

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

PEDRO LUCAS TEIXEIRA SEGA

**ESTUDO E SIMULAÇÃO COMPUTACIONAL DE SUPERFÍCIES REFLETORAS
INTELIGENTES EM SISTEMAS 5G E ALÉM**

CORNÉLIO PROCÓPIO

2022

PEDRO LUCAS TEIXEIRA SEGA

**ESTUDO E SIMULAÇÃO COMPUTACIONAL DE SUPERFÍCIES REFLETORAS
INTELIGENTES EM SISTEMAS 5G E ALÉM**

**Analysis and computer simulation of intelligent reflective surfaces on 5G
and beyond systems**

Trabalho de Conclusão de Curso de Graduação
apresentado como requisito para obtenção do
título de Bacharel em Engenharia Elétrica
do Curso de Bacharelado em Engenharia
Elétrica da Universidade Tecnológica Federal do
Paraná.

Orientador: Prof. Dr. José Carlos Marinello Filho

CORNÉLIO PROCÓPIO

2022



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

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



Universidade Tecnológica Federal do Paraná
Campus Cornélio Procópio
Departamento Acadêmico de Elétrica
Engenharia Elétrica



FOLHA DE APROVAÇÃO

Pedro Lucas Teixeira Segal

Estudo e Simulação Computacional de Superfícies Refletoras Inteligentes em Sistemas 5G e Além

Trabalho de conclusão de curso apresentado às 14:00hs do dia 07/12/2022 como requisito parcial para a obtenção do título de Bacharel em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná. O(A) candidato(a) foi arguido(a) pela Banca Avaliadora composta pelos professores(as) abaixo assinados. Após deliberação, a Banca Avaliadora considerou o trabalho aprovado.

Prof(a). Dr(a). José Carlos Marinello Filho - Presidente (Orientador(a))

Prof(a). Dr(a). Eduardo Alves Hodgson - (Membro)

Prof(a). Dr(a). Renata Coelho Borges - (Membro)

A folha de aprovação assinada encontra-se na coordenação do curso.

AGRADECIMENTOS

Agradeço primeiramente a Deus pelo dom da vida, por ter me oferecido todas as oportunidades e ter colocado pessoas incríveis no meu caminho.

Agradeço à minha família, pelo amor e apoio incondicional.

Agradeço ao meu orientador José Carlos Marinello Filho, por toda atenção, empenho e confiança.

Agradeço a todos professores e colegas de turma, que tornaram essa jornada fascinante e proveitosa.

Agradeço à Universidade Tecnológica Federal do Paraná pelo acolhimento durante todos esses anos.

"Pesquisar é ver aquilo que todos os demais
viram e imaginar aquilo que ninguém havia
pensado."

Albert Szent Györgyi

RESUMO

Superfícies refletoras inteligentes consistem em tecnologias emergentes para redes de telecomunicações além do 5G, são constituídas de elementos refletores passivos, sendo cada um deles capaz de induzir, de forma independente, uma amplitude e mudança de fase do sinal incidente, permitindo reconfigurar de forma inteligente o ambiente de propagação. A reflexão inteligente apresenta como um dos pilares a determinação apropriada dos coeficientes de reflexão, que em implementações práticas assume valores discretos, para potencializar os indicadores de desempenho. Contudo, o processo para obtenção de valores otimizados resulta em um problema de alta complexidade contornado através da implantação de módulos de inteligência artificial, com abordagens que englobam o aprendizado por reforço e os algoritmos genéticos, que possibilitam obter soluções de alta qualidade para compor sistemas de comunicação sem fio de próximas gerações.

Palavras-chave: superfícies refletoras inteligentes; inteligência artificial; 6g.

ABSTRACT

Intelligent reflective surfaces consist of emerging technologies for telecommunications networks beyond 5G. They are made of passive reflective elements, each of them are capable of inducting, independently, an amplitude and a phase change of the incident signal, allowing smart reconfiguration of the propagation environment. Intelligent reflection has one of its foundations being the appropriate determination of the reflection coefficients, which in practical implementations takes on discrete values, to potentialize performance indicators. However, the process to obtain optimized values results in high complexity issues bypassed by the implementation of artificial intelligence modules, with approaches that consist of reinforcement learning and genetic algorithms, which make it possible to obtain high quality solutions to set the ground for wireless communications systems of the next generations.

Keywords: intelligent reflecting surfaces; artificial intelligence; 6g.

LISTA DE FIGURAS

Figura 1 – Formação de feixe	22
Figura 2 – Principais aplicações.	23
Figura 3 – Arquitetura típica.	25
Figura 4 – Modelo de sistema de telecomunicação auxiliado por superfície refletora. . .	36
Figura 5 – Modelo de sistema para otimização do posicionamento.	37
Figura 6 – SNR em dB pela posição da horizontal.	37
Figura 7 – Modelo de sistema para discretização dos desvios de fase.	38
Figura 8 – Relação sinal-ruído em dB por bits de controle.	38
Figura 9 – Capacidade por bits de controle.	39
Figura 10 – <i>Bit error rate</i> por bits de controle.	39
Figura 11 – Modelo de sistema para otimização de reflexão.	40
Figura 12 – Metodologia de aprendizado por reforço para otimização de reflexão.	41
Figura 13 – Convergência do aprendizado por reforço para sistema SISO.	43
Figura 14 – Convergência do aprendizado por reforço para sistema MISO.	43
Figura 15 – Metodologia de algoritmo genético para otimização de reflexão.	44
Figura 16 – Convergência da SNR em dB do algoritmo genético para sistema SISO. . . .	45
Figura 17 – Convergência da SNR em dB do algoritmo genético para sistema MISO. . .	45
Figura 18 – Comparação da convergência para sistema SISO.	46
Figura 19 – Comparação da convergência para sistema SISO incluindo a busca aleatória. .	47
Figura 20 – Análise comparativa da relação sinal-ruído para sistema SISO.	47
Figura 21 – Análise comparativa da <i>bit error rate</i> para sistema SISO.	48
Figura 22 – Análise comparativa da capacidade de canal para sistema SISO.	48
Figura 23 – Comparação da convergência para sistema MISO	49
Figura 24 – Comparação da convergência para sistema MISO incluindo a busca aleatória. .	49
Figura 25 – Análise comparativa da relação sinal-ruído para sistema MISO.	50
Figura 26 – Análise comparativa da <i>bit error rate</i> para sistema MISO.	50
Figura 27 – Análise comparativa da capacidade de canal para sistema MISO.	51

LISTA DE ABREVIATURAS E SIGLAS

Siglas

AG	algoritmos genéticos
AWGN	<i>additive white Gaussian noise</i>
B5G	sistemas de comunicação além do 5G
BER	taxa de erro de bit
BS	estação rádio base
CSI	informações de estado do canal
IA	inteligência artificial
IoE	Internet de tudo
LOS	linha de visão
MC	Monte-Carlo
MINLP	problema de programação não linear de inteiros misto
MISO	<i>Multiple-Input Single-Output</i>
MISO	<i>multiple-input single-output</i>
ML	aprendizado de máquina
mMTC	comunicação massiva do tipo máquina
mmWAVE	ondas milimétricas
MRT	relação de transmissão máxima
NLOS	sem linha de visão
NP	Problemas de tempo polinomial não determinístico
PIN	positivos intrínsecos negativos
QCQP	programa quadrático restrito quadraticamente
QoS	qualidade do serviço

RIS	superfície refletora inteligente
RL	aprendizado por reforço
SISO	<i>Single-Input Single-Output</i>
SNR	relação sinal-ruído
uHDD	densidade de dados ultra-alta
uHSLC	ultra-alta velocidade com comunicações de baixa latência
uMUB	banda ultralarga móvel ubíqua
VR	realidade virtual

LISTA DE SÍMBOLOS

Letras Latinas

a	estado do aprendizado por reforço
b	ação do aprendizado por reforço
r	recompensa
N	Número de elementos refletores
BW	largura de banda
n	n -ésimo elemento refletor
t	tempo
m	Sinal transmitido
x	sinal de informação
w	coeficiente de precodificação
l	variável log-normal associada ao sombreamento
d	distância
PL	perda de percurso
f	frequência
s	sinal em banda base
h	coeficiente de canal entre atrelado à estação base
g	coeficiente de canal entre a superfície refletora e o usuário
z	ruído branco
P	potência
M	ordem de diversidade
r	taxa máxima alcançável
SNR	relação sinal-ruído
p	probabilidade de ocorrência

k	estado da variável aleatória
ind	índice da iteração de aprendizagem
var	constante arbitrária
K	fator da componente de linha de visão
Q	matriz de recompensa
A	espaço de estados do aprendizado por reforço
B	espaço de ações do aprendizado por reforço
R	recompensa do aprendizado por reforço
d	número de bits de controle
D	número de valores possíveis para o deslocamento de fase
$instan$	relação sinal-ruído até a presente iteração de aprendizagem
IQR	intervalo interquartil até a presente iteração de aprendizagem
MD	intervalo interquartil até a presente iteração de aprendizagem
j	unidade imaginária

Letras Gregas

μ	fator de desconto
ρ	coeficiente de larga escala
η	distribuição dos coeficientes de pequena escala
ϵ	coeficiente de pequena escala
α	atenuação de amplitude do canal
ξ	desvio de fase do canal
γ	coeficiente de perda de percurso
β	atenuação de amplitude da superfície refletora inteligente
θ	desvio de fase da superfície refletora inteligente
σ^2	variância
Θ	matriz de reflexão da superfície refletora inteligente
ϕ	ângulo de fase do canal entre a estação e a superfície
ψ	ângulo de fase do canal entre a superfície e o usuário
ζ	ângulo de fase do canal entre a estação e o usuário
Δ	variação
τ	taxa de aprendizagem do aprendizado por reforço
δ	fator de ponderação

Sobrescritos

T	transposto
-----	------------

$*$	conjugado
H	hermitiano
$\times$	Dimensão do espaço

Subscritos

t	tempo atual
$t + 1$	tempo futuro
a	atraso de reflexão
r	parte real
i	parte imaginária
d	link direto
r	link intermediado
c	associado à onda portadora
n	associado ao n -ésimo elemento
1	associado ao canal entre estação base e superfície refletora
2	associado ao canal entre superfície refletora e usuário
θ	associado ao θ -ésimo elemento
out	refletido
in	incidente
D	associado ao conjunto discreto
RL	associado ao aprendizado por reforço
AG	associado ao algoritmo genético

Notações

$diag$	matriz diagonal
mod	operação módulo
$s.t.$	de modo que, do inglês <i>such that</i>
$\mathbb{C}$	conjunto dos números complexos
$\mathcal{F}$	conjunto de valores para os desvios de fase
$\in$	pertence
Re	denota a parte real
$\propto$	denota proporcionalidade

x	variáveis em itálico denotam escalares
$\boldsymbol{x}$	variáveis minúsculas em negrito denotam vetores
$\boldsymbol{X}$	variáveis maiúsculas em negrito denotam vetores

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Motivação	18
1.2	Objetivos	18
1.2.1	Objetivo Geral	18
1.2.2	Objetivos Específicos	18
1.3	Justificativa	18
1.4	Estado da arte	19
2	AMBIENTE SEM FIO RECONFIGURÁVEL POR SOFTWARE	20
2.1	Fenômenos físicos	20
2.2	Processamento de sinais	21
2.3	Fundamentos de superfícies refletoras	23
2.3.1	Aplicações	23
2.3.2	Arquitetura de Hardware	25
3	MODELO DE SISTEMA	27
3.1	Sinal da superfície refletora inteligente e modelo de canal	27
3.2	Sistema MISO auxiliado por IRS	30
3.3	Discretização dos desvios de fase	32
4	MÉTODOS DE OTIMIZAÇÃO	33
4.1	Princípios de aprendizado por reforço	34
4.2	Princípios de Algoritmos Genéticos	35
5	SIMULAÇÃO DE SUPERFÍCIES REFLETORAS INTELIGENTES	36
5.1	Posicionamento da superfície refletora	37
5.2	Discretização dos desvios de fase	38
5.3	Otimização de reflexão	40
5.3.1	Otimização baseada em aprendizado por reforço	41
5.3.2	Otimização baseada em algoritmos genéticos	44
5.3.3	Análise Comparativa	46
6	CONCLUSÃO	52
	REFERÊNCIAS	53

1 INTRODUÇÃO

Sistemas de telecomunicações de quinta geração estão sendo implantados ao redor do mundo. Contudo, tanto a academia (HUANG; MO; YUEN, 2020), quanto a indústria (HUANG *et al.*, 2020), analisam com entusiasmo as necessidades e aplicações de sistemas de comunicação além do 5G (B5G). Tal fato ocorre devido ao rápido desenvolvimento de várias aplicações como inteligência artificial (IA), realidade virtual (VR) e Internet de tudo (IoE), além de uma tendência de uma sociedade com sistemas de gerenciamento remoto e automatizado, que vem gerando um enorme aumento no volume de tráfego (MUMTAZ *et al.*, 2017).

Sistemas de comunicação sem fio esperados para as próximas gerações devem suprir requisitos superiores às redes de quinta geração (TARIQ *et al.*, 2020), como elevado número de dispositivos conectados, conectividade global, baixa latência, eficiência energética e espectral, alta confiabilidade e inteligência conectada com capacidade de aprendizado de máquina (VISWANATHAN; MOGENSEN, 2020) (WU *et al.*, 2021). Além de indicadores de performance como banda ultralarga móvel ubíqua (uMUB), ultra-alta velocidade com comunicações de baixa latência (uHSLLC), comunicação massiva do tipo máquina (mMTC) e densidade de dados ultra-alta (uHDD) (LI; FEI; ZHANG, 2019).

O principal fator que interfere a confiabilidade de um canal de comunicação sem fio é a sua característica estocástica, gerada pela interação com o ambiente de propagação, seja ela devido aos fenômenos de pequena ou larga escala, que provoca uma falta de confiabilidade inerente. Na tentativa de reverter a influência do canal, são utilizados mecanismos sofisticados de processamento de sinais, como protocolos de transmissão, modulação, codificação e técnicas de diversidade e formação de feixe (ELMOSSALLAMY *et al.*, 2020). No entanto, o controle do canal é limitado, impactando diretamente a eficiência da comunicação e qualidade do serviço (QoS).

Com o objetivo de aprimorar os sistemas de comunicação sem fio, com foco no controle do ambiente de propagação, uma nova tecnologia norteia o estado da arte de sistemas de sexta geração e é intitulada, dentre outras denominações, de superfície refletora inteligente (RIS). Sua finalidade principal corresponde em alterar dinamicamente os canais sem fio, buscando melhorar o desempenho da comunicação através da reflexão dos sinais incidentes.

As RISs são superfícies planas formadas por elementos refletores passivos de baixo custo, sendo cada um deles capaz de induzir uma amplitude e mudança de fase controlável e independente. A contribuição conjunta dos elementos refletores possibilita agregar um feixe incidente disperso e irradiar feixes estreitos direcionados à região de interesse.

Por meio da reflexão inteligente, os sinais de rádio podem ser refletidos nas direções desejadas, permitindo a criação de uma linha de visão virtual entre a estação rádio base (BS) e o receptor, com o objetivo de contornar obstáculos, além de criar links suplementares, de modo a aprimorar a classificação do canal, e incrementar o sinal incidente através de associações construtivas e suprimir interferências por meio de adições destrutivas (WU *et al.*, 2021).

Na perspectiva da eficiência energética, os elementos refletores presentes na RIS atuam de forma passiva, sem exigir sofisticados métodos de processamento de sinais e nem novas cadeias de transmissão de radiofrequência, sendo, portanto, operados com gasto energético inferiores às antenas ativas. Além disso, a criação de uma linha de visão virtual proporciona aumento na taxa de transferência de dados aumentando a eficiência espectral (LIU *et al.*, 2021).

Devido às suas dimensões reduzidas e leveza, as RIS podem ser facilmente implantadas em diversas estruturas de forma transparente (WU *et al.*, 2021). Além disso, podem ser integradas nas arquiteturas de telecomunicações atuais devido à sua compatibilidade com os padrões de hardware existente (LIU *et al.*, 2021).

As superfícies refletoras inteligentes são vistas como uma tecnologia promissora capaz de reconfigurar o ambiente de propagação sem fio via reflexão controlada (HUANG *et al.*, 2018), modificando proativamente o canal sem fio e oferecendo um novo grau de liberdade para aprimorar o desempenho da comunicação.

As superfícies refletoras inteligentes deram origem ao conceito emergente de ambiente de rádio inteligente, que consiste em uma rede sem fio onde o ambiente de propagação é reconfigurável por software desempenhando um papel ativo na transferência e processamento de informações (ZAPPONE; RENZO; DEBBAH, 2019). Ambientes com o uso massivo de RISs são programáveis, deixando de ser um componente incontável do sistema e passando a representar uma variável a ser otimizada (ELMOSSALLAMY *et al.*, 2020).

As reflexões passivas precisam ser devidamente projetadas para assegurar o foco cooperativo, exigindo valores otimizados para os parâmetros da RIS, em um amplo espaço de busca, de modo a assegurar métricas elevadas de desempenho. Como forma de contornar a complexidade imposta, arquiteturas de sistemas de comunicação com superfícies refletoras podem ser estruturados com módulos de IA para fornecer soluções promissoras para configuração dos coeficientes de reflexão (JIAN *et al.*, 2022).

Técnicas de IA, mais especificamente no campo do aprendizado de máquina (ML), apresentam grande relevância em comunicação sem fio, especialmente quando aplicadas em RISs (FAISAL; CHOI, 2022). Sua aplicação, por meio do aprendizado por reforço (RL), permite maximizar de forma iterativa uma função objetivo através da distribuição de recompensas que medem o desempenho de uma ação.

Uma abordagem alternativa de IA corresponde aos algoritmos genéticos, que pertencem à classe de métodos metaheurísticos de otimização biologicamente inspirados. São baseados em população e utilizam os princípios da seleção natural, por meio de operadores genéticos, para explorar eficientemente o espaço de busca (WU *et al.*, 2011).

A comparação entre diversas vertentes de IA, que apresentam procedimentos metodológicos diferentes, permite uma análise mais precisa acerca do comportamento e desempenho dos algoritmos de otimização na determinação dos coeficientes de reflexão ótimos requeridos para redes B5G.

1.1 Motivação

Sistemas de comunicação sem fio de gerações futuras exigem múltiplas abordagens para que sejam assegurados os requisitos de qualidade e conectividade. Na perspectiva das superfícies refletoras inteligentes, uma das variáveis a ser otimizada consiste no coeficiente de reflexão, que deve ser ajustado de modo a obter um valor ótimo que aprimore a comunicação sem fio.

1.2 Objetivos

1.2.1 Objetivo Geral

Modelar e implementar um sistema de comunicação sem fio, considerando modelos consolidados de canal, com a presença de superfície refletora inteligente, visando determinar os coeficientes de reflexão por meio de técnicas de inteligência artificial.

1.2.2 Objetivos Específicos

- Modelagem realista de ambientes de propagação sem fio auxiliados por RIS.
- Estudo e análise de aplicabilidade de técnicas de IA, baseadas em metaheurísticas e aprendizado de máquina, em sistemas de telecomunicações.
- Simulação computacional e análise de desempenho de sistemas de comunicação sem fio assistidos por superfícies refletoras inteligentes, com os coeficientes de reflexão proveniente de algoritmos de IA.
- Reconhecimento de variações de desempenho mediante a alteração de parâmetros associados à RIS e aos métodos de otimização.

1.3 Justificativa

As superfícies refletoras inteligentes constituem um novo paradigma para tornar o ambiente de propagação sem fio uma entidade reprogramável e permitem, por meio de da implantação massiva, tornar o canal uma variável que pode ser potencializada no sistema. Atrair seu potencial com as técnicas de inteligência artificial, através da obtenção do coeficientes de reflexão ótimos, possibilita superar desafios associados ao ambiente de propagação e contribuir para atender os requisitos fundamentais para sistemas futuros de comunicação sem fio.

1.4 Estado da arte

Superfícies refletoras inteligentes, que também podem receber as denominações de *Intelligent Wall* (SUBRT; PECHAC, 2012), *smart reflectarray* (TAN *et al.*, 2018), *reconfigurable metasurface/intelligent surface* (RENZO *et al.*, 2019) (BASAR *et al.*, 2019), *large intelligent surface/antennas* (LIANG *et al.*, 2019)(LISA) e RFocus (ARUN; BALAKRISHNAN, 2019), são consideradas tecnologias promissoras para ambientes de comunicação de sexta geração (BASAR, 2021) (MATTHIESEN *et al.*, 2020) (HUANG; ZHENG; ZHANG, 2021) e apresentam grande potencial em canais ponto a ponto (TAN *et al.*, 2018) (WU; ZHANG, 2018) (WANG *et al.*, 2020) (BASAR, 2019), canais de transmissão em *downlink* (HUANG *et al.*, 2018) (HUANG *et al.*, 2018a) (GUO *et al.*, 2019) e canais em *uplink* (CAO *et al.*, 2021) (ZHENG; YOU; ZHANG, 2020) (HUA; SHI, 2019) (JIANG; SHI, 2019).

A obtenção de soluções ótimas para os valores dos coeficientes de reflexão, por meio da otimização da relação sinal-ruído, pode ser realizada por métodos baseados em penalidades (WU; ZHANG, 2020b), aproximação convexa sucessiva (WU; ZHANG, 2019b) (YANG *et al.*, 2020), otimização de variedade (YU; XU; SCHOBBER, 2020), relaxamento semidefinido com randomização Gaussiana (WU; ZHANG, 2019a), otimização alternada (WU; ZHANG, 2020a), além de aprendizado por reforço profundo (FENG *et al.*, 2020).

2 AMBIENTE SEM FIO RECONFIGURÁVEL POR SOFTWARE

O ambiente de propagação apresenta a maior fonte de incerteza durante o processo de comunicação sem fio. As técnicas de processamento de sinais, através do entendimento e modelagem dos fenômenos físicos envolvidos, buscam reverter o efeito do canal. Todavia, o controle do canal é limitado, de modo que o uso de superfícies refletoras inteligentes, com projeto de hardware e programação de software adequados, fornecem a possibilidade de moldar e controlar o ambiente sem fio.

2.1 Fenômenos físicos

A interação com o ambiente de propagação, devido ao grande número de processos aleatórios associados, acarreta em um modelo de canal predominantemente probabilístico que impacta diretamente a potência recebida no usuário. Desse modo, de acordo com o teorema do limite central, a distribuição normalizada da soma de variáveis aleatórias independentes avança em direção de uma distribuição gaussiana conforme o número de variáveis aumenta, independentemente das distribuições individuais. Dessa forma, a potência recebida, devido ao comportamento do canal, pode ser representada por uma parcela determinística e outra estocástica, relacionada com distribuições de probabilidade gaussianas.

As variações na potência média estão associadas a fenômenos de larga escala, já que são observados em ordens superiores à do comprimento de onda. São, em parte, decorrentes de fatores relacionados à perda de percurso, que representa a perda de intensidade natural e gradual à medida que uma onda eletromagnética se propaga. Quando a variação da potência média está associada à presença de bloqueios físicos que geram a obstrução do sinal, o efeito recebe o nome de sombreamento ou desvanecimento lento. A modelagem do sombreamento é realizada através de uma variável aleatória cujo logaritmo é normalmente distribuído, obedecendo o teorema do limite central no domínio logarítmico, que está associado ao produto de variáveis aleatórias positivas.

Os fenômenos de pequena escala, também denominados de desvanecimento rápido, estão atrelados à flutuações na potência instantânea e são gerados pela sobreposição de diversas frentes de onda que geram adições construtivas e destrutivas no sinal do receptor. Cada um dos sinais atrasados apresentam diferentes ganhos de amplitude e fase e estão associados à presença de superfícies refletoras e espalhadoras que geram multipercursos de propagação ao sinal.

A distorção multipercurso é representada, em análises de sistemas de comunicações, como sendo o coeficiente de canal, que denota uma variável aleatória de distribuição gaussiana com efeito multiplicativo ao sinal transmitido. Seu cenário mais hostil, descrito por baixos valores, é denominado de desvanecimento profundo.

A distribuição de probabilidade adotada para a distorção multipercurso varia de acordo com o cenário, sendo o fator predominante a presença, ou não, de uma componente de linha de visada entre emissor e receptor. O desvanecimento de Rice consiste em um modelo estatístico para modelar um ambiente de propagação de um sinal de rádio e assume que a magnitude de um sinal transmitido desvanece de acordo com uma distribuição de Rice, sendo destinado para situações em que há linha de visão (LOS) entre o emissor e o receptor majoritariamente às demais reflexões multipercurso. Enquanto o modelo de Rayleigh é adequado para cenários sem linha de visão (NLOS) entre emissor e receptor, sendo, portanto, um caso específico da distribuição de Rice.

Ao ser transmitido pelo canal sem fio, o sinal sofre um processo de distorção causado pela adição de uma componente aleatória denominada de ruído, decorrente de diversos fenômenos físicos de natureza estocástica, de modo a retornar ao teorema do limite central (HAYKIN; MOHER, 2011). Logo, em sistemas de comunicação, a modelagem do ruído é tipicamente feita por meio do ruído idealizado denotado como *additive white Gaussian noise* (AWGN) que não pode ser filtrado na banda do sinal e apresenta densidade espectral de potência independente de frequência, de modo que todos os atrasos fora da origem apresentam função de autocorrelação nula (AGUIRRE, 2007).

2.2 Processamento de sinais

A partir da segunda geração de sistemas de telecomunicações, o processo de comunicação é realizado de modo digital (GUPTA; JHA, 2015) devido às suas vantagens como robustez, confiabilidade, segurança, eficiência e facilidade de integração, a um custo de aumento de complexidade. Atualmente, os sistemas de comunicação digital podem ser projetados de maneira economicamente viáveis, graças aos contínuos melhoramentos em circuitos integrados (HAYKIN; MOHER, 2011), indicando que as redes futuras estudadas de comunicações sem fio permanecem adotando como padrão o sistema digital.


Nos sistemas de comunicação digital, os bits de informação são codificados em um diagrama de constelação por meio do processo de modulação. O conjunto de estados possíveis representa a ordem de modulação e cada um dos elementos corresponde a um símbolo. Ordens de modulação mais elevadas permitem maiores taxas de dados. Em contrapartida, ocorre a redução da região de decisão atrelada à cada símbolo, tornando o esquema de transmissão mais suscetível a ruídos. Desse modo, grandes constelações são recomendadas para cenários onde a razão entre a potência do sinal e a potência do ruído são elevadas.

Os símbolos modulados sofrem distorção ao se propagar pelo canal sem fio. Em canais reversos, ou de *uplink*, o processo de compensação das alterações no sinal é realizado mediante técnicas de detecção de dados. Enquanto para canais diretos, ou de *downlink*, a estratégia de transmissão engloba a pré-equalização do canal de modo a reverter a interferência antes mesmo delas ocorrerem.

Em conjunto com as técnicas de modulação, as estratégias de diversidade espacial buscam mitigar as distorções do canal através da utilização de arranjos de antenas distribuídos de forma espaçada, com o objetivo de aproveitar a característica multipercurso do canal sem fio. Sendo assim, com o aumento do número de antenas, ou ordem de diversidade, a probabilidade dos elementos de antena enfrentarem um cenário de desvanecimento profundo de forma simultânea diminui. Essencialmente, quanto maior o número de antenas, maior o número de graus de liberdade que o canal de propagação pode oferecer, aprimorando o desempenho em termos de taxa de dados e confiabilidade do link.

A associação dos sinais de diversas antenas pode ser realizada por meio do *beamforming*, visando a transmissão de sinal direcional através dos elementos de antenas, de modo a obter interferência construtiva em sinais de ângulos de fase específicos e destrutiva em outros. A técnica consiste em um formador de feixe controlando a fase e amplitude do sinal de cada antena, gerando um feixe estreito e direcional na frente de onda, de acordo com a Figura 1.

Figura 1 – Formação de feixe



Fonte: Autoria própria (2022).

A pré-codificação consiste em uma generalização do *beamforming* para suportar uma transmissão multicamadas em comunicação sem fio multiantenas. Na formação do feixe, ocorre uma transmissão, com ponderação apropriada de fase e ganho a partir do conhecimento de canal, buscando, de forma concorrente, a maximizar a relação entre a potência do sinal e do ruído no receptor ou suprimir interferências.

O processo de formação de feixe depende das informações acerca do modo como um sinal se propaga do transmissor para o receptor, que é descrito pelas informações de estado do canal (CSI) e representam os efeitos associados de espalhamento, desvanecimento e redução da potência proporcional à distância. Por meio das informações de estado do canal é possível adaptar as transmissões às condições atuais do ambiente de propagação, que é ferramenta essencial para comunicação ultraconfiável, com alta taxa de dados, em sistemas multiantenas.

A estimativa de CSI é realizada no receptor e, geralmente, quantizada e realimentada no transmissor, sendo sua aquisição praticamente limitada pela velocidade em que as condições do canal variam no tempo. A projeção do conhecimento de canal apresenta uma abordagem denominada de sequência piloto, onde um sinal conhecido é transmitido e o estado do canal é estimado comparando o sinal transmitido e recebido (GUPTA; JHA, 2015).


2.3 Fundamentos de superfícies refletoras

2.3.1 Aplicações

Superfícies refletoras inteligentes, de modo geral, corresponde em superfícies planas com um elevado número de elementos refletores passivos, sendo cada um deles capaz de induzir uma mudança de amplitude e fase no sinal incidente de modo independente, possibilitando amplificação do sinal de interesse, por meio de interferência construtiva, e atenuação de sinais indesejados, através de interferências destrutivas.

Nos padrões atuais dos sistemas de telecomunicações, as ondas eletromagnéticas se propagam por meio do canal sem fio sujeita aos seus efeitos e distorções. Em sistemas B5G é esperado, por meio do emprego de RIS implantadas densamente, que o canal sem fio seja um componente a ser otimizado, moldado e, pelo menos de forma parcial, controlado através da reflexão inteligente (RENZO; DANUFANE; TRETYAKOV, 2022).

Suas aplicações, de acordo com a Figura 2, se estendem à criação de uma linha de visão virtual entre a estação rádio base e o terminal, com o objetivo de contornar obstáculos, permitindo ainda a criação de novos caminhos de propagação refinando as estatísticas no canal e convertendo um canal com desvanecimento rápido em lento ou com distribuição de Rayleigh em Rice (WU *et al.*, 2021).



Fonte: Autoria própria (2022).

A RISs atua como um coletor de ondas que permite alterar o campo eletromagnético de forma personalizável, agregando um conjunto de sinais incidentes dispersos espacialmente e realizando o redirecionamento como um feixe estreito e direcionado através da escolha correta nos deslocamentos de fase.

O padrão de interferência da RIS pode ser utilizado para aprimorar a segurança da camada física da rede, já que devido à natureza *broadcast* da transmissão sem fio, o sinal está sujeito a ataques que atentam contra a confidencialidade das informações. O processo é realizado deteriorando o sinal em uma direção não desejada por meio de interações destrutivas, oferecendo uma alternativa às técnicas de ruídos artificiais e complexos protocolos de troca de chaves (CUI; ZHANG; ZHANG, 2019).

A criação de linhas de visão virtuais entre emissor e receptor, por meio de superfícies inteligentes, promove a extensão da área de cobertura, característica essa que pode ser extremamente útil para as promissoras ondas milimétricas (mmWAVE) e ondas submilimétricas (LIASKOS *et al.*, 2018a), que oferecem taxas de transferência de dados sem precedentes e minimização do tamanhos de dispositivos. Em contrapartida, são altamente suscetíveis a bloqueios, por conta da absorção, desvanecimento multipercurso e deslocamento Doppler, sendo seu uso sem RIS limitado à curtas distâncias (AKYILDIZ *et al.*, 2016).

Ao compensar a perda de caminho em longas distâncias e criando uma linha de visão virtual, as RISs possibilitam o aumento da taxa de dados, especialmente quando o link direto está intensamente bloqueado, resultando em maior eficiência espectral que corresponde a uma das premissas de sistemas B5G (LIU *et al.*, 2021).

Na perspectiva do consumo de energia, a RIS apresenta capacidade de incrementar o sinal de incidente sem nenhum amplificador de potência ou cadeia de radiofrequência e sem aplicar métodos de processamento de sinais como amplificação, filtragem ou mixagem, sendo sua capacidade de moldar as ondas de rádio incidentes decorrente apenas do projeto adequado dos deslocamentos de fase aplicados por cada elemento refletor. Além disso, pode ser alimentada com módulos de coleta de energia, resultando em um elemento neutro para o sistema elétrico (JIAN *et al.*, 2022).

A integração de RIS na estrutura de redes de comunicação sem fio permite uma arquitetura híbrida com elementos ativos e passivos trabalhando em conjunto de forma inteligente, o que gera uma redução no custo de implantação, já que os elementos passivos são mais acessíveis que os equivalentes ativos.

As redes sem fio auxiliadas por RIS, ainda, são compatíveis com os padrões e hardware das redes sem fio existentes (LIU *et al.*, 2021) e apresentam operação *full duplex* sem autointerferência significativa ou aumento do nível de ruído (JIAN *et al.*, 2022).


Devido aos seus elementos de baixo custo, baixo consumo energético, baixas dimensões e leveza, as RIS podem ser facilmente implantadas de forma massiva em redes de comunicação nas mais diversas localidades (HUANG *et al.*, 2018b) (LIU *et al.*, 2021) e de forma transparente a outros sistemas de fio (WU *et al.*, 2021).

2.3.2 Arquitetura de Hardware

A maneira mais simples para implementar uma RIS é utilizar uma matriz refletora passiva cuja terminação de antena dos elementos pode ser controlada eletronicamente para retrodifusão e mudança de fase, de modo que cada elemento apresente controle muito limitado nas ondas eletromagnéticas. Contudo, um número considerável de elementos refletores permite manipular de forma eficaz a onda incidente (ELMOSSALLAMY *et al.*, 2020).

Uma implementação mais sofisticada da RIS pode ser realizada por meio de metassuperfícies - que consistem em uma forma plana de materiais sintéticos com propriedades eletromagnéticas não encontradas em materiais naturais - que permitem a reflexão inteligente da onda. Nessa arquitetura, cada elemento refletor atua como uma única matriz de reflexão (WU; ZHANG, 2020c).

A arquitetura típica de uma RIS apresenta dimensão transversal muito superior à espessura, sendo representada, muitas vezes, por um modelo bidimensional (CHEN *et al.*, 2022), sendo sua estrutura de hardware, descrita na Figura 3, composta por três camadas associadas a um controlador externo (WU *et al.*, 2021).



Fonte: Autoria própria (2022).

A camada mais externa apresenta um conjunto de *patches* metálicos reconfiguráveis impressos, sob um substrato dielétrico, atuando diretamente nos sinais incidentes. A camada intermediária é composta por uma placa de cobre para minimizar o vazamento de energia durante o processo de reflexão. Enquanto a camada mais interna equivale a uma placa de circuito de controle responsável por excitar os elementos refletores, de modo a ajustar as amplitudes de reflexão e deslocamento de fase em tempo real.

A adaptação de reflexão é acionada e determinada por um controlador inteligente conectado à RIS. Um cenário usual prevê os coeficientes de reflexão calculados na estação rádio base e enviados ao controlador por meio de uma conexão de *feedback* dedicado, que pode ocorrer por meio de *backhaul* ou link sem fio de controle de baixa taxa de dados (JIAN *et al.*, 2022).

O ajuste de reflexão dinâmico é limitado temporalmente pela velocidade de resposta do dispositivo, sendo muito inferior ao tempo de um bloco de coerência de canal típico (LIU *et al.*, 2021), tornando válida a readequação dos coeficientes de reflexão com base na resposta de desempenho do usuário.

Uma característica peculiar da RIS é a sua reflexão anômala, decorrente da divergência entre o ângulo do sinal incidente e do sinal refletido, diferentemente da lei de Snell-Descartes, onde os ângulos são equivalentes. As metodologias conhecidas do cálculo da reflexão de refletores anômalos de tamanho finito são baseadas na suposição de que o campo refletido é igual ao campo incidente com o deslocamento de fase projetado, enquanto modelos mais avançados acrescentam a correção de amplitude do campo com base na conservação de energia (DÍAZ-RUBIO; TCVETKOVA; TRETYAKOV, 2021).

A reflexão, proveniente da RIS, pode ser idealizada por meio de atuações mecânicas, materiais funcionais, ajustes térmicos ou por meio de dispositivos eletrônicos. A abordagem que utiliza dispositivos eletrônicos é a mais adotada devido às suas vantagens no quesito de tempo de resposta, perda de reflexão, consumo energético e custo de hardware.

Um projeto usual e promissor, por ser altamente escalável, corresponde em controlar os comutadores com um arranjo de diodos (LIASKOS *et al.*, 2018b), seja do tipo positivos intrínsecos negativos (PIN) ou varactor, permitindo o comando do estado de comutação mediante a definição de um valor de tensão de polarização (CHEN *et al.*, 2022).

Além de ajustar a mudança de fase, o controle adicional da amplitude de reflexão de cada elemento refletor fornece mais flexibilidade na remodelação do sinal refletido para alcançar os objetivos da comunicação auxiliada por RIS de forma eficaz. O ajuste de amplitude é realizado comumente por meio da alteração da resistência de cada elemento, dissipando uma parte da energia na forma de calor (WU *et al.*, 2021).

Em projetos ideais, a variação de amplitude é realizada de forma independente ao controle nos desvios de fase. No entanto, o controle do coeficiente reflexão em implementações reais pode gerar uma resposta de amplitude e de fase acoplada de forma não linear, resultando na dependência entre ambas as variáveis (WU *et al.*, 2021).

Outra limitação associada é o número finito de valores de coeficientes de reflexão em projetos práticos de RIS, que resulta em valores discretos para os desvios de fase e mudanças de amplitude relacionados à quantidade de bits de controle. Em geral, para um dado número de bits de controle, a coordenação unicamente dos deslocamentos de fase está associado a um maior custo e melhor desempenho, enquanto a manipulação exclusiva das mudanças de fase gera um menor custo e desempenho reduzido.

3 MODELO DE SISTEMA

3.1 Sinal da superfície refletora inteligente e modelo de canal

Considerando a comunicação *Single-Input Single-Output* (SISO), em *downlink*, assistida por uma superfície refletora inteligente, com um número N de elementos refletores passivos, sendo cada um deles representado por n , com $n \in \{1, \dots, N\}$. O sistema apresenta banda estreita e com canais de desvanecimento plano, de modo que todas as componentes espectrais sejam atenuadas uniformemente, enquanto o sinal transmitido é denotado por $m(t) = x(t)w$, com $x(t)$ representando o sinal de informação e w o coeficiente de precodificação.

Os coeficientes de larga escala são descritos como o quociente entre uma variável log-normal l , que denota o sombreamento, e a distância associada, denotada por d , elevado ao coeficiente de perda de percurso γ , conforme a equação:

$$\rho = \frac{l}{d^\gamma} \quad (1)$$

Os coeficientes de pequena escala correspondem a uma variável aleatória do tipo normal complexa, descrita por $\eta = \eta_r + j\eta_i$. Desse modo, o coeficiente genérico de canal complexo é descrito como sendo:

$$\epsilon = \sqrt{\rho}\eta \quad (2)$$

Os coeficientes de canal complexo entre a BS e a RIS podem ser representados por $\alpha_{1,n}e^{-j\xi_{1,n}}$, sendo $\alpha_{1,n}$ a atenuação de amplitude, que equivale ao módulo de ϵ , e $-\xi_{1,n}$ o desvio de fase do canal, que corresponde à fase de ϵ .

Sendo assim, os coeficientes de canal intermediados pela RIS estão associados às perdas de potência descritas pelo modelo de perda de caminho de distância do produto:

$$PL_{r,n} \propto \frac{1}{d_{1,n}^{\gamma_1} d_{2,n}^{\gamma_2}}. \quad (3)$$

Onde $PL_{r,n}$ denota a perda de potência, $d_{1,n}$ a distância entre a BS e o n elemento da RIS e $d_{2,n}$ a distância entre cada elemento refletor da RIS e o terminal. Sendo γ_1 e γ_2 os coeficiente de perda de percurso entre a BS e a RIS e o entre a RIS e o usuário, de forma respectiva.

Com f_c representando a frequência da portadora, o sinal em banda passante que atinge o n elemento refletor da RIS é definido como:

$$y_{in,n}(t) = \text{Re} \{ \alpha_{1,n} e^{-j\xi_{1,n}} m(t) e^{j2\pi f_c t} \}. \quad (4)$$

Considerando a atenuação de amplitude induzida pela RIS, descrita por $\beta_n \in [0,1]$, o atraso decorrente do processo de reflexão pela superfície, representado como $t_a \in [0,1/f_c]$ e que $m(t) \approx m(t - t_a)$, ao passo que $t_a \leq 1/f_c \leq 1/BW$, com BW denotando a largura de banda, o sinal refletido pelo n elemento da RIS é dado por:

$$\begin{aligned} y_{out,n}(t) &= \beta_n y_{in,n}(t - t_a) \\ &= \text{Re} \left\{ \beta_n \alpha_{1,n} e^{-j\xi_{1,n}} m(t - t_a) e^{j2\pi f_c(t-t_a)} \right\} \\ &\approx \text{Re} \left\{ \left[\beta_n e^{-j\theta'_n} \alpha_{1,n} e^{-j\xi_{1,n}} m(t) \right] e^{j2\pi f_c t} \right\} \end{aligned} \quad (5)$$

Assumindo que o desvio de fase induzido pela RIS $-\theta'_n \triangleq -2\pi f_c t_a$ e que a igualdade expressa em (a) é decorrente da periodicidade do desvio de fase, o sinal refletido em banda base consiste em:

$$s_{out,n}(t) = \beta_n e^{-j\theta'_n} s_{in,n}(t) \stackrel{(a)}{=} \beta_n e^{j\theta_n} s_{in,n}(t), \quad (6)$$

Com $\alpha_{2,n} e^{-j\xi_{2,n}}$ representando o coeficiente complexo entre a RIS e o receptor, o sinal em banda passante refletido pelo n elemento refletor recebido no receptor é descrito por:

$$y_{r,n}(t) = \text{Re} \left\{ \left[\alpha_{1,n} e^{-j\xi_{1,n}} \beta_n e^{j\theta_n} \alpha_{2,n} e^{-j\xi_{2,n}} m(t) \right] e^{j2\pi f_c t} \right\}. \quad (7)$$

Assumindo que o coeficiente de canal entre a BS e a RIS é $h_{r,n}^* = \alpha_{1,n} e^{-j\xi_{1,n}}$, enquanto o coeficiente de canal entre a RIS e o terminal é denotado por $g_n = \alpha_{2,n} e^{-j\xi_{2,n}}$. O modelo de sinal correspondente em banda base é denotado como sendo:

$$y_n(t) = \beta_n e^{j\theta_n} h_{r,n}^* g_n m(t). \quad (8)$$

Considerando que não há acoplamento entre os sinais de reflexão dos elementos refletores vizinhos e, devido à perda considerável de caminho, as reflexões de segunda ordem em diante são desprezadas, o sinal recebido consiste na superposição dos sinais refletidos pelos N elementos refletores passivos da superfícies refletora inteligente:

$$y(t) = \left(\sum_{n=1}^N \beta_n e^{j\theta_n} h_{r,n}^* g_n \right) m(t) = \mathbf{h}_r^H \mathbf{\Theta} \mathbf{g} m(t), \quad (9)$$

Sendo $\mathbf{h}_r^H = [h_{r,1}^*, \dots, h_{r,N}^*]$, $\mathbf{g} = [g_1, \dots, g_N]^T$ e $\mathbf{\Theta} = \text{diag}(\beta_1 e^{j\theta_1}, \dots, \beta_N e^{j\theta_N})$.

A partir do modelo de reflexão da RIS, com P_{BS} sendo a potência transmitida, z o ruído gaussiano aditivo branco, com média zero e variância σ^2 , e h_d^* o canal entre a BS e o terminal, o sinal recebido no usuário é expresso como:

$$y = (\mathbf{h}_r^H \mathbf{\Theta} \mathbf{g} + h_d^*) x w \sqrt{P_{BS}} + z, \quad (10)$$

A relação sinal-ruído (SNR) vista a partir do usuário é descrita como:

$$\begin{aligned} SNR &= \frac{P_{BS} |w(\mathbf{h}_r^H \mathbf{\Theta} \mathbf{g} + h_d^*)|^2}{\sigma^2} \\ &= \frac{P_{BS} |w(h_d^* + \sum_{n=1}^N h_{r,n}^* \beta_n e^{j\theta_n} g_n)|^2}{\sigma^2}. \end{aligned} \quad (11)$$

Que apresenta valor máximo através da otimização do feixe de reflexão passiva da superfície refletora:

$$\begin{aligned} (\text{P1}): \quad & \max_{\boldsymbol{\theta}, \boldsymbol{\beta}} \left| \sum_{n=1}^N h_{r,n}^* g_n \beta_n e^{j\theta_n} + h_d^* \right|^2 \\ & \text{s.t. } 0 \leq \theta_n < 2\pi, \quad n = 1, \dots, N, \\ & \quad 0 \leq \beta_n \leq 1, \quad n = 1, \dots, N, \end{aligned} \quad (12)$$

Sendo $\boldsymbol{\theta} = [\theta_1, \dots, \theta_N]^T$ e $\boldsymbol{\beta} = [\beta_1, \dots, \beta_N]^T$.

Considerando ϕ_n , ψ_n e ζ como sendo as fases de h_r^* , g_n e h_d^* , respectivamente. Os deslocamentos ótimos de fase para um cenário SISO apresentam solução fechada, para $\boldsymbol{\beta} \geq \mathbf{0}$, descritas como:

$$\theta_n = \text{mod}[\zeta - (\phi_n + \psi_n), 2\pi], \quad n = 1, \dots, N, \quad (13)$$

As soluções ótimas para os desvios de fase necessitam de conhecimento de todos os canais envolvidos e independem de $\boldsymbol{\beta}$. Sendo assim, as mudanças de fase induzidas pela RIS devem alinhar todos os sinais incidentes com o sinal de link direto com o objetivo de uma combinação coerente entre os coeficientes de canais complexo h_r^* , g_n e h_d^* .

Ao substituir os valores ótimos, o problema é reduzido à:

$$\begin{aligned} (\text{P2}): \quad & \max_{\boldsymbol{\beta}} \left| \sum_{n=1}^N |h_{r,n}| |g_n| \beta_n + |h_d| \right|^2 \\ & \text{s.t. } 0 \leq \beta_n \leq 1, \quad n = 1, \dots, N. \end{aligned} \quad (14)$$

Desse modo as soluções ótimas são obtidas através de uma atenuação de amplitude unitária $\beta_n = 1, \forall n$.

3.2 Sistema MISO auxiliado por IRS

Para um sistema, em *downlink*, de usuário único, *Multiple-Input Single-Output* (MISO), com M antenas na BS e uma única no receptor, o sinal recebido no usuário, adotando $\mathbf{h}_d \in \mathbb{C}^{M \times 1}$, $\mathbf{G} \in \mathbb{C}^{N \times M}$, $\mathbf{h}_r \in \mathbb{C}^{N \times 1}$ e $\mathbf{w} \in \mathbb{C}^{M \times 1}$, é descrito por:

$$y = (\mathbf{h}_r^H \mathbf{\Theta} \mathbf{G} + \mathbf{h}_d^H) \mathbf{x} \mathbf{w} \sqrt{P_t} + z, \quad (15)$$

Desse modo, a relação sinal-ruído recebida pode ser denotada como sendo:

$$SNR = \frac{P_{BS} |(\mathbf{h}_r^H \mathbf{\Theta} \mathbf{G} + \mathbf{h}_d^H) \mathbf{w}|^2}{\sigma^2} \quad (16)$$

Enquanto a taxa máxima alcançável, que descreve a capacidade do canal, para uma largura de banda unitária, é descrita como sendo:

$$r = \log_2(1 + SNR) \quad (17)$$

O vetor de formação de feixe de transmissão e recepção precisa ser otimizado em conjunto com o *beamforming* passivo da RIS para maximizar a SNR no usuário. Considerando que não há atenuações de amplitude na RIS, tal que $\beta_n = 1, \forall n$, o problema de otimização é dado por:

$$\begin{aligned} \text{(P3): } \quad & \max_{\mathbf{w}, \boldsymbol{\theta}} |(\mathbf{h}_r^H \mathbf{\Theta} \mathbf{G} + \mathbf{h}_d^H) \mathbf{w}|^2 \\ \text{s.t. } \quad & \|\mathbf{w}\|^2 \leq P_t, \\ & 0 \leq \theta_n < 2\pi, \quad n = 1, \dots, N, \end{aligned} \quad (18)$$

Desse modo, quando o link direto entre a BS e usuário apresentar maior desempenho, é favorável que o feixe de transmissão seja direcionado diretamente para o terminal, enquanto no caso de o link direto apresentar bloqueio severo, o feixe deve ser orientado em direção à RIS, de modo a amplificar o ganho cooperativo.

O problema de otimização da SNR é não convexo devido à não concavidade de sua função em relação ao vetor de precodificação $\mathbf{w}$ e os deslocamentos de fase $\boldsymbol{\theta}$. O acoplamento entre as variáveis de otimização do *beamforming* ativo e passivo, proveniente da RIS, está entre as principais dificuldades da otimização conjunta.

Ao fixar uma das variáveis acopladas, o problema é reduzido para uma abordagem de otimização alternada, que consiste em otimizar cada uma das variáveis, de forma intercalada até o processo de convergência.

Para uma matriz de deslocamento de fase qualquer e fixa, a solução do *beamforming* ativo ótima é dada pela relação de transmissão máxima (MRT):

$$\mathbf{w}_{\text{MRT}} = \sqrt{P_{BS}} \frac{(\mathbf{h}_r^H \mathbf{\Theta} \mathbf{G} + \mathbf{h}_d^H)^H}{\|\mathbf{h}_r^H \mathbf{\Theta} \mathbf{G} + \mathbf{h}_d^H\|}. \quad (19)$$

Substituindo a relação de transmissão máxima e reduzindo o problema da otimização da SNR unicamente para o deslocamento de fase:

$$\begin{aligned} (\text{P4}): \quad & \max_{\boldsymbol{\theta}} \|\mathbf{h}_r^H \mathbf{\Theta} \mathbf{G} + \mathbf{h}_d^H\|^2 \\ & \text{s.t. } 0 \leq \theta_n \leq 2\pi, \quad n = 1, \dots, N. \end{aligned} \quad (20)$$

Considerando $\mathbf{v} = [v_1, \dots, v_N]^H$, com $v_n = e^{j\theta_n}$, $\mathbf{\Phi} = \text{diag}(\mathbf{h}_r^H) \mathbf{G} \in \mathbb{C}^{N \times M_t}$ e $\mathbf{h}_r^H \mathbf{\Theta} \mathbf{G} = \mathbf{v}^H \mathbf{\Phi}$, o problema de otimização passa a ser:

$$\begin{aligned} (\text{P5}): \quad & \max_{\mathbf{v}} \mathbf{v}^H \mathbf{\Phi} \mathbf{\Phi}^H \mathbf{v} + \mathbf{v}^H \mathbf{\Phi} \mathbf{h}_d + \mathbf{h}_d^H \mathbf{\Phi}^H \mathbf{v} + \|\mathbf{h}_d^H\|^2 \\ & \text{s.t. } |v_n| = 1, \quad n = 1, \dots, N. \end{aligned} \quad (21)$$

Os deslocamentos de fase da RIS exigem que as potências do canal de diferentes antenas de transmissão estejam equilibradas. Resultando em um programa quadrático restrito quadraticamente (QCQP), já que tanto a função objetivo quanto as restrições são funções quadráticas. Na teoria de complexidade computacional, essa classe de problemas são comumente *NP-Hard*, devido às restrições de módulo unitário que, tipicamente, não são convexas (WANG *et al.*, 2020).

Problemas de tempo polinomial não determinístico (NP) consistem em uma classe de complexidade para problemas de decisão, cujas soluções são difíceis de determinar, mas fáceis de verificar. Problemas *NP-hard* são pelo menos mais difíceis quanto os problemas mais difíceis em NP e não necessariamente precisam compor a classe de NP. Em circunstâncias específicas, no caso em que problemas *NP-hard* pertencem à classe de NP, são classificados como NP-completo.

3.3 Discretização dos desvios de fase

De forma ideal, os deslocamentos de fase e as atenuações de amplitude de cada um dos elementos da IRS podem ser ajustado de modo contínuo e independente. Tal implementação resulta em limites teóricos de desempenho e em um conjunto com infinitos valores possíveis de desvio de fase:

$$\mathcal{F} = \left\{ \theta \mid \theta \in [0, 2\pi) \right\}. \quad (22)$$

Projetos que adotam valores contínuos de desvios de fase apresentam alta complexidade de hardware, necessitando de elementos refletores de alta resolução que tornam o projeto de difícil implementação. Logo, projetos práticos de superfícies refletoras adotam deslocamentos de fase discretos.

Adotando que b denota o número de bits para controlar os níveis de mudança de fase representados por D , definido como $D = 2^b$, e assumindo o intervalo $\Delta\theta = 2\pi/D$ para valores uniformemente distribuídos, o conjunto de deslocamentos de fase possíveis é expresso como:

$$\mathcal{F}_D = \{0, \Delta\theta, \dots, (D-1)\Delta\theta\}. \quad (23)$$

Uma RIS prática, com deslocamentos de fase discretos, ainda pode obter a mesma escala de potência de recepção assintótica para um valor adequado de elementos refletores, possibilitando um projeto factível de hardware e de modo simplificado. (WU; ZHANG, 2020a).

No entanto, o uso de valores discretos para os desvios de fase pode resultar no desalinhamento dos coeficientes de canal, gerando um desempenho degradado em comparação com o caso ideal contínuo, principalmente para poucos bits de controle. Além disso, as restrições também dificultam os algoritmos de otimização devido à complexidade introduzida pelas restrições dos valores possíveis de ângulos (WU *et al.*, 2021).

O uso de valores finitos para o deslocamento de fase modifica o domínio das soluções, deixando de ser um conjunto contínuo e passando a ser discreto, originando um problema de programação não linear de inteiros misto (MINLP) que tipicamente é NP-hard e não apresenta método padrão para obter a solução globalmente ótima de forma eficiente (DI *et al.*, 2020) (WU; ZHANG, 2020a).

4 MÉTODOS DE OTIMIZAÇÃO

O processo de encontrar a melhor maneira de alocar os recursos disponíveis em uma modelagem matemática, sem violar nenhuma das limitações que possam existir, descreve um problema de otimização. Os principais aspectos estão associados às variáveis de decisão, que correspondem às características de projeto, a função objetivo, que denota a propriedade a ser otimizada, e as restrições, que representam às condições que devem ser atendidas (LEÓN-ALDACO; CALLEJA; ALQUICIRA, 2015).

Quando o espaço de busca de soluções engloba um conjunto de valores finito, o processo é denominado de otimização combinatória e exige que todas as soluções possíveis sejam testadas para obter a solução ótima (CARNAHAN; SINHA, 2001). No entanto, a varredura por todos os valores possíveis é, em muitos casos, impraticável. Desse modo, diversos métodos computacionais, incluindo técnicas de IA, podem ser utilizados com o objetivo obter uma solução de alta qualidade, e não necessariamente exata para essa classe de problemas.

Os métodos heurísticos correspondem uma das vertentes da IA e fazem uso de uma função heurística para orientar o processo de busca. Sua utilização não garante, matematicamente, a solução de um problema e fazem pouca, ou nenhuma, suposição sobre o que está sendo otimizado.

Algoritmos heurísticos de alto nível recebem a denominação de metaheurística e são aplicados para obtenção de soluções em uma ampla variedade de problemas com o objetivo de explorar eficientemente o espaço de busca. Grande parte das implementações apresentam algum grau de otimização estocástica, de forma que a solução encontrada é dependente do conjunto de variáveis aleatórias geradas.

O design de técnicas de metaheurísticas, muitas vezes, adentram o campo da computação inspirada biologicamente. De modo a abstrair conceitos, mecanismos e princípios de sistemas naturais, buscando compreender padrões existentes e, posteriormente, replicar em sistemas computacionais.

Através do ML, as técnicas de IA também se estendem ao uso de modelos matemáticos para um sistema adquirir conhecimento sem instrução direta. De forma a construir um padrão de otimização a partir das informações de entrada da função objetivo. (FAISAL; CHOI, 2022)

Devido à sua dependência de inferências no lugar de instruções explícitas, as técnicas de ML apresentam bom desempenho em cenários de natureza estocástica (DAHROUJ *et al.*, 2021) e são aplicáveis em uma grande diversidade de contextos (JORDAN; MITCHELL, 2015).

As técnicas de otimização baseadas em inteligência artificial, muitas vezes, podem encontrar boas soluções com menos esforço computacional do que outros métodos e negociam complexidade, exatidão e velocidade.

4.1 Princípios de aprendizado por reforço

O RL corresponde a um do domínio de ML que apresenta potencial de otimizar de forma iterativa uma função objetivo que se decompõe através de uma sequência discreta de recompensas (SUTTON; BARTO, 1998). É amplamente aplicado em problemas que necessitam de uma percepção excessiva dos ambientes (GHANAVI *et al.*, 2018), operando com grandes e dinâmicos conjuntos de dados (DAHROUJ *et al.*, 2021).

Na perspectiva de problemas de análise combinatória, é possível aplicar métodos de exploração ao longo do espaço de decisões e gerar processos de aprendizado com a experiência acumulada (BENGIO; LODI; PROUVOST, 2021), sem necessitar de rótulos de treinamento.

Um sistema de RL apresenta dois componentes principais - o agente e o ambiente - que interagem entre si pelo Processo de Decisão de Markov (PICARD *et al.*, 2004). A partir do momento em que a ação é realizada, o ambiente é atualizado e emite uma recompensa que mede o desempenho sob o estado atual, buscando determinar a política que maximiza a recompensa de longo prazo.

O estado atual é descrito como a_t enquanto o estado futuro corresponde à a_{t+1} pertencentes ao espaço de estados A . No processo de transição entre os estados é emitida uma recompensa cujo valor é r_{t+1} em um conjunto de recompensas R , que mede o desempenho de uma ação $b_t \in B$, com B representando o espaço de ações.

O *Q-learning* representa um modo típico de escolher a ação, atuando de forma independente do modelo de ambiente, e corresponde à utilização do valor associado à maior recompensa acumulada, presente em uma matriz de recompensa, de valor futuro Q_{t+1} e atual Q_t , descrita por:

$$Q_{t+1}(A_t, B_t) = Q_t(A_t, B_t) + \tau(R(A_t, B_t) + \mu \max_B Q_t(A_{t+1}, B) - Q_t(A_t, B_t)) \quad (24)$$

Sendo $\max_B Q_t(A_{t+1}, B)$ a recompensa máxima que pode ser obtida por meio do estado s_{t+1} , $\tau \in [0, 1]$ o fator de aprendizagem e $\mu \in [0, 1]$ o fator de desconto.

A taxa de aprendizagem determina o quanto as novas informações são relevantes perante às informações antigas. Um fator nulo gera um agente que opera somente com o aprendizado prévio, enquanto um valor unitário faz com que o agente considere apenas o estado mais recente, ignorando o conhecimento prévio.

O fator de desconto está associado a importância das recompensas futuras e imediatas. Ao adotar um valor nulo, o algoritmo considera apenas as recompensas de curto prazo, enquanto um valor próximo à unidade implica em uma priorização das recompensas de longo prazo.

4.2 Princípios de Algoritmos Genéticos

Dentre os métodos de otimização metaheurística baseados em população, estão os algoritmos genéticos (AG), que apresentam como fundamento os princípios de seleção natural da teoria Darwiniana e implementam operadores biologicamente inspirados de mutação, cruzamento e seleção.

Os AG são processos iterativos que evoluem de um conjunto de soluções iniciais, geradas de modo aleatório. Os valores selecionados no espaço de busca sofrem avaliação simultânea e são submetidas a operadores que buscam preservar informações críticas relativas à solução do problema, de modo que a qualidade seja melhorada gradualmente.

A terminologia adotada nos algoritmos genéticos é análoga à presente em sistemas biológicos. O bloco de memória que representa cada uma das soluções no espaço de busca é representada na forma de indivíduos, sendo o seu conjunto denominado de população que por sua vez, recebe a denominação, em cada iteração, de geração.

Cada solução candidata tem um conjunto de propriedades intituladas de genes, que quando agrupados formam os cromossomos. A representação dessas propriedades corresponde a uma abstração da solução do problema e deve permitir avaliação, seleção e manipulação por meio dos operadores genéticos.

Os indivíduos de cada geração são examinados simultaneamente por meio de uma função fitness, que mede a habilidade de adaptação do indivíduo às condições impostas pelo ambiente. Por meio do processo de avaliação; os indivíduos mais aptos da geração atual são selecionados para compor os ascendentes da próxima geração, onde o grau de favorecimento dos melhores é intitulado de pressão seletiva.

Os pares de genitores sofrem troca de material genético entre si para formar a próxima geração. Esse processo, denominado de *crossover*, seleciona, de forma estocástica, um conjunto de genes de um cada um dos indivíduos para formar os descendentes e reduz a diversidade presente na população.

Em oposição ao cruzamento, o operador de mutação adiciona diversidade a população permitindo uma maior varredura do espaço de soluções possíveis. Por meio dele ocorrem alterações em determinadas características selecionadas a partir de um critério probabilístico.


A implementação dos AG apresentam diversos parâmetros que impactam diretamente no seu desempenho. As variáveis como a probabilidade de mutação, probabilidade de cruzamento, pressão seletiva e tamanho da população podem ser ajustadas de modo a aprimorar o comportamento do algoritmo de otimização, além disso outras condições como as representações e dinâmicas de seleção também precisam ser adequadas para o problema em questão (DIAZ-GOMEZ; HOUGEN, 2007).

5 SIMULAÇÃO DE SUPERFÍCIES REFLETORAS INTELIGENTES

O desempenho de sistemas de telecomunicações não pode ser previsto de forma precisa por meio de abordagens determinísticas, devido à interferência de diversas variáveis aleatórias associadas ao processo. Uma abordagem, que dispensa modelos, para modelar a probabilidade de diferentes resultados em ambientes de simulação computacional é o método de Monte-Carlo (MC), que utiliza um número massivo de eventos de amostragem para obtenção dos resultados que convergem ao comportamento real.

Para cada uma das iterações do laço MC é gerado um sinal de informação modelado como uma variável aleatória independente e identicamente distribuída. Em seguida, os dados são modulados digitalmente em QAM-16 e transmitidos, conforme a Figura 4, a uma potência de $P_{BS} = 30dBm$, através de uma via de direta e outra intermediada pela RIS, com atenuação de amplitude unitária $\beta_n = 1$ e número de elementos refletores $N = 100$.

Figura 4 – Modelo de sistema de telecomunicação auxiliado por superfície refletora.



Fonte: Autoria própria (2022).

Durante a sua propagação, o sinal está sujeito aos efeitos do ambiente de propagação, como perda de percurso, com um expoente $\gamma_1 = \gamma_2 = 3$, desvanecimento multipercurso, que obedece a uma distribuição de probabilidade de acordo com a presença de linha de visão, sombreamento, cuja distribuição lognormal é de média zero e variância $8dB$, e ruído AWGN de média zero e variância unitária.


A simulação computacional de sistemas de telecomunicações auxiliados por RIS apresenta como principal métrica a SNR recebida no usuário, que pode ser facilmente decomposta em termos da taxa máxima alcançável, e na confiabilidade da conexão, representada pela taxa de erro de bit (BER). O principal desafio de sistemas assistidos por RIS corresponde à determinação dos deslocamentos de fase adequados. No entanto, o desempenho geral do sistema depende também da otimização dos demais parâmetros associados à RIS.

5.1 Posicionamento da superfície refletora

A estratégia de implantação de RIS apresenta grande influência no desempenho de um sistema de comunicação. Entre os fatores associados estão a presença de uma linha de visão, que são garantido por projetos eficientes, e a distância entre os componentes, que deve ser aprimorada.

A análise precisa da distância considera a posição da RIS variando sobre o eixo horizontal, com uma posição inicial de $50m$, e final de $450m$, intervaladas em $10m$, com o terminal posicionado em $500m$, conforme a Figura 5.


Figura 5 – Modelo de sistema para otimização do posicionamento.



Fonte: Autoria própria (2022).

Para um canal direto severamente bloqueado, seguindo uma distribuição de Rayleigh, e os canais intermediados apresentam uma componente de linha de visão com um fator $1 \leq K \leq 10$ que varia de forma linear com a distância entre os respectivos componentes, de acordo com a Figura 6, o desempenho médio de 100000 iterações de MC, indica que a posição que aprimora o desempenho é próxima à RIS ou próxima à posição do terminal, conforme o esperado pelo modelo de perda de percurso de distância do produto.

Figura 6 – SNR em dB pela posição da horizontal.



Fonte: Autoria própria (2022).

5.2 Discretização dos desvios de fase

Em virtude das limitações de hardware, implementações práticas de RIS adotam valores finitos para os deslocamentos de fase associados à quantidade de bits de controle disponível. No entanto, a discretização provoca uma leve degradação dos limites de desempenho, gerado pelo desalinhamento dos coeficientes de canais complexos, quando comparados aos valores ideais contínuos.

Para análise da quantidade de bits de controle, o cenário apresenta a BS posicionada na origem do sistema de coordenadas, com a RIS na posição horizontal de $450m$ e o terminal alocado em $500m$, conforme a Figura 7.


Figura 7 – Modelo de sistema para discretização dos desvios de fase.



Fonte: Autoria própria (2022).

O resultado para uma perspectiva SISO, arredondando o valor mais próximo pertencente ao domínio dos valores discretos possíveis provenientes da solução ótima, representada na Figura 8, demonstra que o número de bits de controle, para uma potência de transmissão de $30dBm$ e 100000 interações MC, atinge um valor muito próximo aos valores ideais de SNR para o caso contínuo a partir de $b = 6$ bits de controle.


Figura 8 – Relação sinal-ruído em dB por bits de controle.



Fonte: Autoria própria (2022).

No caso da capacidade de canal, representada na Figura 9, a taxa máxima alcançada para uma largura de banda unitária, apresenta comportamento semelhante à SNR, apresentando soluções muito próximas às ideais com $b = 6$.


Figura 9 – Capacidade por bits de controle.



Fonte: Autoria própria (2022).

A análise gráfica da BER, conforme a Figura 10, que representa a confiabilidade do canal, aponta para uma aproximação ao valor contínuo com $b = 4$, representando uma menor sensibilidade da métrica à discretização dos deslocamentos de fase.

Figura 10 – Bit error rate por bits de controle.



Fonte: Autoria própria (2022).


5.3 Otimização de reflexão

As RIS são tecnologias promissoras para compor sistemas B5G devido à sua capacidade de controlar o ambiente de propagação por meio de reflexão inteligente, permitindo revolucionar as redes sem fios e atuar como um dos principais pilares do processo de comunicação.

A implantação de RIS em redes sem fio futuras engloba a realização de projetos realistas, sendo um dos requisitos associados, a presença de um conjunto finito de deslocamentos de fase.

O desempenho acurado, com base no modelo de perda de percurso da RIS, implica em um sistema de telecomunicação projetado com os terminais dispostos de forma aleatória no interior de uma coroa circular de raio superior $R = 250m$ e inferior de $r = 50m$, centrada, em conjunto com a RIS, com $b = 6$ bits de controle, na posição $500m$, conforme a Figura 11. Além disso, devido ao posicionamento dos componentes e à formulação do problema, o *link* direto segue uma distribuição Rayleigh e os canais intermediados apresentam linha de visão, seguindo uma distribuição de Rice de componente $K = 10$.

Figura 11 – Modelo de sistema para otimização de reflexão.



Fonte: Autoria própria (2022).


Um dos componentes necessários para extrair o máximo do potencial da RIS, é a obtenção adequada dos coeficientes de reflexão mediante a solução de um problema de otimização de alta complexidade computacional. Ao integrar módulos de IA à infraestrutura de redes de comunicação, especificamente na determinação dos coeficiente deslocamentos de fase ótimos, é possível obter soluções de alta qualidade que agreguem desempenho às redes sem fio.

Os cenários em análise apresentam 10000 iterações de aprendizagem e 1000 realizações de MC e são realizadas por diferentes abordagens de IA. A otimização dos desvios de fase no caso SISO apresenta uma solução fechada que dependem dos conhecimento completo dos canais, enquanto o *multiple-input single-output* (MISO), com $M = 10$, não apresenta solução analítica.

5.3.1 Otimização baseada em aprendizado por reforço

As técnicas de RL, por conta da capacidade de aprendizado, detêm grande atenção quando aplicadas em telecomunicações e sua ampla área de busca (FAISAL; CHOI, 2022). Na perspectiva de redes sem fio auxiliadas por superfícies refletoras, é possível modelar um sistema adotando o canal de propagação como ambiente, a RIS como agente e a recompensa como dependente da SNR no usuário. Enquanto a escolha da ação depende de uma matriz Q cuja formulação adota com os estados, representados pelas linhas, equivalentes aos valores de ângulo, e ações, denotadas pelas colunas, aos elementos refletoras, conforme a Figura 12.

Figura 12 – Metodologia de aprendizado por reforço para otimização de reflexão.



Fonte: Autoria própria (2022).

Adotando um fator de desconto equivalente a um valor nulo, de modo a maximizar as recompensa imediatas, e acrescentando o termo W , ponderado por um fator δ , que retorna um valor unitário a cada iteração para os valores de ângulos, em A' e seus respectivos elementos refletoras, em B' , correspondente ao maior valor de SNR registrada pelo RL até então, a matriz Q é descrita como:

$$Q_{t+1}(A,B) = Q_t(A,B) + \tau(R(A,B) + \delta W(A',B') - Q_t(A,B)). \quad (25)$$

A formulação da recompensa $R(A,B)$ engloba comparação da relação sinal-ruído de cada iteração de aprendizagem, denotada por $instan$, a média dos valores de SNR de cada canal até a respectiva realização, representada como MD , e uma medida de dispersão correspondente ao intervalo interquartil desses valores, indicada por IQR . A metodologia de distribuição das recompensas atribui, em caso dos valores de cada iteração superarem o valor da soma, um valor de recompensa positivo, caso contrário é distribuído um valor negativo, que resulta na seguinte matriz de recompensa:

$$R(A,B) = \begin{cases} +2, & instan > MD + IQR, \\ -1/2, & instan < MD + IQR \end{cases} \quad (26)$$

De acordo com o algoritmo Q-learning, a escolha da ação apropriada é livre de modelos e corresponde à escolha do maior valor de recompensa acumulada na matriz Q . Na formulação adotada, o espaço de busca entre as possíveis soluções é fracamente explorado, resultando em um processo de convergência prematura. Para a obtenção dos desvios de fase ótimo é conveniente uma configuração que, a princípio, delimite o espaço da região de busca, e, em seguida, refine os resultados.

A decisão de qual ação tomar está sujeita à dualidade entre os processos de exploração e investigação. Representando um dilema entre a escolha de agir com base na melhor informação até o momento ou obter novas informações acerca de regiões ainda não visitadas no espaço de busca, que possam permitir melhores níveis de desempenho no futuro.

O procedimento de investigação e exploração pode ser aprimorado adotando uma flutuação decrescente, conforme o avanço das iterações, na determinação das ações a serem tomadas pelo agente, adicionando uma parcela probabilística no processo de escolha. Desse modo, o critério de escolha passa a depender também de uma variável aleatória que segue uma distribuição de Bernoulli, cujo sucesso corresponde à escolha do valor máximo acumulado para cada elemento refletor na matriz de recompensa, enquanto a falha consiste na escolha de um valor aleatório de deslocamento de fase.

A probabilidade de sucesso p_{RL} está associada ao número de iterações de aprendizagem, sendo cada uma delas denotada por ind_{RL} , e uma constante $var_{RL} = N$, de modo que $p_{RL} = ind_{RL}/var_{RL}$. Sendo assim, função massa de probabilidade, que associa um valor de probabilidade a cada possível ocorrência, de uma variável estocástica discreta de Bernoulli é definida como:


$$f(k, p_{RL}) = \begin{cases} p_{RL}, & \text{se } k=1, \\ 1 - p_{RL}, & \text{se } k=0 \end{cases} \quad (27)$$

A matriz de recompensa Q é atualizada em cada uma das 10000 iterações de aprendizagem e zerada em cada uma das 1000 realizações MC. Os valores de desvios de fase da primeira iteração é realizada de forma randômica. Caso os valores máximos de recompensas acumuladas sejam equivalentes para mais de elemento da matriz, o algoritmo adota um critério aleatório de escolha entre os valores em que o empate persiste.

A escolha dos parâmetros associados ao RL regem o processo de convergência e exploração do algoritmo e precisam ser precisamente ajustados. A taxa de aprendizagem denota a importância do conhecimento prévio e assume um valor $\tau = 0,2$, enquanto o fator de ponderação tendencia o caminho a ser percorrido no espaço de busca e assume um valor equivalente a $\delta = 2$.

A curva de convergência do RL para um cenário SISO, de acordo com a Figura 13, demonstra que o algoritmo retorna uma solução sub-ótima para o problema cuja qualidade pode ser comparada com os valores ótimos contínuos.


Figura 13 – Convergência do aprendizado por reforço para sistema SISO.



Fonte: Autoria própria (2022).

Levando em conta múltiplas antenas na BS, o referencial é perdido já que o problema não apresenta solução na forma fechada. A convergência do algoritmo demonstra uma notável capacidade evolutiva e é descrita conforme a Figura 14

Figura 14 – Convergência do aprendizado por reforço para sistema MISO.




Fonte: Autoria própria (2022).

5.3.2 Otimização baseada em algoritmos genéticos

Os AG representam uma classe de algoritmos biologicamente inspirados que possuem aplicações em uma ampla variedade de problemas e são capazes de fornecer mecanismos de buscas robustos e eficazes (CARNAHAN; SINHA, 2001), com metodologia básica aplicada à otimização da reflexão da RIS descrita na Figura 15.

A modelagem de um AG se inicia na representação do indivíduo de modo a gerar uma abstração com o problema relacionado e deve permitir a operação por meio dos operadores genéticos. Para uma interpretação aplicada às RISs, os valores possíveis de cada gene correspondem ao conjunto deslocamentos de fase induzidos, enquanto o número de genes representam o número de elementos refletoras, formando um indivíduo.

Figura 15 – Metodologia de algoritmo genético para otimização de reflexão.



Fonte: Autoria própria (2022).

A avaliação da capacidade de adaptação é realizada por meio da SNR obtida por cada indivíduo, de forma que os mais aptos apresentam maior probabilidade de repassar suas características, buscando uma evolução gradual do valor da função objetivo de cada geração.


A seleção é feita ordenando os indivíduos em ordem crescente de aptidão, selecionando para compor cada um dos ascendentes o melhor com 80% de chance ou algum dentre os 20% melhores com 20% de oportunidade. A combinação dos genes entre os indivíduos selecionados é do tipo uniforme e cada característica apresenta probabilidade equivalente de ser trocada.

Durante o processo de busca, o desempenho pode ser limitado por um processo de convergência precipitada para um ótimo local. Nos AG, esse processo, é decorrente da perda de alelos críticos gerando falta de diversidade, seja devido ao processo de seleção e cruzamento, seja decorrente da configuração de parâmetros como tamanho da população e taxa de mutação (POTTS; GIDDENS; YADAV, 1994).

Na implementação convencional de um algoritmo genético, o operador de mutação é constante durante a sua execução, o que pode provocar a convergência prematura impedindo o algoritmo de encontrar ótimos globais. Ao adotar a taxa de mutação de forma dinâmica e com base no número de iterações é possível permitir uma busca mais eficiente e obter melhores métricas de desempenho. Dessa forma, a taxa de mutação p_{AG} é descrita como sendo o quociente entre uma constante $var_{AG} = N$ e o número de gerações ind_{AG} , enquanto a população apresenta 10 indivíduos, sendo a inicial gerada de forma aleatória.

A curva de convergência do cenário SISO, com 1000 laços MC, com o número de indivíduos equivalente à quantidade de 10000 iterações de aprendizagem e plotado o melhor de cada geração até então, conforme a Figura 16, que compara com os valores ideais contínuos, exibe uma solução de alta qualidade retornada.


Figura 16 – Convergência da SNR em dB do algoritmo genético para sistema SISO.



Fonte: Autoria própria (2022).

Considerando o cenário MISO, o AG, de acordo com a Figura 17, representa um grande potencial de evolução em termos de SNR com o decorrer das gerações.

Figura 17 – Convergência da SNR em dB do algoritmo genético para sistema MISO.




Fonte: Autoria própria (2022).

5.3.3 Análise Comparativa

Mediante o amplo espaço de busca decorrente do projeto de otimização de reflexão de superfícies refletoras inteligentes, as técnicas de IA são utilizadas para buscar soluções de alta qualidade com menor complexidade computacional e tempo de execução. Dentre as possíveis abordagens, o RL representa uma sistemática que busca aprender com o ambiente por meio da atribuição de recompensas, enquanto o AG faz uso de uma função heurística de alto nível para gerar uma evolução gradual da qualidade das soluções.

O contraste da curva de convergência da otimização de reflexão da RIS, em cenário SISO, que analisa os métodos de RL e AG, para 10000 iterações de aprendizagem e 1000 ciclos MC, com resultado, é disposto na Figura 18.

Figura 18 – Comparação da convergência para sistema SISO.




Fonte: Autoria própria (2022).

A comparação indica um resultado muito promissor e praticamente equivalente das técnicas de IA, seja na velocidade de convergência, seja no desempenho após as iterações de aprendizagem. A solução obtida se aproxima veementemente ao valor ótimo após cerca de 4000 iterações. Com cerca de 2000 iterações o resultado já apresenta um ótimo desempenho e novas iterações, que geram maior gasto de processamento, podem não justificar de forma contundente os reduzidos ganhos em termos de relação sinal-ruído.

Ao aplicar metodologias com princípios de operação distintos, é possível realizar uma análise de forma mais precisa das métricas obtidas, de modo a corroborar ou refutar os resultados obtidos por cada um das técnicas. Além disso, os ganhos obtidos através da implementação de inteligência artificial em superfícies refletoras deve justificar a complexidade computacional imposta.

Uma forma de analisar as vantagens obtidas por meio da aplicação dos métodos de otimização é a comparação com um processo de busca aleatória, retornando ao melhor valor obtido entre as iterações, cujo desempenho comparado na Figura 19, demonstra um singelo ganho de desempenho quando comparados aos métodos de IA.


Figura 19 – Comparação da convergência para sistema SISO incluindo a busca aleatória.



Fonte: Autoria própria (2022).

Para $30dBm \leq P_{BS} \leq 50dBm$ em passos de $10dBm$, a SNR retornada pelos métodos de IA são dispostas de forma quase sobreposta ao valor ótimo, conforme a Figura 20.


Figura 20 – Análise comparativa da relação sinal-ruído para sistema SISO.



Fonte: Autoria própria (2022).

O desempenho comparado da BER é disposto na Figura 21.


Figura 21 – Análise comparativa da *bit error rate* para sistema SISO.



Fonte: Autoria própria (2022).

Enquanto na perspectiva da capacidade do canal, os algoritmos descrevem um comportamento conforme a Figura 22.

Figura 22 – Análise comparativa da capacidade de canal para sistema SISO.




Fonte: Autoria própria (2022).

Para todos as métricas do cenário de SISO, a semelhança entre os métodos de IA e os valores ótimos foram mantidos, enquanto a busca aleatória teve um desempenho módico, mas superior ao não uso da RIS.

Para o cenário MISO o *benchmark* é perdido, sendo a comparação entre os métodos a mais adequada para análise de desempenho. Desse modo, para a curva de convergência descrita na Figura 23, a similaridade entre as técnicas de IA são mantidas para as velocidades de convergência e alta capacidade de evolução, analogamente ao cenário SISO.


Figura 23 – Comparação da convergência para sistema MISO



Fonte: Autoria própria (2022).

As vantagens em relação à varredura aleatória também são mantidas, conforme a representação gráfica da curva comparada de convergência na Figura 24.


Figura 24 – Comparação da convergência para sistema MISO incluindo a busca aleatória.



Fonte: Autoria própria (2022).

Variando a potência transmitida $30dBm \leq P_{BS} \leq 50dBm$ com intervalos de $10dBm$, a SNR proveniente de cada método de otimização é representada na Figura 25 e demonstra a capacidade da IA em oferecer boas soluções ao desafio de otimização da reflexão da RIS.


Figura 25 – Análise comparativa da relação sinal-ruído para sistema MISO.



Fonte: Autoria própria (2022).

Levando em conta a confiabilidade do link, a BER é exibida conforme a Figura 26 e mantém o comportamento das demais métricas.


Figura 26 – Análise comparativa da *bit error rate* para sistema MISO.



Fonte: Autoria própria (2022).

E por fim, a capacidade do canal proveniente dos métodos de busca para um cenário MISO, denotada na Figura 27, demonstra a superioridade da aplicação da IA.

Figura 27 – Análise comparativa da capacidade de canal para sistema MISO.



Fonte: Autoria própria (2022).

No cenário MISO, os ganhos do uso MISO combinadas, ofuscam, mas não eliminam, a capacidade de atuação da RIS. A análise conjunta de ambos os mecanismos possibilita ratificar o desempenho de cada um deles, ao passo que apresentam o curva de convergência e valor de retorno profundamente semelhantes

Considerando ambos os cenários, por intermédio das técnicas de IA é possível obter soluções promissoras e com elevado potencial de evolução, exibindo desempenho bem superior ao esquema de busca aleatória e ao cenário que dispensa o uso da RIS.

O uso do aprendizado por reforço e do algoritmo genético possibilita um ganho notável da SNR, que corresponde à principal grandeza associada. Além disso, por meio da capacidade de canal, é possível obter um maior limite da taxa máxima alcançável de dados, enquanto a análise da BER comprova a capacidade da RIS de gerar um ambiente de propagação com maior confiabilidade, de forma a justificar a complexidade acrescentada pela implantação dos módulos de IA.

Em sistemas previstos, a implantação é densa e distribuída, circunstância que ressalta ainda mais as incrementações de desempenho e reduz as limitações presentes no modelo que considera uma única superfície refletora e disposição dos terminais, que muitas vezes, estão posicionados em distâncias que não utilizam de forma eficiente às potencialidades acrescentadas.

A análise da variação da potência de transmissão indica que as vantagens da RIS é amplificada para cenários onde a BS emite menos energia, representando uma alternativa ao aumento na potência de transmissão, contribuindo para a eficiência energética.

6 CONCLUSÃO

O canal sem fio possui característica probabilística, seus efeitos impactam de forma negativa o desempenho de sistemas de comunicação. Estratégias de processamento de sinais buscam atenuar os efeitos decorrentes do ambiente de propagação, contudo, apresentam eficácia limitada. Uma tecnologia emergente, que dá origem ao conceito de rádio inteligente, denominada de superfícies refletoras inteligentes, buscam tornar o canal sem fio mais determinístico, de modo que ele se comporte como uma variável a ser otimizada.

Superfícies refletoras inteligentes consistem em superfícies planas com elementos refletores passivos com a finalidade de auxiliar o processo de comunicação sem fio, seja criando linha de visão virtual entre emissor e receptor, seja manipulando os ângulos de fase para criar interferências construtivas e destrutivas, tornando o sistema escalável, de modo a assegurar os requisitos das próximas redes sem fio.

A implantação das RIS podem ser realizadas de modo denso e facilitado, devido à sua característica passiva e compatível com os demais sistemas sem fios em uso. Além disso, o design adequado de sistemas futuros contempla superfícies refletoras posicionadas próximas ao terminais ou à estação base, que correspondem aos melhores cenários devido ao modelo de perda de percurso.

O projeto das superfícies refletoras inteligentes envolve a determinação dos deslocamentos de fase, idealmente contínuo. No entanto, a discretização se mostrou válida acima de um determinado limiar, embasando uma das variáveis para a determinação dos valores ótimos com base na aplicação de métodos de otimização em um problema de elevada complexidade.

As aplicações de IA em sistemas de telecomunicações auxiliados por RIS permitem o valor quase ótimo no cenário de antena única e capacidade de impactar positivamente sistemas de múltiplas antenas, se mostrando muito superior ao processo de varredura aleatória e ao cenário sem RIS. Além disso, tanto o processo de obtenção dos deslocamentos de fase por meio do aprendizado por reforço, baseado em aprendizado de máquina, quanto o algoritmo genético, baseado em metaheurística, apresentam velocidades de convergência e retorno final do algoritmo praticamente equivalentes, corroborando o desempenho de um para com o outro.

O potencial descrito pela aplicação de superfícies refletores em sistema de telecomunicações assistidos por RIS, demonstram a capacidade da implantação módulos de IA para otimização da reflexão. Os resultados indicam capacidade de agregar performance ao sistema e constituir uma das bases do sistemas de comunicação B5G.

REFERÊNCIAS

- AGUIRRE, L. A. Introdução à identificação de sistemas. **Editora UFMG, Belo Horizonte**, v. 2, 2007.
- AKYILDIZ, I. F. *et al.* 5g roadmap: 10 key enabling technologies. **Computer Networks**, Elsevier, v. 106, p. 17–48, 2016.
- ARUN, V.; BALAKRISHNAN, H. Rfocus: Practical beamforming for small devices. **arXiv preprint arXiv:1905.05130**, 2019.
- BASAR, E. Transmission through large intelligent surfaces: A new frontier in wireless communications. In: IEEE. **2019 European Conference on Networks and Communications (EuCNC)**. [S.l.], 2019. p. 112–117.
- BASAR, E. Reconfigurable intelligent surfaces for doppler effect and multipath fading mitigation. **Frontiers in Communications and Networks**, Frontiers, p. 14, 2021.
- BASAR, E. *et al.* Wireless communications through reconfigurable intelligent surfaces. **IEEE Access**, v. 7, p. 116753–116773, 2019.
- BENGIO, Y.; LODI, A.; PROUVOST, A. Machine learning for combinatorial optimization: A methodological tour d'horizon. **European Journal of Operational Research**, v. 290, n. 2, p. 405–421, 2021. ISSN 0377-2217. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0377221720306895>.
- CAO, Y. *et al.* Delay-constrained joint power control, user detection and passive beamforming in intelligent reflecting surface-assisted uplink mmwave system. **IEEE Transactions on Cognitive Communications and Networking**, IEEE, v. 7, n. 2, p. 482–495, 2021.
- CARNAHAN, J.; SINHA, R. Nature's algorithms [genetic algorithms]. **IEEE Potentials**, v. 20, n. 2, p. 21–24, 2001.
- CHEN, R. *et al.* Reconfigurable intelligent surfaces for 6g iot wireless positioning: A contemporary survey. **IEEE Internet of Things Journal**, v. 9, n. 23, p. 23570–23582, 2022.
- CUI, M.; ZHANG, G.; ZHANG, R. Secure wireless communication via intelligent reflecting surface. **IEEE Wireless Communications Letters**, v. 8, n. 5, p. 1410–1414, 2019.
- DAHROUJ, H. *et al.* An overview of machine learning-based techniques for solving optimization problems in communications and signal processing. **IEEE Access**, v. 9, p. 74908–74938, 2021.
- DI, B. *et al.* Hybrid beamforming for reconfigurable intelligent surface based multi-user communications: Achievable rates with limited discrete phase shifts. **IEEE Journal on Selected Areas in Communications**, v. 38, n. 8, p. 1809–1822, 2020.
- DIAZ-GOMEZ, P. A.; HOUGEN, D. F. Initial population for genetic algorithms: A metric approach. In: **Gem**. [S.l.: s.n.], 2007. p. 43–49.
- DÍAZ-RUBIO, A.; TCVETKOVA, S.; TRETYAKOV, S. Analytical models of reflection and scattering by finite-size anomalously reflecting metasurfaces. In: **2021 15th European Conference on Antennas and Propagation (EuCAP)**. [S.l.: s.n.], 2021. p. 1–3.

- ELMOSSALLAMY, M. A. *et al.* Reconfigurable intelligent surfaces for wireless communications: Principles, challenges, and opportunities. **IEEE Transactions on Cognitive Communications and Networking**, v. 6, n. 3, p. 990–1002, 2020.
- FAISAL, K. M.; CHOI, W. Machine learning approaches for reconfigurable intelligent surfaces: A survey. **IEEE Access**, v. 10, p. 27343–27367, 2022.
- FENG, K. *et al.* Deep reinforcement learning based intelligent reflecting surface optimization for miso communication systems. **IEEE Wireless Communications Letters**, IEEE, v. 9, n. 5, p. 745–749, 2020.
- GHANAVI, R. *et al.* Efficient 3d aerial base station placement considering users mobility by reinforcement learning. In: **2018 IEEE Wireless Communications and Networking Conference (WCNC)**. [S.l.: s.n.], 2018. p. 1–6.
- GUO, H. *et al.* Weighted sum-rate maximization for intelligent reflecting surface enhanced wireless networks. In: IEEE. **2019 IEEE Global Communications Conference (GLOBECOM)**. [S.l.], 2019. p. 1–6.
- GUPTA, A.; JHA, R. K. A survey of 5g network: Architecture and emerging technologies. **IEEE Access**, v. 3, p. 1206–1232, 2015.
- HAYKIN, S.; MOHER, M. **Sistemas de Comunicação-5**. [S.l.]: Bookman Editora, 2011.
- HUA, S.; SHI, Y. Reconfigurable intelligent surface for green edge inference in machine learning. In: IEEE. **2019 IEEE globecom workshops (GC Wkshps)**. [S.l.], 2019. p. 1–6.
- HUANG, C. *et al.* Energy efficient multi-user miso communication using low resolution large intelligent surfaces. In: IEEE. **2018 IEEE Globecom Workshops (GC Wkshps)**. [S.l.], 2018. p. 1–6.
- HUANG, C. *et al.* Energy efficient multi-user miso communication using low resolution large intelligent surfaces. In: **2018 IEEE Globecom Workshops (GC Wkshps)**. [S.l.: s.n.], 2018. p. 1–6.
- HUANG, C. *et al.* Holographic mimo surfaces for 6g wireless networks: Opportunities, challenges, and trends. **IEEE Wireless Communications**, v. 27, n. 5, p. 118–125, 2020.
- HUANG, C.; MO, R.; YUEN, C. Reconfigurable intelligent surface assisted multiuser miso systems exploiting deep reinforcement learning. **IEEE Journal on Selected Areas in Communications**, v. 38, n. 8, p. 1839–1850, 2020.
- HUANG, C. *et al.* Achievable rate maximization by passive intelligent mirrors. In: **2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)**. [S.l.: s.n.], 2018. p. 3714–3718.
- HUANG, Z.; ZHENG, B.; ZHANG, R. Transforming fading channel from fast to slow: Irs-assisted high-mobility communication. In: IEEE. **ICC 2021-IEEE International Conference on Communications**. [S.l.], 2021. p. 1–6.
- JIAN, M. *et al.* Reconfigurable intelligent surfaces for wireless communications: Overview of hardware designs, channel models, and estimation techniques. **Intelligent and Converged Networks**, v. 3, n. 1, p. 1–32, 2022.
- JIANG, T.; SHI, Y. Over-the-air computation via intelligent reflecting surfaces. In: IEEE. **2019 IEEE Global Communications Conference (GLOBECOM)**. [S.l.], 2019. p. 1–6.

- JORDAN, M. I.; MITCHELL, T. M. Machine learning: Trends, perspectives, and prospects. **Science**, American Association for the Advancement of Science, v. 349, n. 6245, p. 255–260, 2015.
- LEÓN-ALDACO, S. E. D.; CALLEJA, H.; ALQUICIRA, J. A. Metaheuristic optimization methods applied to power converters: A review. **IEEE Transactions on Power Electronics**, v. 30, n. 12, p. 6791–6803, 2015.
- LI, B.; FEI, Z.; ZHANG, Y. Uav communications for 5g and beyond: Recent advances and future trends. **IEEE Internet of Things Journal**, v. 6, n. 2, p. 2241–2263, 2019.
- LIANG, Y.-C. *et al.* Large intelligent surface/antennas (lisa): Making reflective radios smart. **Journal of Communications and Information Networks**, PTP, v. 4, n. 2, p. 40–50, 2019.
- LIASKOS, C. *et al.* A new wireless communication paradigm through software-controlled metasurfaces. **IEEE Communications Magazine**, v. 56, n. 9, p. 162–169, 2018.
- LIASKOS, C. *et al.* A new wireless communication paradigm through software-controlled metasurfaces. **IEEE Communications Magazine**, IEEE, v. 56, n. 9, p. 162–169, 2018.
- LIU, Y. *et al.* Reconfigurable intelligent surfaces: Principles and opportunities. **IEEE Communications Surveys Tutorials**, v. 23, n. 3, p. 1546–1577, 2021.
- MATTHIESEN, B. *et al.* Intelligent reflecting surface operation under predictable receiver mobility: A continuous time propagation model. **IEEE Wireless Communications Letters**, IEEE, v. 10, n. 2, p. 216–220, 2020.
- MUMTAZ, S. *et al.* Terahertz communication for vehicular networks. **IEEE Transactions on Vehicular Technology**, v. 66, n. 7, 2017.
- PICARD, R. W. *et al.* Affective learning—a manifesto. **BT technology journal**, Springer, v. 22, n. 4, p. 253–269, 2004.
- POTTS, J.; GIDDENS, T.; YADAV, S. The development and evaluation of an improved genetic algorithm based on migration and artificial selection. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 24, n. 1, p. 73–86, 1994.
- RENZO, M. D.; DANUFANE, F. H.; TRETYAKOV, S. Communication models for reconfigurable intelligent surfaces: From surface electromagnetics to wireless networks optimization. **Proceedings of the IEEE**, v. 110, n. 9, p. 1164–1209, 2022.
- RENZO, M. D. *et al.* Smart radio environments empowered by reconfigurable ai meta-surfaces: An idea whose time has come. **EURASIP Journal on Wireless Communications and Networking**, Springer, v. 2019, n. 1, p. 1–20, 2019.
- SUBRT, L.; PECHAC, P. Intelligent walls as autonomous parts of smart indoor environments. **IET communications**, IET, v. 6, n. 8, p. 1004–1010, 2012.
- SUTTON, R.; BARTO, A. Reinforcement learning: An introduction. **IEEE Transactions on Neural Networks**, v. 9, n. 5, p. 1054–1054, 1998.
- TAN, X. *et al.* Enabling indoor mobile millimeter-wave networks based on smart reflect-arrays. In: IEEE. **IEEE INFOCOM 2018-IEEE Conference on Computer Communications**. [S.l.], 2018. p. 270–278.
- TARIQ, F. *et al.* A speculative study on 6g. **IEEE Wireless Communications**, v. 27, n. 4, p. 118–125, 2020.

- VISWANATHAN, H.; MOGENSEN, P. E. Communications in the 6g era. **IEEE Access**, v. 8, p. 57063–57074, 2020.
- WANG, P. *et al.* Intelligent reflecting surface-assisted millimeter wave communications: Joint active and passive precoding design. **IEEE Transactions on Vehicular Technology**, IEEE, v. 69, n. 12, p. 14960–14973, 2020.
- WU, H.-t. *et al.* Application of genetic algorithm to the development of artificial intelligence module system. In: **2011 2nd International Conference on Intelligent Control and Information Processing**. [S.l.: s.n.], 2011. v. 1, p. 290–294.
- WU, Q.; ZHANG, R. Intelligent reflecting surface enhanced wireless network: Joint active and passive beamforming design. In: IEEE. **2018 IEEE Global Communications Conference (GLOBECOM)**. [S.l.], 2018. p. 1–6.
- WU, Q.; ZHANG, R. Intelligent reflecting surface enhanced wireless network via joint active and passive beamforming. **IEEE Transactions on Wireless Communications**, IEEE, v. 18, n. 11, p. 5394–5409, 2019.
- WU, Q.; ZHANG, R. Weighted sum power maximization for intelligent reflecting surface aided swipt. **IEEE Wireless Communications Letters**, IEEE, v. 9, n. 5, p. 586–590, 2019.
- WU, Q.; ZHANG, R. Beamforming optimization for wireless network aided by intelligent reflecting surface with discrete phase shifts. **IEEE Transactions on Communications**, v. 68, n. 3, p. 1838–1851, 2020.
- WU, Q.; ZHANG, R. Joint active and passive beamforming optimization for intelligent reflecting surface assisted swipt under qos constraints. **IEEE Journal on Selected Areas in Communications**, IEEE, v. 38, n. 8, p. 1735–1748, 2020.
- WU, Q.; ZHANG, R. Towards smart and reconfigurable environment: Intelligent reflecting surface aided wireless network. **IEEE Communications Magazine**, v. 58, n. 1, p. 106–112, 2020.
- WU, Q. *et al.* Intelligent reflecting surface-aided wireless communications: A tutorial. **IEEE Transactions on Communications**, v. 69, n. 5, p. 3313–3351, 2021.
- YANG, Y. *et al.* Intelligent reflecting surface meets ofdm: Protocol design and rate maximization. **IEEE Transactions on Communications**, IEEE, v. 68, n. 7, p. 4522–4535, 2020.
- YU, X.; XU, D.; SCHÖBER, R. Optimal beamforming for miso communications via intelligent reflecting surfaces. In: IEEE. **2020 IEEE 21st International Workshop on Signal Processing Advances in Wireless Communications (SPAWC)**. [S.l.], 2020. p. 1–5.
- ZAPPONE, A.; RENZO, M. D.; DEBBAH, M. Wireless networks design in the era of deep learning: Model-based, ai-based, or both? **IEEE Transactions on Communications**, v. 67, n. 10, p. 7331–7376, 2019.
- ZHENG, B.; YOU, C.; ZHANG, R. Intelligent reflecting surface assisted multi-user ofdma: Channel estimation and training design. **IEEE Transactions on Wireless Communications**, IEEE, v. 19, n. 12, p. 8315–8329, 2020.