



Universidade de Brasília

Instituto de Ciências Exatas
Departamento de Ciência da Computação

Agrupamento DBSCAN de Usuários em Sistemas Millimeter-Wave NOMA

Vinícius C. Souza

Monografia apresentada como requisito parcial
para conclusão do Bacharelado em Ciência da Computação

Orientador
Prof. Dr. Marcelo Antonio Marotta

Brasília
2023

Dedicatória

Dedico este trabalho aos meus pais e meus amigos, que me ajudaram durante todos esses anos.

Agradecimentos

Gostaria de agradecer ao professor Marcelo Marotta por ser meu orientador e me guiar com excelência durante o trabalho, e aos alunos Juliano Balcante e Giordano Monteiro por me apresentarem o *framework* OMNeT++ e tirar minhas dúvidas no decorrer do projeto.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES), por meio do Acesso ao Portal de Periódicos.

Resumo

O aumento de demandas em futuras redes torna necessário o estudo de novas técnicas para atender tais demandas. Esquema *power domain (PD) non-orthogonal multiple access (NOMA)* possibilita o aprimoramento da eficiência espectral ao dividir recursos ortogonais como tempo e frequência para diferentes *user equipments (UEs)*, fazendo com que mais UEs consigam se conectar em um sistema de redes. Para que o compartilhamento seja feito de forma eficaz, UEs precisam ter alguma relação entre si, tornando necessário a utilização de algoritmos de agrupamento. Neste trabalho é apresentado um algoritmo baseado em *Density-based spatial clustering of applications with noise (DBSCAN)* para agrupar UEs em sistemas *millimeter-wave (mmWave) PD NOMA*. O agrupamento é realizado considerando a correlação dos canais dos UEs ao utilizar bandas mmWave, as quais resultam em ondas altamente direcionais. Além disso, são implementadas novas versões do algoritmo para levar em conta cenários em que UEs entram e saem do sistema. Resultados mostram que mais UEs em sistemas PD NOMA conseguem receber pacotes em comparação ao sistema *orthogonal multiple access (OMA)*.

Palavras-chave: mmWave, NOMA, agrupamento de usuários

Abstract

The increase in demands in future networks makes it necessary to study new techniques to meet said demands. power domain (PD) non-orthogonal multiple access (NOMA) scheme allows the improvement of spectral efficiency by dividing orthogonal resources such as time and frequency to different user equipments (UEs), making more UEs able to connect in a network system. For sharing to be done effectively, users need to have some relationship with each other, making it necessary to use clustering algorithms. In this work it is presented an algorithm based on Density-based spatial clustering of applications with noise (DBSCAN) to group UEs in millimeter-wave (mmWave) PD NOMA systems. The cluster is made considering the correlation of UEs channels by utilizing mmWave bands, which results in highly directional waves. Furthermore, new versions are implemented to take in consideration scenarios where UEs come and leave the system. Results showed that more UEs in PD NOMA are able to receive packets in comparison to orthogonal multiple access (OMA) system.

Keywords: mmWave, NOMA, user clustering

Sumário

1	Introdução	1
2	Trabalhos Relacionados	4
3	Proposta	7
3.1	Procedimento do Algoritmo DBSCAN	7
3.2	Algoritmo DBSCAN em Sistemas mmWave PD NOMA	9
3.3	DBSCAN em Cenários Dinâmicos	10
3.3.1	Entrada de UEs	11
3.3.2	Saída de UEs	11
3.3.3	Movimentação de UEs	12
4	Protótipo	13
4.1	<i>Frameworks</i> e Simulador Simu5G	13
4.1.1	OMNeT++	13
4.1.2	INET	14
4.1.3	Simu5G	15
4.2	Funções Implementadas	15
5	Resultados	18
5.1	Resultado do SINR	19
5.2	Resultado do <i>throughput</i>	20
6	Conclusão e Trabalhos Futuros	21
	Referências	23

Lista de Figuras

1.1	Exemplo de modelo PD NOMA aplicado em dois UEs. (Fonte: [1]).	2
3.1	Exemplo de agrupamento utilizando algoritmo DBSCAN.	8
4.1	Exemplo de simulação apresentado na interface Qtenv. (Fonte: [2]).	14
4.2	Cenário da simulação.	16
4.3	Módulo de um UE.	17
5.1	Valor médio do SINR de todos os UEs.	19
5.2	CDF do throughput de todos os UEs.	20

Lista de Tabelas

2.1	Características dos algoritmos de agrupamento	6
5.1	Parâmetros de simulação	18

Lista de Abreviaturas e Siglas

3GPP 3rd Generation Partnership Program.

5G Quinta Geração.

6G Sexta Geração.

BS base station.

CF Cell-Free.

CQI channel quality indicator.

DBSCAN Density-based spatial clustering of applications with noise.

GUI Graphical User Interface.

IoT Internet of Things.

LoS line-of-sight.

MIMO Multiple-Input Multiple-Output.

mMIMO massive Multiple-Input Multiple-Output.

mmWave millimeter-wave.

NLoS non-line-of-sight.

NOMA non-orthogonal multiple access.

NR New Radio.

NSA non-standalone.

OMA orthogonal multiple access.

PD power domain.

RBs resource blocks.

SIC successive interference cancelation.

SINR Signal-to-Interference-plus-Noise Ratio.

TB Transport Block.

THz Terahertz.

UE user equipment.

UEs user equipments.

Capítulo 1

Introdução

As redes móveis de Quinta Geração (5G) foram projetadas para ter desempenho de vazão de 10 Gbps por conexão, latência de interface aérea de 1 ms e um milhão de conexões por quilômetro quadrado [3]. A alta demanda de conexões se deve ao fato de dispositivos *Internet of Things (IoT)* serem essenciais para o projeto de cidades inteligentes, os quais devem ser implementados por toda a cidade. Como é estimado que cada vez mais dispositivos devam estar conectados nos próximos anos [4], novos métodos e tecnologias já devem ser estudados para suportar futuras redes de Sexta Geração (6G), as quais necessitarão de vazão de até 1 Tbps e bandas de frequência maiores com o objetivo de atender altas quantidades de *user equipments (UEs)* [5].

Para atender a futura alta demanda de conexões a eficiência espectral e de energia devem ser aprimoradas, uma possível forma de melhorar a eficiência espectral é utilizando novos esquemas de múltiplo acesso. Em gerações de redes móveis anteriores os UEs eram alocados recursos como frequência, tempo ou *resource blocks (RBs)* diferentes para que não houvesse interferência entre eles, isto caracteriza os esquemas como *orthogonal multiple access (OMA)* [6]. A utilização de esquemas que não sejam ortogonais, denominados *non-orthogonal multiple access (NOMA)*, possuem mais graus de liberdade e logo conseguem melhorar a eficiência espectral para a futura rede 6G.

Esquemas NOMA possibilitam que UEs consigam utilizar recursos como tempo e frequência simultaneamente a partir de outros domínios como da energia e código. No caso do *power domain (PD)* em um cenário *Downlink*, um único sinal contendo múltiplas mensagens pode ser mandado para vários UEs, os quais são ordenados a partir do quão forte são seus canais, e cada um utiliza *successive interference cancellation (SIC)* para cancelar a interferência, mandá-la para o próximo UE e decodificar o sinal resultante, sendo que o sinal do UE com canal mais fraco possui a menor interferência [7]. Além de melhorar a eficiência espectral, NOMA também melhora a equidade dos UEs e diminui a latência de transmissão [6].

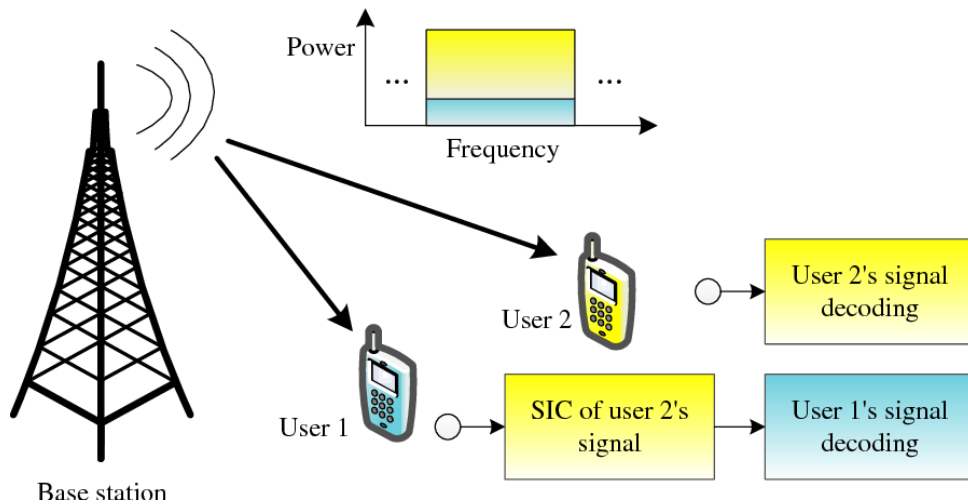


Figura 1.1: Exemplo de modelo PD NOMA aplicado em dois UEs. (Fonte: [1]).

Para poder melhorar ainda mais a eficiência espectral, PD NOMA pode ser integrado com bandas de frequência *millimeter-wave (mmWave)*, as quais variam entre 30 e 300 GHz. O comprimento de onda curto destas bandas facilita a implementação de sistemas *massive Multiple-Input Multiple-Output (mMIMO)*, resultando em largura de feixe mais estreita na técnica de *beamforming* [6],[8]. Isto melhora a implementação de redes com bandas de frequência mmWave devido a sua natureza altamente direcional. Portanto, utilizando bandas mmWave o esquema PD NOMA pode determinar quais UEs usam os mesmos recursos a partir da correlação de seus canais [9], sendo desejável que o compartilhamento do recurso seja feito em um mesmo feixe a partir da técnica *beamforming*.

O compartilhamento de recursos entre UEs é decidido por algoritmos de agrupamento, os quais precisam juntar UEs que possuam características semelhantes entre eles e sejam distintas em outros grupos. No caso do esquema PD NOMA, é necessário minimizar a interferência entre grupos formados e considerar a entrada, saída e movimentação de UEs no espaço. Além disso, é preciso considerar a capacidade dos dispositivos de decodificar utilizando SIC, quanto maior for o número de dispositivos maior será a complexidade para decodificar, tornando necessário limitar a quantidade de dispositivos por grupo [10]. Apesar de já terem sido propostos algoritmos para lidar com o agrupamento de usuários, como o baseado em *matching game* [11], poucos lidam com cenários dinâmicos de usuários e com a capacidade de decodificação.

Quando um problema possui alta complexidade em possuir solução ótima, aprendizagem de máquina pode ser utilizada para encontrar soluções sub-ótimas. Dado um conjunto de dados, aprendizagem não supervisionada faz com que uma máquina aprenda a agrupar esses dados em diferentes rótulos a partir de determinadas características de cada um [12]. Então, considerando a banda mmWave, é possível utilizar aprendizagem de máquina para

agrupar UEs em uma rede a partir da correlação de seus canais. Algoritmos propostos para esquemas PD NOMA mostraram melhor performance em relação a OMA [13].

Sendo assim, o objetivo deste trabalho foi desenvolver um algoritmo de agrupamento baseado em *Density-based spatial clustering of applications with noise (DBSCAN)* para o esquema PD NOMA utilizando aprendizagem de máquina não supervisionada. Este algoritmo leva em consideração as características dos UEs ao utilizar bandas mmWave e também a capacidade de decodificação SIC para formar grupos. Além disso, é lidado com o cenário em tempo real, onde UEs chegam, movem e saem do sistema. O desenvolvimento do algoritmo e experimentos realizados com ele foram feitos utilizando o simulador de redes Simu5G.

O restante do artigo está descrito a seguir. No capítulo Capítulo 2 é apresentado como outros trabalhos implementaram algoritmos de agrupamento em sistemas PD NOMA. No capítulo Capítulo 3 é apresentado o modelo do algoritmo DBSCAN e quais modificações foram feitas para o projeto. O simulador e os *frameworks* utilizados para realizar experimentos são descritos no capítulo Capítulo 4. No capítulo Capítulo 5 são mostradas as configurações definidas nos experimentos e os resultados. Por fim, no capítulo Capítulo 6 é apresentado as conclusões e possíveis trabalhos para o futuro.

Capítulo 2

Trabalhos Relacionados

Algoritmos de agrupamento somente agrupam dados em um cenário fixo, o que não é desejável em cenários de redes os quais possuem usuários entrando, saindo e se movimentando constantemente. Por isso, é vantajoso que esses algoritmos sejam modificados para tratar cenários em tempo real. Considerando o sistema mmWave PD NOMA, os autores em [13] utilizaram o algoritmo de agrupamento *k-means*. A direção normalizada do canal dos UEs é utilizada como *feature space* para calcular o erro quadrático entre o centroide e os pontos de um grupo, sendo este um fator que determina quando o algoritmo deve parar. Para lidar com a chegada de UEs em tempo real foi proposto uma segunda versão do algoritmo, no qual atualiza o agrupamento no cenário quando determinada quantidade de UEs aparecem. Entretanto, é necessário iterar o algoritmo várias vezes para determinar o número ideal de grupos e também não existe limite para quantos UEs podem pertencer a cada grupo.

Em [14], o agrupamento foi proposto baseado no algoritmo *Expectation-Maximization* em sistemas mmWave PD NOMA. Assim como [13], os autores propõem uma segunda versão do algoritmo para lidar com cenários em tempo real, porém também levando em conta casos em que UEs saem e mudam de grupos no sistema. No entanto, o número ideal de grupos não é detectado na primeira iteração e também não é limitado a quantidade de UEs por grupo. Além disso, o trabalho não utiliza a direção normalizada do canal dos UEs como *feature space*.

Os autores em [15] utilizaram o algoritmo de agrupamento hierárquico para identificar o melhor número de grupos automaticamente em sistemas mmWave PD NOMA. Isto é feito pois a distribuição de UEs no sistema é randômica, o que dificulta obter o número de grupos ideais, e também pois a identificação automática reduz o tempo de computação do agrupamento. Assim como [13] e [14], o algoritmo define como *feature space* a direção normalizada do canal dos UEs. No entanto, os autores não consideram entrada, saída e movimentação de UEs e também não limitam o número de UEs por grupo.

Os autores em [16] propõem dois algoritmos para lidar com cenários de UEs com limite

de capacidade de decodificação SIC em sistemas mmWave PD NOMA. A diferença dos dois está na capacidade de decodificação dos UEs, onde um algoritmo trata um cenário homogêneo em que todos os UEs possuem capacidade similar e o outro algoritmo não. Em ambos os casos é colocado um limite para quantos UEs podem pertencer a um mesmo grupo baseado no fato de que em cenários com quantidade densa de UEs, se não existir limite por grupo UEs poderão receber poucos recursos para conseguir decodificar sinais sobrepostos, fazendo com que todos os UEs em um grupo não consigam receber suas mensagens. Os dois algoritmos também realizam agrupamento a partir da direção normalizada do canal de UEs, porém o agrupamento é realizado comparando o canal de um UE com o vetor do possível *beam* que irá agrupá-lo. Porém, ambos os algoritmos não consideram chegada, saída e movimento de UEs no sistema.

Em sistemas *Cell-Free (CF)* mMIMO, os autores em [17] propõem duas versões aprimoradas do algoritmo de agrupamento *k-means*. A primeira delas escolhe novos centroides a partir da distância mais longa entre um UE e dos centroides que já foram escolhidos, assim é evitado cenários em que centroides estão perto um dos outros ou estão longe de todos os UEs, podendo diminuir o tempo de execução. A segunda versão escolhe centroides a partir de UEs que possuem maior quantidade de *base stations* com melhor conexão. Ambos os algoritmos limitam a quantidade de UEs por grupo, porém não decidem em tempo real o agrupamento de UEs e não utilizam a direção normalizada do canal de UEs como *feature space*, visto que não trabalham com bandas mmWave.

Em [18], os autores propõem um algoritmo de agrupamento baseado em *mean shift* para cenários CF MIMO e mMIMO co-localizado. Apesar de não trabalhar com bandas mmWave os autores propõem agrupar UEs utilizando como *feature space* o vetor normalizado do canal de UEs. Diferente dos outros trabalhos é possível que UEs pertençam a nenhum grupo caso eles não possuam canais similares a outros. Isto é vantajoso pois UEs que não tenham nenhuma relação com outros UEs não terão vantagem ao receber recursos compartilhados em um grupo. O algoritmo também consegue determinar o número ideal de grupos automaticamente, porém não limita o número de UEs por grupo e também não considera cenários dinâmicos.

Bandas de frequência Terahertz (THz) também sofrem alta perda de caminho, tornando o canal de UEs altamente correlacionados. Os autores em [19] utilizam estas características em seu algoritmo de agrupamento baseado em *k-means* para melhorar o método inicial de encontrar centroides. Em vez de escolher centroides aleatoriamente no espaço, cada um é escolhido a partir da menor correlação entre o seu canal e dos centroides já determinados. Entretanto, cenários dinâmicos e limite de usuários para cada grupo não foram considerados na implementação e como bandas THz são maiores que mmWave a transmissão de sinais ocorre somente em distâncias curtas.

Tabela 2.1: Características dos algoritmos de agrupamento

Trabalho	Decide em Tempo Real	Limite de Usuários por Grupo	Número de Grupos Ideal Determinado Automaticamente	UEs não Precisam Pertencer a Grupos	Direção Normalizada Utilizada como <i>Feature Space</i>
[13]	✓				✓
[14]	✓				✓
[15]			✓		✓
[16]		✓			✓
[17]		✓			
[18]			✓	✓	✓
[19]					✓
Proposta	✓	✓	✓	✓	✓

Capítulo 3

Proposta

Neste capítulo será apresentada a proposta do algoritmo de agrupamento baseado em DBSCAN desenvolvido no projeto. Na seção 3.1 é descrito o procedimento de agrupamento de usuários a partir do modelo DBSCAN. Em seguida, é apresentado como o algoritmo é implementado em sistemas mmWave PD NOMA junto com seu pseudocódigo na seção 3.2. Por fim, a seção 3.3 mostra como o algoritmo foi modificado para considerar cenários em que UEs entram, saem e movimentam no sistema.

3.1 Procedimento do Algoritmo DBSCAN

DBSCAN é um algoritmo de agrupamento baseado em densidade no qual encontra o número ideal de grupos em um conjunto de dados automaticamente. Nele dados podem pertencer a nenhum grupo caso não tenham os requerimentos necessários, sendo então classificados como ruídos. Dados pertencentes a um grupo são classificados entre pontos de centro e borda, sendo centro aqueles que possuem quantidade de vizinhos maior ou igual ao valor do parâmetro $MinPts$ e borda os que são vizinhos de pontos de centro porém não possuem quantidade mínima de vizinhos [20]. Essas classificações dependem de dois parâmetros e da *feature space*, a qual mudará de acordo com o cenário em que DBSCAN será aplicado.

O parâmetro ϵ delimita o valor necessário para que dois pontos no conjunto de dados sejam considerados vizinhos. Assim, considerando dois pontos p e q no conjunto de dados D e uma função de distância $dist(p, q)$ que depende da *feature space*, podemos definir a vizinhança do ponto p a partir da seguinte função:

$$Vizinhos(p) = \{q \in D | dist(p, q) \leq \epsilon\} \quad (3.1)$$

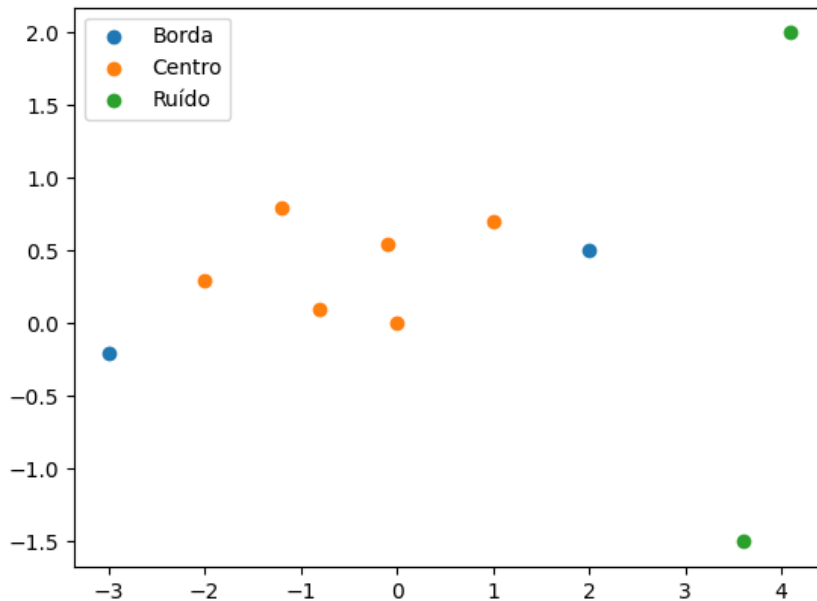


Figura 3.1: Exemplo de agrupamento utilizando algoritmo DBSCAN.

O segundo parâmetro, denominado *minPts*, determina a quantidade mínima de vizinhos na qual um ponto deve ter para ser classificado como ponto de centro. Dessa forma, um ponto de borda p de um grupo deve atender os seguintes requisitos:

1. $p \in \text{Vizinhos}(q)$ e
2. $|\text{Vizinhos}(q)| \geq \text{minPts}$.

Assim, o algoritmo DBSCAN percorre todos os pontos de um conjunto de dados, classificando-os entre ruído, borda ou centro. Um grupo é encontrado quando um ponto possui quantidade de vizinhos maior ou igual a *minPts*, a partir dele seus vizinhos serão classificados entre pontos de borda ou centro. Este processo se repetirá para todos os vizinhos dos pontos de centro que forem encontrados no grupo. Desta forma, pontos primeiramente determinados como ruído podem mudar para borda na condição de um de seus vizinhos for classificado posteriormente como ponto de centro. A Figura 3.1 mostra um exemplo de pontos agrupados de acordo com o algoritmo DBSCAN, nele é possível ver que pontos distantes uns dos outros são classificados como ruídos, pontos perto de poucos pontos são do tipo borda e os pontos que possuem vários vizinhos são classificados como tipo centro.

3.2 Algoritmo DBSCAN em Sistemas mmWave PD NOMA

Como UEs e *base station (BS)* possuem recursos limitados para transferir e receber informações o agrupamento ilimitado de UEs por grupo pode prejudicar a divisão de recursos. Logo, para implementar o algoritmo DBSCAN em sistemas mmWave PD NOMA foi limitado a quantidade de UEs que podem pertencer a um grupo. Também foi inserido um novo parâmetro, denominado *maxPts*, no algoritmo do projeto para que ele determine quando um grupo não possa mais agrupar novos pontos. Assim, Considerando que no sistema existam U UEs com índice de conjunto $\mathcal{U} = \{1, \dots, U\}$ e K grupos com índice de conjunto $\mathcal{K} = \{1, \dots, K\}$, o tamanho do conjunto de UEs no l -ésimo grupo, definido como $\mathcal{N}_l = \{1_l, \dots, N_l\}$, não pode ultrapassar *MaxPts*.

O agrupamento de UEs em sistemas mmWave PD NOMA deve levar em consideração a interferência causada por grupos diferentes, para reduzi-la os UEs de um grupo devem ser fortemente correlacionados. Em cenários simples de aprendizagem não supervisionada geralmente se utilizam distâncias como euclidiana para agrupar pontos de um conjunto de dados, porém no caso de sistemas mmWave PD NOMA, onde ocorre interferência e perda de caminho, é importante escolher uma *feature space* apropriada para classificar UEs. Considerando as propriedades de bandas mmWave, o algoritmo agrupa UEs a partir da correlação de seus canais.

Devido a natureza altamente direcional de bandas mmWave os canais possuem poucos multi caminhos em seus componentes. Devido a isso, canais com links de *line-of-sight (LoS)* sofrem pouca mudança com links de *non-line-of-sight (NLoS)* por causa da alta perda de caminho em componentes NLoS [21]. Logo, podemos considerar um modelo de canal com caminho único, o qual pode ser o caminho LoS caso ele exista ou, caso contrário, o caminho dominante NLoS.

Tendo em mente o modelo de canal com caminho único e a correlação dos canais dos UEs, determinamos a função de distância do algoritmo DBSCAN a partir do cosseno do ângulo entre dois vetores de canais, o qual pode ser simplificado para a comparação entre a direção normalizada de dois canais, definida como $\phi = \frac{2D \sin(\theta)}{\lambda}$ [13], onde θ é o ângulo de partida e D e λ são a distância entre duas antenas adjacentes da BS e o comprimento de onda da portadora, respectivamente.

O pseudocódigo 1 representa o algoritmo DBSCAN utilizado para agrupar UEs em sistemas mmWave PD NOMA. Com ele, UEs que estão em um mesmo grupo receberão o mesmo sinal sobreposto de uma BS, enquanto UEs classificados como ruído receberão sinais por esquema OMA. A diferença entre o algoritmo do projeto e o do modelo original está no parâmetro *maxPts*, o qual determina quando o agrupamento de um grupo deve terminar por causa do limite de UEs. Além disso, o parâmetro modifica a função de *Vizinhos* pois UEs que estão em grupos cheios não são mais considerados vizinhos.

Algorithm 1 Algoritmo DBSCAN em sistemas mmWave PD NOMA

Require: $UEs, \epsilon, minPts, maxPts$

```
1:  $ID \leftarrow -1$ 
2: for all  $UE \in UEs$  do
3:    $L \leftarrow 0$ 
4:   if  $UE.tipo \neq NaoIdentificado$  then
5:     continue
6:   end if
7:    $VetorUE\ N \leftarrow Vizinhos(UE)$ 
8:   if  $|N| < minPts$  then
9:      $UE.tipo \leftarrow Ruido$ 
10:    continue
11:  end if
12:   $ID \leftarrow ID + 1$ 
13:   $UE.id \leftarrow ID$ 
14:   $UE.tipo \leftarrow Centro$ 
15:   $L \leftarrow L + 1$ 
16:  for all  $V \in N$  do
17:    if  $V.tipo == Ruido$  then
18:       $V.tipo \leftarrow Borda$ 
19:       $V.id \leftarrow ID$ 
20:       $L \leftarrow L + 1$ 
21:    end if
22:    if  $V.tipo \neq NaoIdentificado$  then
23:      continue
24:    end if
25:     $V.id \leftarrow ID$ 
26:     $L \leftarrow L + 1$ 
27:     $VetorUE\ N' \leftarrow Vizinhos(V)$ 
28:    if  $|N'| \geq minPts$  then
29:       $V.tipo \leftarrow Centro$ 
30:       $N \leftarrow N \cup N'$ 
31:    else
32:       $V.tipo \leftarrow Borda$ 
33:    end if
34:    if  $L \geq maxPts$  then
35:      break
36:    end if
37:  end for
38: end for
```

3.3 DBSCAN em Cenários Dinâmicos

O algoritmo proposto consegue agrupar somente UEs em um cenário fixo, em um cenário real o estado dos UEs pode mudar de acordo com o tempo, o que pode prejudicar o agru-

pamento realizado anteriormente. O surgimento de um UE pode modificar a classificação de UEs vizinhos de pontos de borda para centro ou ruído para borda, tornando possível a criação de um novo grupo. A saída de um UE pode desfazer um grupo caso o UE seja o único ponto de centro, tornando todos os outros UEs em pontos de ruído. O movimento de um UE pode resultar em diferentes ações, da criação de um novo grupo até o desagrupamento de outro. A seguir é apresentado como esses cenários dinâmicos foram tratados.

3.3.1 Entrada de UEs

A classificação de um UE que entrou no cenário muda de acordo com sua quantidade de vizinhos e seus tipos:

- Quando a quantidade de vizinhos do UE for menor que *minPts* ele é classificado como ponto de ruído caso nenhum de seus vizinhos sejam pontos de centro, caso contrário o UE é classificado como ponto de borda do grupo. Nos próximos itens é considerado que a quantidade de vizinhos do UE é maior ou igual a *minPts*;
- Se a quantidade de vizinhos os quais são pontos de ruído é maior que *minPts* o UE e os pontos de ruídos são agrupados em um novo grupo;
- Caso não seja possível criar um novo grupo é verificado se alguma quantidade de vizinhos maior ou igual a *minPts* pertence a um grupo, na hipótese de houver, o UE é classificado como ponto de centro do grupo;
- Se nenhum dos itens acima forem realizados o algoritmo verifica se o UE possui algum vizinho classificado como ponto de centro, se tiver o UE faz parte do grupo como ponto de borda, caso contrário o UE é classificado como ruído.

Os itens descritos acima também consideram que o UE novo só pode entrar em um grupo que não esteja cheio, além disso os seus vizinhos podem mudar de ponto de borda ou ruído para ponto de centro caso o aparecimento do novo UE faça com que eles tenham um valor igual a *minPts*.

3.3.2 Saída de UEs

Na saída de um UE no cenário é verificado se ele pertence a algum grupo. Se sim, todos os outros UEs deste grupo irão verificar se ainda existe um ponto de centro que seja seu vizinho, se não possuir nenhum, o UE muda sua classificação para ponto de ruído. Logo, se o UE que sair do grupo for o único ponto de centro todos os outros UEs serão classificados como ruído e o grupo deixará de existir.

3.3.3 Movimentação de UEs

Considerando que a movimentação de um único UE pode criar ou desfazer grupos e trocar a classificação de outros pontos, se todos os UEs estiverem se movimentando no cenário é possível que todos os grupos e pontos mudem. Assim, para lidar com este cenário foi utilizada a versão do algoritmo apresentada em 1, o qual é executada uma quantidade de vezes em tempos diferentes. O período de tempo em que o algoritmo é executado foi escolhido arbitrariamente baseado em um cenário onde todos os UEs possuem mesma velocidade constante.

Capítulo 4

Protótipo

Neste capítulo será detalhado como foram conduzidos os experimentos com o algoritmo DBSCAN em sistemas mmWave PD NOMA. Na seção 4.1 é apresentado os *frameworks* e o simulador utilizados no projeto. Em seguida, as funções implementadas para simular sistemas mmWave PD NOMA são apresentadas na seção 4.2.

4.1 *Frameworks* e Simulador Simu5G

4.1.1 OMNeT++

OMNeT++ é um *framework open source* de simulação de eventos discretos com design orientado a objetos que consegue trabalhar com vários tipos de redes como sem fios, com fios ou *on-chip* [22]. Seus principais componentes são a biblioteca de *kernel* de simulação feita em C++, linguagem de descrição de topologia NED, *Graphical User Interface (GUI)* para observar simulações em tempo real (QtEnv) e interface de linha de comando para executar as simulações (CmdEnv). A característica fundamental deste *framework* é a arquitetura de componentes para modelos de simulação como o Simu5G.

Um modelo OMNeT++ é formado a partir de módulos, os quais podem ser reusados em outros módulos e modelos. Módulos são divididos entre simples e compostos, módulos simples são do nível mais baixo da hierarquia de módulos e descrevem o comportamento do modelo em linguagem C++ usando a biblioteca da simulação. Módulos compostos podem possuir tanto módulos compostos quanto simples, fazendo com que o aninhamento não tenha limite. Assim, o modelo que representa a rede, denominado *network*, é um módulo composto no topo da hierarquia que possui submódulos como roteadores e servidores.

Módulos interagem uns com os outros a partir de mensagens que podem conter dados arbitrários. A comunicação entre eles ocorre de duas maneiras, a primeira sendo a partir de *gates*, parâmetros criados em um módulo a partir do seu arquivo NED, que servem como

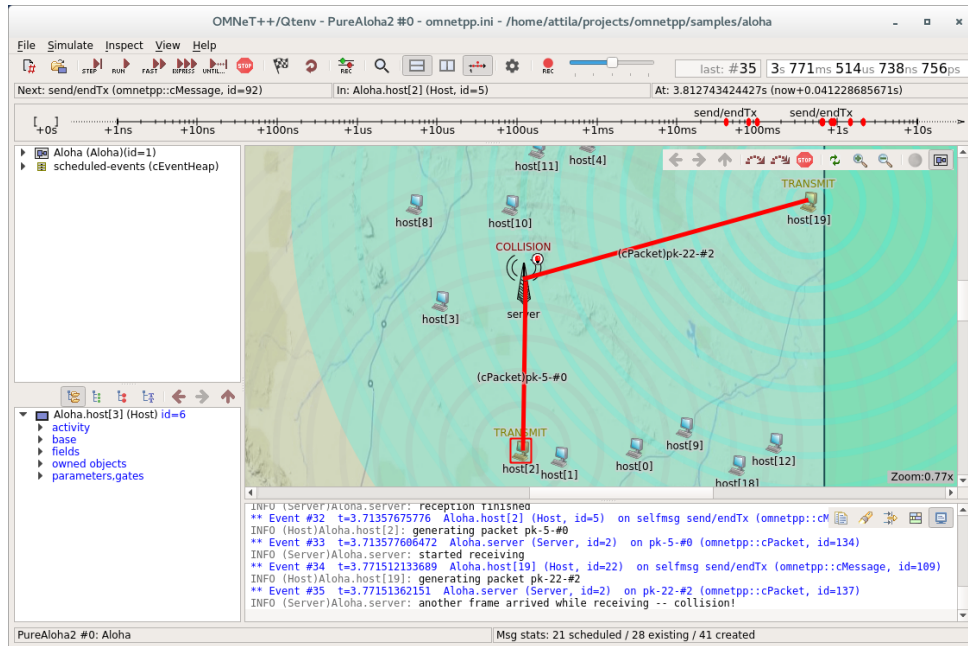


Figura 4.1: Exemplo de simulação apresentado na interface Qtenv. (Fonte: [2]).

interface para comunicar com outros módulos a partir dos *gates* deles. Na segunda maneira módulos conseguem mandar mensagens diretamente para outros módulos, o que é útil em redes sem fio. Mensagens também podem ser mandadas em determinado tempo a partir de agendamento e também podem ser transferidas para o próprio módulo.

As simulações são configuradas em arquivos INI, neles existem funções como determinar o tempo de simulação e a quantidade de vezes em que a simulação repetirá. Para evitar que as execuções ocorram de forma igual é possível definir o conjunto de *seeds*, assim o gerador de números aleatórios não irá gerar resultados idênticos toda simulação. Caso seja necessário um estudo de parâmetros o arquivo INI possibilita que um parâmetro seja executado com diferentes valores para execuções distintas [23].

4.1.2 INET

O *framework* INET oferece recursos de redes de comunicação no ambiente OMNeT++ [24]. Ele implementa módulos referentes a protocolos de redes baseados no modelo OSI, os quais podem ser utilizados em módulos como UEs e BS. Outras características do *framework* são o suporte à mobilidade, o qual foi utilizado no projeto para simular a movimentação de UEs, e diferentes tipos de transmissão de dados, podendo aumentar o tráfego na rede.

4.1.3 Simu5G

Simu5G é um simulador de redes 5G com funções implementadas de acordo com os padrões *3rd Generation Partnership Program (3GPP)* [25]. A arquitetura do simulador possui *design* semelhante ao SimuLTE, simulador de redes 4G, para simplificar a implementação do padrão *non-standalone (NSA)*. É destacado a seguir os módulos que foram importantes para implementar o projeto:

- NrUe: módulo do UE que possui recursos *New Radio (NR)*, responsável por relatar o seu *channel quality indicator (CQI)*, baseado no *Signal-to-Interference-plus-Noise Ratio (SINR)*, para a BS. O CQI é um dos fatores que determina se um UE consegue ou não receber pacotes;
- gNodeB: módulo da BS 5G responsável pelo agendamento de recursos e transmissão de *Transport Block (TB)* para UEs agendados;
- Camada PHY: módulo da camada física responsável por simular efeitos de propagação de sinais em TB. O aspecto importante para o projeto está na interação com o módulo *channelModel*, o qual computa SINR baseado na perda de caminho, *fading* e *shadowing*.

4.2 Funções Implementadas

A primeira função implementada no projeto foi a entrada e saída de UEs em tempo de execução. Como é necessário manter o controle do momento em que UEs vão aparecer ou sair do sistema foi criado um módulo baseado no padrão de *design Observer*. Neste padrão, o objeto *subject* tem a responsabilidade de notificar os objetos *observers* quando ocorre uma mudança no sistema. Assim, foi criado um módulo simples chamado *subject* no sistema, o qual trata UEs como *observers* e atualiza-os quando ocorre uma mudança no agrupamento do algoritmo DBSCAN. A Figura 4.2 mostra o cenário da simulação, onde tem uma BS no meio e vários UEs aparecendo aleatoriamente no sistema, enquanto a Figura 4.3 apresenta os componentes de um módulo de UE, onde é possível ver a divisão das camadas e também quantos pacotes o UE está recebendo.

A funcionalidade de mandar mensagens agendadas para o próprio módulo é utilizada em *subject*. Três mensagens diferentes são mandadas, as primeiras duas contêm mensagens para que seja realizada a entrada e saída de UEs na simulação e a última mensagem é utilizada para reexecutar o algoritmo DBSCAN devido à movimentação de UEs, como mencionado na seção 3.3.3. Toda vez que um UE aparece ou sai da simulação são executados os agrupamentos apresentados em 3.3.1 e 3.3.2, respectivamente. Para notificar os UEs quando




Figura 4.2: Cenário da simulação.

são agrupados em um grupo, o *subject* guarda todos os grupos formados atualmente com quais UEs estão em cada um.

Apesar do simulador Simu5G ter suporte para bandas mmWave não existe suporte para técnica de *beamforming* [26]. Portanto, não foi possível implementar o esquema PD NOMA pois cada grupo deveria estar em um feixe formado por *beamforming*. Então, para avaliar o agrupamento do algoritmo DBSCAN foi implementado um novo *channelModel*, o qual modifica o ganho do SINR a partir da correlação dos UEs em grupos. Quando um UE pertence a um grupo, o novo *channelModel* verifica qual é o maior ângulo entre os UEs do grupo em relação à BS como uma forma de verificar a correlação do canal dos UEs. Dependendo do valor do ângulo medido, o ganho do SINR é maior ou menor. Os módulos implementados no projeto estão disponíveis *online* no site <https://github.com/vinis-caixe/TCC>.

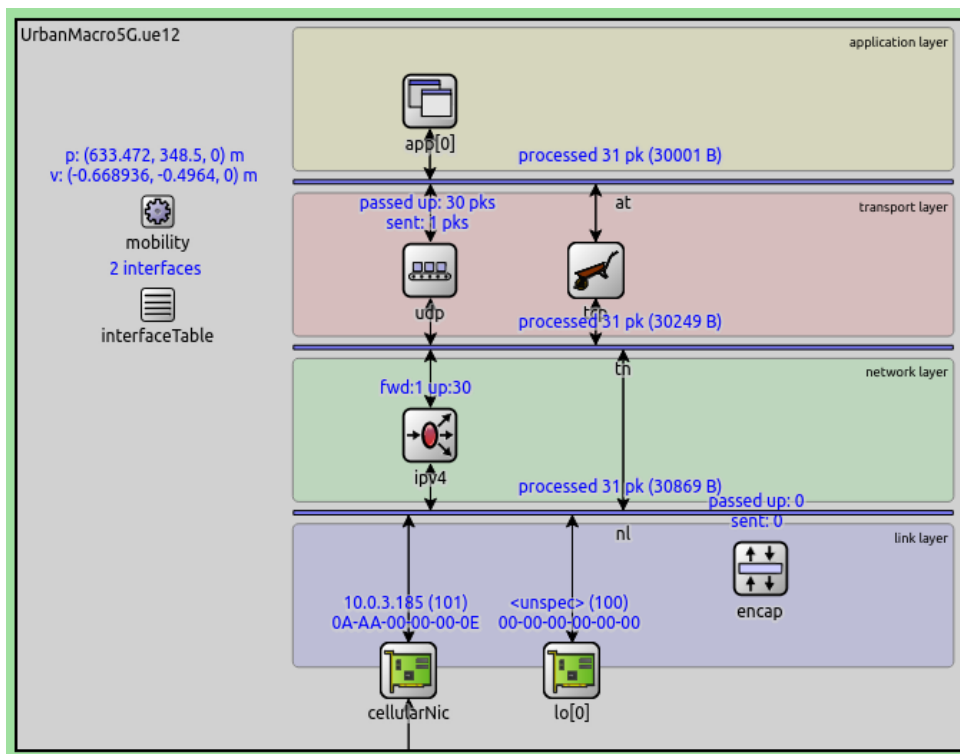


Figura 4.3: Módulo de um UE.

Capítulo 5

Resultados

Para avaliar o desempenho do algoritmo DBSCAN em sistemas mmWave PD NOMA foi realizado um estudo de parâmetro entre o *channelModel* desenvolvido em 4.2 e o *channelModel* padrão do simulador Simu5G, implementado de acordo com padrões 3GPP. Como o novo *channelModel* é responsável por aumentar o ganho do SINR a partir do agrupamento, a comparação dos dois *channelModels* é equivalente a comparar os sistemas OMA e PD NOMA. A obtenção de bons resultados ocorre quando os UEs conseguem ficar agrupados e quando seus ângulos em relação à BS são semelhantes. É possível obter a média do ganho do SINR e do *throughput* de cada UE na simulação a partir dos dados gravados pelo *framework* OM-NeT++, estes dois valores foram utilizados como avaliadores do desempenho do algoritmo DBSCAN.

A simulação do cenário dinâmico foi feita impondo um limite de 60 UEs no sistema. O cenário começa com nenhum UE presente e são adicionados de tempos em tempos novos UEs aleatoriamente até chegar na metade do tempo da simulação. Depois, são retirados UEs aleatoriamente do sistema até o final da simulação. Todos os UEs na simulação possuem velocidade de 3 Km/h e se movimentam em uma direção fixa aleatória. Os parâmetros e seus valores utilizados nas simulações são apresentados na tabela 5.1.

Tabela 5.1: Parâmetros de simulação

Energia de transmissão (dBm)	46
Frequência portadora (GHz)	28
Largura de banda (MHz)	100
Modelo de propagação	<i>Free Space</i>
Tempo de simulação	10s
Repetições de simulação	150

O limite de UEs e a velocidade deles foi determinada a partir de padrões 3GPP. Além disso, os UEs estão ao ar livre no mesmo plano para simplificar a simulação, visto que a adição de paredes afeta a propagação de ondas. O tempo curto de simulação foi colocado por

causa do tempo de processamento para cada repetição ser alto, resultando em UEs pouco se movimentando nos cenários.

Nos primeiros testes havia aumento do ganho do SINR porém não do *throughput*, isto ocorria pois a quantidade de recursos disponíveis satisfazia a demanda dos UEs. Para aumentar o tráfego foi simulado a demanda de *video streaming*, onde todos os UEs requerem um vídeo e a BS envia pacotes de 1000 B a cada 10 ms para os UEs que possuem condições para receber.

5.1 Resultado do SINR

A Figura 5.1 apresenta a comparação da média do SINR medido em todos os UEs no cenário *Downlink*, o lado esquerdo representa o *channelModel* padrão do simulador Simu5G e o da direita o desenvolvido no projeto. O aumento do ganho do SINR no lado direito mostra que o algoritmo DBSCAN consegue agrupar os UEs de tal forma que seus canais sejam similares. Além disso, o aumento mostra que o tempo decidido para reexecutar o algoritmo DBSCAN, como mencionado em 3.3.3, é suficiente para evitar que UEs em um grupo se distanciem uns dos outros, o que resultaria em perda no ganho do SINR. O desvio padrão baixo se deve ao fato da maioria dos UEs conseguirem pertencer a grupos, a repetição da simulação possibilitou que UEs que não tivessem grupo uma vez conseguissem ser agrupados em outras repetições.

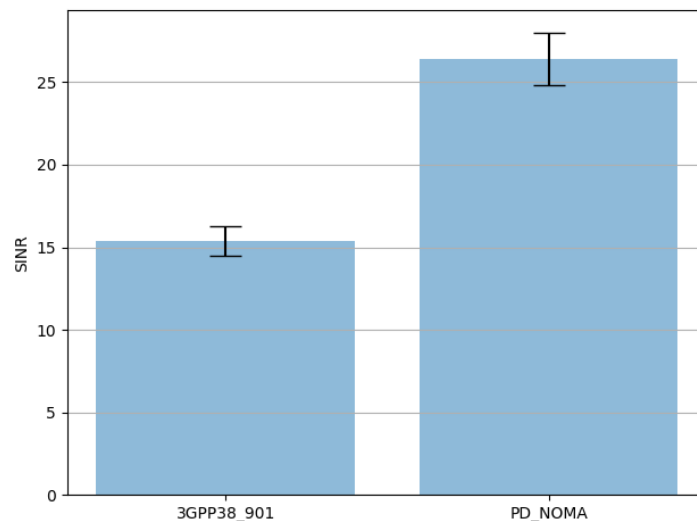


Figura 5.1: Valor médio do SINR de todos os UEs.

5.2 Resultado do *throughput*

A Figura 5.2 apresenta a *Cumulative Distribution Function* em relação ao *throughput* dos UEs, a linha azul representa o *channelModel* padrão do simulador Simu5G e a linha vermelha o desenvolvido no projeto. Cerca de 60% dos UEs na linha azul não conseguiram receber pacotes nas simulações por causa da alta perda de caminho nas bandas *mmWave* e pelo fato de não ter sido utilizada a técnica de *beamforming*, como mencionado em 4.2. Na linha vermelha apenas 10% dos UEs não recebem pacotes, mostrando que o ganho do SINR é suficiente para possibilitar mais conexões com a BS. Portanto, o sistema *mmWave* PD NOMA garante maior equidade para os UEs que estão distantes da BS ao melhorar o canal.




Figura 5.2: CDF do throughput de todos os UEs.

Capítulo 6

Conclusão e Trabalhos Futuros

Este trabalho lidou com o problema de falta de recursos em sistemas de redes atuais para atender a futura demanda de altas conexões. A utilização de bandas mmWave em esquema PD NOMA foi considerada como uma solução para aumentar a eficiência espectral. Como no esquema PD NOMA UEs compartilham um mesmo recurso, foi apresentado um algoritmo baseado em DBSCAN com o objetivo de agrupar UEs em sistemas mmWave PD NOMA baseado na correlação de seus canais. O algoritmo foi modificado para limitar a quantidade de UEs em cada grupo e também foram criadas novas versões para lidar com a entrada e saída de UEs no cenário.

Para implementar o algoritmo e realizar simulações utilizou-se os *frameworks* OMNeT++ e INET e o simulador Simu5G. Não foi possível implementar o esquema PD NOMA corretamente pois o simulador não tinha suporte para *beamforming* e divisão de recursos, então para simular o esquema o ganho do canal dos UEs foi modificado de acordo com o agrupamento. Simulações foram feitas para comparar os esquemas PD NOMA e OMA e os resultados mostraram que os UEs conseguem ser agrupados corretamente em tempo real devido ao aumento do SINR. Também observou-se que a equidade no cenário melhorou devido ao aumento de UEs os quais receberam pacotes.

Como trabalhos futuros é sugerido:

- Aplicar o algoritmo desenvolvido neste trabalho em simuladores que tenham suporte para *beamforming* e sistemas PD NOMA;
- Estudos de alocação de energia em sistemas mmWave PD NOMA, visto que não foi considerado neste trabalho e a distribuição de energia para cada UE em um grupo será diferente dependendo da qualidade de seus canais;
- Estudos com cenários mais complexos, visto que o cenário projetado neste trabalho possui somente uma BS no centro e vários UEs andando ao ar livre. Possíveis for-

mas de modificar o cenário são colocar UEs em prédios e considerar quando está chovendo, pois paredes e chuvas afetam a propagação de bandas mmWave;

- Estudos acerca do tempo necessário para reexecutar o algoritmo DBSCAN. Os UEs deslocavam poucos metros nas simulações devido à baixa velocidade e tempo de execução de dez segundos, por causa disso UEs em um grupo não se afastavam o bastante para modificar os seus ganhos nos canais. Logo, é de interesse verificar como o aumento de velocidade dos UEs pode modificar o tempo otimizado para reexecutar o algoritmo DBSCAN.

Referências

- [1] Wei, Zhiqiang, Jinhong Yuan, Derrick Wing Kwan Ng, Maged ElKashlan e Zhiguo Ding: *A survey of downlink non-orthogonal multiple access for 5g wireless communication networks*. ArXiv, abs/1609.01856, 2016. viii, 2
- [2] Varga, András: *Screenshots*. <https://omnetpp.org/intro/screenshots>, acesso em 2023-06-16. viii, 14
- [3] ITU: *IMT Vision – Framework and overall objectives of the future development of IMT for 2020 and beyond*, 2015. 1
- [4] *Ericsson Mobility Report*, novembro 2022. <https://www.ericsson.com/en/reports-and-papers/mobility-report/reports/november-2022>, acesso em 2023-06-18. 1
- [5] Letaief, Khaled B., Wei Chen, Yuanming Shi, Jun Zhang e Ying Jun Angela Zhang: *The roadmap to 6g: Ai empowered wireless networks*. IEEE Communications Magazine, 57(8):84–90, 2019. 1
- [6] Maraqa, Omar, Aditya S. Rajasekaran, Saad Al-Ahmadi, Halim Yanikomeroglu e Sadiq M. Sait: *A survey of rate-optimal power domain noma with enabling technologies of future wireless networks*. IEEE Communications Surveys & Tutorials, 22(4):2192–2235, 2020. 1, 2
- [7] Vaezi, Mojtaba, Robert Schober, Zhiguo Ding e H. Vincent Poor: *Non-orthogonal multiple access: Common myths and critical questions*. IEEE Wireless Communications, 26(5):174–180, 2019. 1
- [8] Xiao, Ming, Shahid Mumtaz, Yongming Huang, Linglong Dai, Yonghui Li, Michail Matthaiou, George K. Karagiannidis, Emil Björnson, Kai Yang, Chih Lin I e Amitabha Ghosh: *Millimeter wave communications for future mobile networks*. IEEE Journal on Selected Areas in Communications, 35(9):1909–1935, 2017. 2
- [9] Wang, Shiguo, Youan Long, Rukhsana Ruby e Xuewen Fu: *Clustering and power optimization in mmwave massive mimo–noma systems*. Physical communication, 49:101469, 2021, ISSN 1874-4907. 2
- [10] Islam, S. M. Riazul, Nurilla Avazov, Octavia A. Dobre e Kyung sup Kwak: *Power-domain non-orthogonal multiple access (noma) in 5g systems: Potentials and challenges*. IEEE Communications Surveys & Tutorials, 19(2):721–742, 2017. 2

- [11] Di, Boya, Lingyang Song e Yonghui Li: *Sub-channel assignment, power allocation, and user scheduling for non-orthogonal multiple access networks*. IEEE Transactions on Wireless Communications, 15(11):7686–7698, 2016. 2
- [12] Simeone, Osvaldo: *A brief introduction to machine learning for engineers*. Foundations and Trends® in Signal Processing, 12(3-4):200–431, 2018, ISSN 1932-8346. <http://dx.doi.org/10.1561/2000000102>. 2
- [13] Cui, Jingjing, Zhiguo Ding, Pingzhi Fan e Naofal Al-Dhahir: *Unsupervised machine learning-based user clustering in millimeter-wave-noma systems*. IEEE Transactions on Wireless Communications, 17(11):7425–7440, 2018. 3, 4, 6, 9
- [14] Ren, Jie, Zulin Wang, Mai Xu, Fang Fang e Zhiguo Ding: *An em-based user clustering method in non-orthogonal multiple access*. IEEE Transactions on Communications, 67(12):8422–8434, 2019. 4, 6
- [15] Marasinghe, Dileepa, Nalin Jayaweera, Nandana Rajatheva e Matti Latva-Aho: *Hierarchical user clustering for mmwave-noma systems*. Em *2020 2nd 6G Wireless Summit (6G SUMMIT)*, páginas 1–5, 2020. 4, 6
- [16] Rajasekaran, Aditya S., Omar Maraqa, Hamza Umit Sokun, Halim Yanikomeroglu e Saad Al-Ahmadi: *User clustering in mmwave-noma systems with user decoding capability constraints for b5g networks*. IEEE Access, 8:209949–209963, 2020. 4, 6
- [17] Le, Quang Nhat, Van Dinh Nguyen, Octavia A. Dobre, Nam Phong Nguyen, Ruiqin Zhao e Symeon Chatzinotas: *Learning-assisted user clustering in cell-free massive mimo-noma networks*. IEEE Transactions on Vehicular Technology, 70(12):12872–12887, 2021. 5, 6
- [18] Kiani, Sharareh, Min Dong, Shahram ShahbazPanahi, Gary Boudreau e Majid Bavand: *Learning-based user clustering in noma-aided mimo networks with spatially correlated channels*. IEEE Transactions on Communications, 70(7):4807–4821, 2022. 5, 6
- [19] Zhang, Haijun, Haisen Zhang, Wei Liu, Keping Long, Jiangbo Dong e Victor C. M. Leung: *Energy efficient user clustering, hybrid precoding and power optimization in terahertz mimo-noma systems*. IEEE Journal on Selected Areas in Communications, 38(9):2074–2085, 2020. 5, 6
- [20] Ester, Martin, Hans Peter Kriegel, Jörg Sander e Xiaowei Xu: *A density-based algorithm for discovering clusters in large spatial databases with noise*. Em *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining, KDD'96*, página 226–231. AAAI Press, 1996. 7
- [21] Lee, Gilwon, Youngchul Sung e Junyeong Seo: *Randomly-directional beamforming in millimeter-wave multiuser miso downlink*. IEEE Transactions on Wireless Communications, 15(2):1086–1100, 2016. 9
- [22] Varga, Andras: *OMNeT++*, páginas 35–59. Springer Berlin Heidelberg, Berlin, Heidelberg, 2010, ISBN 978-3-642-12331-3. https://doi.org/10.1007/978-3-642-12331-3_3. 13

- [23] Varga, András: *Part 7 - Parameter Studies*. <https://docs.omnetpp.org/tutorials/tictoc/part7/>, acesso em 2023-06-17. 14
- [24] *INET Framework*. <https://inet.omnetpp.org/>, acesso em 2023-06-16. 14
- [25] Nardini, Giovanni, Dario Sabella, Giovanni Stea, Purvi Thakkar e Antonio Virdis: *Simu5g—an omnet++ library for end-to-end performance evaluation of 5g networks*. IEEE Access, 8:181176–181191, 2020. 15
- [26] *Beamforming and PMI reporting in Simu5G*. <https://github.com/Unipisa/Simu5G/issues/158>, acesso em 2023-06-16. 16