



UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA

EVERTON ALEX MATOS

**META-HEURÍSTICAS APLICADAS AO PROBLEMA DE ALOCAÇÃO DE
SEQUÊNCIAS PILOTO EM SISTEMAS MASSIVE MIMO**

DISSERTAÇÃO DE MESTRADO

CORNÉLIO PROCÓPIO
2022

EVERTON ALEX MATOS

META-HEURÍSTICAS APLICADAS AO PROBLEMA DE ALOCAÇÃO DE SEQUÊNCIAS PILOTO EM SISTEMAS MASSIVE MIMO

Metha-heuristics applied to pilot allocation problem em Massive MIMO systems

Dissertação apresentada ao Programa de Pós-Graduação em Informática da Universidade Tecnológica Federal do Paraná – UTFPR, como requisito parcial para obtenção do título de Mestre em Informática.

Orientador: Dr. Lucas Dias Hiera Sampaio

CORNÉLIO PROCÓPIO
2022



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/)

Esta licença permite remixe, adaptação e criação a partir do trabalho, para fins não comerciais, desde que sejam atribuídos créditos ao(s) autor(es) e que licenciem as novas criações sob termos idênticos. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



EVERTON ALEX MATOS

META-HEURÍSTICAS APLICADAS AO PROBLEMA DE ALOCAÇÃO DE SEQUÊNCIAS PILOTO EM SISTEMAS MASSIVE MIMO

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Informática da Universidade Tecnológica Federal do Paraná (UTFPR).
Área de concentração: Computação Aplicada.

Data de aprovação: 16 de Dezembro de 2021

Prof Lucas Dias Hiera Sampaio, Doutorado - Universidade Tecnológica Federal do Paraná

Prof Bruno Bogaz Zarpelao, Doutorado - Universidade Estadual de Londrina (UEL)

Prof Henrique Yoshikazu Shishido, Doutorado - Universidade Tecnológica Federal do Paraná

Prof Rafael Gomes Mantovani, - Universidade Tecnológica Federal do Paraná

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 16/12/2021.

Aos meus pais, Nueli Matos e Sebastião Matos

AGRADECIMENTOS

Registro aqui meus agradecimentos, inicialmente a Deus pelas oportunidades e caminhos que aqui me trouxeram. Juntamente com Ele meus pais: Nueli Matos e Sebastião Matos (*in memoriam*), e irmã Eonara Matos, os quais sempre me apoiaram e incentivaram a seguir novos e desafiadores caminhos por mais difíceis se apresentem.

Ao meu professor orientador, Dr. Lucas Sampaio o qual não mediu esforços, considerou horários, feriados ou finais de semana em prol de me guiar pelo caminho do conhecimento, onde pacientemente me ajudou a construir o aprendizado de até então por mim pouco explorada e fascinante área da informática: a comunicação sem fios, onde tive uma formação técnica e suporte fabuloso disponível para compreender conceitos e mecanismos aplicados.

À UTFPR-CP e toda sua equipe técnica e docente que desde o primeiro contato me atenderam e acolheram de forma ímpar.

Aos docentes que ministraram aulas nas disciplinas do PPGI em 2019, pelas quais pude lapidar ideias, pensamento analítico e agregar novos e importantes aprendizados.

Aos membros da banca e colaboradores que dispuseram de tempo e dedicação para ler e contribuir com este trabalho.

Aos amigos que vibraram, torceram e acompanharam todo o desfecho que aqui se desdobra contribuindo no compartilhamento de experiências, vivências e conhecimentos.

E a todos que de alguma forma fizeram por meio desta caminhada alcançar o objetivo de lapidar pensamentos e ideias cuidadosamente aprofundados nas páginas desta dissertação.

À todos o meu mais sincero MUITO OBRIGADO! =)

A mente que se abre a uma nova ideia jamais voltará ao seu tamanho original. (Albert Einstein)

RESUMO

MATOS, Everton Alex. META-HEURÍSTICAS APLICADAS AO PROBLEMA DE ALOCAÇÃO DE SEQUÊNCIAS PILOTO EM SISTEMAS MASSIVE MIMO. 94 f. Dissertação – Programa de Pós-Graduação em Informática, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2022.

A quinta geração de sistemas de telecomunicações modernos, o 5G, surgiu com o desafio de aumentar a eficiência espectral e energética dos sistemas de comunicação. Para atingir este objetivo, uma das tecnologias empregadas é o uso massivo de antenas nas estações rádio-base (ERB), método conhecido como Massive MIMO. O sistema utiliza a diversidade espacial para permitir a transmissão do downlink e uplink livre de interferência por meio de sequências de treinamento ortogonais entre os usuários. Todavia, o crescimento do número de usuários no sistema implica num aumento do tamanho das sequências para manutenção da característica de ortogonalidade e este aumento, por sua vez, implica numa redução das eficiências no sistema. Logo, faz-se necessário re-utilizar as sequências piloto o que gera um fenômeno conhecido como contaminação piloto onde usuários diferentes acabam interferindo nos sinais de outros usuários degradando o desempenho do elo de comunicação. Para contornar este problema e reduzir o impacto da contaminação piloto na comunicação, técnicas de otimização podem ser empregadas para realizar a alocação de sequências piloto com o objetivo de maximizar a eficiência espectral do sistema. Sendo assim, este trabalho apresenta a aplicação de diferentes meta-heurísticas para solucionar o problema de alocação de sequências piloto, bem como, a criação de um *dataset* público para testes em diferentes cenários de comunicação móvel onde os algoritmos discutidos foram testados e seu desempenho analisado.

Palavras-chave: Massive MIMO, Sequência Piloto, Algoritmo evolutivo, 5G, Interferência Piloto, Algoritmo Genético, Otimização por Enxame de Partículas e Maximizar vazão de dados

ABSTRACT

MATOS, Everton Alex. Meta-heuristics applied to pilot allocation problem in Massive MIMO systems. 94 f. Dissertação – Programa de Pós-Graduação em Informática, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2022.

The fifth generation of modern telecommunications systems, the 5G, came up with the challenge of incrementing the spectral and energetic efficiencies of communications systems. To reach this objective, one of the employed technologies is the massive use of antennas on the base station, a method known as Massive MIMO. The system uses space diversity to allow the transmission of downlink and uplink without interference by training it with orthogonal sequences. However, as the number of users on the system grows, the size of the sequences also grows in order to ensure orthogonality. This causes an efficiency reduction on the system. For this reason, it is necessary to reuse the pilot sequences, which leads to the phenomenon known as pilot contamination, where different users interfere with the signals for other users degrading the performance of the communication link. To get around this problem and minimize the pilot contamination impact on communications, optimization techniques can be applied to the allocation process of the pilot sequences with the objective to maximize the spectral efficiency of the system. Therefore, this work shows the application of different meta-heuristics to solve the pilot sequence allocation problem, as well as the development of a public dataset in order to test the solutions in different mobile communications scenarios.

Keywords: Massive MIMO, Pilot Sequence, Particle Swarm Optimization, Genetic Algorithm, Evolutionary Algorithm, 5G System, Pilot Interference, Maximize data output

LISTA DE FIGURAS

FIGURA 1 – Transmissores e receptores com diferentes configurações de antenas (Chiueh et al. 2012)	21
FIGURA 2 – Disposição dos canais de comunicação disponíveis para os usuários em um sistema de comunicação com Múltiplo Acesso por Divisão em Frequências. Adaptado de (Goldsmith 2005).	22
FIGURA 3 – Disposição dos canais de comunicação disponíveis para os usuários em um sistema de comunicação com Múltiplo Acesso por Divisão de Tempo. Adaptado de (Goldsmith 2005).	23
FIGURA 4 – Disposição dos canais de comunicação disponíveis para os usuários em um sistema de comunicação com Múltiplo Acesso por Divisão de Código. Adaptado de (Goldsmith 2005).	23
FIGURA 5 – Subportadoras em sistemas com multiplexação não ortogonais e ortogonais. Adaptado de (Goldsmith 2005).	24
FIGURA 6 – Ilustração do efeito Multi-percurso a partir de um sinal omnidirecional e dos efeitos de reflexão, refração, difração e dispersão. Fonte: do Autor.	29
FIGURA 7 – Atrasos decorrente do multi-percurso fonte: do Autor.	30
FIGURA 8 – Perda de Percurso, Sombreamento e Multi-percurso em função da distância e potência. Adaptado de (Goldsmith 2005)	31
FIGURA 9 – Bloco de coerência, adaptado de (Björnson et al. 2017)	38
FIGURA 10 – Contaminação sequência piloto (Björnson et al. 2017)	43
FIGURA 11 – Representação de hiper-matriz binária em um cenário com 10 células atendendo 10 usuários por célula.	52
FIGURA 12 – Fluxograma GA - fonte: próprio autor	55
FIGURA 13 – Configuração típica de um cenário de simulação com $L = 7$ células e $K = 10$ usuários por célula e raio da célula igual a 200 metros. ...	66
FIGURA 14 – Eficiência espectral média por usuário de cada algoritmo analisado com $K = 20$ e $R = 1.000m$ para os diferentes números de iterações/gerações.	69
FIGURA 15 – Tempo para execução dos algoritmos (Instância executada no Google Cloud Platform: 32vCPUs, 32GB RAM, Sistema Operacional Ubuntu 20 e Múltiplos Workers em Matlab).	71
FIGURA 16 – Eficiência espectral por usuário (em bits/segundo/Hertz) para diferentes valores de taxa de mutação (T_m) em um cenário com $K = 20$ usuários e raio da célula de $R = 1000$ metros.	72
FIGURA 17 – Resultados dos testes para encontrar o melhor parâmetro para	

inércia ($K = 20$, $R = 1000m$ e $v_{\max} = 1$)	73
FIGURA 18 – Resultados do teste para encontrar o melhor parâmetro VNS em um cenário com $K = 20$ usuários por célula de raio $R = 1000m$	76
FIGURA 19 – CDF Empírica pra diferentes tamanhos de células com $K = 20$ usuários, $G_{\max} = 50$ iterações $I = 50$ iterações.	77
FIGURA 20 – CDF Empírica para $K = 20$, $K = 40$ e $K = 60$ usuário com células de $R = 1000m$ de raio com o máximo de iterações configurados em 50 para todos os algoritmos.	81

LISTA DE TABELAS

TABELA 1	– Intervalo de referência do parâmetro γ para diferentes cenários e ambientes. Adaptado de (Goldsmith 2005).	28
TABELA 2	– Trabalhos Relacionados	48
TABELA 3	– Trabalhos Relacionados	49
TABELA 4	– Exemplo de funcionamento do SPV em um vetor arbitrário.	60
TABELA 5	– Parâmetros do sistema usados nas simulações computacionais.	65
TABELA 6	– Parâmetros utilizado na otimização dos algoritmos.	68
TABELA 7	– Eficiência espectral média por usuário utilizando diferentes taxas de mutação para o GA com $R = 1000m$, $K = 20$	72
TABELA 8	– Resultados para os testes do coeficiente inercial ω , (resultados exibidos em <i>bps/Hz</i> por usuário - os melhores resultados estão destacados em negrito)	74
TABELA 9	– Eficiência espectral média por usuário utilizando BPSO e PSO-SPV com diferentes configurações de c_1 e c_2 em um cenário com $K = 20$ usuários e célula de raio $R = 1000$ metros.	75
TABELA 10	– Resultados das simulações <i>rvns</i> , valores exibidos em <i>bps/Hz</i> por usuário.	75
TABELA 11	– Melhores parâmetros para as diferentes versões do PSO obtidos por meio de simulação em um cenário com $K = 20$ usuários por célula de $R = 1000$ metros de raio.	77
TABELA 12	– Área sob a curva dos melhores resultados dos algoritmos em análise do tamanho do cenário ($I = 50$)	78
TABELA 13	– Eficiência espectral máxima por usuários em diferentes tamanhos de células. Os melhores resultados estão marcados em negrito.	79
TABELA 14	– Eficiência espectral mínima por usuário ($K = 20$) em diferentes tamanhos de células. Os melhores valores estão marcados em negrito.	79
TABELA 15	– Eficiência espectral mínima (<i>bps/Hz</i>) considerando $K = 20$ usuários em células de $R = 1000$ metros de raio.	80
TABELA 16	– Eficiência espectral máxima em diferentes carregamentos de sistema com células de raio $R = 1000m$. Os melhores resultados estão marcados em negrito.	82
TABELA 17	– Eficiência espectral mínima para diferentes carregamentos de sistema com células de raio $R = 1000m$. Os melhores resultados estão marcados em negrito.	82

LISTA DE SIGLAS

5G	Quinta geração de internet móvel
ERB	Estação Rádio Base
MIMO	Múltiplas entradas e múltiplas saídas - <i>Multiple-input Multiple-output</i>
IoT	<i>Internet of Things</i>
GA	<i>Genetic Algorithm</i>
PSO	<i>Particle Swarm Optization</i>
M2M	<i>Machine to Machine</i>
SISO	<i>Single-input Single -output</i>
SIMO	<i>Single-input Multiple-output</i>
MISO	<i>Multiple-input Single-output</i>
TDD	<i>Time Division Duplexing</i>
FDD	<i>Frequency Division Duplexing</i>
FDMA	<i>Frequency Division Multiple Access</i>
TDMA	<i>Time Division Multiple Access</i>
CDMA	<i>Code Division Multiple Access</i>
OFDM	<i>Orthogonal Frequency Division Multiplexing</i>
QAM	<i>Quadrature Amplitude Modulation</i>
FFT	<i>Fast Fourier Transform</i>
IFFT	<i>Inverse Fast Fourier Transform</i>
DSL	<i>Digital Subscriber Lines</i>
LOS	<i>Line of Sight</i>
NLOS	<i>Non Line of Sight</i>
FMD	<i>Frequency Division Multiplexing</i>
CDM	<i>Code Division Multiplexing</i>
TDM	<i>Time Division Multiplexing</i>
OFDM	<i>Orthogonal Frequency Division Multiplexing</i>
LTE/4G	<i>Long Term Evolution - 4G</i>
IEEE 802.11	<i>Padrão de transmissão Wi-Fi</i>
AWGN	<i>Additive White Gaussian Noise</i>
QoS	<i>Quality of Service</i>
SNR	<i>Signal-to-noise ratio</i>
IEEE	<i>Institute of Electric and Eletronic Engineers</i>
LTE	<i>Long Term Evolution</i>
SDMA	<i>Space Division Multiple Access</i>
MRC	<i>Maximum Ratio Combining</i>
SINR	<i>Signal to Interference plus Noise Ratio</i>
MLP	<i>Multilayer Perceptron</i>
CNN	<i>Convolutional Neural Network</i>
OVSF	<i>Orthogonal Variable Spreading Factor</i>
VNS	<i>Variable Neighbourhood Search</i>
BPSO	<i>Binary Particle Swarm Optimization</i>

RA	<i>Random Allocation</i>
CDF	Função de Distribuição Cumulativa
DE	<i>Differential Evolution</i>

LISTA DE SÍMBOLOS

p_r	Potência recebida
p_t	Potência transmitida
G	Produto do ganho da diretividade das antenas de transmissão
λ	Comprimento da onda do sinal
d	Distância percorrida pelo sinal
d_0	Distância de referência
d	Distância entre transmissor e receptor
\mathcal{C}	Constante da perda de percurso
β	Coefficiente de canal
γ	Expoente de perda de percurso
S	Efeito de sombreamento
ψ	Variável aleatória do sombreamento
σ	Desvio padrão
f_r	Função de distribuição de probabilidade
I_0	Função Bessel modificada de ordem zero
p	Distorção na amplitude do sinal
v^2	Potência
p_{dif}	Potência média sem linha de visada
T_c	Tempo de coerência do canal
f_D	Desvio Doppler
v	Velocidade relativa
c	Velocidade da luz
f_c	Frequência da onda portadora utilizada
T_s	Período de símbolo
B_c	Banda de coerência
B	Banda do canal
y_n	Sinal transmitido pelo terminal
t	Representação do tempo
x	Símbolo transmitido
f	Formatador de pulso
c	Resposta impulsiva do canal
η	Ruído Aditivo Gaussiano Branco - AWGN
P_{sinal}	Potência do sinal recebido
$P_{ruído}$	Potência do ruído de fundo
N_0	Densidade espectral de potência do ruído
g	Ganho de amplitude do canal
δ	Relação Sinal Ruído - SNR
R	Capacidade do sistema igual ao somatório de todos os subcanais
M	Antenas
\mathbf{s}_k	Sequência piloto
ℓ	ERB de interesse

σ^2	Variância do desvio padrão
ℓ'	ERB interferente
$\mathbf{G}_{\ell, \ell'}$	Matriz de ganho de canal
$\hat{\mathbf{G}}$	Matriz de estimativa do canal
ρ_p	Relação sinal ruído das sequências piloto
$\bar{\mathbf{a}}_\ell$	Vetor $K \times 1$
$\bar{\mathbf{w}}$	Vetor de antenas
$(\cdot)^H$	O operador de transposto conjugado
$(\cdot)^T$	Operador de transposição de matriz
$(\cdot)^*$	Operador complexo conjugado
k	Indexador do usuário
β	Coefficiente de atenuação da potência
h	Desvanecimento de pequena escala
L	Célula
K	Dispositivos móveis (usuários)
T_p	Sequência piloto
Φ	hiper-matriz de alocação de usuários
T_m	Taxa de mutação
t	Interação atual do algoritmo
ω	Inércia
\mathbf{v}_j	Velocidade do candidato
\mathbf{x}_j	Posição da partícula no espaço de busca
\mathbf{p}_i	Melhor posição da partícula
\mathbf{p}_g	Melhor posição geral da partícula em relação a população
q	Representação da sequência piloto no PSO
\mathcal{J}	Função <i>fitness</i> do problema de otimização
\mathcal{P}	Somatório das restrições C.1 e C.2
r_{vns}	Taxa de alteração da vizinhança - PSO
c_{vns}	Quantidade de pares de usuários que são trocados durante a busca VNS
G_{\max}	Número máximo de gerações
c_1	Coefficiente de aceleração local (PSO)
c_2	Coefficiente de aceleração global (PSO)

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Redes Sem-Fio na Atualidade	15
1.2	Motivação	17
1.3	Objetivos	18
1.3.1	Objetivo Geral	18
1.3.2	Objetivos Específicos	19
1.4	Organização do Texto	19
1.5	Produção Científica	19
2	FUNDAMENTAÇÃO TEÓRICA	20
2.1	Fundamentos de Comunicação Sem-Fio	20
2.2	Canais de Comunicação Sem-Fio	25
2.2.1	Perda de percurso	25
2.2.1.1	Perda de Percurso no Espaço Livre	26
2.2.1.2	Modelo de perda de percurso empírico	26
2.2.1.3	Modelo de perda de percurso simplificado	27
2.2.2	Sombreamento	28
2.2.3	Desvanecimento	29
2.2.4	Classificação dos Canais de Comunicação Sem-Fio	32
2.2.4.1	Classificação na Dimensão Tempo	33
2.2.4.2	Classificação na Dimensão Frequência	33
2.3	Sistemas de comunicação Sem-Fio SISO	33
2.3.1	Métricas de desempenho	35
2.4	Sistemas de comunicação Sem-Fio MIMO e Massive MIMO	36
2.4.1	Transmissão e Recepção em Sistemas Massive MIMO	37
2.4.2	Métricas de desempenho em sistemas Massive MIMO	40
2.4.3	O problema da contaminação piloto	42
2.5	Trabalhos relacionados	42
3	METODOLOGIA	50
3.1	Alocação de Sequências Piloto em Sistemas Massive MIMO	50
3.2	Ferramentas utilizadas	53
3.3	Algoritmo Genético	53
3.4	Otimização por Enxame de Partículas (PSO)	56
3.4.1	PSO Binário (BPSO)	57
3.4.2	PSO-SPV	60
3.4.3	PSO-VNS	61
3.4.4	PSO com velocidade global (SPV e VNS)	64

3.5	Cenários de Simulação	64
4	RESULTADOS E DISCUSSÕES	67
4.1	Meta-heurísticas Analisadas	67
4.2	Otimização de Parâmetros das Meta-heurísticas	69
4.3	Otimização de parâmetro para o GA	71
4.4	Otimização dos parâmetros do PSO	72
4.5	Desempenho dos algoritmos em diferentes cenários	75
5	CONCLUSÃO	84
6	REFERÊNCIAS	87

1 INTRODUÇÃO

Comunicar-se é uma necessidade da humanidade desde o início de sua história, tamanha importância faz logo nos primeiros anos de vida os bebês desenvolverem uma clássica forma de comunicação: o choro. Decorrido o tempo outras maneiras surgem: gestos, códigos sonoros, palavras, frases e, desta forma a capacidade de comunicar-se na sociedade moderna.

A medida que uma criança cresce e se desenvolve, tornam-se cada vez mais independentes em sua troca de informações, pois, dominando meios de se comunicar, sua história, de seus antepassados e conhecimentos, podem ser compartilhados entre outras pessoas e até mesmo repassados às futuras gerações por meio de comunicação verbal entre indivíduos ou via codificação escrita nas mais diferentes formas que se conhece.

No entanto, na maioria das vezes não é necessário enviar narrativas históricas entre pessoas ou mesmo uma mensagem através do tempo transcendendo gerações, grande parte desta comunicação do dia a dia são mensagens imediatistas, pequenos recados a pessoas que não se encontram fisicamente disponíveis para trocá-las, por tal, requerem uma transmissão para outro ambiente por meio da utilização de algum meio de transporte destas informações.

As primeiras formas de comunicação sem-fio envolviam o envio de cartas, pombos correios, sinais luminosos e até mesmo sinais de fumaça, este último data da idade pré industrial e foi reconhecido como a primeira rede sem-fios (Goldsmith 2005).

Desde então as comunicações tiveram importantes saltos evolutivos, como em 1838 quando Samuel Morse inventou o Telégrafo, primeiro mecanismo da era de telecomunicações modernas. O sistema telegráfico de Morse era capaz apenas de

enviar código Morse para transmitir suas informações (Goldsmith 2005).

A tecnologia criada por Morse do início do século XVIII foi gradualmente substituída a partir de 1863, quando Alexander Graham Bell alcança a habilidade de transmitir a voz humana por meio de pulsos elétricos, inovação que viabilizaria em 1881 ao público na Alemanha a primeira rede telefônica (Siemens 2020).

Um ano depois, em 1864 James Clerk Maxwell formulou uma teoria sobre a propagação eletromagnética, uma conjectura sobre a existência de ondas de rádio, hipóteses que foram comprovadas em 1887 pelo trabalho de Heinrich Hertz (Goldsmith 2005).

Todavia, mesmo provando experimentalmente a existência de ondas eletromagnéticas, Hertz argumentou que as mesmas não poderiam ser utilizadas para transmitir a voz humana. No caminho oposto ao raciocínio de Hertz, Oliver Lodge criou em 1894 o primeiro sistema de transmissão por ondas eletromagnéticas para comunicação sem-fio de curta distância (150 metros) (Goldsmith 2005).

O trabalho de Lodge foi aprimorado e em 1897 Guglielmo Marconi estabeleceu um canal de comunicação sem-fio transpondo 28,9 quilômetros utilizando ondas eletromagnéticas. Os sistemas de comunicação sem-fio da época avançara e em 1901 foram realizadas as primeiras transmissões transatlânticas, bem como, a transmissão de voz e música feita por Reginald Fessenden por meio da modulação de amplitude que contornava as limitações das baixas frequências (Goldsmith 2005).

Nesta época os rádios utilizados efetuavam comunicações analógicas as quais são consideravelmente mais sensíveis a interferências, pois o sistema analógico utiliza uma transcodificação contínua, isto é, as informações transmitidas são codificadas de forma contínua dentro de um intervalo pré-estabelecido. Com a evolução dos rádios, além do benefício de serem energeticamente mais eficientes e ocuparem menos espaço, a tecnologia permitiu que as transmissões passassem de analógicas a digitais, ou seja, um processo de discretização e quantização é aplicado nas informações a serem transmitidas de tal forma que apenas níveis discretos de energia, tempo e frequência são utilizados na transmissão de informações (Goldsmith 2005).

Em 1971 no Havaí a primeira rede de comutação de pacotes sem-fio digital utilizando rádios foi desenvolvida denominada ALOHAnet. Esta rede interligava computadores e *websites* pertencentes a sete campi espalhados em quatro ilhas utilizando topologia estrela e cujo o nó central atuava como *hub* e estava situado na ilha de Oahu (Goldsmith 2005) e (Kurose e Ross 2013).

Durante as décadas de 70 a 80 que os projetos com redes sem-fio ganharam força graças ao surgimento da Agência de Projetos de Pesquisa Avançada de Defesa (*Defense Advanced Research Projects Agency - DARPA*) nos Estados Unidos. Esta agência investiu na pesquisa e desenvolvimento das comunicações sem-fio para fins de otimizar troca de informações em campos de batalha, em razão de possuir a capacidade de auto reconfigurar-se em caso de um dos nós ser desconectado ou até mesmo destruído, outro benefício é não possuir cabos e outras estruturas que pudessem ser facilmente rompidos (Goldsmith 2005) e (Kurose e Ross 2013).

A partir dos anos 90, as redes sem-fio para fins comerciais ganham importância justamente com a popularização do acesso a Internet e a criação de novos serviços multimídia como o correio eletrônico, compartilhamento de arquivos, comércio eletrônico e posteriormente, serviços de *streaming* e redes sociais (Kurose e Ross 2013).

1.1 REDES SEM-FIO NA ATUALIDADE

De acordo com a (Cisco 2020) o número total de usuários de Internet em todo o mundo alcançou a marca de 3,9 bilhões em 2018, com perspectivas de crescimento para 5,3 bilhões em 2023. Este crescimento representará 66% da população global segundo estatísticas de crescimento populacional da (UN-DESA 2019), a qual estima uma população de 8 bilhões de pessoas em 2023. Referente ao tráfego de dados, 54% será originado de dispositivos móveis (*smartphones, phables* e *tablets*) e o volume de dados mensal, segundo a (Ericsson 2019) pode alcançar os 160 exabytes em 2025 o que representará um crescimento de 321% frente aos 38 exabytes mensurados em 2019.

A fim de que as redes suportem esse crescente número de usuários, são

necessárias novas tecnologias capazes de atingir níveis melhores de confiabilidade, latência e eficiência energética. Neste sentido, a quinta geração de telefonia móvel, o 5G, cuja a Agência de Notícias Reuters noticia o início da implantação em abril de 2019 na Coreia do Sul (Park 2019), busca garantir o aumento da capacidade de transmissão dos sistemas de comunicação sem-fio com baixa latência e ultra confiabilidade capaz de viabilizar novos serviços como a utilização em automação industrial em áreas internas e externas, aplicações de IoT (do inglês, *Internet of Things*) para cidades e casas inteligentes, dispositivos vestíveis conectados (*wearables*), carros autônomos e conectados, segurança pública com a utilização de câmeras inteligentes, mobilidade urbana, saúde, entre outros (Davies 2019) e (Uddin et al. 2019).

Entre as novidades presentes no 5G destaca-se o uso do sistema de transmissão MIMO em larga escala (Múltiplas Entradas e Múltiplas Saídas em Larga Escala). Essa nomenclatura foi utilizada por (Marzetta 2010) e refere-se a qualquer modelo de sistema multi-usuário com pelo menos 16 antenas transmissoras e receptoras.

Neste tipo de sistema proposto por (Marzetta 2010) a Estação Rádio Base (ERB) trabalha com dezenas e até mesmo centenas de antenas trabalhando em altas frequências, também conhecidas como ondas milimétricas por possuírem um comprimento de onda inferior a um milímetro (Davies 2019). Esta característica impacta positivamente o espectro eletromagnético uma vez que permite a utilização de faixas pouco ou não utilizadas.

Em função das altas frequências, o alcance máximo de cobertura de uma ERB é consideravelmente reduzido, o que cria a necessidade nesta tecnologia do uso de células ¹ de raio menor e mais próximas uma das outras, também denominadas de femto ou pico-células.

Neste sistema para identificar os usuários a ERB realiza um processo de treinamento de canais a cada intervalo de coerência do canal sem-fio, este processo atribui uma sequência de bits pré-determinada e única para cada um dos transmissores e são denominadas sequências piloto ou sequências de treinamento. (Marzetta 2006)

¹Área de cobertura de uma Estação Rádio Base

Considerando o menor alcance em ambientes urbanos com uma densidade de usuários grande torna-se um problema devido a recepção de um sinal oriundo de um usuário pertencente à célula vizinha pode se tornar frequente quando este se localiza próximo do limite máximo de alcance de sua célula.

Esse tipo de situação quando reutiliza as mesmas sequências piloto em células vizinhas causa uma interferência também conhecida como contaminação piloto, o que se torna uma fator limitador de desempenho (Rodriguez 2015) e (Saxena et al. 2015).

Como alternativa capaz de contornar o problema de contaminação por sequências pilotos, este trabalho aborda meta-heurísticas baseadas em algoritmos evolutivos utilizando o Algoritmo Genético (do inglês, *Genetic Algorithm - GA*) e Optimização por Enxame de Partículas (do inglês, *Particle Swarm Optimization - PSO*) como instrumentos para realizar a distribuição de sequências de treinamento (sequências piloto) em cada uma das células de forma a atender todos os usuários conectados ao sistema.

1.2 MOTIVAÇÃO

De acordo com a (GSMA 2019), as companhias de telecomunicações consomem cerca de 2 a 3% da energia elétrica gerada no mundo, o que segundo (Enerdata 2018) equivale a cerca de 563 Terawatts hora, isto é cerca de 40 *TWh* a mais do que a energia consumida no Brasil, representando um significativo impacto econômico-ambiental.

Dado a importância que o percentual energético consumido pelas telecoms representa, é evidente a necessidade em utilizar recursos disponíveis em sistemas de telecomunicações modernos de forma eficiente, uma vez que são limitados e possuem um grande efeito na experiência de usuários, bem como, faturamento de companhias detentoras da infraestrutura.

Os trabalhos do (CEET 2015) concluem que é possível aumentar a eficiência energética dos sistemas modernos de telecomunicações em 10%. Uma vez que a matriz energética mundial depende cerca de 76% de fontes não-renováveis de acordo

com (IEA 2017), isto implicaria não somente em uma economia para as empresas, mas também em uma redução nos níveis de emissão de carbono decorrentes da produção de energia elétrica.

Adicionalmente, a alocação dos recursos de forma eficiente pode aumentar a capacidade do sistema tanto em termos de quantidade de usuários conectados como também de velocidade média de conexão, o que melhora a experiência do usuário.

Neste sentido, é de fundamental importância formalizar e propor soluções para os diferentes cenários e recursos disponíveis de tal forma a considerar a complexidade, aplicabilidade e benefícios da solução proposta por meio de figuras de mérito como: as eficiências energética e espectral, consumo médio de energia ou potência, taxa de interrupção (*outage rate*), complexidade computacional, entre outros.

Entre os problemas de alocação de recursos está o problema de alocação de sequências pilotos. Estas sequências são fundamentais para o bom funcionamento dos sistemas *Massive MIMO* e devem ser reusadas por inúmeras estações uma vez que sua quantidade é finita. O uso indiscriminado destas sequências incorre no problema de contaminação piloto cruzada no qual o sinal de usuários de células distintas causam interferência mútua, degradando assim a qualidade da conexão e podendo até mesmo interrompê-la.

1.3 OBJETIVOS

Esta dissertação de mestrado tem o objetivo de empregar uma das diferentes técnicas de inteligência computacional, denominados algoritmos evolutivos para solucionar problemas de otimização atrelados a alocação de recursos nos sistemas 5G.

1.3.1 OBJETIVO GERAL

Avaliar o desempenho de múltiplos algoritmos evolucionários no problema de alocação de sequências piloto em sistemas de comunicação sem-fio de quinta

geração (5G).

1.3.2 OBJETIVOS ESPECÍFICOS

- Implementar um cenário de teste para os diferentes algoritmos escolhidos;
- Otimizar os parâmetros de diferentes meta-heurística para solução do problema de alocação de sequências piloto;
- Avaliar o desempenho de diferentes algoritmos em diferentes cenários comparando a relação entre qualidade da solução e complexidade computacional dos mesmos;
- Mensurar o impacto da escolha de um algoritmo de alocação de sequências piloto em comparação com a alocação aleatória;

1.4 ORGANIZAÇÃO DO TEXTO

Este trabalho se organiza em: introdução a qual antecipa os assuntos percorridos ao longo desta dissertação, bem como, objetivos e motivações para sua produção. Fundamentação teórica: abordando os principais termos e autores que já produziram conteúdos sobre contaminações de sequências piloto. Desenvolvimento: com modelos e técnicas para a solução do problema. Resultados e Discussões onde os resultados obtidos são analisados e testes de desempenho são realizados e finalmente a Conclusão onde as considerações finais deste trabalho são apresentadas.

1.5 PRODUÇÃO CIENTÍFICA

1. MATOS, Everton Alex; SAMPAIO, Lucas Dias Hiera. **Meta-heurísticas Binárias Aplicadas ao Problema de Distribuição de Sequências Piloto em Sistemas Massive MIMO**. No: *III FÓRUM PPGC-PR*, 3., 2021, Cornélio Procópio-Pr. Resumo Técnico. Cornélio Procópio-Pr: Ppgi-Cp, 2021.

2 FUNDAMENTAÇÃO TEÓRICA

Este Capítulo está dividido em quatro Seções pelas quais são apresentados conceitos fundamentais em sistemas de telecomunicações sem-fio onde: a Seção 2.1 discorre referente aos canais de comunicações e efeitos decorrentes da propagação do sinal. A Seção 2.3 apresenta sistemas de comunicação SISO e suas métricas de desempenho. A Seção 2.4 apresenta múltiplos tipos de configuração de antenas para transmissão sem-fio e interferência causada. A Seção 2.5 apresenta os trabalhos relacionados disponíveis na literatura.

2.1 FUNDAMENTOS DE COMUNICAÇÃO SEM-FIO

A Internet em 2021 conecta uma diferente gama de dispositivos, por meio guiado ou não, oferece por meio destas conexões serviços como: multimídia, redes sociais, comunicação *machine to machine* (M2M), cidades inteligentes, carros autônomos, agropecuária inteligente, entre outros. Suportar toda esta crescente demanda implica em uma evolução rápida das diferentes tecnologias de redes de comunicação sem-fio a fim de que possuam uma vazão maior de dados, latência menor e alta disponibilidade.

Neste cenário, garantir os requisitos estabelecidos pelo advento de novos serviços e sua popularização pode ser feito por meio da exploração da diversidade de diferentes dimensões, e.g. a dimensão espacial pode ser explorada para aumentar a confiabilidade das transmissões ou para a multiplexação por meio do uso de mais de uma antena de transmissão e/ou recepção. Neste caso, diversas configurações podem ser estabelecidas. como: *Single-input Single-output* (SISO) quando há apenas uma antena de transmissão e uma de recepção, *Single-Input Multiple-output* (SIMO)

quando há uma antena de recepção e múltiplas de transmissão, *Multiple-input Single-output* (MISO) quando há múltiplas antenas de recepção e uma de transmissão e, finalmente, *Multiple-input Multiple-output* (MIMO) quando há múltiplas antenas de recepção e transmissão, assim como ilustrado na Figura 1.

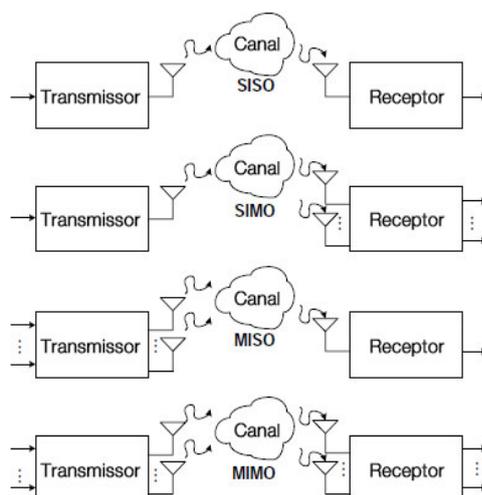


Figura 1: Transmissores e receptores com diferentes configurações de antenas (Chiueh et al. 2012)

De maneira geral, as configurações denominadas entrada (*input*) e saída (*output*) referem-se aos terminais móveis e as estações de transmissão, respectivamente. A Figura 1 demonstra a relação entre transmissor e receptor de acordo com as variadas configurações possíveis.

Adicionalmente, os sistemas de comunicação sem-fio utilizam outras dimensões para permitir o acesso simultâneo dos dispositivos conectados à mesma rede, bem como, viabilizar a comunicação em modo *full-duplex* ou *half-duplex*. Neste sentido, quando a comunicação da estação rádio-base para o terminal móvel (*downlink*) e a comunicação reversa (*uplink*) ocorrem na mesma frequência é necessário alocar intervalos de tempo para que cada curso da comunicação ocorra. Este tipo de transmissão é denominado Duplexação por Divisão de Tempo (do inglês, *Time Division Duplexing* - TDD). De forma equivalente, os canais de comunicação do *downlink* e do *uplink* podem operar em frequências distintas de tal forma que podem estar ativos simultaneamente. Este tipo de comunicação é denominada Duplexação de Divisão por Frequência (do inglês, *Frequency Division Duplexing* - FDD).

Outro aspecto importante na comunicação sem-fio é a capacidade de suportar de forma simultânea diferentes transceptores. Neste sentido, o múltiplo acesso pode ser alcançado utilizando varias dimensões dos sistemas de comunicação: Divisão ao Longo do Tempo (do inglês, *Time Division*), Divisão em Frequência (do inglês, *Frequency Division*), Divisão por Meio de Códigos (do inglês, *Code Division*), além de soluções híbridas (Goldsmith 2005).

Os sistemas de Múltiplo Acesso por Divisão de Frequências (do inglês, *Frequency Division Multiple Access - FDMA*) são sistemas de comunicação de múltiplo acesso no qual o canal é dividido em faixas de frequência predefinidas para operação, tal como, ilustrado na Figura 2, de tal forma que cada usuário utiliza faixas diferentes de frequência dos demais usuários do sistema (Goldsmith 2005).

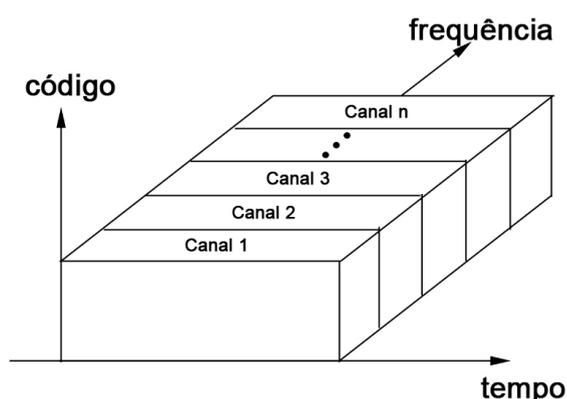


Figura 2: Disposição dos canais de comunicação disponíveis para os usuários em um sistema de comunicação com Múltiplo Acesso por Divisão em Frequências. Adaptado de (Goldsmith 2005).

Os sistemas de Múltiplo Acesso por Divisão de Tempo (do inglês, *Time-Division Multiple Access - TDMA*) utilizam a divisão dos canais no domínio do tempo como na Figura 3, isto é, os usuários transmitem na mesma frequência de operação, porém o fazem em intervalos de tempos distintos (Goldsmith 2005).

Uma terceira forma de transmissão a qual permite o acesso simultâneo de diferentes usuários é o Múltiplo Acesso por Divisão de Código (do inglês, *Code Division Multiple Access - CDMA*), no qual as informações de cada usuário são combinadas a um sinal espalhador único para cada usuário (código). Diferente dos outros dois sistemas citados e como ilustra a Figura 4, os sinais ocupam toda a largura

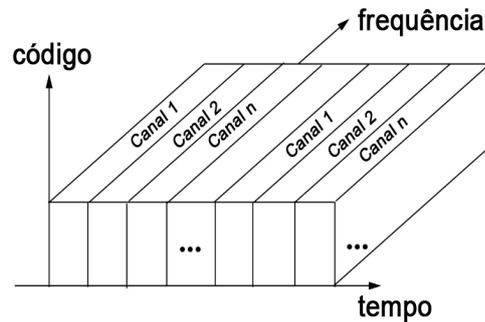


Figura 3: Disposição dos canais de comunicação disponíveis para os usuários em um sistema de comunicação com Múltiplo Acesso por Divisão de Tempo. Adaptado de (Goldsmith 2005).

de banda do sistema e são transmitidos simultaneamente. A ortogonalidade entre os códigos utilizados para espalhar os sinais é fundamental para evitar qualquer tipo de interferência de múltiplo acesso (Goldsmith 2005).

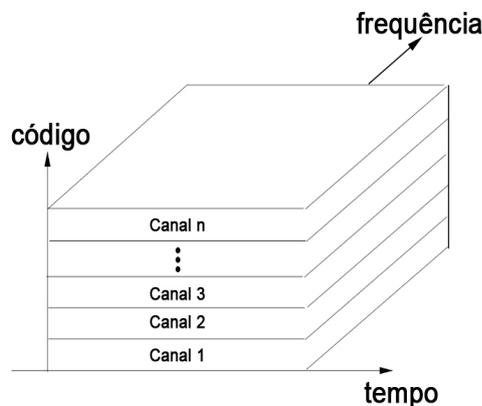


Figura 4: Disposição dos canais de comunicação disponíveis para os usuários em um sistema de comunicação com Múltiplo Acesso por Divisão de Código. Adaptado de (Goldsmith 2005).

Em sistemas de Multiplexação por Divisão Ortogonal de Frequência (do inglês, *Orthogonal Frequency Division Multiplexing* - OFDM), acontece a divisão do fluxo de bits em vários sub-fluxos diferentes e transmitidos por subportadoras ou subcanais distintos de banda mais estreita que a largura de banda de coerência do canal. Este mecanismo faz com que os subcanais experimentem um desvanecimento relativamente plano, característica que propicia maior robustez contra interferência intersimbólica (Goldsmith 2005) e (Sampaio 2015).

Conforme a Figura 5 ilustra, em um sistema com N subportadoras com largura de banda B pela qual cada subportadora é representada por f , neste, o sinal ortogonal é submetido a um Modulador de Amplitude em Quadratura (do inglês, *Quadrature Amplitude Modulation* - QAM), dividindo o sinal em amplitude e fase para transmissão e também por meio do mesmo QAM é possível recuperar as informações originais (Goldsmith 2005).

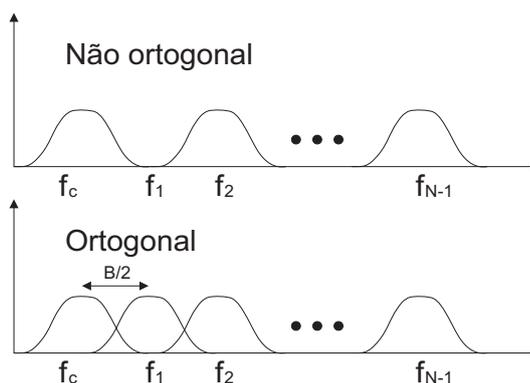


Figura 5: Subportadoras em sistemas com multiplexação não ortogonais e ortogonais. Adaptado de (Goldsmith 2005).

A modulação multiportadora é empregada em diversos sistemas de comunicação sem-fios, contudo sua primeira utilização data do final dos anos 50 e início dos anos 60 em rádios militares, porém devido a complexidade da implementação que requisitava moduladores individuais por cada subcanal, somente vinte anos depois com o desenvolvimento de novos algoritmos para a transformada de Fourier, a transformada rápida de Fourier (do inglês, *Fast Fourier Transform* - FFT), e a transformada inversa rápida de Fourier (do inglês, *Inverse Fast Fourier Transform* - IFFT) pode ser utilizada em diversas aplicação sem-fio como: áudio e vídeo digital, linhas de assinante digital (do inglês, *Digital Subscriber Lines* - DSL) e as mais recentes redes sem-fio (Goldsmith 2005) e (Sampaio 2015).

Os sistemas de comunicação modernos sempre se estabeleceram no uso de uma ou mais dessas técnicas apresentadas. Todavia, o trabalho de (Marzetta 2010) introduz uma forma diferente de múltiplo acesso que explora a diversidade espacial de transmissores e receptores, permitindo a comunicação simultânea na mesma frequência. Marzetta assume em seu trabalho que a chave para a nova evolução das comunicações móveis está intrinsecamente relacionada ao uso massivo de

antenas em transmissores e receptores. Este modelo de comunicação foi denominado *Massive MIMO* em referência ao uso massivo de antenas. Detalhes a respeito do funcionamento dos sistemas *Massive MIMO* serão apresentados na Seção 2.4.

2.2 CANAIS DE COMUNICAÇÃO SEM-FIO

Independente de como o acesso ao meio é realizado, a propagação do sinal nas redes sem-fio é dada por meio do espectro eletromagnético que é responsável por distorcer o sinal em razão dos efeitos de reflexão, dispersão, absorção e refração. O resultado destes fenômenos naturais se traduz em três efeitos sob o sinal recebido que percorre o espaço por meio de ondas eletromagnéticas: a perda de percurso, o sombreamento e o desvanecimento. Os dois primeiros efeitos são em muitos casos denominados: Desvanecimentos de Larga Escala e o desvanecimento é denominado: Desvanecimento de Pequena Escala (Goldsmith 2005).

De forma geral, o primeiro efeito está atrelado a distância percorrida pelo sinal e a frequência no qual o mesmo é transmitido, o segundo às superfícies opacas e translúcidas que o sinal atravessa, bem como o fenômeno de dispersão do sinal; finalmente, o último está diretamente ligado a presença de espalhadores locais que geram cópias do sinal original com diferentes atrasos podendo estes criar interferências construtivas ou destrutivas.

2.2.1 PERDA DE PERCURSO

A Perda de Percurso ou do inglês, *Path loss*, é um fenômeno caracterizado pela dissipação da energia irradiada pelo transmissor no caminho até o receptor, seja ela pela presença de obstáculos ou em ambientes abertos pela atenuação referente a distância percorrida. Existem diferentes modelos de perda de percurso estudados de forma abrangente na literatura, dentre os quais é possível citar: a Perda de Percurso no Espaço Livre (do inglês, *Free-space Path loss*), Perda de Percurso por Modelos Empíricos (do inglês, *Empirical Path loss Model*) e Modelo Simplificado para Perda de Percurso (do inglês, *Simplified Path loss Model*). Esses três modelos serão apresentados nas subseções seguintes.

2.2.1.1 PERDA DE PERCURSO NO ESPAÇO LIVRE

Em um ambiente onde se considera o espaço livre entre transmissor e receptor, isto é, assumindo que não há construções, objetos e/ou qualquer tipo de elemento que obstrua o sinal em linha de visada entre os dois pontos, é possível utilizar o modelo de Perda de Percurso no Espaço Livre. Este cenário de perda de percurso possui como principal característica a linha de visada, (do inglês *Line of Sight* - LOS) o qual é matematicamente definido como (Goldsmith 2005):

$$\frac{p_r}{p_t} = \left[\frac{\sqrt{G_l} \lambda}{4 \pi d} \right]^2 \quad (1)$$

onde p_r é a potência recebida, p_t potência transmitida, G_l é o Produto da diretividade das antenas de transmissão e recepção em termos da linha de visada, λ é o comprimento da onda do sinal e d é a distância percorrida pelo sinal.

2.2.1.2 MODELO DE PERDA DE PERCURSO EMPÍRICO

Determinar a relação da perda de energia com a distância percorrida, frequência de operação, tipos, formatos, tamanhos de antena de transmissão e recepção é uma tarefa complexa uma vez que mesmo conhecendo os diferentes parâmetros e o terreno, as condições de operação podem influenciar na criação de um modelo. Mesmo com estas dificuldades, ao longo do tempo diferentes modelos empíricos foram criados como, por exemplo os modelos de (Okumura 2017) e o de (Hata 1980) (Goldsmith 2005).

O modelo de Okumura pode ser utilizado em distâncias de 1 a 100 quilômetros e em frequências entre 150 a 1500 Mhz. Seu modelo foi criado a partir de observações da comunicação entre estação rádio-base e terminal móvel em Tóquio, Japão. De forma semelhante, o modelo de Hata, que é baseado nos dados coletados por Okumura, funciona também no mesmo intervalo de frequências, se aproxima notavelmente do modelo de Okumura para valores de distância superiores a 1 quilômetro (Goldsmith 2005).

Uma vez que os dois modelos possuem parâmetros distintos da realidade dos sistemas *Massive MIMO*, o modelo de perda de percurso não será considerado neste trabalho.

2.2.1.3 MODELO DE PERDA DE PERCURSO SIMPLIFICADO

Definir a perda de percurso em diferentes ambientes é uma tarefa difícil, especialmente quando deseja-se obter um modelo único para uma gama consideravelmente numerosa de situações, cenários e parâmetros de comunicação. Neste sentido, a proposta de um modelo simplificado agrega a possibilidade de testar modelos de comunicação sem-fio tanto no pior quanto no melhor cenário. O modelo de perda de percurso simplificado leva em consideração a perda de percurso medida em uma distância de referência d_0 , a qual é uma constante que caracteriza a frequência de transmissão, os ganhos das antenas, entre outros parâmetros do cenário, onde ocorre a transmissão. O modelo simplificado de perda de percurso é matematicamente descrito em (Goldsmith 2005) como:

$$p_r = p_t \mathcal{C} \left[\frac{d_0}{d} \right]^\gamma \quad (2)$$

onde p_r é potência recebida, p_t potência transmitida, \mathcal{C} é uma constante adimensional que depende das características das antenas, da mesma maneira que a frequência de transmissão, d_0 refere-se a distância de referência, d a distância entre transmissor e receptor e λ , é o expoente de perda de percurso que está diretamente atrelada ao ambiente onde ocorre a comunicação, i.e. em cenário bucólicos ele assume valores menores que em ambiente de alta densidade urbana. De acordo com (Goldsmith 2005) os valores de γ possuem um intervalo dependendo do ambiente onde ocorre a comunicação conforme descrito na Tabela 1.

Neste trabalho será utilizado o modelo de Perda de Percurso Simplificado de tal forma que a constante \mathcal{C} será dada por:

$$\mathcal{C} = \left(\frac{\lambda}{4\pi d_0} \right)^2 \quad (3)$$

Ambiente	Intervalo de Valores para γ
Macrocelular Urbano	[3, 7; 6, 5]
Microcelular Urbano	[2, 7; 3, 5]
Prédio de Escritórios (Mesmo Andar)	[1, 6; 3, 5]
Prédio de Escritórios (Andar Diferente)	[2; 6]
Loja	[1, 8; 2, 2]
Indústria	[1, 6; 3, 3]
Residência	3

Tabela 1: Intervalo de referência do parâmetro γ para diferentes cenários e ambientes. Adaptado de (Goldsmith 2005).

Desta forma, o coeficiente de canal β em termos de potência será definido como:

$$\beta = \left(\frac{\lambda}{4\pi d_0} \right)^2 \left(\frac{d_0}{d} \right)^\gamma S \quad (4)$$

onde λ é o comprimento de onda, d_0 a distância de referência, d a distância entre transmissor e receptor, γ é o expoente da perda de percurso definido conforme a Tabela 1 e S é o efeito do sombreamento que será discutido na próxima Seção.

2.2.2 SOMBREAMENTO

Sinais transmitidos por meio de canais sem-fio frequentemente sofrem uma variação aleatória em decorrência do bloqueio de objetos pelo caminho de sua propagação, estas variações geram oscilações de potência recebida a uma determinada distância, o que justifica o termo: Efeito de Média Escala.

A fim de calcular estas variações, diferentes modelos estatísticos para caracterizar estas atenuações foram desenvolvidos, o mais comum segundo (Goldsmith 2005) é o Sombreamento log-normal. Este modelo foi empiricamente definido para calcular com precisão a variação da potência recebida em ambientes internos e externos onde, a razão da potência de transmissão para recepção, $\psi = p_t/p_r$, é uma variável aleatória de distribuição log-normal cuja densidade de probabilidade é definida como:

$$p(\psi) = \frac{\varepsilon}{\sqrt{2\pi}\sigma_{\psi dB}\psi} = \exp\left[-\frac{(10\log_{10}\psi - \mu_{\psi dB})^2}{2\sigma_{\psi dB}^2}\right], \psi > 0 \quad (5)$$

onde $\varepsilon = \frac{10}{\ln(10)}$, $\mu_{\psi dB}$ é a média de $\psi_{dB} = 10\log_{10}(\psi)$ em dB, σ representa o desvio padrão e σ_{db}^2 é a variância de ψ_{dB} , a qual segundo (Goldsmith 2005) deve estar em um intervalo entre cinco e doze dB em cenários macro células e quatro e treze dB em micro células.

2.2.3 DESVANECIMENTO

Em ambientes que oferecem diferentes tipos de obstáculos, muito mais frequente em áreas urbanas, as ondas eletromagnéticas emitidas não chegam diretamente ao seu destino uma vez que árvores, prédios, entre outros tipos de obstruções situam-se na linha de visada entre receptor e transmissor.

Neste cenário o efeito de Desvanecimento de Pequena Escala é denominado Multi-percurso, onde o sinal recebido é a soma das diferentes réplicas do sinal original que estão atenuadas e atrasadas em relação ao sinal original devido aos efeitos de reflexão, dispersão e difração decorrentes dos obstáculos como pode ser observado por meio da ilustração na Figura 6.

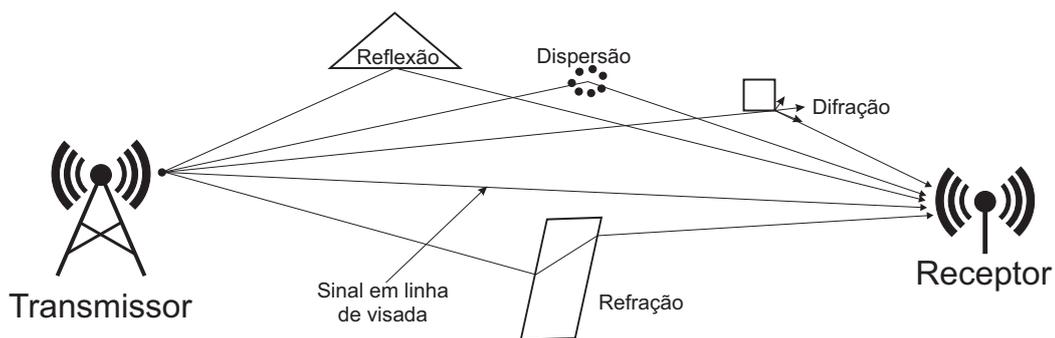


Figura 6: Ilustração do efeito Multi-percurso a partir de um sinal omnidirecional e dos efeitos de reflexão, refração, difração e dispersão. Fonte: do Autor.

Os sinais atrasados e atenuados devido ao multi-percurso causam interferência no sinal original que pode ser construtiva ou destrutiva. Neste sentido, a fim de exemplificar este efeito, é introduzida a Figura 7 onde um sinal de frequência 1 Hertz e amplitude 1 Volt sofre interferência de duas cópias do sinal: a primeira cópia

tem amplitude de 50% do sinal original e está atrasada 0,5 segundos enquanto a segunda cópia tem amplitude de 25% do sinal original e está atrasada 1 segundo.

É evidente que a primeira cópia causa interferência destrutiva no sinal, como pode ser observado na Figura 7 no intervalo $[0,5; 1]$ segundos: a amplitude do sinal resultante (em vermelho tracejado) é equivalente a 50% da amplitude original. É dito que a primeira cópia do sinal, neste exemplo, está fora de fase, ocasionando uma interferência destrutiva no sinal. Por outro lado, a segunda cópia está em fase com o sinal original, causando assim, uma interferência construtiva e aumentando a amplitude do sinal no intervalo $[1,5]$ em 25% em relação ao intervalo $[0,5; 1]$.

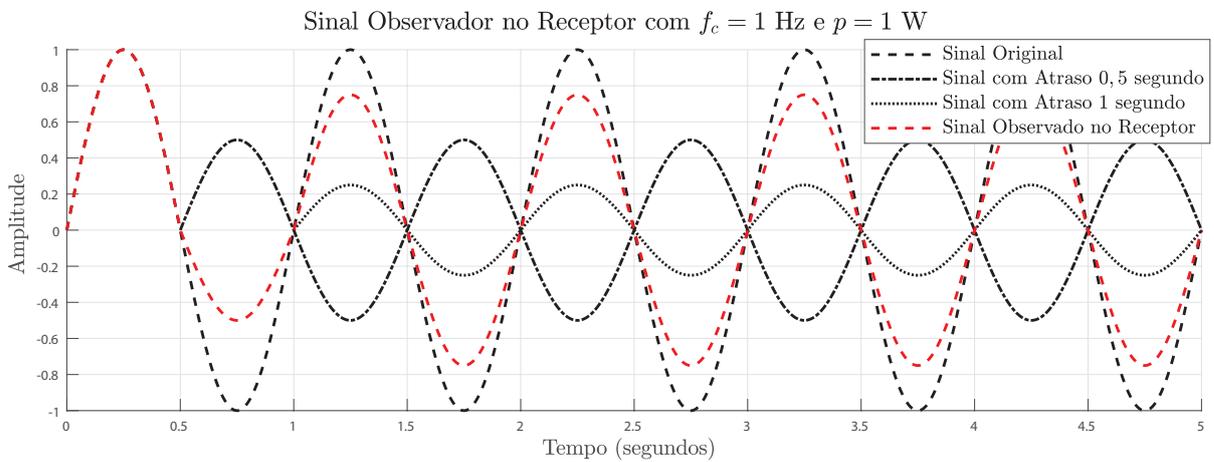


Figura 7: Atrasos decorrente do multi-percurso fonte: do Autor.

Existem diferentes modelos matemáticos para a situação onde o canal passa por Desvanecimento Multi-percurso onde pode-se destacar o de Rice, o qual aplica-se em situações onde há linha de visada entre o transmissor e receptor, e cópias deste sinal são observadas também no receptor. Nesse caso o desvanecimento pode ser modelado por uma variável aleatória que assume distribuição Riciana cuja função de distribuição de probabilidade ($f_r(p)$) é dada por (Durgin 2002):

$$f_r(p) = \frac{2p}{p_{dif}} \exp\left(\frac{-p^2 - v^2}{p_{dif}}\right) I_0\left(\frac{2pv_1^2}{p_{dif}}\right), p \geq 0 \quad (6)$$

onde I_0 é a função Bessel modificada de ordem zero, p é a distorção na amplitude do sinal, v^2 é a potência do sinal na linha de visada e p_{dif} é potência média das componentes sem linha de visada.

Em cenários onde não há linha de visada (do inglês, *Non Line of Sight* - NLOS) entre transmissor e receptor, o canal multi-percurso pode ser modelado por uma variável aleatória com distribuição de *Rayleigh*, cuja função de distribuição de probabilidade é definida por (Durgin 2002):

$$f_r(p) = \frac{2p}{p_{dif}} \exp\left(\frac{-p^2}{p_{dif}}\right) \quad p \geq 0 \quad (7)$$

onde p é potência/energia, p_{dif} potência média do componente não especular.

Comparando de forma qualitativa os modelos de Rice e *Rayleigh*, se torna fácil perceber que o modelo de *Rayleigh* trata do pior caso enquanto o de Rice do melhor caso, uma vez que para uma mesma distância (entre transmissor e receptor) a tendência é que o canal NLOS observe uma distorção maior que o canal LOS justamente pela ausência da componente de linha de visada.

Aprimorando a elucidação desses conceitos, a Figura 8 demonstra em forma gráfica como os efeitos da Perda de Percurso, Sombreamento e Multi-percurso podem influenciar diretamente na perda de potência em função da distância percorrida pelo sinal transmitido.

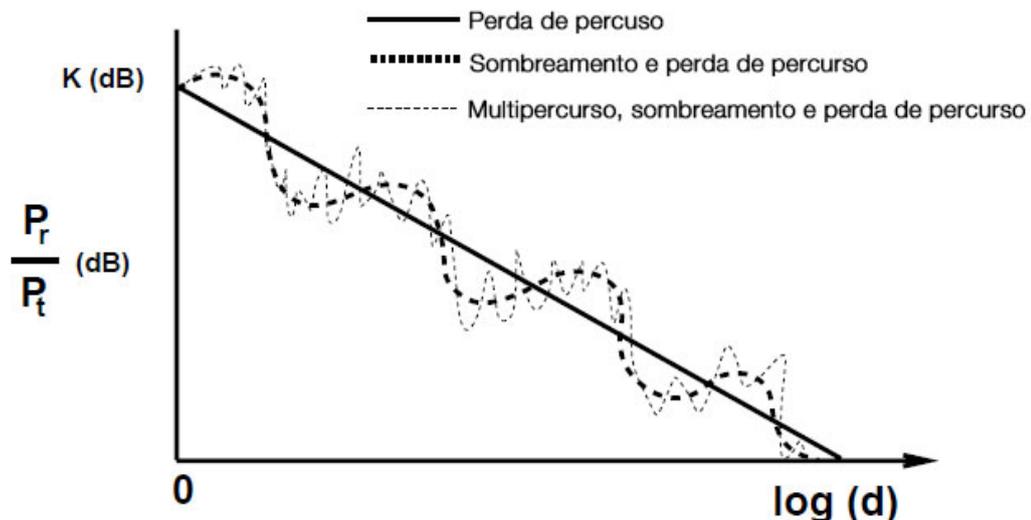


Figura 8: Perda de Percurso, Sombreamento e Multi-percurso em função da distância e potência. Adaptado de (Goldsmith 2005)

2.2.4 CLASSIFICAÇÃO DOS CANAIS DE COMUNICAÇÃO SEM-FIO

Responsável por alterar a amplitude do sinal por meio de flutuações de grande e pequena escala, quando em pequena escala o desvanecimento pode ser classificado em: conforme parâmetros atrelados ao tempo e frequência. Para esta classificação é fundamental a compreensão de dois parâmetros inerentes ao canal de comunicação: o tempo de coerência e a banda de coerência (Tse e Viswanath 2004).

O tempo de coerência é definido como o período no qual o estado do canal permanece constante e está diretamente ligado a mobilidade: quanto maior é a mobilidade (velocidade relativa) entre transmissor e receptor menor é o tempo de coerência e, portanto maior é a variação do estado do canal com o tempo. Matematicamente, o tempo de coerência T_c é inversamente proporcional ao desvio Doppler f_D , i.e. $T_c \propto \frac{1}{f_D}$. O desvio Doppler por sua vez é definido como (Halliday e Resnick 2012):

$$f_D = \frac{v}{c} f_c \quad (8)$$

onde v é a velocidade relativa entre transmissor e receptor, c é a velocidade da luz e f_c a frequência da onda portadora utilizada. Desta forma, fica evidente a relação entre a mobilidade (velocidade relativa) e o tempo de coerência do canal.

Outro parâmetro importante para classificação dos canais de comunicação é a banda de coerência, isto é, o intervalo de frequências que o canal apresenta o mesmo estado. A banda de coerência é inversamente proporcional ao atraso máximo do canal, i.e. $B_c \propto \frac{1}{\tau_{\max}}$. O atraso máximo do canal pode ser interpretado como o intervalo de tempo entre a primeira amostra recebida do sinal e a última amostra recebida do mesmo. Logo, a banda de coerência está diretamente alinhada ao efeito do multi-percurso (Goldsmith 2005).

Com base nos conceitos de banda de coerência e tempo de coerência do canal, os canais podem ser classificados como: desvanecimento rápido ou lento na dimensão tempo e seletivo ou plano na dimensão frequência.

2.2.4.1 CLASSIFICAÇÃO NA DIMENSÃO TEMPO

1. Desvanecimento rápido

O desvanecimento é denominado rápido quando o tempo de coerência do canal T_c é menor que o período de símbolo T_s . Isto é, o tempo necessário para transmitir um símbolo é maior que o período no qual o canal não sofre alterações em seu estado (Tse e Viswanath 2004).

2. Desvanecimento lento

Ocorre quando o período de transmissão de um símbolo é menor que o tempo de coerência, i.e. $T_s < T_c$. Desta forma, o estado do canal permanece inalterado durante a transmissão de todo o símbolo (Tse e Viswanath 2004).

2.2.4.2 CLASSIFICAÇÃO NA DIMENSÃO FREQUÊNCIA

1. Seletivo em frequência

Um canal é denominado seletivo em frequência quando a banda de coerência do canal não é muito maior que a banda do canal, isto é, quando $B_c \gg B$ não é satisfeito, sendo B a largura do canal. De forma geral, canais seletivos em frequência possuem estados diferentes ao longo de toda a largura de banda ocupada (Tse e Viswanath 2004).

2. Desvanecimento Plano

Um canal é plano quando a banda de coerência do canal é muito maior que a banda utilizada, i.e. $B_c \gg B$. Os canais planos possuem o mesmo estado ao longo de uma faixa de frequência delimitada pela largura de banda do canal (Tse e Viswanath 2004).

2.3 SISTEMAS DE COMUNICAÇÃO SEM-FIO SISO

Os sistemas de comunicação baseados em SISO possuem tanto transmissor quanto receptor utilizando apenas uma única antena para transmissão e uma antena

para recepção. Desta maneira, a comunicação ocorre somente via um canal, não existindo assim multiplexação ou diversidade espacial (Patel e Sagar 2012).

Todavia, estes sistemas podem utilizar diferentes tipos de modulação de sinais tais como: Multiplexação por Divisão de Frequência (FMD), Multiplexação por Divisão de Código (CDM), Multiplexação por Divisão de Tempo (TDM), Multiplexação por Divisão de Frequências Ortogonais (OFDM). As tecnologias mais atuais de comunicação sem-fio como o *Long Term Evolution* (LTE/4G) e o padrão IEEE 802.11 (Wi-Fi) utilizam a modulação OFDM. Em sistemas onde o sinal é transmitido a partir de um terminal móvel para uma estação rádio-base utilizando o sistema SISO por meio de multiplexação OFDM pode ser descrito como (Tse e Viswanath 2004):

$$y_n(t) = \sqrt{p} x(t) f(t) \quad (9)$$

onde n é a n -ésima sub-portadora ou sub-canal OFDM, $y_n(t)$ é o sinal transmitido pelo terminal como função do tempo, p é a potência de amplificação de rádio-frequência, $x(t)$ é o símbolo transmitido e $f(t)$ o formatador de pulso, ambos como função do tempo.

O sinal $y_n(t)$ passa por uma canal físico que pode introduzir distorção e ruído no sinal prejudicando o desempenho da transmissão. De forma geral, pode-se descrever o sinal contínuo recebido na estação rádio-base como uma função do tempo, tal que (Tse e Viswanath 2004):

$$r_n(t) = y_n(t) c_n(t) + \eta(t) \quad (10)$$

onde $c(t)$ é a resposta impulsiva do canal no tempo e $\eta(t)$ é o ruído aditivo Gaussiano branco (do inglês, *Additive White Gaussian Noise* - AWGN) no tempo considerando que todas as sub-portadoras possuem a mesma largura de banda.

2.3.1 MÉTRICAS DE DESEMPENHO

A fim de garantir níveis apropriados da qualidade do serviço (QoS) oferecido, um canal e/ou sistema de comunicação necessita de uma métrica com o propósito de determinar a qualidade do mesmo a ser entregue, ou ainda identificar parâmetros insatisfatórios que eventualmente possam gerar dificuldade na comunicação entre usuários prejudicando sua experiência.

No âmbito de qualificar o desempenho, a relação sinal ruído, do inglês *Sinal-to-noise Ratio* (SNR) ou S/N, é uma informação pontual que em cenário de comunicações sem-fios é um indicador utilizado para mensurar o nível do sinal desejado em relação ao nível de ruído de fundo no receptor. Matematicamente (Gragido Daniel Molina 2012) define a SNR como:

$$\delta = \frac{P_{sinal}}{P_{ruído}} \quad (11)$$

onde a δ é a SNR observada no receptor, P_{sinal} é a potência do sinal recebido e $P_{ruído}$ é a potência do ruído de fundo que é equivalente a:

$$P_{ruído} = N_0 B \quad (12)$$

onde N_0 é a densidade espectral de potência do ruído e B a largura de banda do sistema. À temperatura ambiente, $N_0 = K_B \times 298,15 = 4,1164 \times 10^{-21}$ Watts por Hertz.

Adicionalmente à SNR, a capacidade do canal define a taxa máxima de informações que podem ser transmitidas de forma confiável. A taxa de transmissão máxima teórica de um canal, denominada R , é dada pelo teorema de Shannon-Hartley e é matematicamente definida como (Valkenburg 2001):

$$R = B \log_2(1 + \delta) = B \log_2 \left(1 + \frac{Pg}{N_0 B} \right) \quad (13)$$

onde B é a largura de banda do sistema, p é a potência de transmissão, g é o ganho de amplitude do canal, $N_0 B$ é a potência do ruído AWGN.

Considerando um sistema de comunicação sem-fio SISO e suas particularidades, também é possível generalizar as equações para medidas de desempenho em canais paralelos. Utilizando modulação OFDM com N subcanais de mesma largura de banda, pode-se definir a relação sinal-ruído observada na n -ésima subportadora como:

$$\delta_n = \frac{P_n g_n}{N_0 B} \quad (14)$$

onde δ é a relação sinal ruído (SNR), p_n é a potência de transmissão, g_n o ganho de potência do n -ésimo canal, N_0 é a densidade espectral de potência do ruído AWGN e B a largura de banda do subcanal.

A capacidade do sistema pode ser matematicamente definida como:

$$R = \sum_{n=1}^N B \log_2(1 + \delta_n) \quad (15)$$

onde R é a capacidade do sistema igual ao somatório de todos os subcanais N , B é a banda dos subcanais e σ_n é o SNR de cada subcanal.

2.4 SISTEMAS DE COMUNICAÇÃO SEM-FIO MIMO E MASSIVE MIMO

De acordo com o Teorema de Shannon-Hartley, uma forma direta de aumentar a capacidade de transmissão de informação é por meio do aumento na quantidade de potência utilizada para amplificar o sinal, o que gera uma relação sinal ruído maior e portanto uma maior taxa de transmissão. De forma prática, isso permite o uso de modulações de ordem mais alta mantendo as restrições de qualidade de serviço.

Todavia, dada a natureza da equação da capacidade, em que a quantidade de energia necessária para aumentar a taxa de transmissão cresce muito mais rápido do que a quantidade extra de informação efetivamente transmitida, uma vez que trata-se de um logaritmo, é fundamental utilizar a diversidade em diferentes dimensões para aumentar a capacidade dos sistemas de comunicação. Entre as dimensões que podem ser utilizadas está o espaço.

A tecnologia atual que utiliza o espaço como diversidade para aumentar a capacidade do sistema é denominada MIMO, na qual múltiplas antenas de transmissão e recepção são empregadas. O MIMO foi criado em 1993 e patenteado por (Paulraj e Kailath 1994). Tratava-se de um sistema capaz de combinar os sinais provenientes de diferentes transmissores, de tal forma a aumentar a capacidade do sistema transmitindo uma maior quantidade de informação por unidade de tempo.

Nas décadas seguintes os sistemas MIMO evoluíram e tornaram possível tanto o aumento da eficiência espectral por meio da multiplexação de informações em diferentes fluxos espaciais, como o aumento da confiabilidade dos enlaces por meio da transmissão de informação utilizando codificação espaço-temporal. Os sistemas modernos de comunicação, como o padrão IEEE 802.11 e o *Long Term Evolution* (LTE), possibilitam a comunicação utilizando múltiplas antenas de transmissão e recepção.

Em 2010 o trabalho de Marzetta introduziu uma nova perspectiva no universo da tecnologia MIMO: o uso indiscriminado de antenas. Essa nova abordagem onde o número de antenas nas estações rádio base torna-se muito elevado permitiu a proposta de um novo sistema de múltiplo acesso: o Múltiplo Acesso por Divisão Espacial (do inglês, *Space Division Multiple Access* - SDMA) (Björnson et al. 2017).

Esse sistema propõe uma comunicação móvel apoiada na utilização massiva de antenas (ao mínimo de 16) trabalhando com alta eficiência espectral. Ainda segundo (Marzetta 2010), o Massive MIMO possibilita uma comunicação móvel de baixa complexidade nos terminais móveis por meio de uma pré-codificação linear na estação rádio base, que torna o processo de recepção muito mais simples e energeticamente mais eficiente.

2.4.1 TRANSMISSÃO E RECEPÇÃO EM SISTEMAS MASSIVE MIMO

Considere um sistema de comunicação sem-fio operando em TDD com M antenas na estação rádio-base e uma única antena nos terminais móveis. O sistema opera de tal forma que a cada intervalo de coerência do canal sem-fio, a estação rádio-base passa por um processo de treinamento por meio do envio, a partir dos K

usuários do sistema, de uma sequência de bits pré-determinada e única para cada um dos transmissores (denominada sequência piloto), onde devem ser ortogonais entre si, ou seja, s_k e $s_{k'}$ as sequências de treinamento ou sequências piloto dos usuários k e k' respectivamente, então $\langle s_k, s_{k'} \rangle = 0$ (Björnson et al. 2017).

Após o treinamento, ainda no mesmo intervalo de coerência, o sistema pode operar tanto como *uplink* como *downlink*, uma vez que o sistema tem sua duplexação realizada pela dimensão tempo. A Figura 9 ilustra uma configuração típica do sistema *Massive MIMO* onde cada faixa de frequência é utilizada durante um primeiro intervalo para envio do sinal piloto e posteriormente informações (*uplink*, *downlink* ou ambos).

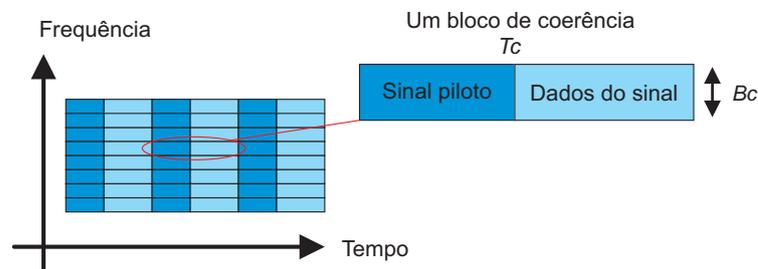


Figura 9: Bloco de coerência, adaptado de (Björnson et al. 2017)

Matematicamente, o sinal de treinamento no *uplink* recebido pela estação rádio base ℓ considerando L células no sistema, é um vetor $M \times 1$ (Björnson et al. 2017):

$$\mathbf{y}_\ell = \sum_{\ell'=1}^L \mathbf{G}_{\ell,\ell'} \mathbf{s}_{\ell'} + \boldsymbol{\eta}_\ell \quad (16)$$

onde $\boldsymbol{\eta}_\ell \sim N(0, \sigma^2)$ é o vetor $M \times 1$ do ruído aditivo Gaussiano de média zero e variância σ^2 sendo cada elemento do vetor mutuamente decorrelacionados; $s_{\ell'}$ são os sinais piloto dos $K_{\ell'}$ usuários da célula ℓ' , $\mathbf{G}_{\ell,\ell'} \in \mathbb{C}^{M \times K_{\ell'}}$ é a matriz de canal onde cada linha indica a condição de canal entre as M antenas da estação rádio base ℓ e o usuário k (coluna) da célula ℓ' .

Na sequência, a estação rádio base ℓ , ao receber o sinal de treinamento das sequências piloto, é capaz de estimar o canal de comunicação entre cada uma das suas M antenas e os terminais móveis, uma vez que as sequências piloto s_ℓ são ortogonais entre si. Desta forma, a matriz de canal estimada pela estação rádio-

base ℓ , $\hat{G}_{\ell,\ell} \in \mathbb{C}^{M \times K}$, assumindo que cada usuário k de cada uma das ℓ célula utiliza a mesma sequência piloto, é definida como (Marzetta 2010):

$$\hat{G}_{\ell,\ell} = \sqrt{\rho_p} \sum_{\ell'=1}^L \mathbf{G}_{\ell,\ell'} + \eta_\ell \quad (17)$$

onde ρ_p é a relação sinal ruído das sequências piloto.

Note que, conforme ressaltado anteriormente, o treinamento ou envio das sequências piloto deve ocorrer uma vez a cada intervalo de coerência neste cenário. Uma vez que as estações rádio-base tenham estimado os valores dos canais o sistema pode passar a enviar informações via *uplink* ou *downlink*.

No caso de uma transmissão via *uplink* o sinal recebido pela torre ℓ pode ser definido como (Marzetta 2010):

$$\mathbf{x}_\ell = \sqrt{\rho_r} \sum_{\ell'}^L \mathbf{G}_{\ell,\ell'} \bar{\mathbf{a}}'_\ell + \bar{\mathbf{w}}_\ell \quad (18)$$

onde $\sqrt{\rho_r}$ é a relação sinal ruído do sinal recebido, $\bar{\mathbf{a}}_\ell$ é o vetor $K \times 1$ com os símbolos de cada usuário e $\bar{\mathbf{w}}_\ell$ é o vetor $M \times 1$ de ruído AWGN com média zero e variância σ^2 .

O sinal recebido é processado utilizando a técnica de Combinação de Taxa Máxima (do inglês, *Maximum Ratio Combining* - MRC) no qual o sinal recebido é multiplicado pelo conjugado transposto da matriz de estimativa de canal $\hat{G}_{\ell,\ell}$. Logo, o sinal recebido e processado pela estação rádio-base ℓ é matematicamente definido como (Marzetta 2010):

$$\begin{aligned} \hat{\mathbf{x}}_\ell &= \hat{G}_{\ell,\ell}^H \mathbf{x}_\ell \\ &= \left[\sqrt{\rho_p} \sum_{\ell'=1}^L \mathbf{G}_{\ell,\ell'} + \eta_\ell \right]^H \left[\sqrt{\rho_r} \sum_{\ell'=1}^L \mathbf{G}_{\ell,\ell'} \bar{\mathbf{a}}'_\ell + \bar{\mathbf{w}}_\ell \right] \end{aligned} \quad (19)$$

onde $(\cdot)^H$ é o operador de transposto conjugado.

De acordo com (Marzetta 2010) o crescimento indiscriminado do número de antenas M implica na eliminação completa do ruído descorrelacionado observado no

receptor e do Desvanecimento de Pequena Escala.

Por outro lado, o sinal enviado pelo sistema no *downlink* passa por um processo de pré-codificação linear, no qual o vetor $K \times 1$ de símbolos enviados é multiplicado pelo conjugado da matriz de estimativas de canais $\hat{\mathbf{G}}_{\ell,\ell}$ da célula em questão. Desta forma, o sinal recebido pelos K usuários da célula ℓ é definido como $\bar{\mathbf{x}}_{\ell} \in \mathbb{C}^{K \times 1}$ tal que (Marzetta 2010):

$$\begin{aligned} \bar{\mathbf{x}} &= \sqrt{p_f} \sum_{\ell'=1}^L \mathbf{G}_{\ell,\ell'}^T \hat{\mathbf{G}}_{\ell,\ell}^* \bar{\mathbf{a}}_{\ell} + \mathbf{w}_i \\ &= \sqrt{p_f} \sum_{\ell'=1}^L \mathbf{G}_{\ell,\ell'}^T \underbrace{\left[\sqrt{p_p} \sum_{\ell'=1}^L \mathbf{G}_{\ell,\ell'} + \boldsymbol{\eta}_{\ell} \right]^*}_{\text{Pré-codificação Linear}} \bar{\mathbf{a}}_{\ell} + \mathbf{w}_{\ell} \end{aligned} \quad (20)$$

onde $(\cdot)^T$ é o operador de transposição de matriz e $(\cdot)^*$ o operador de complexo conjugado.

Ainda de acordo com (Marzetta 2010), o processo de pré-codificação linear permite atingir dois objetivos: o primeiro é equivalente ao observado no *uplink*, isto é, o crescimento do número de antenas implica no desaparecimento dos efeitos nocivos tanto do ruído do receptor como do desvanecimento de pequena escala. O segundo objetivo é a simplificação dos receptores dos terminais móveis, pois não há necessidade de um processamento de sinal digital complexo uma vez que o mesmo é feito por meio da pré-codificação na estação rádio-base, aumentando desta forma a eficiência energética dos receptores móveis e reduzindo os custos de construção dos mesmos.

2.4.2 MÉTRICAS DE DESEMPENHO EM SISTEMAS MASSIVE MIMO

Para introduzir as métricas de desempenho ao sistema *Massive MIMO* é fundamental diferenciar nos coeficientes de ganho de canal das matrizes \mathbf{G} os efeitos de desvanecimento de Pequena e de Grande Escala. Logo, considerando $\mathbf{G}_{\ell,\ell'} \in \mathbb{C}^{M \times K}$ cujos os elementos são (Marzetta 2010):

$$g_{m,k,\ell,\ell'} = \sqrt{\beta_{k,\ell,\ell'}} h_{m,k,\ell,\ell'} \quad (21)$$

onde M é o indexador de antena, k de usuário, ℓ de célula de interesse à qual pertencem os usuários k , ℓ' de célula de destino à qual pertencem as antenas M , β é o coeficiente de atenuação da potência em decorrência da perda de percurso e do sombreamento e, finalmente h é o desvanecimento de pequena escala atrelado ao efeito do multi-percurso. De forma equivalente, é possível representar uma linha da matriz $G_{\ell,\ell'}$ como:

$$\mathbf{g}_{k,\ell,\ell'} = \sqrt{\beta_{k,\ell,\ell'}} \mathbf{h}_{k,\ell,\ell'} \quad (22)$$

Nota-se que para uma determinada combinação de terminal móvel (k, ℓ) e estação rádio-base (ℓ') , os efeitos de perda de percurso e sombreamento são considerados idênticos em todas as M antenas da estação ℓ . Adicionalmente, neste trabalho assume-se que os diferentes coeficientes do desvanecimento, $h_{m,k,\ell,\ell'}$ são resultado de soma complexa de variáveis aleatórias Gaussianas de média nula e variância unitária. Já o efeito da Perda de Percurso e Sombreamento são considerados conforme a Equação (4).

Desta forma, a relação sinal ruído mais interferência do usuário k da célula ℓ é definida como (Marzetta 2010):

$$\delta_{k,\ell} = \frac{\beta_{k,\ell,\ell}}{\sum_{\substack{\ell' \neq \ell \\ \ell'=1}}^L \beta_{k,\ell,\ell'}} \quad (23)$$

Note na Equação (23) que os usuários k de cada uma das L células utilizam a mesma sequência piloto e, portanto, causam interferência inter-celular (ℓ) durante todo o processo de treinamento e transmissão de informação. Este problema de interferência é denominado contaminação piloto e será discutido na próxima Seção.

2.4.3 O PROBLEMA DA CONTAMINAÇÃO PILOTO

A fim de possibilitar o múltiplo acesso e estimar as condições de cada canal no sistema *Massive MIMO*, (Marzetta 2010) propôs uma sequência de bits denominada sequência piloto. Trata-se de uma sequência única para cada terminal do sistema e que são ortogonais entre si. Este mecanismo é utilizado para treinar a comunicação de tal forma a permitir uma pré-codificação linear na estação rádio-base a qual busca anular os efeitos nocivos introduzidos pelo canal sem-fio e simplifica o receptor aumentando assim sua eficiência energética.

A contaminação piloto ocorre em razão da necessidade de reaproveitamento de sequências piloto pela ERB conforme cresce o número de usuários no sistema. Uma vez que a sequência piloto deve ser transmitida a cada intervalo de coerência do canal, o que na prática significa múltiplas vezes por segundo, quanto maior o tamanho desta sequência, maior será o tempo necessário para estimar o canal, em outras palavras, em um cenário de sequência consideravelmente longa o usuário passará a maior parte do tempo estimando o canal ao invés de efetivamente transmitindo ou recebendo informações da estação rádio-base. Adicionalmente, as sequências podem ser utilizadas por células próximas que transmitem na mesma frequência e estariam interferindo no sinal utilizado para treinamento de ambas as células conforme ilustra a Figura 10.

Quando esta situação ocorre, as estimativas dos coeficientes de canal passam a conter erros e o desempenho do sistema em termos de vazão e confiabilidade podem ser comprometidos (Björnson et al. 2017). Desta forma, a distribuição das sequências piloto torna-se um problema de importância fundamental para operacionalização dos sistemas *Massive MIMO* conforme pode ser observado nos trabalhos relacionados encontrados na literatura apresentados na Seção 2.5.

2.5 TRABALHOS RELACIONADOS

Após o conceito de múltiplas antenas ser proposto por (Marzetta 2010), como já discutido na Seção 2.1, diferentes autores passaram a debruçar-se sobre o problema de alocação de sequências piloto com o intuito de minimizar o efeito

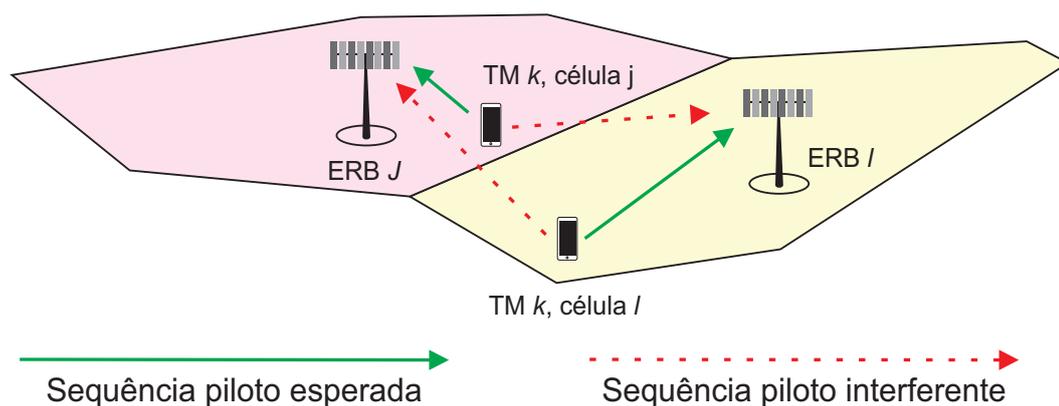


Figura 10: Contaminação sequência piloto (Björnson et al. 2017)

da contaminação piloto. Neste sentido, esta Seção apresenta de forma cronológica trabalhos relacionados que utilizando diferentes técnicas e ferramentas contribuíram para os avanços na área.

O trabalho de (Jin et al. 2015) aborda a contaminação piloto em sistemas *Massive MIMO* como um problema de otimização cuja solução é obtida utilizando algoritmos gulosos de baixa complexidade e com o objetivo de maximizar a vazão total do sistema. O artigo compara em cenários macrocelulares o desempenho dos algoritmos: busca gulosa, busca Tabu e um algoritmo híbrido combinando a busca gulosa à busca Tabu.

Nos trabalho de (Zhu et al. 2015) foi proposta uma melhoria referente a contaminação piloto em sistemas *Massive MIMO* por meio de uma técnica pelos autores denominada *Smart Pilot Assingment*. O algoritmo proposto busca a maximização da relação sinal interferência mais ruído de todos os usuários da célula. Para tal, a estação rádio-base mensura a interferência intercelular de cada sequência piloto causada por usuários que utilizam a mesma sequência em células adjacentes. O algoritmo então atribuí as sequências piloto com menor interferência intercelular aos usuários com a pior qualidade de canal.

Buscando resultados similares, o trabalho de (Ku et al. 2016) apresenta solucionar o problema por meio de um algoritmo de baixa complexidade utilizando uma estratégia de busca gulosa. O algoritmo dos autores seleciona um usuário de cada célula a fim de formar um grupo de usuários onde é calculado a taxa de transmissão de todas as combinações possíveis escolhendo o grupo que possui a maior taxa de

transmissão para alocar as sequências. Feito isso, os usuários selecionados de cada célula são removidos, a taxa de transmissão de todas as combinações possíveis dos usuários em cada célula são calculados e então é selecionado o grupo com maior taxa de transferência para alocar a sequência piloto, este processo é repetido (remover os usuários de cada célula e calcular a taxa de transmissão de todas as possibilidades) até que todas as sequências estejam atribuídas.

De forma alternativa, o trabalho de (Teeti et al. 2016) modela o problema de alocação de sequências piloto por meio de um problema de otimização multi-objetivo o qual é solucionado utilizando o método de otimização Épsilon-restrito. O algoritmo proposto considera apenas um dos objetivos enquanto os demais são transformados em restrições.

Em uma outra abordagem (Zhou e Wang 2016) utilizam uma técnica de agendamento baseado no algoritmo de *water-filling*. Nesta solução considera-se características dos canais e sinais pilotos analisando o grau de interferência entre diferentes canais. Ainda de acordo com o algoritmo, são designados sequências pilotos cuja interferência inter-celular é menor para usuários que possuem canais mais favoráveis e sequências com interferências severas para usuários com canais ruins, sendo assim, todo o desempenho do sistema pode ser otimizado.

Já para os autores (Zhang et al. 2016) o problema de alocação de sequências piloto em sistemas *Massive MIMO* foi solucionado utilizando Algoritmos Genéticos. Os resultados puderam ser avaliados em desempenho e complexidade computacional com os experimentos publicados no ano anterior pelos autores (Jin et al. 2015).

No trabalho de (Niu et al. 2017) é proposto que a contaminação de sequências piloto seja minimizada considerando a divisão setorial das células onde atribui-se sequências ortogonais para os diferentes usuários da mesma célula setorializada, estas são reutilizadas entre as diversas células reduzindo o tamanho do piloto e otimizando a eficiência espectral por meio de estimativa Bayesiana explorando as estatísticas de segunda ordem dos vetores com as condições dos canais.

O sistema de alocação de sequências piloto proposto por (Alkhaled et al. 2017) é adaptativo e baseia-se nos valores assintóticos de relação

sinal interferência mais ruído dos usuários do sistema. O algoritmo agrupa os usuários de cada célula em grupos de alta e baixa interferência o qual embora consuma mais recursos do sistema se comparado ao método de alocação convencional, conforme citado por (Alkhaled et al. 2017), é capaz de melhorar o desempenho do sistema por utilizar menos sequências ortogonais baseando-se apenas no coeficiente de larga escala que mudam lentamente ao longo do tempo e são rastreados com baixa complexidade.

Os autores (Zhang et al. 2017) sugerem em seu trabalho uma solução para mitigação da contaminação piloto baseado no controle de potência. A fim de alcançar este objetivo, o controle de energia do *uplink* busca maximizar o menor valor da Relação Sinal Ruído mais Interferência (do inglês, *Signal to Interference Plus Noise Ratio* - SINR) dos usuários do sistema ou a SINR média do *downlink* de toda a rede. Para isso o GA foi empregado no cálculo dos níveis de potência a serem utilizados pelos terminais móveis. Estes valores são calculados na estação rádio-base e transmitidos aos terminais por meio do canal de serviço.

Sob a mesma perspectiva, os autores (Lago et al. 2018) apresentaram um algoritmo para mitigar a contaminação de pilotos baseado na combinação de sequências piloto multiplexadas no tempo. Os autores propuseram a divisão celular para atribuição de pilotos cujo princípio básico esta em separar espacialmente usuários que compartilhem a mesma sequência piloto. A partir desta abordagem implementaram um algoritmo capaz de explorar amostras contaminadas durante a estimativa do canal que puderam ser obtidas por meio de pilotos multiplexados no tempo, no qual a qualidade da estimativa do canal se baseia no piloto sobreposto durante a transmissão de dados no uplink.

Para (Kim et al. 2018) a alocação de sequências piloto pode ser otimizada por meio de aprendizado supervisionado. Os autores indicaram que os usuários fossem rotulados conforme sua localização em todas as células e pré-processados para aprendizado considerando localização, qualidade do canal e interferência inter-celular em todas as células. A partir destas métricas o aprendizado supervisionado foi implementado com *Multilayer Perceptron* (MLP) e *Convolutional Neural Network* (CNN), onde após processamento a atribuição de sequências para cada usuário é

realizada.

Os autores (Gao et al. 2018) desenvolveram um algoritmo de Clusterização para definir o uso das múltiplas sequências piloto de forma única em cada cluster. Nesta abordagem os usuários são divididos em grupos de baixa e alta interferência no qual grupos com baixa interferência reutilizam pilotos aleatoriamente enquanto grupos de usuários de alta interferência são agrupados por afinidade de propagação. Os autores aplicam nestes grupos uma estratégia de alocação de sequência piloto onde todos os usuários classificados como altamente interferentes são designados com sequências pilotos mutuamente ortogonais, usuários diferentes são alocados com sequências reutilizadas sobre o princípio da definição da união de todos os conjuntos de índices que o usuário usa. Um usuário só pode utilizar a sequência caso não haja elemento em comum entre o conjunto de índices no seu cluster.

Em uma abordagem conjunta propondo uma solução que aloca sequências pilotos e potência, os autores (Luo et al. 2019) utilizaram a Árvore de Busca de Monte Carlo juntamente com o algoritmo *AlphaGo*. Neste estudo ainda utilizaram *Markov Decision Problem* para alocação de energia. O conjunto de soluções propõem aprender qual a melhor potencia e sinal para cada usuário aumentando assim a relação SINR.

Para os autores (Khan et al. 2019) o problema da alocação de sequências piloto pode ser mitigado categorizando os usuários em alta e baixa interferência baseado no Desvanecimento de Larga Escala. Nesta abordagem pilotos ortogonais são atribuídos para usuários de alta interferência e para usuários de baixa interferência as sequências são atribuídas em base de prioridade utilizando *Edge Weighted Graph*, sendo assim capaz de aprimorar a performance do sistema.

Mais recentemente, (Nie e Zhao 2020) apresentaram em seu trabalho um método para alocação de sequências piloto e otimização do tamanho das sequências piloto em sistemas *Massive MIMO* com o objetivo de maximizar a eficiência espectral. O trabalho propõe um *range* de sequências pilotos baseado no intervalo de coerência estabelecendo uma base de alocação com a qual as sequências piloto devem ser alocadas. Na sequência, o trabalho então um esquema que simultaneamente minimiza o tamanho das sequências piloto e o efeito da contaminação piloto e desta

forma maximiza a eficiência espectral do sistema. O algoritmo é baseado nos trabalhos de (Zhu et al. 2017) e no de (Xu et al. 2018).

Assim como já citado nos trabalhos relacionados acima, a literatura já apresenta variadas soluções candidatas para o problema da contaminação por sequências piloto, há trabalhos propondo utilização de soluções baseados em algoritmos clássicos como: busca guiada, aprendizado supervisionado, clusterização, controle de potência, algoritmos heurísticos, além de outras soluções personalizadas como já citado e pode ser consultados de maneira sucinta na Tabela 2. Contudo esse trabalho propõe otimização com a alocação de sequências piloto por meio de meta-heurísticas aplicadas por meio de algoritmos evolutivos GA e PSO.

A escolha da aplicação de meta-heurísticas está diretamente relacionado a condição temporal ao qual se aplica o problema, isto é, para alcançar o objetivo da otimização os algoritmos devem ser rápidos o suficiente para representarem um ganho de performance em relação a não utilização dos mesmos, ou ainda do gargalo gerado pela contaminação, requisitos estes encontrados nas meta-heurística escolhidas.

Autor	Natureza do problema	Tipo de solução usada	Cenário
(Jin et al. 2015)	Agendamento e reutilização de sequências pilotos	Algoritmo Guloso, Busca Tabu e Busca Tabu Gulosa comparando com busca exaustiva	Cenário macro celular de testes de até 3 células, testado entre 2 e 32 usuários.
(Zhu et al. 2015)	Maximizar SINR	Maximizar SINR por meio da remoção de inferência inter celular por meio do algoritmo denominado <i>Smart Pilot Assignment</i>	7 células de 500m com 8 usuários e até 512 antenas.
(Ku et al. 2016)	Contaminação de sequências pilotos	Utiliza busca gulosa em comparativo com busca exaustiva	3 células com 100 antenas cada, raio de 1000m com 4 usuários por célula.
(Teeti et al. 2016)	Alocação de sequências pilotos	Otimização por meio de um algoritmo utilizando Épsilon Restrito	20 usuários por célula de 1000m cada.
(Zhou e Wang 2016)	Contaminação de sequências pilotos	Técnica de agendamento por meio da utilização do algoritmo de <i>Water-filling</i>	7 células de 2000m com 5 usuários cada.
(Zhang et al. 2016)	Alocação de sequências piloto e otimização da taxa de transferência do sistema	Algoritmo Genético utilizado para alocação de sequências piloto	Até 4 células de 1.600m, 100 antenas com até 4 usuários executando 100 iterações.
(Luo et al. 2019)	Alocação de sequência pilotos e energia baseado em games	Utilizando os algoritmos Arvore de Busca Monte Carlo, AlphaGo e <i>Markov Decision Problem</i> propõem um aprendizado para alocação de recursos	4 células com 8 usuários em um total de 32 usuários totais no sistema com uma distância entre cada um de 35 a 1.000m.

Tabela 2: Trabalhos Relacionados

Autor	Natureza do problema	Tipo de solução usada	Cenário
(Khan et al. 2019)	Alocação de sequências piloto com mitigação de interferência baseado em <i>Edge Weight Graph</i>	Contaminação piloto é mitigada dividindo os usuários em dois grupos: alta e baixa interferência onde pilotos ortogonais são atribuídos para usuários de alta interferência e sequencias pilotos baseadas em <i>Edge Weight Graph</i> são atribuídas para pilotos de baixa interferência.	7 células, 32 a 512 antenas, 6 usuários, célula com raio de 1000m.
(Nie e Zhao 2020)	Alocação de sequências piloto baseado em otimização conjunta	Inspirados nos algoritmos <i>Weight Algorithm</i> e <i>Length Optimization</i> os autores propõe um algoritmo pelo qual é criado um range de sequências pilotos onde tem seu tamanho reduzido via otimização conforme a alocação baseada na distância entre usuários.	19 Células, 10 usuários por célula de raio entre 5 e 500m e número de antenas entre 10 e 1000.
Neste trabalho	Alocação de sequências piloto	Utilização do GA binário, BPSO, técnica <i>Smallest Position Value</i> e <i>Variable Neighborhood Search</i> atrelados ao PSO.	7 células, 20/40/60 usuário por célula, raios de 100/250/500/1.000m com 200 antenas

Tabela 3: Trabalhos Relacionados

3 METODOLOGIA

Neste Capítulo é apresentado o problema de otimização abordado e os diferentes algoritmos utilizados na resolução. Neste sentido o Capítulo se divide nas seguintes seções: inicialmente a Seção 3.1 apresenta a alocação de sequências piloto em sistemas *Massive MIMO*, na sequência a Seção 3.2 aborda as ferramentas candidatas a solução do problema proposto, na Seção 3.3 o Algoritmo Genético é implementado de modo a solucionar o problema proposto na Seção 3.1. Finalmente, na Seção 3.4 o algoritmo de Otimização por Enxame de Partículas é apresentado e comparado o desempenho obtido com o GA.

3.1 ALOCAÇÃO DE SEQUÊNCIAS PILOTO EM SISTEMAS MASSIVE MIMO

Neste trabalho, para alocação de sequências pilotos considera-se um sistema *Massive MIMO* com $L > 1$ células operando no mesmo canal de comunicação sem-fio em modo TDD com K_ℓ dispositivos móveis conectados a cada uma das $\ell = 1, \dots, L$ estações rádio-base pertencentes as L células, cada uma delas com M antenas, $M \gg K_\ell$.

O processo de transmissão é dividido em treinamento e transmissão de dados. Para realizar o treinamento por meio de sequências piloto mutuamente ortogonais, em cada uma das células o sistema utiliza a técnica: Fator de Propagação Variável Ortogonal (do inglês, *Orthogonal Variable Spreading Factor* - OVSF) para gerar o código da sequência piloto. Desta forma, para um número K_ℓ de usuários na célula basta que a sequência tenha o mesmo tamanho em bits para que todos os usuários de uma célula tenham sequências piloto ortogonais umas as outras.

O processo de alocação de sequências piloto (T_p) a usuários é feito por meio

de uma hiper-matriz $\Phi \in \{0, 1\}^{K_\ell \times T_p \times L}$ na qual os elementos são definidos como:

$$\phi_{k,q,\ell} = \begin{cases} 0 & \text{sequência piloto não está alocada} \\ 1 & \text{sequência piloto está alocada} \end{cases} \quad (24)$$

onde $\phi_{k,q,\ell}$ representa a alocação da sequência piloto q para o usuário k da célula ℓ .

De acordo com (Marzetta 2010), a relação sinal ruído do *uplink* do usuário k na célula ℓ quando o número de antenas M cresce indefinidamente é dado por:

$$\delta_{k,\ell} = \frac{\beta_{k,\ell,\ell}}{\sum_{\substack{\ell' \neq \ell \\ \ell'=1}}^L \sum_{k'=1}^{K_{\ell'}} \phi_{k,\ell} \phi_{k',\ell'}^T \beta_{k',\ell',\ell}} \quad (25)$$

onde k e ℓ são o usuário e célula de interesse, k' e ℓ' os indexadores de usuários e células interferentes, respectivamente, β é o ganho de potência do canal¹, $\phi_{k,\ell}$ é um vetor de alocação para o usuário k da célula ℓ , isto é, trata-se de uma linha da hiper-matriz Φ . O produto interno dos vetores no denominador será equivalente a 1 quando a sequência piloto alocada for a mesma identificando assim os interferentes. Quando as sequências piloto alocadas para os usuários k da célula ℓ e k' da célula ℓ' forem diferentes o produto interno $\phi_{k,\ell} \phi_{k',\ell'}^T$ será nulo, i.e. o usuário k' da célula ℓ' não é interferente.

A hiper-matriz binária de alocação de sequências piloto possui três dimensões: a primeira dimensão, as linhas da matriz, trata dos usuários, a segunda, as colunas, designam as sequências piloto disponíveis, e por fim, a terceira, profundidade, representando o número de células diferentes.

A Figura 11 apresenta de forma visual a hiper-matriz de um cenário hipotético com 10 usuários e 10 células, compondo uma hiper-matriz com 10 linhas por 10 colunas por 10 linhas em profundidade.

A eficiência espectral do sistema pode ser calculada a partir da SINR utilizando-se o Teorema de Shanon-Hartley (Tse e Viswanath 2004):

¹Neste caso, o ganho de potência considerando os efeitos da perda de percurso e do sombreamento conforme a Eq. (4).

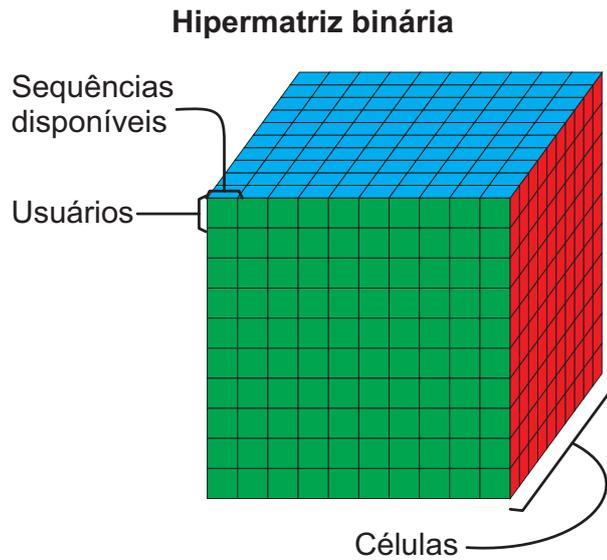


Figura 11: Representação de hiper-matriz binária em um cenário com 10 células atendendo 10 usuários por célula.

$$R_{k,\ell} = \log_2(1 + \delta_{k,\ell}) \quad (26)$$

onde $R_{k,\ell}$ é a eficiência espectral do usuário k da célula ℓ e $\delta_{k,\ell}$ a SINR do mesmo.

A partir das definições matemáticas apresentadas ao longo desta Seção é possível descrever o problema de otimização cujo objetivo é a maximização da eficiência espectral do sistema:

$$\begin{aligned}
 & \underset{\Phi}{\text{maximize}} && \mathcal{J}(\Phi) = \sum_{\ell=1}^L \sum_{k=1}^{K_\ell} \log_2(1 + \delta_{k,\ell}) \\
 & \text{subject to} && \text{(C.1)} \quad \sum_{q=1}^{T_p} \phi_{k,q,\ell} \leq 1, \forall k \text{ and } \ell \\
 & && \text{(C.2)} \quad \sum_{k=1}^{K_\ell} \phi_{k,q,\ell} \leq 1, \forall q \text{ and } \ell \\
 & && \text{(C.3)} \quad \phi_{k,q,\ell} \in \{0, 1\}, \forall k, q, \ell
 \end{aligned} \quad (27)$$

onde (C.1) é a restrição de uma sequência piloto alocada por usuário em cada célula, (C.2) é a restrição de um usuário por sequência piloto em cada célula, e (C.3) é a restrição que cada elemento da matriz da alocação de sequência piloto é binário.

As restrições C.1, C.2 e C.3 descritas no problema de alocação (27) também

são a base para a inicialização da primeira geração de sequências pilotos para os algoritmos (população), isto é, considerando a representação da hiper-matriz apresentada na Figura 11, cada usuário recebe uma sequência aleatória repetindo o domínio do problema (27).

3.2 FERRAMENTAS UTILIZADAS

Considerando os resultados obtidos pela aplicação de diferentes métodos computacionais para a resolução do problema de otimização abordado, apresentados na Seção 2.5, neste trabalho são utilizadas diferentes meta-heurísticas para solucionar o problema da alocação de sequências piloto descrito na Equação (27): Algoritmo Genético e diferentes versões do algoritmo de Otimização por Enxame de Partículas (do inglês, *Particle Swarm Optimization* - PSO) aplicando ainda o SPV (do inglês, *Smallest Position Value*), escolhido em razão de ser um mecanismo também utilizado para transformar o domínio do problema de binário para inteiro.

Uma vez que o processo de alocação de sequências piloto pode ser repetido múltiplas vezes num intervalo de tempo curto, em decorrência da mobilidade dos terminais e também pela volatilidade das conexões, utilizar técnicas menos complexas do ponto de vista computacional que métodos clássicos para solução de problemas, como o abordado, torna-se uma alternativa promissora.

3.3 ALGORÍTMO GENÉTICO

No início dos anos sessenta, John Holland introduziu o algoritmo estocástico baseado na teoria evolucionária das espécies, o Algoritmo Genético. Essa meta-heurística reproduz artificialmente gerações, populações, cromossomos, genes e indivíduos de tal forma que estas representações são manipuladas probabilisticamente a fim de gerar novos indivíduos e mutações com o intuito de alcançar um resultado cada vez melhor para o problema otimização (Guo e Han 2010).

Com o propósito de avaliar constantemente sua população e indivíduos gerados é necessário qualificar melhores e piores resultados existentes e para tal os

indivíduos da população são submetidos a função *fitness* do problema de otimização apresentada na Equação (27) e reproduzida a seguir:

$$\mathcal{J}(\Phi) = \sum_{\ell=1}^L \sum_{k=1}^{K_{\ell}} \log_2(1 + \delta_{k,\ell}) \quad (28)$$

onde k e ℓ são os indexadores de usuário e célula, respectivamente, L são as células, δ é a SINR e Φ é o indivíduo da população do GA candidato a solução (hiper-matriz binária).

Adicionalmente, as restrições (C.1), (C.2) e (C.3) apresentadas no problema original (27) são incorporadas no GA por meio da implementação dos operadores de *crossover* e mutação, i.e. as operações ocorrem de tal forma a gerar apenas indivíduos que estejam contidos no domínio do problema considerando as restrições impostas. Desta forma, nenhum tipo de descarte de soluções infactíveis ou até mesmo de função penalidade é necessário para que o GA atenda as restrições do problema.

O fluxograma de operação do GA é apresentado na Figura 12. O primeiro passo é a inicialização da população inicial que é feita de forma aleatória e composta apenas por soluções factíveis. Posteriormente, é feita a avaliação dos indivíduos por meio da função *fitness* e, em seguida, os melhores indivíduos da população são selecionados utilizando o método conhecido como roleta viciada. Nesse processo são favorecidos estatisticamente indivíduos com valores de *fitness* melhores uma vez que possuem maior probabilidade de serem escolhidos. Os indivíduos selecionados (pais) passam pela operação de *crossover* trocando parte de seus genes dando origem a novos indivíduos chamados de filhos.

Na sequência, os filhos gerados podem sofrer uma mutação a qual permite que os novos indivíduos possam ser melhores que gerações anteriores. Neste trabalho a taxa de mutação é um parâmetro a ser otimizado no GA definido como T_m . Durante a mutação, parte da solução contida no indivíduo é alterada de forma aleatória gerando uma solução que mistura parte do resultado do *crossover* com outra parte aleatória. Este processo é executado de tal forma que o resultado da mutação não deixe de atender as restrições (C.1) a (C.3) do problema original na Equação (27).

Após os operadores genéticos terem sido processados, os indivíduos são

novamente avaliados pela função *fitness*, conforme a Equação (27), após avaliação, caso o novo indivíduo seja melhor que o pior indivíduo alocado na geração anterior, este é incorporado a nova geração substituindo o pior, tal como a Figura 12.

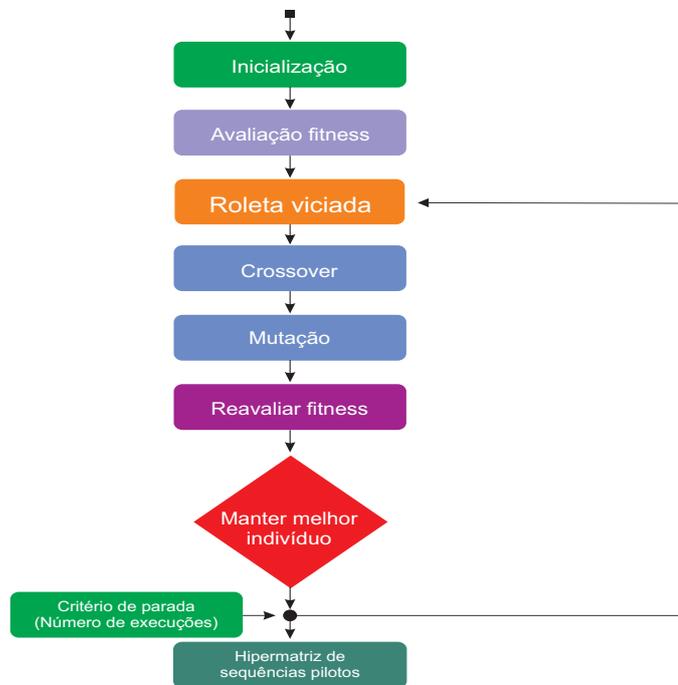


Figura 12: Fluxograma GA - fonte: pr prio autor

Aplicando os conceitos de Holland, o Algoritmo 1 apresenta o pseudoc digo do algoritmo gen tico utilizado no problema de aloca o de sequ ncias piloto. Este busca maximizar o somat rio de todas as efici ncias espectrais e simultaneamente atender as restri es C.1, C.2 e C.3 do problema de otimiza o descrito na Equa o (27).

Por este trabalho abordar um problema de otimiza o cujo o  timo global n o   conhecido a priori, dada a diversidade de cen rios poss veis, um comparativo com outros algoritmos evolutivos se faz necess rio para parametriza o da assertividade da solu o escolhida. Desta forma, nas pr ximas se es ser o apresentadas outras meta-heur stica tamb m utilizadas para solu o do problema de aloca o de sequ ncias piloto em sistemas *Massive MIMO*.

Algorithm 1: GA Binário

input : Número máximo de gerações - G_{\max}
 Taxa de mutação - T_m
 Beta - β
 Hiper-matrix - Φ
 Tamanho População - P_{\max}
 Número de rádios - R
 Sequência piloto - T_p
 Número de células - ℓ

output:
 Hiper-matrix de sequências pilotos alocadas Φ
 Cria N soluções candidatas $\mathbf{x}_1[1], \dots, \mathbf{x}_N[1]$;
for $t = 1$ **until** G_{\max} **do**
 for $n = 1$ **until** $N/2$ **do**
 Selecionar dois pais $\mathbf{x}_i[t]$ e $\mathbf{x}_j[t]$ usando partes proporcionais;
 Executar a operação crossover gerando $x_i[t + 1]$ e $x_j[t + 1]$;
 if $\text{rand}(0, 1) > T_m$ **then**
 | Executar a operação de mutação;
 end
 end
 Avaliar $\mathcal{J}(\mathbf{x}_n[t + 1])$ para todo x ;
 if $\nexists n$ de modo que $\mathcal{J}(\mathbf{x}_n[t + 1]) > \max(\mathcal{J}(\mathbf{x}[t]))$ **then**
 | Preserve a melhor solução da geração t substituindo a pior solução
 | em $t + 1$;
 | $\min_n(\mathcal{J}(\mathbf{x}_n[t + 1])) = \max_n(\mathcal{J}(\mathbf{x}_n[t]))$;
 end
end

3.4 OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS (PSO)

Utilizando o paradigma da cooperação entre indivíduos, ao contrário da competição do GA, James Kennedy e Russell Eberhart em 1995 apresentaram uma meta-heurística capaz de otimizar resultados abstraindo o movimento de grupo de aves em busca de comida. Esse algoritmo recebeu o nome de Otimização por Enxame de Partículas (*Particle Swarm Optimization* - PSO) onde a velocidade e posição de cada indivíduo é alterada de forma dinâmica com o intuito de buscar a melhor solução para um problema de otimização (Banks 2007).

Por se tratar de uma heurística amplamente utilizada e ao mesmo tempo computacionalmente simples, diferentes versões do PSO serão abordadas neste trabalho: o PSO binário, o PSO combinado com a técnica SPV, PSO com Busca

em Vizinhança Variável (do inglês, *variable neighborhood search* - VNS) e o PSO com Velocidade Global.

3.4.1 PSO BINÁRIO (BPSO)

Diferentemente do PSO contínuo original, onde trajetórias são definidas como alteração na posição, o *Binary Particle Swarm Optimization* (BPSO) proposto em 1997 associa a posição de uma partícula a probabilidade de seus valores binários mudarem em cada uma das dimensões, ou seja, no caso deste trabalho as dimensões usuários, sequências e células (Nezamabadi-pour et al. 2008).

De acordo com os trabalhos de (Banks 2007) e (Nezamabadi-pour et al. 2008), a velocidade de uma partícula no BPSO é atualizada da mesma forma que no PSO convencional, isto é:

$$\mathbf{v}_j[t+1] = \omega \mathbf{v}_j[t] + c_1 r_1 (\mathbf{x}_j[t] - \mathbf{p}_j) + c_2 r_2 (\mathbf{x}_j[t] - \mathbf{p}_g) \quad (29)$$

onde t designa a iteração atual do algoritmo, ω é a inércia, \mathbf{v}_j é a velocidade do candidato j velocidade, \mathbf{x}_j é a posição da partícula no espaço de busca, \mathbf{p}_i é a melhor posição candidata j , \mathbf{p}_g é a melhor posição de geral de toda população. Adicionalmente, r_1 e r_2 são variáveis aleatórias com distribuição uniforme no intervalo $(0,1)$ e c_1 e c_2 são parâmetros a serem otimizados no algoritmo.

Uma vez que a falta de controle na velocidade da partícula pode impedi-la de encontrar uma solução melhor para o problema, uma restrição de velocidade no intervalo entre $\{0,1\}$ pode ser aplicada a cada dimensão como a Equação (30) demonstra:

$$v_i[t+1] = \begin{cases} v_{\max} & \text{se } v_i[t+1] > v_{\max} \\ -v_{\max} & \text{se } v_i[t+1] < -v_{\max} \end{cases} \quad (30)$$

Com a velocidade calculada e seus limites inferior e superior impostos, é possível atualizar a posição de cada uma das partículas da população seguindo a

Equação:

$$\mathbf{x}_i[t+1] = \mathbf{x}_i[t] + \mathbf{v}_i[t+1] \quad (31)$$

onde $\mathbf{x}_i[t]$ é a posição da partícula i na t -ésima iteração do algoritmo.

Uma vez que $\mathbf{x}_i[t]$ é uma variável contínua atrelada a probabilidade de mudança de cada uma das dimensões do problema, a probabilidade de mudança no valor binário de cada dimensão de \mathbf{x} é calculada por meio da Equação:

$$p(x_{i,k,q,\ell}[t]) = e^{-x_{i,k,q,\ell}[t]} \quad (32)$$

onde $x_{i,k,q,\ell}[t]$ é o valor da posição do indivíduo i para o usuário k , sequência piloto q e célula ℓ . No BPSO, cada indivíduo i tem sua posição \mathbf{x}_i atrelada a uma matriz de alocação Φ_i que contém valores apenas binários. Neste sentido, $p(x_{i,k,q,\ell}[t])$ é a probabilidade de $\phi_{i,k,q,\ell}$ mudar de valor, isto é, a cada iteração t do algoritmo, para cada indivíduo i da população e para cada uma dos elementos da hiper-matriz Φ_i define-se $r_{i,k,q,\ell} \sim U(0,1)$ e calcula-se o novo valor de alocação para cada elemento de acordo com a Equação:

$$\phi_{i,k,q,\ell}[t+1] = \begin{cases} 0, & \text{se } \phi_{i,k,q,\ell}[t] = 0 \text{ e } r_{i,k,q,\ell}[t+1] > p(x_{i,k,q,\ell}[t+1]) \\ 1, & \text{se } \phi_{i,k,q,\ell}[t] = 0 \text{ e } r_{i,k,q,\ell}[t+1] \leq p(x_{i,k,q,\ell}[t+1]) \\ 1, & \text{se } \phi_{i,k,q,\ell}[t] = 1 \text{ e } r_{i,k,q,\ell}[t+1] > p(x_{i,k,q,\ell}[t+1]) \\ 0, & \text{se } \phi_{i,k,q,\ell}[t] = 1 \text{ e } r_{i,k,q,\ell}[t+1] \leq p(x_{i,k,q,\ell}[t+1]) \end{cases} \quad (33)$$

Com os valores atualizados de Φ podemos calcular o novo valor da função *fitness*. Todavia, uma vez que a Equação (33) não faz nenhum tipo de verificação em relação às restrições (C.1) a (C.3) do problema na Equação (27), é fundamental que algum tipo de penalidade seja dada a soluções não factíveis, i.e. a todos os Φ que não satisfazem uma das três restrições do problema. Desta forma, para o BPSO propõe-se a seguinte função *fitness* atualizada:

$$\tilde{\mathcal{J}}(\Phi) = \begin{cases} \mathcal{J}(\Phi) & \text{se factível} \\ \mathcal{J}_{\min} - \mathcal{P} & \text{se não factível} \end{cases} \quad (34)$$

onde \mathcal{J}_{\min} é a pior solução factível na população do PSO e \mathcal{P} é a soma das restrições C.1 e C.2, i.e.:

$$\mathcal{P} = \sum_{\ell=1}^L \sum_{k=1}^{K_{\ell}} \left(\sum_{q=1}^{T_p} \phi_{k,q,\ell} - 1 \right) + \sum_{\ell=1}^L \sum_{q=1}^{T_p} \left(\sum_{k=1}^{K_{\ell}} \phi_{k,q,\ell} - 1 \right) \quad (35)$$

Por fim o PSO binário pôde ser reformulado moldado ao problema e apresentado no Algoritmo 2.

Algorithm 2: Otimização de Enxame de Partículas (Binário)

input : Ganho de canal Hiper-matrix - β

Tamanho da população - N

Número máximo de iterações - I

output: Hiper-matrix de Sequências Piloto alocadas Φ

Cria N soluções candidatas aleatórias $\mathbf{x}_1[1], \dots, \mathbf{x}_N[1]$;

Avalia $\mathcal{J}(\mathbf{x}_1), \dots, \mathcal{J}(\mathbf{x}_N)$ de acordo com (27);

Início \mathbf{p}_i

for each $i = 1, \dots, N$ e $\mathbf{p}_g = \arg \max_{\mathbf{p}_i} \mathcal{J}(\mathbf{p}_i)$;

for $i = 1$ **until** I **do**

for $j = 1$ **until** N **do**

 Update $\mathbf{x}_j[i+1]$ usando Eq. (29) até Eq. (30);

 Avalia a nova solução usando Eq. (34) e (35);

if $\mathcal{J}(\mathbf{x}_j[i+1]) > \mathcal{J}(\mathbf{p}_j)$ **then**

 | $\mathbf{p}_j = \mathbf{x}_j[i+1]$;

end

if $\mathcal{J}(\mathbf{x}_j[i+1]) > \mathcal{J}(\mathbf{p}_g)$ **then**

 | $\mathbf{p}_g = \mathbf{x}_j[i+1]$;

end

end

end

3.4.2 PSO-SPV

Uma alternativa ao PSO binário é a associação do PSO à regra do valor da menor posição (SPV) conforme (Dubey et al. 2017). No SPV o valor de cada posição é trocada pela posição daquele valor numa versão ordenada do vetor, isto é, os valores reais são substituídos pela classificação dos elementos do vetor. A Tabela 4 apresenta um exemplo de aplicação do SPV em um vetor arbitrário de quatro posições contendo valores reais. Note que os menores valores do vetor são indexados primeiro no SPV.

Posição no Vetor Real	1	2	3	4
Valor Real	4,85	-2,15	145	-1,333
SPV	3	1	4	2

Tabela 4: Exemplo de funcionamento do SPV em um vetor arbitrário.

A aplicação do SPV substitui em parte a existência da Equação (33). Todavia, esta regra muda o domínio do problema de um cenário binário para um com números naturais. Nesta nova representação do problema, ao invés de uma matriz de alocação de sequências piloto, cada célula ℓ possui apenas um vetor de alocação onde o indexador do vetor refere-se a sequência piloto e o valor armazenado em cada posição o usuário para o qual aquele indexador está alocado. Matematicamente, seja $\phi_i^{\text{SPV}} \in \{0, \dots, K\}^{T_p \times L}$ a matriz de alocação de sequências piloto² representada pelo indivíduo i da população então temos que:

$$\phi_{q,\ell}^{\text{SPV}} \in [1, K] \quad (36)$$

isto é, $\phi_{q,\ell}^{\text{SPV}}$ armazena o usuário da célula ℓ para a qual a sequência piloto q está alocada.

Fica evidente, portanto, que para aplicar todas as formulações apresentadas é necessário estabelecer uma função que converta a matriz ϕ^{SPV} na hiper-matriz Φ . Isto pode ser feito por meio da seguinte função:

²Nesta representação, para simplificar a notação, assume-se que todas as células possuam o mesmo número de usuários, i.e. $K_1 = K_2 = \dots = K_L$.

$$\Phi_{k,q,\ell} = \begin{cases} 0 & \text{se } \phi_{q,\ell}^{\text{SPV}} \neq k \\ 1 & \text{caso contrário} \end{cases} \quad (37)$$

Portanto, o funcionamento do PSO-SPV deixa de estar sujeito a aplicação das Equações (32) e (33) e passa a utilizar a Equação (37) associada a um algoritmo de ordenação para determinar os valores SPV.

3.4.3 PSO-VNS

De acordo com (Hansen et al. 2010) a Busca de Vizinhança Variável (VNS), trata-se de uma meta-heurística baseada na mudança sistemática da vizinhança de cada possível solução a fim de melhorar os resultados obtidos. Esta regra quando aplicada ao PSO possibilita que o desempenho do algoritmo evite ótimos locais e aumenta a probabilidade de atingir o ótimo global. Desta forma, o VNS é mais um mecanismo de busca que tende a melhorar o desempenho do algoritmo quando comparado ao PSO clássico.

No contexto deste trabalho, o VNS é aplicada ao PSO-SPV por meio da troca das sequências alocadas a pares de usuários em uma mesma célula, ou seja, busca na vizinhança variável ocorre quando toda a solução é mantida, enquanto alguns pares de usuários tem as sequências piloto trocadas. Matematicamente, para cada par k' e k'' de usuários:

$$\begin{aligned} \phi_{q',\ell} = k' &\rightarrow \phi_{q',\ell} = k'' \\ \phi_{q'',\ell} = k'' &\rightarrow \phi_{q'',\ell} = k' \end{aligned} \quad (38)$$

Este mecanismo de busca local não é executado em todo indivíduo da população, pelo contrário, um parâmetro de taxa de alteração da vizinhança, r_{vns} , define a probabilidade de um indivíduo realizar esta busca e outro parâmetro, c_{vns} indica a quantidade de pares de usuários que são trocados durante a busca. Neste trabalho, para todo conjunto de usuários K para o valor de c_{vns} é igual ao número de

usuários, i.e. todos os usuários são pareados e realizam a troca de sequência piloto quando o VNS é aplicada ao indivíduo.

O Algoritmo 3 apresenta o pseudocódigo do PSO utilizando as técnicas SPV e VNS. Fica evidente que a diferença operacional entre o PSO-SPV e o PSO-SPV com VNS é o valor da variável r_{vns} , de tal forma que: se o valor aleatório criado pela função *rand* está distribuído uniformemente no intervalo $[0, 1]$ então atribuindo $r_{vns} = -1$, por exemplo, impede a execução da busca em vizinhança variável.

Algorithm 3: Otimização de Enxame de Partículas com SPV e VNS

input : Ganho de canal Hiper-matrix - β

Função *fitness* - $\mathcal{J}(\Phi)$

Tamanho da população - N

Numero máximo de iterações - I

output: Hiper-matrix de Sequencias Pilotos alocadas Φ

Cria N soluções candidatas $\mathbf{x}_1[1], \dots, \mathbf{x}_N[1]$;

Converte os valores de $\mathbf{x}_i[1]$ utilizando o SPV a Equação (65) para
converter os valores em matrizes de alocação $\Phi_1[1], \dots, \Phi_N[1]$;

Avalia $\mathcal{J}(\Phi_1[1]), \dots, \mathcal{J}(\Phi_N[1])$;

Início $\mathbf{p}_i = \Phi_i[1]$ for each $i = 1, \dots, N$ e $\mathbf{p}_g = \arg \max(\mathcal{J}(\mathbf{p}_1), \dots, \mathcal{J}(\mathbf{p}_N))$;

for $t = 1$ **until** I **do**

for $i = 1$ **until** N **do**

 Calcula velocidade da partícula utilizando (29) e (30) ;

 Atualiza a posição da partícula utilizando (31);

 Atualiza os valores candidatos Φ_j de acordo com (37);

 Avalia a solução candidata por meio de (28);

 Atualiza melhor local caso $\mathcal{J}(\Phi_i[t]) > \mathcal{J}(\mathbf{p}_i)$;

if $\text{rand}() < r_{vns}$ **then**

 Emparelhar os usuários de cada célula no indivíduo i de forma
 aleatória;

 Para cada par de usuários trocar as sequências alocadas
 conforme (38);

end

end

 Atualiza melhor global caso $\max(\mathcal{J}(\mathbf{p}_1), \dots, \mathcal{J}(\mathbf{p}_N)) > \mathcal{J}(\mathbf{p}_i)$

end

3.4.4 PSO COM VELOCIDADE GLOBAL (SPV E VNS)

Uma variação do algoritmo PSO, o PSO com velocidade global é implementada, neste trabalho onde a Equação (29) é ajustada da seguinte forma:

$$\mathbf{v}_i[t + 1] = \omega \mathbf{v}_i[t] + c_2 r_2 (\mathbf{x}_i[t] - \mathbf{p}_g) \quad (39)$$

isto é, o parâmetro c_1 é nulo e desta forma apenas a contribuição do melhor global é utilizada no cálculo da velocidade. Juntamente com esta variação as técnicas de VNS e SPV também foram implementadas e testados, dando origem a duas novas versões do PSO com velocidade global: o SPVG-PSO e o SPVG-VNS-PSO.

3.5 CENÁRIOS DE SIMULAÇÃO

A fim de verificar a aplicabilidade das soluções apresentadas nesta dissertação para o problema da alocação de sequências piloto, bem como, impacto do seu uso em termos de SINR, eficiência espectral máxima e mínima e número de usuários, foi desenvolvido um *script* em MATLAB para criar um *dataset* o qual está disponível publicamente em: <https://github.com/everttonalex/utfpr-ppgi-pilotcontamination>.

O *dataset* criado é composto por um conjunto de milhares de arquivos nos quais cada um deles possui informações como: número de células, tamanho do cenário, frequência de operação, número de antenas, ganho de potência do canal de cada usuário e torre no sistema, número de usuários, potência de ruído, largura de banda e posição geográfica de cada terminal na célula.

Foi considerado um cenário hexagonal com 7 células distribuídas geograficamente tal como apresenta a Figura 13. Cada usuário k na célula é aleatoriamente posicionado, entretanto em prol de estabelecer limites físicos, posições de usuários apenas podem ser pares de números inteiros e devem respeitar os limites do hexágono. i.e. seja $(x, y) \in \mathbb{Z}^2$ a posição de algum usuário relacionado com a sua ERB, a qual está posicionada na origem, então $x, y \sim \mathcal{U}[2, R]$ e segue as condições:

$$\begin{aligned}
|x| &\leq R \\
|y| &\leq \frac{\sqrt{3}}{2}R \\
\frac{\sqrt{3}}{2}|x| + |y| &\geq \frac{\sqrt{3}}{2}R
\end{aligned} \tag{40}$$

onde R é o raio da célula hexagonal e \mathcal{U} indica uma distribuição uniforme.

Após suas posições serem geradas aleatoriamente respeitando as regras estabelecidas com relação a origem, cada posição do usuário é transladada para a posição da célula. Adicionalmente, o *script* responsável por gerar o *dataset* substitui qualquer sobreposição de usuários com uma nova posição aleatória para ambos usuários sobrepostos. Os parâmetros utilizados na confecção deste conjunto de dados podem ser consultados na Tabela 5.

Sobre a simulação dos canais de cada usuário em relação a todas as estações rádio-base, foram simulados utilizando o modelo simplificado de perda de percurso apresentado na Seção 2.2.1.3, juntamente com o sombreamento sendo uma variável aleatória com distribuição Log-normal de média zero e variância no intervalo [6, 12]dB.

A metodologia para avaliação dos algoritmos apresentados neste trabalho consiste nos seguintes passos:

1. Otimização dos parâmetros dos algoritmos GA, BPSO, PSO-SPV, PSO-SPV com VNS e PSO com velocidade Global com SPV e VNS com base em um

Parâmetro	Valores adotados(s)
Número de células (L)	7
Número de usuários por célula (K)	{20, 40, 60}
Tamanho da célula (R)	{100, 250, 500, 1000} (m)
Comprimento de onda (λ)	8.56 (cm)
Distância de referência (d_0)	10 (m)
Expoente de perda de percurso (γ)	6
Variação do sombreamento (σ_s^2)	6 (dB)
Largura do canal (B)	20 (MHz)
Frequência de transmissão	3,5 (GHz)
Instâncias do <i>dataset</i>	1000 por conjunto de parâmetros

Tabela 5: Parâmetros do sistema usados nas simulações computacionais.

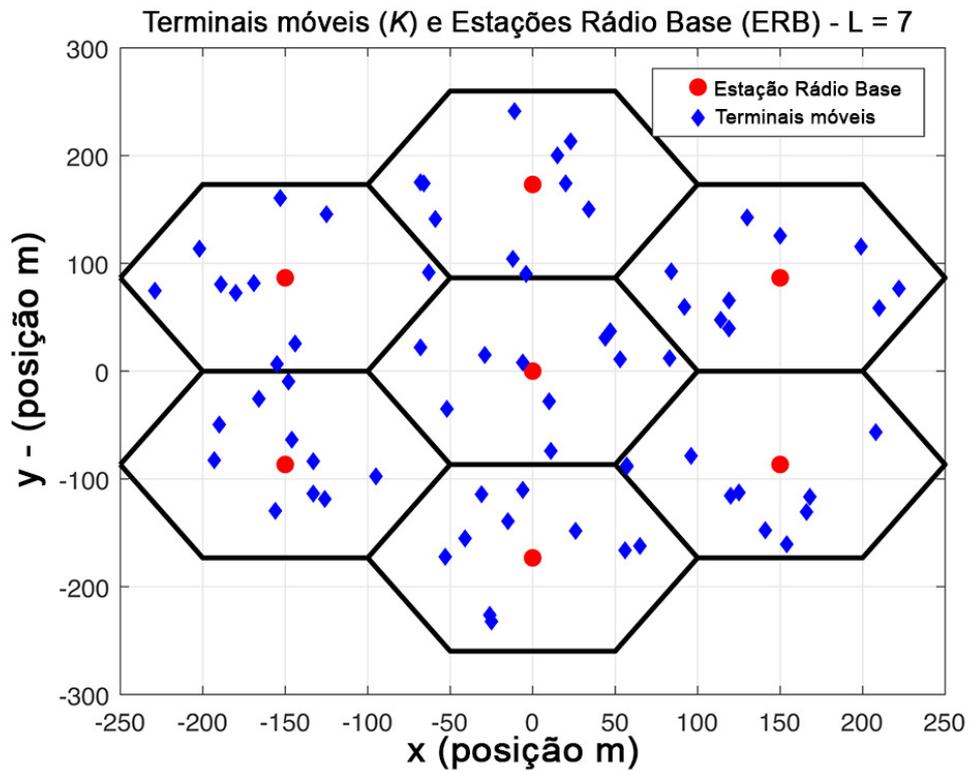


Figura 13: Configuração típica de um cenário de simulação com $L = 7$ células e $K = 10$ usuários por célula e raio da célula igual a 200 metros.

cenário típico do 5G: micro celular e de alta densidade urbana;

2. Avaliar os algoritmos em diferentes cenários (macro, micro, femto e pico celular) analisando o impacto de diferentes parâmetros no comportamento dos mesmos;
3. De acordo com os resultados derivar conclusões a respeito do desempenho em termos de: tempo de execução, eficiência espectral do sistema e eficiência espectral mínima.

4 RESULTADOS E DISCUSSÕES

Neste Capítulo são apresentados os resultados decorrentes das simulações e testes aos quais as meta-heurísticas discutidas foram submetidas. Inicialmente, a Seção 4.1 discorre sobre as soluções empregadas, na sequência a Seção 4.2 são otimizados parâmetros para todas as meta-heurísticas, na Seção: 4.3 são otimizados parâmetros específicos para o GA, a Seção: 4.4 trata sobre a otimização dos parâmetros específicos para o PSO, por fim a Seção: 4.5 discorre sobre o desempenho dos algoritmos em diferentes cenários.

Com o intuito de avaliar e qualificar os resultados obtidos pelas ferramentas de inteligência computacional propostas, um ambiente virtual de simulação foi desenvolvido como descrito na Seção 3.5 do Capítulo 3, usuários, ERBs, sinais, potência e demais parâmetros comuns necessários para transmissão e recepção dos dados em redes *wireless*, assim como, a distribuição geográfica dos terminais móveis também simulados neste cenário, como pode ser visto na ilustração da Figura 13 e descritos na Tabela 5. Todos estes parâmetros são a base para os testes executados no decorrer desse Capítulo.

4.1 META-HEURÍSTICAS ANALISADAS

Durante o Capítulo 3, o qual trata sobre o desenvolvimento deste trabalho foram apresentadas seis meta-heurística potenciais candidatas a otimizar a distribuição de sequências pilotos aos usuários em sistemas *Massive MIMO*, sendo:

- Algoritmo Genético em sua versão binária (Seção 3.3);
- Otimização por Enxame de Partículas na versão binária (Seção 3.4);

- Otimização por Enxame de Partículas em sua variação considerando o menor valor de posição (SPV) (Seção: 3.4.2);
- Otimização por Enxame de Partículas com busca por vizinhança variável (VNS) e menor valor de posição (SPV) (Seção: 3.4.3):
- Otimização por Enxame de Partículas com Velocidade Global com SPV (Seção: 3.4.4);
- Otimização por Enxame de Partículas com Velocidade Global com SPV e VNS (Seção: 3.4.4).

Os algoritmos descritos acima podem ser executados sob diferentes configurações de parâmetros, como por exemplo: número de iterações, população, número de usuários, dentre outros. Para cada conjunto de parâmetros e cenários distintos todos os algoritmos são avaliados em diferentes métricas de desempenho.

Na busca de conhecer os parâmetros ideais de configuração para realização dos testes comparativos, um conjunto de valores iniciais foram definidos para criação do cenário ao qual os algoritmos seriam inicialmente testados. A Tabela 6 apresenta parâmetros e valores usados para a primeira fase dos testes.

Os valores iniciais de configurações descritos na Tabela 6 foram definidos com base nos parâmetros para o funcionamento do 5G, considerando um cenário urbano com 20 usuários operando uma das possíveis frequências (3.5GHz) a entrar em operação no Brasil segundo edital da (ANATEL 2020).

Parâmetro	Valores adotados(s)
Número de células (L)	7
Número de usuários por célula (K)	20
Tamanho da célula (R)	1000 (m)
Comprimento de onda (λ)	8.56 (cm)
Distância de referência (d_0)	10 (m)
Expoente de perda de percurso (γ)	6
Variação do sombreamento (σ_s^2)	6 (dB)
Largura do canal (B)	20 (MHz)
Frequência de transmissão	3.5 (GHz)
Instâncias do <i>dataset</i>	1000
Tamanho da População (N)	2K

Tabela 6: Parâmetros utilizado na otimização dos algoritmos.

4.2 OTIMIZAÇÃO DE PARÂMETROS DAS META-HEURÍSTICAS

Durante a execução de cada algoritmo, faz-se necessário conduzir um processo de otimização dos parâmetros utilizados pelas meta-heurísticas para que cada uma seja adaptada ao problema abordado. O primeiro desses parâmetros é comum à todas as meta-heurísticas discutidas e trata-se do número de iterações. No GA por exemplo, a cada nova geração há uma tendência de evolução conforme a teoria evolucionária das espécies, de igual modo já discutido na Seção 3.3 no Capítulo 3. Já nas diferentes versões do PSO, o movimento de um grupo de aves em busca de alimento é simulado de forma que cada iteração ao menos um indivíduo da população se aproxime cada vez mais de uma solução melhor que na iteração anterior.

O cenário de testes que foi utilizado para conduzir estes experimentos é o retratado na Tabela 6 e a Figura 14 apresenta o desempenho de cada algoritmo em termos de eficiência espectral média por usuário conforme o número de iterações/gerações cresce. É possível notar que os resultados de eficiência espectral média dos usuários do sistema estão dentro de uma margem de diferença inferior a 1%.

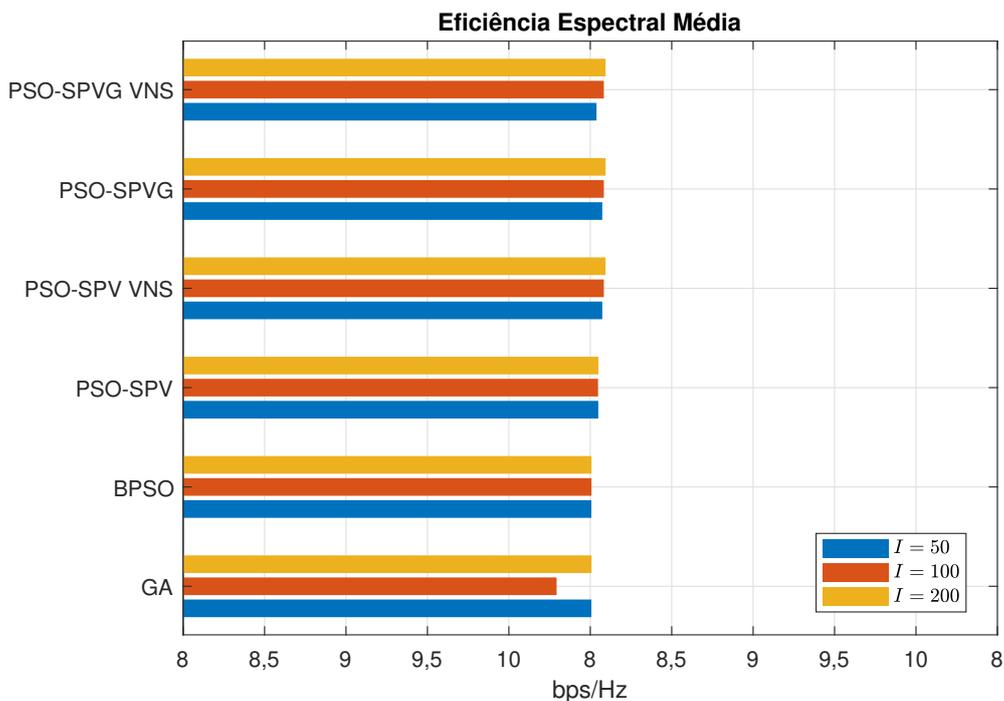


Figura 14: Eficiência espectral média por usuário de cada algoritmo analisado com $K = 20$ e $R = 1.000m$ para os diferentes números de iterações/gerações.

Numericamente quando o número máximo de gerações do GA (G_{\max}) aumenta de 100 para 200 há um acréscimo de desempenho na ordem de 0,96%, todavia, ao se comparar o desempenho aumentando o número máximo de iterações de 50 para 100, há na verdade uma redução de 0,94%. Essa diferença se dá pelo fato do algoritmo usar populações iniciais aleatórias que não foram repetidas nos diferentes testes. Já no caso das diferentes versões do PSO, ao compararmos o desempenho do pior caso e melhor caso a diferença é de 0,45% de incremento entre o BPSO e PSO com velocidade global com e sem VNS.

Por outro lado, analisando o tempo de execução¹ e o impacto direto nos algoritmos (exceto o algoritmo de alocação aleatória, do inglês, *Random Allocation* - RA), nota-se evidentemente que quanto maior o número de iterações maior o tempo de execução e recursos consumidos conforme a Figura 15 apresenta. Note que: ao quadruplicar o número de iterações de $I = 50$ para $I = 200$ observa-se um tempo de duração também quatro vezes maior. Este resultado corrobora o fato do tempo de execução do algoritmo crescer linearmente com o número de iterações.

Outra observação fundamental na Figura 15 é o aumento de 74% no tempo médio do algoritmo BPSO em relação aos demais algoritmos apresentados na figura.

Em suma, os resultados apresentados nesta Seção demonstram que a diferença de desempenho é pequena, considerada marginal dado o fato da população inicial ser criada de forma aleatória. Adicionalmente, considerando os resultados de tempo de simulação é possível afirmar diante do cenário de alocação de recursos em telecomunicações, onde os algoritmos devem ser executados em um intervalo de tempo inferior a uma unidade de segundo, que utilizar 100 ou 200 iterações não corresponde a uma solução factível para o problema em razão do tempo consumido para se efetuar todas as iterações dos algoritmos.

Sendo assim, todas as simulações apresentadas nas próximas seções utilizaram um número máximo $I = G_{\max} = 50$.

¹Utilizando 32 processadores virtuais em nuvem.

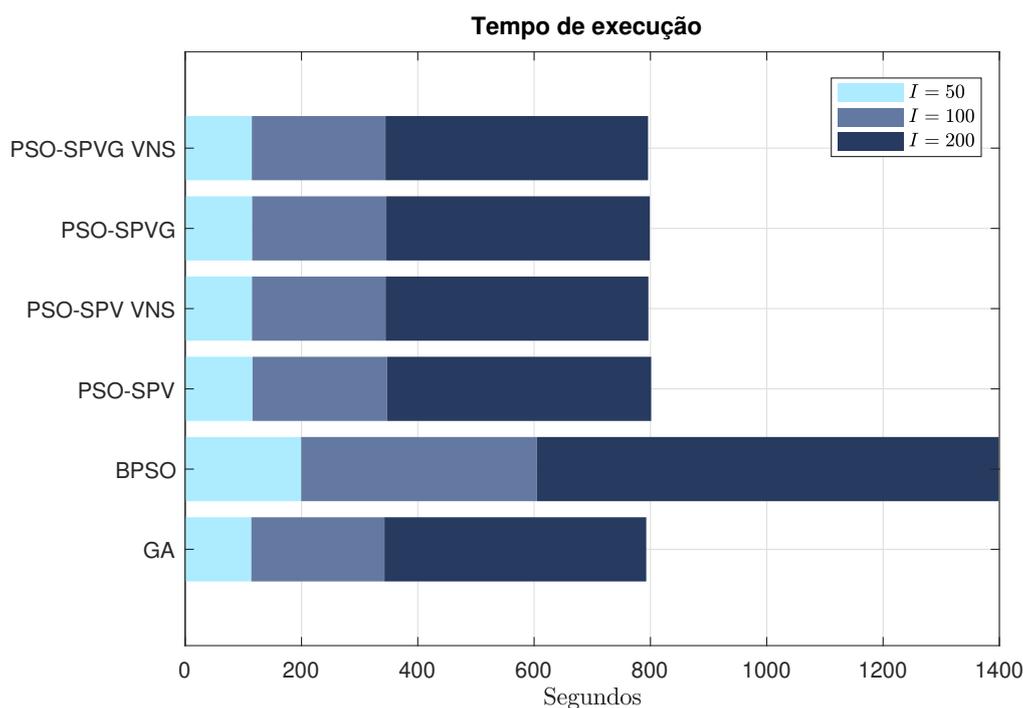


Figura 15: Tempo para execução dos algoritmos (Instância executada no Google Cloud Platform: 32vCPUs, 32GB RAM, Sistema Operacional Ubuntu 20 e Múltiplos Workers em Matlab).

4.3 OTIMIZAÇÃO DE PARÂMETRO PARA O GA

Nesta Seção são apresentados os resultados do processo de otimização dos parâmetros de população e Taxa de Mutação do GA.

O tamanho da população estabelecido para os testes foi $N = 2K$ (duas vezes o número de usuários na célula), i.e. a população é duas vezes maior que o número de usuários por célula no sistema. Uma vez que o aumento da população tem impacto no tempo de execução do algoritmo não foram utilizados valores maiores visto que os tempos apresentados na Figura 15 já ultrapassam a barreira dos minutos.

A taxa de mutação do GA, T_m , por sua vez, é um parâmetro contido no intervalo $(0;1)$. Desta forma, foram testados diferentes valores cujos resultados em termos de eficiência espectral média por usuário são apresentados na Tabela 7. O melhor resultado, destacado na tabela, ocorre quando $T_m = 0,9$ e resultou numa eficiência espectral média por usuário de 9,00370 bps/Hz. Adicionalmente, é importante perceber que a diferença de desempenho da taxa de mutação para a

métrica apresentada na Tabela 7 entre o pior e o melhor caso é de 0,96%.

Taxa de mutação (T_m)	Eficiência Espectral (bps/Hz)
0,10	8,91807
0,25	9,00268
0,50	9,00334
0,70	9,00300
0,80	9,00367
0,90	9,00370
1,00	9,00365

Tabela 7: Eficiência espectral média por usuário utilizando diferentes taxas de mutação para o GA com $R = 1000m$, $K = 20$.

Essa diferença está descrita também de forma gráfica na Figura 16 onde é possível observar que após $T_m = 0,8$ a diferença de alteração de desempenho é marginal do ponto de vista gráfico.

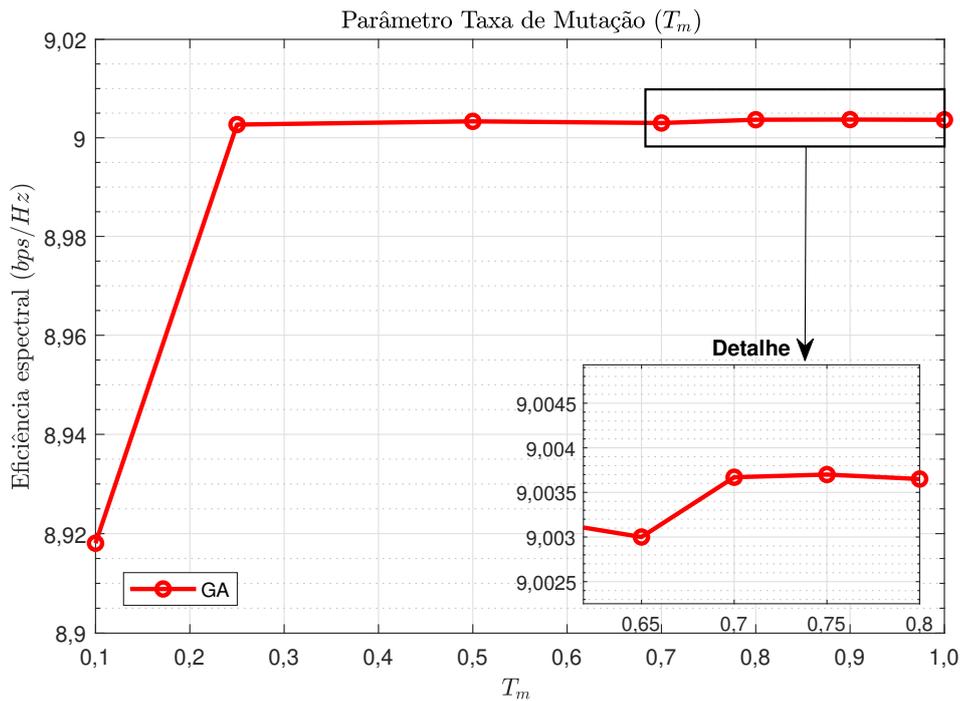


Figura 16: Eficiência espectral por usuário (em bits/segundo/Hertz) para diferentes valores de taxa de mutação (T_m) em um cenário com $K = 20$ usuários e raio da célula de $R = 1000$ metros.

4.4 OTIMIZAÇÃO DOS PARÂMETROS DO PSO

A fim de encontrar os parâmetros que adaptam as meta-heurísticas derivadas do PSO foi definido um processo de condução de simulações no seguinte formato: o

primeiro parâmetro analisado foi o coeficiente inercial (ω), posteriormente uma análise envolvendo valores de velocidade máxima (v_{\max}) e, conjuntamente, coeficiente inercial foi conduzida. O passo seguinte foi analisar os pesos de velocidade local e global c_1 e c_2 e para as versões do PSO com busca variável de vizinhança foi analisado o comportamento do parâmetro r_{\max} utilizado nas diferentes versões do PSO abordado neste trabalho. É importante pontuar que: o cenário utilizado para a otimização de parâmetros das diferentes versões do PSO é o mesmo do GA, descrito na Tabela 6.

O processo de otimização iniciou-se pelo coeficiente inercial ω . A Figura 17 apresenta os resultados iniciais com diferentes valores de inércia. Neste ponto é importante salientar que as versões do PSO com VNS não foram testadas pois os parâmetros são descorrelacionados da busca em vizinhança variável.

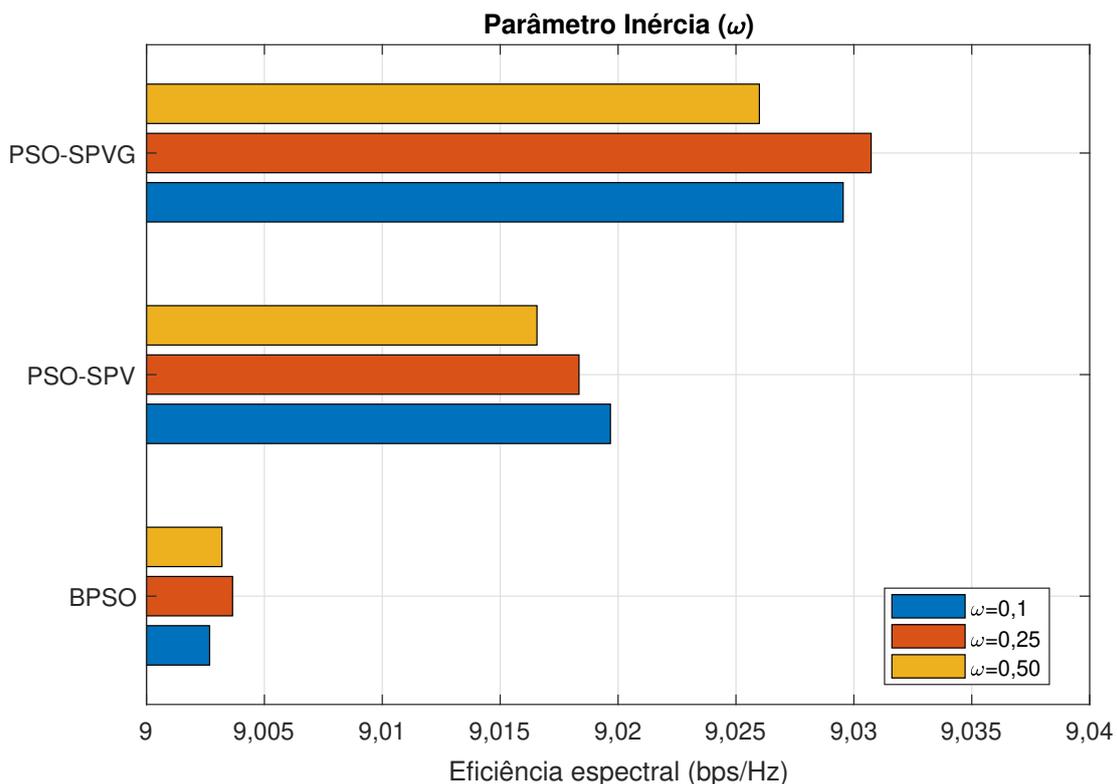


Figura 17: Resultados dos testes para encontrar o melhor parâmetro para inércia ($K = 20$, $R = 1000m$ e $v_{\max} = 1$)

Como é possível notar na Figura 17, os melhores valores de inércia para cada algoritmo não são necessariamente os mesmos, enquanto para o SPVG-PSO e para o BPSO a melhor inércia é $\omega = 0,25$, no SPV-PSO o melhor resultado de inércia é $0,1$.

O passo seguinte da investigação é verificar quais os valores de velocidade

máxima que possuem o melhor desempenho. Todavia, nas primeiras simulações conduzidas o que se percebeu em alguns casos foi, na verdade, uma queda de desempenho em relação aos resultados simulados com diferentes valores de inércia. Desta forma, optou-se por verificar de forma simultânea diferentes combinações de inércia e velocidade máxima. Os resultados numéricos, tanto relacionados a Figura 17, como os obtidos nesta parte do estudo, são apresentados na Tabela 8.

É importante notar que os valores obtidos para na primeira simulação no caso do PSO-SPV permaneceram os mesmos, i.e. $\omega = 0,1$ e $v_{\max} = 1$. Todavia, para o BPSO os melhores valores passaram a ser $\omega = 0,5$ e $v_{\max} = 4$, enquanto no caso do PSO-SPVG $\omega = 0,25$ e $v_{\max} = 2$.

Os parâmetros seguintes a serem analisados foram os pesos que controlam a influência na determinação da velocidade com base no melhor individual (local) e global, i.e. (c_1 e c_2). Estes parâmetros não são usados nas variantes PSO SPV com velocidade Global, pois nesta o c_1 é sempre nulo. Sendo assim os testes foram conduzidos para o BPSO e PSO-SPV. Note que como estes parâmetros não estão relacionados ao VNS, as versões do algoritmo com busca em vizinhança não foram simuladas também.

A Tabela 9 apresenta os resultados obtidos com diferentes configurações dos parâmetros c_1 e c_2 . A diferença de desempenho entre os parâmetros quando comparado o maior e menor valor da Tabela é de aproximadamente 0,06% para ambos algoritmos. Portanto, é possível afirmar que em termos de eficiência espectral média por usuário a escolha dos parâmetros c_1 e c_2 tem um impacto marginal no

Parâmetro	Algoritmo		
	BPSO	PSO-SPV	PSO-SPVG
$\omega = 0,1 / v_{\max} = 1$	9,002676	9,019674	9,029547
$\omega = 0,25 / v_{\max} = 1$	9,003650	9,018344	9,030732
$\omega = 0,50 / v_{\max} = 1$	9,003201	9,016561	9,025994
$\omega = 0,25 / v_{\max} = 1$	9,003650	9,018344	9,030732
$\omega = 0,25 / v_{\max} = 2$	9,003343	9,017226	9,033911
$\omega = 0,50 / v_{\max} = 3$	9,003671	9,019641	9,028396
$\omega = 0,50 / v_{\max} = 4$	9,003961	9,019206	9,028506

Tabela 8: Resultados para os testes do coeficiente inercial ω , (resultados exibidos em bps/Hz por usuário - os melhores resultados estão destacados em negrito)

desempenho.

Parâmetros		Algoritmos	
c_1	c_2	BPSO (bps/Hz)	PSO-SPV (bps/Hz)
1	1	9,00396	9,01967
2	1	9,00407	9,01720
5	1	9,00352	9,01562
1	5	9,00350	9,02180

Tabela 9: Eficiência espectral média por usuário utilizando BPSO e PSO-SPV com diferentes configurações de c_1 e c_2 em um cenário com $K = 20$ usuários e célula de raio $R = 1000$ metros.

Finalmente, para as versões do PSO com VNS, foram conduzidos experimentos com o objetivo de verificar o impacto da probabilidade de ocorrência do VNS no desempenho dos algoritmos.

Parâmetro	Algoritmo	
r_{vns}	PSO-SPV-VNS	PSO-SPVG-VNS
0,15	9,03017	9,038689
0,30	9,03489	9,041813
0,60	9,03821	9,044897
0,90	9,04148	9,045624

Tabela 10: Resultados das simulações r_{vns} , valores exibidos em bps/Hz por usuário.

A Figura 18 apresenta os resultados das simulações para diferentes taxas de execução do VNS em termos de eficiência espectral média por usuário. Os resultados corroboram que o VNS é capaz de melhorar os resultados de tal forma que quanto maior é o r_{vns} na tentativa de fugir do ótimo local, maior o é desempenho dos algoritmos. Os resultados apresentados em conjunto com a análise de tempos de execução dos algoritmos apresentado na Figura 15 subsidiaram a decisão de optar pelo uso do $r_{vns} = 0,9$ uma vez que o custo computacional da técnica VNS não incrementa de forma significativa o tempo de execução do algoritmo.

Em suma, após analisados os parâmetros ω , v_{max} , c_1 , c_2 e r os valores ótimos para cada algoritmo são apresentados na Tabela 11.

4.5 DESEMPENHO DOS ALGORITMOS EM DIFERENTES CENÁRIOS

Nesta Seção são apresentadas diferentes análises a respeito das meta-heurísticas aplicadas ao problema de alocação de sequências piloto: o impacto da

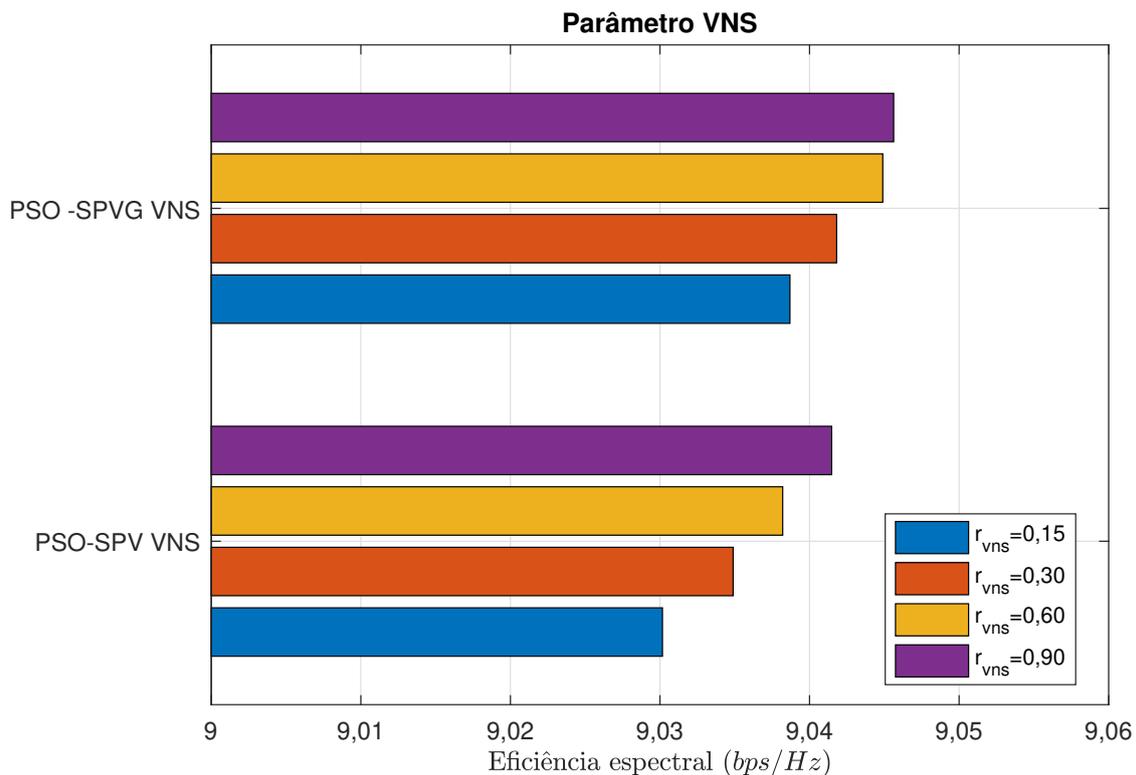


Figura 18: Resultados do teste para encontrar o melhor parâmetro VNS em um cenário com $K = 20$ usuários por célula de raio $R = 1000m$.

quantidade de usuários no sistema (*system loading*) e o impacto do tamanho da célula no desempenho dos algoritmos utilizando como métricas: eficiência espectral média por usuário, função de distribuição cumulativa (do inglês *Cumulative Distribution Function*, CDF) da SINR em dB e eficiência espectral mínima e máxima por usuário do sistema.

Uma CDF conforme (Everitt e Skrondal 2010) é a probabilidade de que uma variável aleatória seja menor que os valores informados, em outras palavras, cada ponto da CDF é a probabilidade que um determinado ponto seja menor ou igual aquele valor, isto é, se um ponto está em zero dB e a curva está em 80% isso representa que a probabilidade da SINR ser menor que zero dB é 80%, representando um resultado ruim, ou seja quanto mais a direita a curva estiver, melhor será o resultado apresentado.

Conforme já mencionado no Capítulo 3, as simulações foram conduzidas utilizando o software MATLAB o qual também foi utilizado para criar um *dataset* disponível publicamente em: <https://github.com/evertonalex/>

Algoritmo	Parâmetros Ótimos				
	ω	v_{max}	c_1	c_2	r_{vns}
BPSO	0,5	4	2	1	-
PSO-SPV	0,1	1	1	5	-
PSO-SPVG	0,25	2	-	1	-
PSO-SPV-VNS	0,1	1	1	5	0,9
PSO-SPVG-VNS	0,25	2	-	1	0,9

Tabela 11: Melhores parâmetros para as diferentes versões do PSO obtidos por meio de simulação em um cenário com $K = 20$ usuários por célula de $R = 1000$ metros de raio.

utfpr-ppgi-pilotcontamination.

A fim de iniciar a análise, foram realizadas simulações em cenários com diferentes raios de célula: $R = 100m$, $R = 250m$, $R = 500m$ e $R = 1.000m$. A Figura 19 apresenta uma CDF Empírica para os diferentes algoritmos nas diferentes configurações de raio com os parâmetros de $K = 20$ usuários, número máximo de iterações $I = 50$ e demais parâmetros conforme as Tabelas 5 e 6.

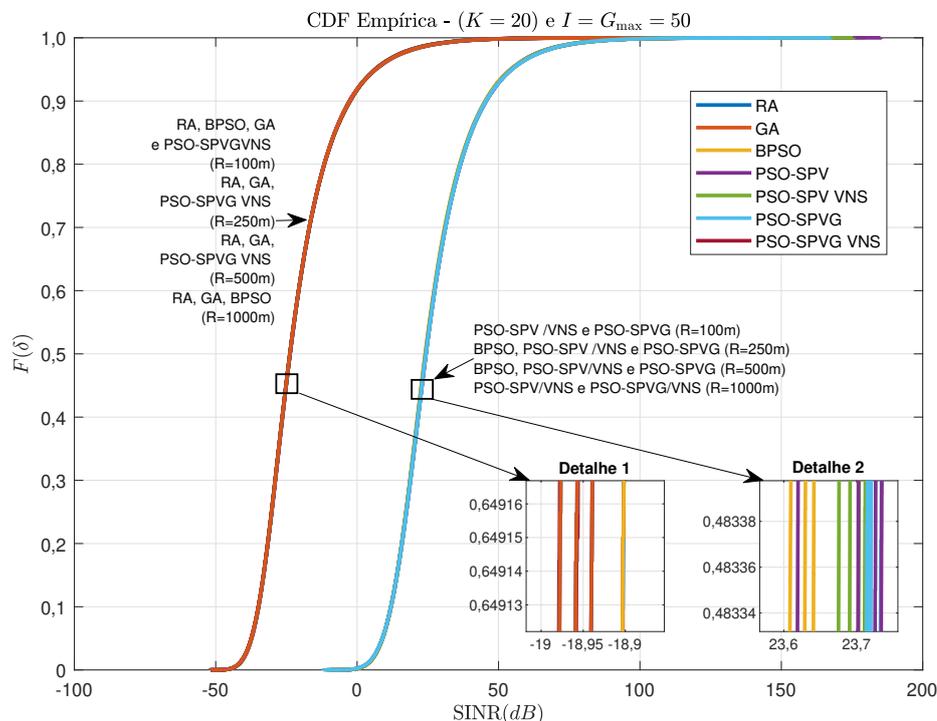


Figura 19: CDF Empírica pra diferentes tamanhos de células com $K = 20$ usuários, $G_{max} = 50$ iterações $I = 50$ iterações.

Como se pode observar, as 28 CDFs contidas na Figura 19 agrupam-se

em dois conjuntos: uma curva iniciando-se na faixa de -50dB (curva vermelha) e outra na faixa de -15dB (curva azul). A solução mais simples para o problema, o RA, tem sempre desempenho próxima da primeira CDF. É importante salientar neste resultado o impacto da distância para os diferentes algoritmos: o BPSO tem resultados melhores nos cenários com $R = 250$ e 500 metros, o PSO-SPVG-VNS tem resultados melhores em células de 1000 metros. Já os demais algoritmos são estáveis, isto é, possuem CDFs próximas umas das outras independente da distância: no caso do GA os resultados sempre estão próximos a CDF que se inicia na faixa de -50dB , enquanto PSO-SPV, PSO-SPV-VNS e PSO-SPVG estão sempre próximos a curva azul da Figura 19.

Adicionalmente, as diferenças apontadas nos detalhes da Figura 19 mostram que os algoritmos tem um desempenho muito próximo um do outro o que poderia indicar que o sistema não é limitado por interferência e sim pela perda de percurso e sombreamento de cada usuário. A fim de estabelecer critérios melhores de comparação de desempenho dos diferentes algoritmos, são apresentados na Tabela 12 a área sob a curva de cada uma das CDFs.

Área Sob a Curva		
Algoritmo	Cenário	Valor
RA, BPSO and GA	$K = 20 R = 250m$	-20,6903
PSO-SPV	$K = 20 R = 100m$	26,9351
PSO-SPV VNS	$K = 20 R = 500m$	26,9661
PSO-SPVG	$K = 20 R = 500m$	26,9912
PSO-SPVG VNS	$K = 20 R = 250m$	27,0692

Tabela 12: Área sob a curva dos melhores resultados dos algoritmos em análise do tamanho do cenário ($I = 50$)

Dada as limitações visuais existentes na Figura 19, é possível analisar os resultados por outra métrica: a área sob a curva. A Tabela 12 apresenta os melhores resultados de área sob a curva das CDFs apresentadas na Figura 19. Note que para diferentes raios de célula os melhores algoritmos se alternam, e.g. enquanto PSO-SPVG-VNS se destaca em células menores ($R = 250m$) o PSO-SPVG tem um desempenho marginalmente melhor em células maiores ($R = 500m$). Outro resultado importante é o fato do PSO-SPV apresentar o melhor desempenho nos menores cenários testados, i.e. $R = 100m$.

Ainda sobre o impacto do tamanho da célula em cada um dos algoritmos, propõe-se analisar o desempenho por meio de outra figura de mérito: a eficiência espectral máxima por usuário, cujos resultados são apresentados na Tabela 13 e correspondem a média das 1000 instâncias do *dataset*. Note que no cenário onde $R = 1000$ metros o desempenho em bps/Hz dos algoritmos baseados em PSO é, na média, 119% maior do que o RA, GA e BPSO.

Parâmetros	Eficiência espectral máxima por usuários (em bps/Hz)			
	$R = 1000m$	$R = 500m$	$R = 250m$	$R = 100m$
RA, BPSO e GA	13,4015	12,9367	12,7704	13,1714
PSO-SPV	29,3362	28,8354	28,7173	29,0950
PSO-SPV VNS	29,3362	28,9150	28,8393	29,0974
PSO-SPVG	29,3378	28,8825	28,7896	29,1499
PSO-SPVG VNS	29,3515	28,9445	28,7380	29,2260

Tabela 13: Eficiência espectral máxima por usuários em diferentes tamanhos de células. Os melhores resultados estão marcados em negrito.

Embora os algoritmos apresentem desempenhos similares em termos de CDF e eficiência espectral média, a diferença em termos de eficiência espectral máxima por usuário levou a análise da eficiência espectral mínima por usuário. A depender dos valores obtidos de eficiência espectral mínima pode-se chegar a conclusão que em alguns algoritmos os usuários estariam, na prática, desconectados do sistema.

Neste sentido, a Tabela 14 apresenta os valores numéricos da menor eficiência espectral por usuário do sistema em termos de valores médios das 1000 instâncias do *dataset*.

Algoritmos	Eficiência espectral mínima por usuário (em bps/Hz)			
	$R = 1000m$	$R = 500m$	$R = 250m$	$R = 100m$
RA, BPSO e GA	$7,56 \times 10^{-5}$	$7,85 \times 10^{-5}$	$7,90 \times 10^{-5}$	$8,03 \times 10^{-5}$
PSO SPV	1,4143	1,4233	1,4142	1,4414
PSO SPV VNS	1,3762	1,4020	1,3858	1,3605
PSO SPVG	1,3897	1,4093	1,3782	1,3986
PSO SPVG VNS	1,3191	1,3561	1,3873	1,3424

Tabela 14: Eficiência espectral mínima por usuário ($K = 20$) em diferentes tamanhos de células. Os melhores valores estão marcados em negrito.

Note que a diferença entre os resultados dos algoritmos RA, BPSO e GA foram marginais, portanto, os resultados foram agrupados para facilitar a leitura e compreensão. Nesta análise surge o resultado mais significativo do ponto de vista

numérico: o desempenho dos algoritmos baseados no PSO-SPV em termos de eficiência espectral mínima podem chegar a ser 1.795.000% maior do que os valores para o RA, BPSO e GA.

Conjectura-se aqui que: como RA, BPSO e GA possuem uma eficiência espectral mínima média inferior a 1 bps/Hz, é possível afirmar que na prática o usuário foi desligado do sistema, isto é, ele não consegue transmitir informações. Sendo assim, PSO atrelado ao SPV nas suas diferentes versões permite organizar as sequências piloto de tal forma que todos usuários do sistema estão efetivamente transmitindo, enquanto nos demais algoritmos os usuários estariam desligados.

O fato do desempenho dos algoritmos ser tão diferente, especialmente sob a métrica de eficiência espectral mínima por usuário, levou a uma segunda análise sobre o impacto do número de iterações no desempenho. A Tabela 15 apresenta os resultados para eficiência espectral mínima por usuário no sistema sendo que os valores dispostos são a média das 1000 instâncias do *dataset*.

Note que as maiores diferenças apresentadas ainda representam um aumento inferior a 2%. Além disto, embora a Tabela 15 demonstre que RA, BPSO e GA tiveram o mesmo desempenho apesar da mudança no número de iterações, a diferença média no desempenho foi da ordem de 0,0013% quando o número de iterações aumentou de 50 para 100, corroborando mais uma vez para a conclusão que o ganho de desempenho é pequeno frente ao tempo de execução necessário pra execução.

Algoritmo	Max. # de iterações (I) e (G_{\max})		
	50	100	200
RA	$7,56 \times 10^{-5}$	$7,56 \times 10^{-5}$	$7,56 \times 10^{-5}$
BPSO	$7,56 \times 10^{-5}$	$7,56 \times 10^{-5}$	$7,56 \times 10^{-5}$
GA	$7,56 \times 10^{-5}$	$7,56 \times 10^{-5}$	$7,56 \times 10^{-5}$
PSO-SPV	1,4143	1,4329	1,4246
PSO-SPV VNS	1,3762	1,3364	1,3239
PSO-SPVG	1,3897	1,3794	1,3956
PSO-SPVG VNS	1,3191	1,3419	1,2982

Tabela 15: Eficiência espectral mínima (bps/Hz) considerando $K = 20$ usuários em células de $R = 1000$ metros de raio.

A última análise conduzida neste trabalho, trata do impacto do carregamento de sistema (número de usuários) e avalia o desempenho em termos de eficiência

espectral do usuário: máxima, média e mínima. Outra figura de mérito utilizada na análise é a CDF da SINR (dB) por usuário. A Figura 20 apresenta a CDF empírica para diferentes cenários de carregamento do sistema: $K = 20$, $K = 40$ e $K = 60$ usuários.

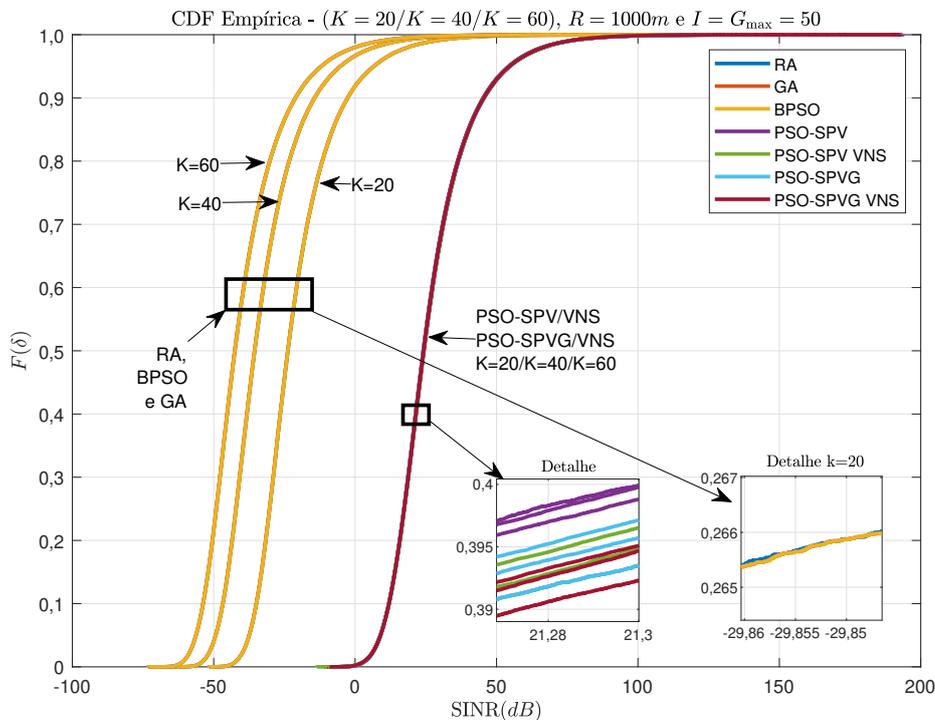


Figura 20: CDF Empírica para $K = 20$, $K = 40$ e $K = 60$ usuário com células de $R = 1000m$ de raio com o máximo de iterações configurados em 50 para todos os algoritmos.

Os resultados das simulações deixam claro que RA, BPSO e GA sofrem um impacto no desempenho a medida que o carregamento do sistema aumenta para o mesmo tamanho da célula. Entretanto a diferença não é percebida nos demais algoritmos, o que significa que eles podem lidar com uma densidade de usuários melhor que os três algoritmos anteriores. Numericamente, a CDF desloca-se aproximadamente $-11dB$ de $K = 20$ para $K = 40$ usuários e $-7dB$ quando a comparação é de $K = 40$ para $K = 60$. Enquanto isso, para os algoritmos baseados no PSO-SPV o deslocamento da CDF de $K = 20$ para $K = 60$ é inferior a $0,1dB$.

Analisando o impacto no carregamento do sistema em relação a eficiência espectral máxima e mínima são apresentados os resultados sumarizados na Tabela 16 (máxima) e na Tabela 17 (mínima).

Note na Tabela 16, que no sistema com $K = 40$ os resultados obtidos

Parâmetros	Eficiência espectral máxima por usuários (em bps/Hz)		
	$K = 20$	$K = 40$	$K = 60$
RA, BPSO e GA	13,4015	11,9834	11,9672
PSO-SPV	29,3362	31,7357	34,0838
PSO-SPV-VNS	29,3362	31,7985	34,0927
PSO-SPVG	29,3378	31,7012	34,0214
PSO-SPVG-VNS	29,3515	31,7935	34,009

Tabela 16: Eficiência espectral máxima em diferentes carregamentos de sistema com células de raio $R = 1000m$. Os melhores resultados estão marcados em negrito.

pelos algoritmos baseados em PSO-SPV são 165% maiores que o desempenho dos algoritmos RA, BPSO e GA. Ainda nesta tabela, quando o carregamento atinge $K = 60$ usuários no sistema, o aumento de desempenho é 184%. Para os cenários com carregamento maior que $K = 20$ usuários, o PSO-SPV-VNS apresentou os maiores valores de eficiência espectral máxima por usuário, quando considerado a média entre as 1000 instâncias do *dataset*. Numericamente, a eficiência espectral média do melhor usuário passou de 11,9 bps/Hz, no RA, para 34 bps/Hz utilizando PSO-SPV-VNS.

Parâmetros	Eficiência espectral mínima por usuários (em bps/Hz)		
	$K = 20$	$K = 40$	$K = 60$
RA, BPSO e GA	$7,56 \times 10^{-5}$	$3,75 \times 10^{-6}$	$6,42 \times 10^{-7}$
PSO-SPV	1,4143	1,0979	0,98732
PSO-SPV-VNS	1,3762	1,0775	0,95831
PSO-SPVG	1,3897	1,0798	0,95392
PSO-SPVG-VNS	1,3191	1,0579	0,92445

Tabela 17: Eficiência espectral mínima para diferentes carregamentos de sistema com células de raio $R = 1000m$. Os melhores resultados estão marcados em negrito.

Por fim, foram realizadas simulações para examinar o ganho de desempenho de eficiência espectral mínima dos usuários e os resultados são apresentados na Tabela 17. Observe que se comparados numericamente, o usuário com menor eficiência espectral quando o PSO-SPV é usado para alocação de sequências, tem um eficiência espectral, na média, 29.265.527% maior que no cenário com RA, quando o carregamento do sistema é $K = 40$ usuários. Adicionalmente, quando $K = 60$ o PSO-SPV permite uma eficiência espectral mínima 153.732.986% maior que o RA. Do ponto de vista prático o usuário passa de uma eficiência espectral de $6,42 \times 10^{-7}$ bps/Hz para 0,98 bps/Hz, i.e. no primeiro caso o usuário seria incapaz de transmitir com qualidade de serviço, já no segundo, a transmissão é viável.

Sintetizando todos os ensaios discorridos até este ponto: fica claro que as meta-heurísticas testadas são divididas em dois grupos bastante distintos quanto ao desempenho: grupo de baixo desempenho incluindo RA, BPSO e GA, enquanto outro grupo de alto desempenho é composto por PSO-SPV, PSO-SPV VNS, PSO-SPV com velocidade Global e PSO-SPV VNS com velocidade Global.

5 CONCLUSÃO

Este trabalho abordou o problema da alocação de sequências pilotos em sistemas Massive MIMO para redes 5G propondo solucioná-lo por meio de meta-heurísticas evolucionárias. O problema de otimização apresentado busca maximizar a eficiência espectral do sistema.

Foram empregados ao todos seis meta-heurísticas: GA, BPSO, PSO-SPV, PSO-SPVG, PSO-SPV-VNS e PSO-SPVG-VNS. O *dataset* bem como os scripts de cada uma dos algoritmos utilizados estão disponíveis publicamente no endereço: github.com/evertonalex/utfpr-ppgi-pilotcontamination. Adicionalmente, foram conduzidas simulações e uma busca não-exaustiva para verificar os parâmetros ótimos para cada uma das meta-heurísticas empregadas, sempre considerando o aspecto da complexidade computacional dada a escassez de recursos nos transceptores.

Os algoritmos utilizados foram analisados por meio de diferentes métricas: a primeira foi a própria função custo utilizada, a eficiência espectral. Mesmo com todos os ajustes nos parâmetros, as soluções obtidas, em linhas gerais, não foram capazes de obter grandes saltos de desempenho sendo que a média de aumento quando comparado a alocação aleatória de sequências atingiu 1,15%.

Todavia, utilizando outras métricas, como a eficiência espectral máxima e mínima por usuário, foi possível perceber a importância da aplicação de algoritmos de otimização no problema de alocação de sequência piloto. Em termos de eficiência espectral máxima, a utilização do PSO-SPVG-VNS obteve um aumento de 184% em relação ao RA.

Por outro lado, o PSO-SPV foi capaz de aumentar a eficiência espectral

mínima em 153.732.986% quando comparado ao RA. Na prática, este resultado indicou que utilizando algoritmos evolutivos para realizar a alocação de sequências piloto pode garantir que nenhum usuário do sistema esteja desligado ou operando em condições abaixo da qualidade de serviço esperada.

De forma geral, estas meta-heurísticas se mostraram soluções candidatas factíveis para o problema da alocação de sequências piloto, uma vez que reduzem o tempo de busca de uma solução quando comparado, por exemplo, a uma busca exaustiva e também pela melhora de desempenho quando comparado a algoritmos triviais como a alocação aleatória.

Sendo assim, esta dissertação contribui com a solução do problema sumarizada nos seguintes pontos:

1. Desenvolvimento e compartilhamento público de script e *dataset* utilizados para obter os resultados são públicos;
2. Otimização de parâmetros dos algoritmos para o problema foram avaliados e testados sob diferentes condições;
3. Avaliação e teste de seis abordagens heurísticas para o problema apresentando;
4. Simulação de cenários reais sob diferentes parâmetros para estabelecer o real impacto na performance dos algoritmos e sistema em geral;
5. Apresentar uma solução factível para otimizar a performance geral de sistemas baseados em Massive MIMO.

Como trabalhos futuros são sugeridos os seguintes tópicos:

1. Utilização de outros algoritmos meta-heurísticos como o *Differential Evolution (DE)*, que possuem mecanismos similares as meta-heurísticas aqui abordadas;
2. Aplicar algoritmos baseados em redes neurais como *Convolutional Neural network (CNN)* e *Multilayer Perceptron (MLP)* e comparar com outros resultados na literatura utilizando redes neurais;

3. Analisar o desempenho dos algoritmos apresentados neste trabalho no contexto de femto-células e pico-células a fim de determinar em quais cenários o sistema é totalmente limitado por interferência e em quais o sistema é limitado por condições do canal;
4. Estender o problema para que a alocação de potência seja feita de forma conjunta a alocação de sequências piloto e adaptar as meta-heurísticas apresentadas e este novo problema;
5. Analisar o desempenho dos algoritmos discutidos neste trabalho em sistemas com interferência intra-celular.

6 REFERÊNCIAS

ALKHALED, M.; ALSUSA, E.; HAMDY, K. A. Adaptive pilot allocation algorithm for pilot contamination mitigation in tdd massive mimo systems. **IEEE Transactions on Wireless Communications**, 2017 IEEE Wireless Communications and Networking Conference (WCNC), San Francisco, CA, USA, p. 6, May 2017. ISSN 1. Disponível em: <<https://ieeexplore.ieee.org/document/7925885>>.

ANATEL, A. N. d. T. **Edital de 5G já está aberto para contribuições da sociedade.** Fev 2020. Disponível em: <<https://antigo.anatel.gov.br/institucional/component/content/article/171-manchete/2505-edital-de-5g-ja-esta-aberto-para-contribuicoes-da-sociedade>>.

BANKS, J. V. e. C. A. A. A review of particle swarm optimization part i background and development. **Springer Science e Business Media**, Springer Science e Business Media, Jul 2007. ISSN 1.

BJÖRNSSON, E.; HOYDIS, J.; SANGUINETTI, L. **Massive MIMO Networks: Spectral, energy, and hardware efficiency.** [S.l.]: Printed books, 2017.

CEET, C. f. E.-E. T. **CEET Report 2013-2015.** 2015. Disponível em: <<https://ceet.unimelb.edu.au/publications/ceet-annualreport-2015.pdf>>.

CHIUEH, T.-D.; TSAI, P.-Y.; LAI, I.-W. **Baseband Receiver Design for Wireless MIMO-OFDM Communications.** Singapore: John Wiley Sons Singapore Pte, 2012.

CISCO. **Cisco Visual Networking Index: Forecast and Trends, 2018-2023 White Paper.** Mar 2020. Disponível em: <<https://www.cisco.com/c/en/us/solutions/collateral/service-provider/visual-networking-index-vni/white-paper-c11-741490.html>>.

DAVIES, D. **Small Cells – Big in 5G**. may 2019. Disponível em: <<https://www.nokia.com/blog/small-cells-big-5g/>>.

DUBEY; ISHITA; GUPTA; MANISH. Uniform mutation and spv rule based optimized pso algorithm for tsp problem. **2017 4th International Conference on Electronics and Communication Systems (ICECS)**, Coimbatore, India, p. 168–172, 02 2017. Disponível em: <https://www.researchgate.net/publication/320665275_Uniform_mutation_and_SPV_rule_based_optimized_PSO_algorithm_for_TSP_problem>.

DURGIN, G. D. **Space-Time Wireless Channels**. Saddle River, NJ - USA: Prentice Hall, 2002.

ENERDATA. **Electricity domestic consumption**. 2018. Disponível em: <<https://yearbook.enerdata.net/electricity/electricity-domestic-consumption-data.html>>.

ERICSSON. **Ericsson Mobility Report**. Nov 2019. Disponível em: <<https://www.ericsson.com/4acd7e/assets/local/mobility-report/documents/2019/emr-november-2019.pdf>>.

EVERITT, B.; SKRONDAL, A. **The Cambridge Dictionary of Statistics**. Cambridge - United Kingdom: United States of America by Cambridge University Press, 2010.

GAO, H.; ZHANG, T.; FENG, Y. W. C. Clustering based pilot allocation algorithm for mitigating pilot contamination in massive mimo systems. **IEEE Transactions on Wireless Communications**, 2018 Asia-Pacific Microwave Conference (APMC), Kyoto, Japan, Nov 2018. ISSN 1. Disponível em: <<https://ieeexplore.ieee.org/document/8617326>>.

GOLDSMITH, A. **Wireless Communications**. Cambridge, United Kingdom: Cambridge University Press, 2005.

GRAGIDO DANIEL MOLINA, J. P. N. S. W. **Blackhatonomics**: An inside look at the economics of cybercrime. Waltham, USA: Syngress, 2012.

GSMA. **Energy Efficiency: An Overview**. May 2019. Disponível em: <<https://www.gsma.com/futurenetworks/wiki/energy-efficiency-2/>>.

GUO, X. W. P.; HAN, Y. The enhanced genetic algorithms for the optimization design. **IEEE Transactions on Wireless Communications**, 2010 3rd International Conference on Biomedical Engineering and Informatics, Yantai, China, Oct 2010. ISSN 1. Disponível em: <<https://ieeexplore.ieee.org/document/5639829>>.

HALLIDAY; RESSNICK. **Fundamentos de Física: Gravitação, ondas e termodinâmica**. Rio de Janeiro, RJ: Livros Técnicos e Científicos Editora LTDA, 2012.

HANSEN; PIERRE; MLADENOVIC; NENAD; BRIMBERG; JACK; MORENO-PÉREZ, J. Variable neighborhood search. **European Journal of Operational Research**, v. 191, p. 61–86, 09 2010. Disponível em: <https://www.researchgate.net/publication/225155945_Attraction_probabilities_in_variable_neighborhood_search>.

HATA, M. Empirical formula for propagation loss in land mobile radio services. **IEEE Transactions on Vehicular Technology**, v. 29, n. 3, p. 317–325, 1980.

IEA, I. E. A. **Energy data**. 2017. Disponível em: <<https://www.iea.org/data-and-statistics?country=WORLD&fuel=Energy\%20supply&indicator=Coal\%20production\%20by\%20type>>.

Jin, S.; Li, M.; Huang, Y.; Du, Y.; Gao, X. Pilot scheduling schemes for multi-cell massive multiple-input–multiple-output transmission. **IEEE Xplore**, IET Communications (Volume: 9, Issue: 5 , 3 26 2015), p. 689–700, 2015. Disponível em: <<https://ieeexplore.ieee.org/document/7076715>>.

Khan, A.; Irfan, M.; Ullah, Y.; Ahmad, S.; Ullah, S.; Hayat, B. Pilot contamination mitigation for high and low interference users in multi-cell massive mimo systems. **IEEE**, p. 1–5, 2019.

Kim, K.; Lee, J.; Choi, J. Deep learning based pilot allocation scheme (dl-pas) for 5g massive mimo system. **IEEE Communications Letters**, IEEE, v. 22, n. 4, p. 828–831, fev 2018. Disponível em: <<https://ieeexplore.ieee.org/document/8283585>>.

KU, L.; FAN, J.; DENG, J. Low complexity pilot allocation in massive mimo systems. **IEEE Transactions on Wireless Communications**, 2016 8th IEEE International

Conference on Communication Software and Networks (ICCSN), Beijing, China, p. 5, Jun 2016. ISSN 1. Disponível em: <<https://ieeexplore.ieee.org/document/7586691>>.

KUROSE, J. F.; ROSS, K. W. **Redes de computadores e a internet**: Uma abordagem top-down. [S.l.]: Pearson Education do Brasil Ltda, 2013.

Lago, L. A.; Zhang, Y.; He, Z.; Fei, Z. Pilot decontamination based on superimposed pilots in massive mimo systems. **IEEE Xplore**, 2018 IEEE 88th Vehicular Technology Conference (VTC-Fall), Chicago, IL, USA, USA, v. 8, p. 1–5, 2018. Disponível em: <<https://ieeexplore.ieee.org/document/8690763>>.

LUO, S.; ZHANG, C.; DUAN, Y.; CHEN, J. Pilot allocation game: A monte carlo tree based method. **IEEE**, Jeju, Korea (South), p. 277–282, 2019.

MARZETTA, T. L. How much training is required for multiuser mimo? **IEEE**, Pacific Grove, CA, USA, p. 359–363, 2006.

MARZETTA, T. L. Noncooperative cellular wireless with unlimited numbers of base station antennas. **IEEE Transactions on Wireless Communications**, v. 9, n. 11, p. 3590–3600, nov 2010. ISSN 15361276. Disponível em: <<http://ieeexplore.ieee.org/document/5595728/>>.

NEZAMABADI-POUR; HOSSEIN; ROSTAMI-SHAHRBABAHI; MAJID; FARSANGI; MALIHE. Binary particle swarm optimization: challenges and new solutions. **The Journal of Computer Society of Iran (CSI) On Computer Science and Engineering (JCSE)**, Research Gate, p. 21–32, April 2008. ISSN 1. Disponível em: <https://www.researchgate.net/publication/258456389_Binary_Particle_Swarm_Optimization_challenges_and_New_Solutions>.

NIE, X.; ZHAO, F. Joint pilot allocation and pilot sequence optimization in massive mimo systems. **IEEE Access**, Yulin, China, v. 8, p. 60637–60644, 2020. Disponível em: <<https://ieeexplore.ieee.org/document/9046793>>.

NIU, G.; MU, X.; GUO, X.; ZHANG, J. Pilot pollution algorithm based on cell sectorization elimination in massive mimo system. **IEEE Transactions on Wireless Communications**, 7th IET International Conference on Wireless, Mobile Multimedia

Networks (ICWMMN 2017), Beijing, China, p. 6, Nov 2017. ISSN 1. Disponível em: <<https://ieeexplore.ieee.org/document/8494663>>.

OKUMURA, Y. The mobile radio propagation model “okumura-curve” and the world’s first full-scale cellular telephone system. **2017 IEEE HISTory of ELectrotechnolgy CONference (HISTELCON)**, p. 107–112, 2017.

PARK, J.-M. **S.Korea first to roll out 5G services, beating U.S. and China.** 2019. Disponível em: <<https://www.reuters.com/article/southkorea-5g-idUSL3N21K114>>.

PATEL; SAGAR. Analysis implemetation of different detection techniques for multiple input multiple output communication system. **Conference: International Conference On Electronics and Communication Engineering(ICECE - 2012)**, Pondicherry, India, 09 2012.

PAULRAJ, A.; KAILATH, T. **Increasing capacity in wireless broadcast systems using distributed transmission/directional reception (DTDR).** Spacenet, 1994. US Patent 5,345,599. Disponível em: <<https://worldwide.espacenet.com/patent/search?q=pn\%3DUS5345599A>>.

RODRIGUEZ, J. **Small Cells for 5G Mobile Networks.** Pondicherry, India: John Wiley Sons, Ltd, 2015. 63-104 p.

SAMPAIO, L. D. H. Eficiência energética e capacidade: estratégias de alocação de recursos em redes sem fio de múltiplo acesso. **Biblioteca Digital de Tesis y Disertaciones de la USP**, Biblioteca Digital de Tesis y Disertaciones de la USP, São Paulo, SP, p. 1, may 2015. Disponível em: <<https://teses.usp.br/teses/disponiveis/3/3142/tde-13072016-160851/es.php>>.

SAXENA, V.; FODOR, G.; KARIPIDIS, E. Mitigating pilot contamination by pilot reuse and power control schemes for massive mimo systems. **IEEE**, Glasgow, UK, p. 1–6, 2015.

SIEMENS. **Telephony.** March 2020. Disponível em: <<https://new.siemens.com/global/en/company/about/history/technology/information-and-communications-technology/telephony.html>>.

TEETI, M. A.; WANG, R.; LIU, Y.; NI, Q. Pilot optimization in multicell massive mimo. **IEEE Xplore**, 2016 IEEE International Conference on Communication Systems (ICCS), Shenzhen, China, v. 8, p. 1–6, 2016. Disponível em: <<https://ieeexplore.ieee.org/document/7833554>>.

TSE, D.; VISWANATH, P. **Fundamentals of Wireless Communication**. Cambridge, United Kingdom: Cambridge University Press, 2004.

UDDIN, H.; GIBSON, M.; SAFDAR, G. A.; KALSOOM, T.; RAMZAN, N.; UR-REHMAN, M.; IMRAN, M. A. IoT for 5g/b5g applications in smart homes, smart cities, wearables and connected cars. **2019 IEEE 24th International Workshop on Computer Aided Modeling and Design of Communication Links and Networks (CAMAD)**, Limassol, Cyprus, p. 1–5, 2019.

UN-DESA, D. **World Population Prospects 2019**. 2019. Disponível em: <<https://population.un.org/wpp/>>.

VALKENBURG, M. E. V. **Reference Data for Engineers: Radio, electronics, computer, and communications**. Woburn, USA: Newnes, 2001.

Xu, S.; Zhang, H.; Tian, J.; Wu, D.; Yuan, D. Pilot length optimization for spectral and energy efficient d2d communications underlay massive mimo networks. In: **2018 International Conference on Computing, Networking and Communications (ICNC)**. Maui, HI, USA: IEEE, 2018. p. 855–860.

ZHANG, N.; BAI, Z. Q.; ZHANG, B.; SU, Y.; HAN, T.; KWAK, K. Genetic algorithm based pilot allocation scheme for massive mimo system. **IEEE Transactions on Wireless Communications**, 2016 IEEE International Conference on Communication Systems (ICCS), Shenzhen, China, p. 5, Dec 2016. ISSN 1. Disponível em: <<https://ieeexplore.ieee.org/document/7833582>>.

Zhang, X.; Liu, J.; Wu, S.; Zhai, C.; Yu, S. Uplink pilot power control with genetic algorithm for massive mimo networks. **IEEE Xplore**, 2017 9th International Conference on Wireless Communications and Signal Processing (WCSP), Nanjing, China, v. 8, p. 1–6, 2017. Disponível em: <<https://ieeexplore.ieee.org/document/8171161>>.

ZHOU, Z.; WANG, D. Pilot scheduling based on water-filling algorithm in massive mimo. **IEEE Xplore**, 2016 6th International Conference on Electronics Information and Emergency Communication (ICEIEC), Beijing, China, p. 89–92, 2016. Disponível em: <<https://ieeexplore.ieee.org/document/7589694>>.

Zhu, X.; Dai, L.; Wang, Z.; Wang, X. Weighted-graph-coloring-based pilot decontamination for multicell massive mimo systems. **IEEE Transactions on Vehicular Technology**, v. 66, n. 3, p. 2829–2834, 2017.

Zhu, X.; Wang, Z.; Dai, L.; Qian, C. Smart pilot assignment for massive mimo. **IEEE Communications Letters**, IEEE Communications Letters (Volume: 19, Issue: 9, Sept. 2015), v. 19, n. 9, p. 1644–1647, may 2015. Disponível em: <<https://ieeexplore.ieee.org/document/7055279>>.

