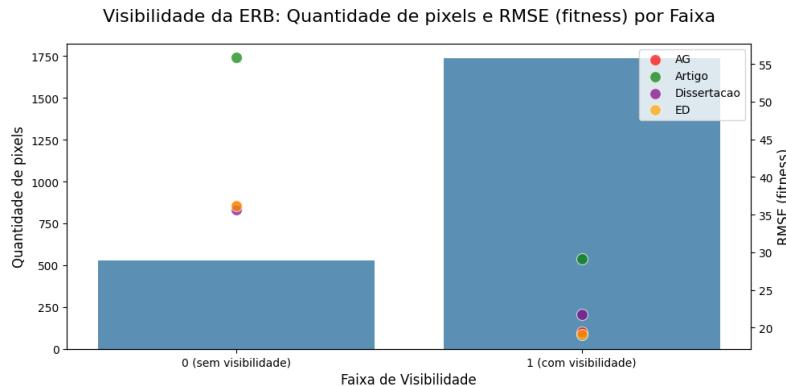


Figura 7. Análise do RMSE das soluções em relação à quantidade de *pixels* por faixa de visibilidade da ERB. Fonte: Elaborado pelo autor (baseado em [da Silva Castro 2025])

A Figura 8 exibe o RMSE das soluções em relação à densidade populacional e à quantidade de *pixels* por faixa, seguindo o mesmo padrão da Figura 7 com mais barras devido ao maior número de faixas. Os algoritmos de otimização superaram os trabalhos anteriores em todas as faixas, exceto naquelas com mais de 10.000 hab./km², onde o ED teve o pior desempenho. Diferente da análise de visibilidade, não há uma relação direta entre o número de *pixels* e o RMSE.

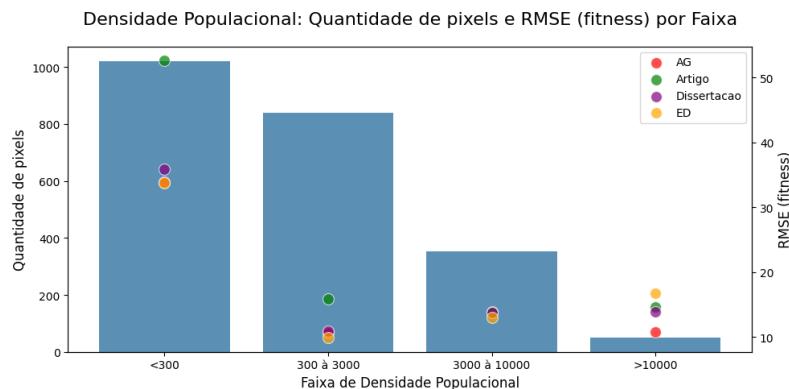


Figura 8. Análise do RMSE das soluções em relação à quantidade de *pixels* por faixa de densidade populacional. Fonte: Elaborado pelo autor (baseado em [da Silva Castro 2025])

A Figura 9 apresenta o RMSE das soluções em relação à distância da ERB e à quantidade de *pixels* por faixa, seguindo o mesmo padrão da Figura 7 com mais barras devido ao maior número de faixas. No geral, os algoritmos de otimização obtiveram resultados semelhantes à dissertação, exceto na faixa abaixo de 500 metros, onde AG e ED tiveram melhor desempenho. Além disso, as soluções seguem a mesma tendência das demais ao longo das faixas de distância.

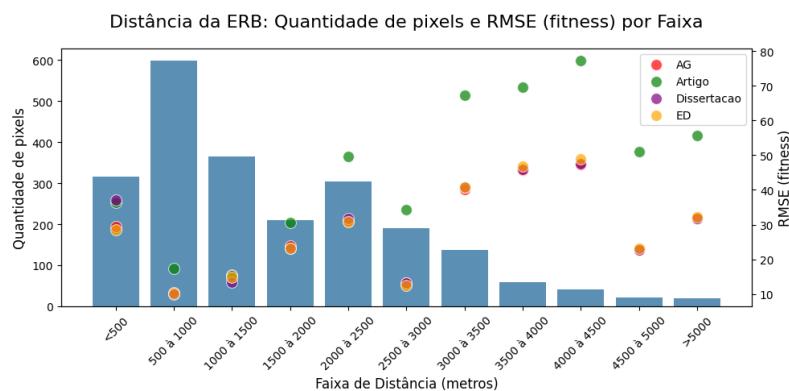


Figura 9. Análise do RMSE das soluções em relação à quantidade de *pixels* por faixa de distância da ERB. Fonte: Elaborado pelo autor (baseado em [da Silva Castro 2025])

Dessa forma, os algoritmos AG e ED demonstraram eficiência na otimização dos parâmetros do modelo de predição.

5. Conclusão

Este estudo explorou a utilização de Algoritmos Genéticos e Evolução Diferencial para otimizar os parâmetros de modelos de predição de cobertura celular. Através de uma abordagem experimental, diferentes configurações dos algoritmos foram testadas e comparadas, focando na redução do erro de predição.

Os resultados mostraram que ambas as técnicas melhoraram a precisão do modelo em comparação com estudos anteriores. O modelo otimizado pelo ED foi mais preciso

em áreas próximas às ERBs (até 3000 metros), enquanto o AG obteve melhor desempenho em distâncias maiores. Em relação à densidade populacional, o ED obteve melhores resultados nas faixas abaixo de 10.000 hab/km², enquanto o AG foi superior nas faixas acima desse limite. Quanto à visibilidade, os algoritmos apresentaram desempenhos semelhantes na faixa sem visibilidade, mas, na faixa com visibilidade, o ED superou o AG.

Foram identificados conjuntos de parâmetros que proporcionaram o melhor desempenho, com erro reduzido e maior estabilidade, embora a escolha dos parâmetros dependa do cenário e das características específicas da área, sugerindo a necessidade de ajustes para diferentes contextos.

Com isso, o trabalho mostrou que existe uma relevância nas técnicas de otimização na calibração de modelos de predição de sinal, pois elas têm o potencial de melhorar a precisão desses modelos e apoiar o planejamento de redes móveis no Brasil.

Trabalhos futuros incluem a criação de *rasters* de entrada com dimensões uniformes, para melhorar a qualidade dos dados, exploração de novos parâmetros de otimização, experimentação de diferentes formas de penalização e aplicação do modelo em diferentes cidades para validar sua adaptação à variações geográficas, demográficas e topográficas.

Referências

- Cavalcante, G. A. (2010). Otimização de modelos de predição da perda de propagação aplicáveis em 3,5ghz utilizando algoritmos genéticos. Master's thesis, Universidade Federal do Rio Grande do Norte.
- da Silva Castro, G. J. (2025). Aplicação de metaheurísticas na otimização de parâmetros em modelos de predição de cobertura celular.
- do Amaral, M. M. and Bohadana, E. (2008). Conectividade e mobilidade social: pilares da inclusão digital? *Contemporânea*, 6(2).
- Gillies, S. (2019). rasterio documentation. *MapBox: San Francisco, CA, USA*, 23.
- Holland, J. H. (1992). Genetic algorithms. *Scientific american*, 267(1):66–73.
- Mota, V. F. A. (2024). Otimização de modelo de predição de sinal celular utilizando algoritmo genético - estudo da aplicação em rede lte 4g (700mhz). Master's thesis, Universidade Federal de São João del-Rei.
- Mota, V. F. A., Pereira, M. A., and Xavier, C. R. (2023). Modelo de predição de sinal celular baseado em relevo e densidade populacional. ISSN 2179-4847. IBI: 8JMKD3MGPDW34P/4ADCTSE. Available from: <http://urlib.net/ibi/8JMKD3MGPDW34P/4ADCTSE>.
- Moyroud, N. and Portet, F. (2018). Introduction to qgis. *QGIS and generic tools*, 1:1–17.
- Oliveira, G. T. d. S. et al. (2006). Estudo e aplicações da evolução diferencial. Master's thesis, Universidade Federal de Uberlândia.
- Price, K. V. (2013). Differential evolution. In *Handbook of optimization: From classical to modern approach*, pages 187–214. Springer.
- Storn, R. and Price, K. (1997). Differential evolution – a simple and efficient heuristic for global optimization over continuous spaces. *Journal of global optimization*, 11:341–359.