



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CAMPUS DE SOBRAL**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**  
**E DE COMPUTAÇÃO**

**WESKLEY VINICIUS FERNANDES MAURICIO**

**ALOCAÇÃO DE RECURSOS DE RÁDIO PARA MAXIMIZAÇÃO DA**  
**EFICIÊNCIA ESPECTRAL E EFICIÊNCIA ENERGÉTICA EM REDES**  
**MULTISSERVIÇOS COM RESTRIÇÕES DE QoS**

**SOBRAL**

**2017**

WESKLEY VINICIUS FERNANDES MAURICIO

ALOCAÇÃO DE RECURSOS DE RÁDIO PARA MAXIMIZAÇÃO DA EFICIÊNCIA ESPECTRAL E EFICIÊNCIA ENERGÉTICA EM REDES MULTISSERVIÇOS COM RESTRIÇÕES DE QoS

Tese ou Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica e de Computação do *Campus* de Sobral da Universidade Federal do Ceará, como parte dos requisitos necessários para a obtenção do título de Mestre em Engenharia Elétrica e de Computação. Área de concentração: Sistemas de Comunicação.

Orientador: Prof. Dr. Francisco Rafael Marques Lima.

SOBRAL

2017

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Biblioteca Universitária

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

- M414a Mauricio, Weskley.  
ALOCAÇÃO DE RECURSOS DE RÁDIO PARA MAXIMIZAÇÃO DA EFICIÊNCIA ESPECTRAL E EFICIÊNCIA ENERGÉTICA EM REDES MULTISSERVIÇOS COM RESTRIÇÕES DE QoS / Weskley Mauricio. – 2017.  
92 f. : il. color.
- Dissertação (mestrado) – Universidade Federal do Ceará, Campus de Sobral, Programa de Pós-Graduação em Engenharia Elétrica e de Computação, Sobral, 2017.  
Orientação: Prof. Dr. Francisco Rafael Marques Lima.
1. Alocação de Recursos de Rádio. 2. Eficiência Espectral. 3. Eficiência Energética. 4. Qualidade de Serviço. 5. Multisserviços. I. Título.

CDD 621.3

---

WESKLEY VINICIUS FERNANDES MAURICIO

ALOCAÇÃO DE RECURSOS DE RÁDIO PARA MAXIMIZAÇÃO DA EFICIÊNCIA ESPECTRAL E EFICIÊNCIA ENERGÉTICA EM REDES MULTISSERVIÇOS COM RESTRIÇÕES DE QoS

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica e de Computação da Universidade Federal do Ceará, *Campus* Sobral, como parte dos requisitos necessários para a obtenção do título de Mestre em Engenharia Elétrica e de Computação. Área de concentração: Sistemas de Comunicação.

Aprovada em: 26/01/2017.

BANCA EXAMINADORA

---

Prof. Dr. Francisco Rafael Marques Lima (Orientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Carlos Alexandre Rolim Fernandes  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Taufik Abrão  
Universidade Estadual de Londrina (UEL)

Aos meus pais, namorada e irmão.

## AGRADECIMENTOS

Primeiramente agradeço aos meus pais, Veralucia de Assis Fernandes e Pedro Mauricio da Silva, por me apoiarem nas realizações dos meus sonhos. Agradeço por todos seus ensinamentos e valores morais. Também agradeço ao meu irmão, Wesley Vannucci Fernandes Mauricio. Sou grato por todo amor incondicional de vocês.

A minha namorada, Gabriela Anastácio Leite, por todo o apoio, companheirismo, paciência em todos esses anos de namoro e essa fé inabalável em nós dois. Também agradeço a sua família, Adriana Cristina Anastácio Leite, Wanderley Almeida Leite, Iuri Anastácio Leite e Ismael Anastácio Leite. Sou grato por também serem minha família.

Ao Prof. Dr. Francisco Rafael Marques Lima, meu orientador. Meus agradecimentos por todo o suporte, incentivo, confiança, orientações tanto profissional quanto pessoal e as oportunidades que me deu. Agradeço por compartilhar conhecimento, pela ajuda e paciência que me permitiu concluir esta dissertação de mestrado.

Aos membros que aceitaram participar da banca dessa dissertação Prof. Dr. Taufik Abrao e Prof. Dr. Carlos Alexandre Rolim Fernandes.

Aos meus amigos de pós-graduação Laszlon Costa, Alexandre Matos e Allysson Alex, com quem compartilhei momentos de tensão e risadas.

A UFC, pelos professores com alto nível de capacitação e conhecimento. E por fim, agradeço a FUNCAP pelo suporte financeiro durante a produção deste trabalho.

A todos minha sincera gratidão.

“No fim tudo dá certo, e se não deu certo é porque ainda não chegou ao fim.” Fernando Sabino

## RESUMO

Nesta dissertação, primeiramente formulamos o problema de maximização da eficiência espectral para um sistema sem fio utilizando alocação de recursos de rádio na forma de blocos de recursos frequência e potência de transmissão sujeito a restrições de satisfação do usuário em cenários multisserviços. Mostramos que apesar deste problema de otimização ser não linear, ele pode ser convertido em um problema de programação linear. Deste modo, técnicas padrões podem ser usadas para obter a solução ótima. Motivado pela alta complexidade computacional da solução ótima, propomos um algoritmo subótimo com complexidade de pior caso polinomial. Resultados de simulação mostraram que nossa proposta alcança um desempenho próximo ao ótimo em cargas leves e moderadas com uma complexidade computacional muito menor comparada ao algoritmo utilizado para obter a solução ótima. Portanto, o algoritmo proposto para essa solução alcança uma boa troca entre desempenho e complexidade computacional. Também mostramos que a adição de alocação de potência adaptativa proporciona ganhos significantes de desempenho no cenário considerado.

Nesta dissertação de mestrado também formulamos diferentes problemas de eficiência energética para sistemas de comunicação sem fio através da alocação de blocos de recursos na frequência e potência de transmissão sujeito a restrições de satisfação do usuário em cenários multisserviços. Mais especificamente, formulamos os problemas PMEE (Problema de Maximização da Eficiência Energética), PMP (Problema de Minimização da Potência) e PMDTP (Problema de Maximização da Diferença entre Taxa e Potência). Mostramos que apesar destes problemas de otimização serem não lineares, o problema PMEE pode ser convertido em um problema MILP (do inglês, *Mixed Integer Linear Problem*), enquanto que os problemas PMP e PMDTP podem ser convertidos em problemas ILP (do inglês, *Integer Linear Problem*). Deste modo, técnicas padrões podem ser usadas para obter as soluções ótimas. Motivado pela alta complexidade computacional das soluções ótima, propomos um algoritmo subótimo para o problema PMEE com complexidade polinomial no pior caso. Resultados de simulação mostram que a solução PMEE apresenta-se como o melhor compromisso em relação a taxa de dados transmitida e economia de potência quando comparada às soluções PMP e PMDTP. Verificamos também que nossa proposta atinge um desempenho próximo ao da solução ótima do problema PMEE em cargas leves e moderadas porém com uma complexidade computacional muito menor. Portanto, o algoritmo proposto para essa solução alcança uma boa troca entre desempenho e complexidade computacional.

**Palavras-chave:** Alocação de Recursos de Rádio, Eficiência Espectral, Eficiência Energética, Qualidade de Serviço e Multisserviços.



## ABSTRACT

We formulate the frequency resource assignment and power assignment allocation of maximizing the spectral efficiency in a wireless system subject to user satisfaction constraints in the multiservice scenario. We show that although this optimization problem is nonlinear, it can be converted into an integer linear program. In this way, standard techniques can be used to obtain the optimal solution. Motivated by the high computational complexity of the optimal solution, we propose a suboptimal algorithm with polynomial complexity in the worst case. Simulation results show that our proposal achieves near-optimal performance in low and medium loads with a much lower computational complexity compared with the algorithm used to obtain the optimal solution. Therefore, our proposed algorithm achieves a good tradeoff between performance and computational complexity. We also show that the addition of adaptive power allocation renders significant performance gains in the considered scenario.

In this dissertation we also propose some energy efficiency problems to a wireless system using power and resource allocation subject to user satisfaction constraint. More specifically, we formulate the PMEE, PMP and PMDTP problems. We show that although those optimizations problems are non linear, the PMEE, problem can be converted to an MILP problem while PMP and PMDTP are converted to ILP problems. In this way, standard techniques can be used to obtain the optimal solution to these problems. Motivated by the high computational complexity of the optimal solution, we propose a suboptimal algorithm with polynomial complexity in the worst case. Simulation results show that PMEE presents the best trade-off transmitted data rate and power economy when compared to the PMP and PMDTP solutions. We also show that our proposal achieves near-optimal performance in low and medium loads with a much lower computational complexity compared with the algorithm used to obtain the optimal solution. Therefore, our proposed algorithm achieves a good tradeoff between performance and computational complexity.

**Keywords:** Radio Resource Allocation, Spectral Efficiency, Energy Efficiency, Quality of Service and Multiservice.

## LISTA DE FIGURAS

Figura 1 – Funcionamento da modulação OFDM [1]. . . . .	17
Figura 2 – Comportamento ILP : Taxa de <i>outage</i> versus taxa de dados requisitada para a solução original PMT e a solução PMT após a seleção dos melhores terminais $k_s$ . . . . .	38
Figura 3 – Primeira parte da solução subótima para o problema PMT. . . . .	40
Figura 4 – Segunda parte da solução subótima para o problema PMT. . . . .	41
Figura 5 – Taxa de <i>outage</i> versus taxa de dados requisitada para os algoritmos PMT OPT, RAP OPT e PROP com dois serviços ( $S = 2$ ). Assumimos os cenários 1 a 3 e avaliamos o impacto da variável $k_s$ . . . . .	45
Figura 6 – Taxa de <i>outage</i> versus taxa de dados requisitada para os algoritmos PMT, RAP OPT e PROP com três serviços ( $S = 3$ ). Cenários 4 a 6 e o impacto da variável $t_j$ . . . . .	46
Figura 7 – Taxa de <i>outage</i> versus taxa de dados requisitada para os algoritmos PMT, RAP OPT e PROP com quatro serviços ( $S = 4$ ). Assumimos os cenários 7 a 9 e avaliamos o impacto da variável $k_s$ . . . . .	47
Figura 8 – Taxa de <i>outage</i> versus taxa de dados requisitada para os algoritmos PMT OPT, RAP OPT e PROP com quatro serviços ( $S = 4$ ). Assumimos os cenários 8, 10 e 11, e avaliamos o impacto da variável $t_j$ . . . . .	47
Figura 9 – CDF da taxa de dados total para um requisito de taxa de dados específico no cenário 1 para os algoritmos PMT OPT, RAP OPT, e PROP com dois serviços ( $S = 2$ ). . . . .	48
Figura 10 – CDF da taxa de dados total para um requisito de taxa de dados específico para os algoritmos PMT OPT, RAP OPT, e PROP com três serviços ( $S = 3$ ). Assumindo os cenários 4 e 6 e avaliamos o impacto da variável $t_j$ . . . . .	49
Figura 11 – CDF da taxa de dados total para um requisito específico de taxa de dados para os algoritmos PMT OPT, RAP OPT, e PROP com quatro serviços ( $S = 4$ ). Assumimos os cenários 7 e 9 e avaliamos o impacto da variável $k_s$ . . . . .	49
Figura 12 – Comportamento MILP: CDF (do inglês, <i>Cumulative Distribution Function</i> ) da eficiência energética total para um requisito de taxa de dados específico considerando 4 usuários satisfeitos de 8 para os algoritmos PMEE original e PMEE após a seleção dos $k_s$ terminais com um único serviço ( $S = 1$ ). . . . .	62
Figura 13 – Comportamento MILP: CDF da eficiência energética total para um requisito de taxa de dados específico considerando 6 usuários satisfeitos de 8 para os algoritmos PMEE original e PMEE após a seleção dos $k_s$ terminais com um único serviço ( $S = 1$ ). . . . .	63

Figura 14 –Primeira parte da solução subótima para o problema PMEE. . . . .	65
Figura 15 –Segunda parte da solução subótima para o problema PMEE. . . . .	67
Figura 16 –Terceira parte da solução subótima para o problema PMEE. . . . .	68
Figura 17 –CDF da taxa de dados total para um requisito de taxa de dados específico no cenário 1 para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com dois serviços ( $S = 2$ ). . . . .	72
Figura 18 –CDF da taxa de dados total para um requisito de taxa de dados específico para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com três serviços ( $S = 3$ ). Assumindo os cenários 4 e 6 e avaliamos o impacto da variável $t_j$ . . . . .	72
Figura 19 –CDF da taxa de dados total para um requisito específico de taxa de dados para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com quatro serviços ( $S = 4$ ). Assumimos os cenários 7 e 9 e avaliamos o impacto da variável $k_s$ . . . . .	73
Figura 20 –Potência não utilizada versus taxa de dados requerida para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com dois serviços ( $S = 2$ ). Cenários 1 a 3 e o impacto da variável $k_s$ . . . . .	74
Figura 21 –Potência não utilizada versus taxa de dados requerida para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com três serviços ( $S = 3$ ). Cenários 4 a 6 e o impacto da variável $t_j$ . . . . .	76
Figura 22 –Potência não utilizada versus taxa de dados requerida para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com quatro serviços ( $S = 4$ ). Assumimos os cenários 7 a 9 e avaliamos o impacto da variável $k_s$ . . . . .	76
Figura 23 –Potência não utilizada versus taxa de dados requerida para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com quatro serviços ( $S = 4$ ). Assumimos os cenários 8, 10 e 11, e avaliamos o impacto da variável $t_j$ . . . . .	77
Figura 24 –CDF da eficiência energética para um requisito de taxa de dados específico no cenário 1 para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com dois serviços ( $S = 2$ ). . . . .	77
Figura 25 –CDF eficiência energética para um requisito de taxa de dados específico para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com três serviços ( $S = 3$ ). Assumindo os cenários 4 e 6 e avaliamos o impacto da variável $t_j$ . . . . .	78
Figura 26 –CDF da eficiência energética total para um requisito específico de taxa de dados para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com quatro serviços ( $S = 4$ ). Assumimos os cenários 7 e 9 e avaliamos o impacto da variável $k_s$ . . . . .	79

## LISTA DE TABELAS

Tabela 1 – Mapeamento geral entre SNR e taxa de dados transmitida por RB. . . .	28
Tabela 2 – Principais parâmetros de simulação. . . . .	43
Tabela 3 – Esquemas de codificação e modulação. . . . .	43
Tabela 4 – Parâmetros dos cenários considerados para simulações computacionais. .	44
Tabela 5 – Principais parâmetros de simulação. . . . .	69
Tabela 6 – Esquemas de modulação e codificação. . . . .	70
Tabela 7 – Parâmetros dos cenários considerados para simulações computacionais. .	71
Tabela 8 – Descrição dos parâmetros utilizados nos algoritmos. . . . .	89
Tabela 9 – Descrição dos parâmetros utilizados nos algoritmos. . . . .	92

## LISTA DE ABREVIATURAS E SIGLAS

<b>IoT</b>	do inglês, <i>Internet of Things</i>
<b>GEE</b>	do inglês, <i>Global Energy Efficiency</i>
<b>EE</b>	Eficiência Energética
<b>HH</b>	Hughes-Hartogs
<b>1G</b>	Primeira geração
<b>3GPP</b>	do inglês, <i>3<sup>rd</sup> Generation Partnership Project</i>
<b>4G</b>	Quarta Geração
<b>5G</b>	Quinta Geração
<b>AP</b>	do inglês, <i>Access Point</i>
<b>BB</b>	do inglês, <i>Branch and Bound</i>
<b>BC</b>	do inglês, <i>Branch and Cut</i>
<b>BLER</b>	do inglês, <i>Block Error Rate</i>
<b>ERB</b>	Estação Rádio Base
<b>CDF</b>	do inglês, <i>Cumulative Distribution Function</i>
<b>CQI</b>	do inglês, <i>Channel Quality Indicator</i>
<b>C-RAN</b>	do inglês, <i>Cloud - Radio Access Network</i>
<b>CSI</b>	do inglês, <i>Channel State Information</i>
<b>eICIC</b>	do inglês, <i>Enhanced ICIC</i>
<b>EPA</b>	do inglês, <i>Equal Power Allocation</i>
<b>ICIC</b>	do inglês, <i>Inter-cell Interference Coordination</i>
<b>ILP</b>	do inglês, <i>Integer Linear Problem</i>
<b>MILP</b>	do inglês, <i>Mixed Integer Linear Problem</i>
<b>ISI</b>	do inglês, <i>Inter Symbol Interference</i>
<b>PMT</b>	Problema de Maximização da Taxa
<b>PMP</b>	Problema de Minimização da Potência
<b>PMDTP</b>	Problema de Maximização da Diferença entre Taxa e Potência
<b>PMEE</b>	Problema de Maximização da Eficiência Energética
<b>LTE</b>	do inglês, <i>Long Term Evolution</i>
<b>MCS</b>	do inglês, <i>Modulation and Coding Scheme</i>
<b>OFDMA</b>	do inglês, <i>Orthogonal Frequency Division Multiple Access</i>
<b>OFDM</b>	do inglês, <i>Orthogonal Frequency Division Multiplexing</i>
<b>PRB</b>	do inglês, <i>Physical Resource Block</i>
<b>QoE</b>	Qualidade de Experiência
<b>QoS</b>	Qualidade de Serviço
<b>RB</b>	do inglês, <i>Resource Block</i>
<b>RRA</b>	do inglês, <i>Radio Resource Allocation</i>
<b>SNR</b>	do inglês, <i>Signal to Noise Ratio</i>

**TDMA** do inglês, *Time Division Multiple Access*  
**TTI** do inglês, *Transmission Time Interval*

## SUMÁRIO

1	INTRODUÇÃO . . . . .	16
1.1	Fundamentação . . . . .	17
1.1.1	Fundamentação OFDM e OFDMA . . . . .	17
1.1.2	<i>Resource Block</i> . . . . .	18
1.1.3	QoS . . . . .	18
1.1.4	Alocação de Recursos de Rádio . . . . .	18
1.2	Estado da Arte . . . . .	19
1.3	Objetivo da Dissertação e Contribuições . . . . .	23
1.3.1	Produções Científicas . . . . .	25
1.3.2	Organização da Dissertação . . . . .	25
2	MODELAGEM DO SISTEMA E PROBLEMAS ABORDADOS	26
2.1	Modelagem do Sistema . . . . .	26
2.2	Formulação do Problema PMT . . . . .	29
2.3	Formulação do Problema PMEE . . . . .	30
2.4	Formulação do Problema PMP . . . . .	31
2.5	Formulação do Problema PMDTP . . . . .	31
3	SOLUÇÃO ÓTIMA PARA PMT E HEURÍSTICA . . . . .	32
3.1	Solução Ótima . . . . .	32
3.2	Heurística . . . . .	36
3.2.1	Comportamento de Solução ILP: Seleção de Usuários . . . . .	36
3.2.2	Descrição do Algoritmo . . . . .	37
3.3	Resultados de Desempenho . . . . .	42
3.3.1	Parâmetros de Simulação . . . . .	42
3.3.2	Resultados . . . . .	44
4	SOLUÇÃO ÓTIMA PARA PROBLEMAS DE EFICIÊNCIA ENERGÉTICA E HEURÍSTICA . . . . .	50
4.1	Solução Ótima para o Problema PMEE . . . . .	50
4.2	Solução Ótima para o Problema PMP . . . . .	56
4.3	Solução Ótima para o Problema PMDTP . . . . .	58
4.4	Heurística . . . . .	60
4.4.1	Comportamento da Solução MILP: Seleção de Usuários . . . . .	60
4.4.2	Descrição do Algoritmo . . . . .	64
4.5	Resultados de Desempenho . . . . .	69
4.5.1	Parâmetros de Simulação . . . . .	69
4.5.2	Resultados . . . . .	71
5	CONCLUSÕES DA DISSERTAÇÃO . . . . .	79

REFERÊNCIAS . . . . .	81
APÊNDICE A – COMPLEXIDADE COMPUTACIONAL E PSEUDOCÓDIGO DOS ALGORITMOS DO CAPÍTULO 3 .	88
APÊNDICE B – COMPLEXIDADE COMPUTACIONAL E PSEUDOCÓDIGO DOS ALGORITMOS DO CAPÍTULO 4 .	91
APÊNDICE C – PSEUDOCÓDIGO DO ALGORITMO DE ALOCAÇÃO DE POTÊNCIA HH . . . . .	95



## 1 INTRODUÇÃO

As comunicações móveis vêm experimentando um incrível desenvolvimento ao longo de 30 anos, desde a 1G (Primeira geração) analógica dos sistemas celulares a implantação comercial das redes 4G (Quarta Geração) em diversos países. Atualmente, a rede de Quinta Geração 5G (Quinta Geração) é alvo de intensa pesquisa na área industrial e acadêmica [2]. Os principais agentes motivadores para desenvolvimento desta nova tecnologia consiste na busca por melhor QoS (Qualidade de Serviço), QoE (Qualidade de Experiência), menor latência, maiores taxas de transmissão de dados, novos serviços (multimídia), maior EE (Eficiência Energética) e evolução/massificação da tecnologia digital com novos dispositivos cada vez mais poderosos [3]. Hoje em dia, o tráfego de dados aumenta a uma taxa exponencial de acordo com a previsão da indústria e a novos dispositivos precisam ser conectados as redes móveis, compondo assim um cenário desafiador para a evolução das comunicações móveis.

Apesar de estudos sobre comunicações com EE terem sua origem há pelo menos duas décadas no contexto de teoria da informação, este campo de estudo tornou-se muito ativo na última década. Atualmente, com o projeto das redes 5G a previsão é de que existirão 100 vezes mais dispositivos conectados [4]. A principal razão para tal fato é devido a IoT (do inglês, *Internet of Things*) onde teremos carros, *drones*, dispositivos portáteis e vestimentas todos conectados entre si por uma rede celular [5]. Dessa forma, a futura rede 5G terá que apresentar um ganho substancial em capacidade em relação a geração atual de forma a servir de forma satisfatória todos esses dispositivos. Em [6] estima-se que as redes 5G terão que aumentar sua capacidade em 1.000 vezes, em relação a capacidade atual dos sistemas celulares. Dessa forma, a EE será um dos pilares da nova geração das redes 5G, pois o uso de cada vez mais energia para aumentar a capacidade do sistema levará a custos operacionais inaceitáveis. Outra motivação para maior EE é o cuidado com o meio ambiente visto que sistemas de tecnologia e informação são responsáveis por cerca de 5% da emissão global de dióxido de carbono [7], [8]. Atender as demandas da 5G com o atual quantidade de Watts por bits/s aumentaria drasticamente a emissão de dióxido de carbono desta indústria. Recentemente, o custo de energia e sua contribuição na emissão global de dióxido de carbono estão surgindo como grandes preocupações em diversas indústrias incluindo as comunicações móveis [9].

De forma a lidar com este cenário desafiador, avanços tecnológicos da arquitetura e das tecnologias de acesso de rádio devem ser capazes de suprir os requisitos das redes 5G. Destacamos RRA (do inglês, *Radio Resource Allocation*) como uma das características mais importante das redes móveis. Os algoritmos de RRA consistem em um conjunto de funcionalidades que são capazes de otimizar o desempenho das redes móveis. Utilizamos os algoritmos de RRA para gerenciar os escassos recursos de rádio tais como potência, *slots* de tempo, canais espaciais e faixas de frequência. Estas funcionalidades

têm sido utilizadas com sucesso para otimizar as redes móveis em termos de eficiência espectral, satisfação de QoS e aumento da capacidade [10].

## 1.1 Fundamentação

Nas seções seguintes serão introduzidos o esquema de multiplexação OFDM (do inglês, *Orthogonal Frequency Division Multiplexing*) e múltiplo acesso OFDMA (do inglês, *Orthogonal Frequency Division Multiple Access*), QoS e RRA.

### 1.1.1 Fundamentação OFDM e OFDMA

OFDM é uma técnica de modulação de dados que tem como princípio a multiplexação por divisão de frequência, ou seja, é uma transmissão de dados realizada através da divisão da banda de frequência em múltiplas portadoras ortogonais (chamadas subportadoras) para modulação. Como as subportadoras são ortogonais, não há ISI (do inglês, *Inter Symbol Interference*). OFDMA é um esquema de múltiplo acesso baseado em OFDM [11].

OFDM faz uma conversão da taxa de dados total em taxas de dados muito menores em cada subcanal. Dessa forma a largura de banda de cada subcanal é muito menor que a largura de banda do sistema total. Assim, através da utilização de subportadoras o OFDM é capaz de transformar um canal de banda larga seletivo em frequência em vários subcanais planos de banda estreita [12]. Uma representação da modulação OFDM pode ser visto na Figura 1.1.




Figura 1: Funcionamento da modulação OFDM [1].

As principais vantagens da técnica OFDM comparada com outras técnicas que fazem uso de uma única portadora são: OFDM consegue obter uma mesma taxa de transferência, OFDM possui maior resistência às más condições do meio, OFDM possui resistência à ISI, OFDM possui resistência a interferências causadas por múltiplos percursos.

### 1.1.2 *Resource Block*

O bloco de recursos é o elemento básico para a alocação de recursos de rádio. O tamanho mínimo do recurso de rádio que pode ser alocado é o TTI mínimo no domínio do tempo, ou seja, um subframe. O tamanho de cada bloco de recursos é o mesmo para todas as largura de banda. Existem dois tipos de blocos de recursos definidos para LTE: blocos de recursos físicos e virtuais, que são definidos para diferentes esquemas de alocação de recursos. Nesta dissertação trabalharemos apenas com os blocos de recursos físicos ou PRBs (do inglês, *Physical Resource Blocks*).

### 1.1.3 QoS

Diferente das redes cabeadas, em redes móveis o operador do sistema tem que lidar com recursos limitados como largura de banda e potência, e a natureza imprevisível das comunicações sem fio. Todos estes fatores levam os operadores de rede móvel a empregar parâmetros de controle que impactam em como o serviço é recebido. Os parâmetros de QoS mais comum são:

- Taxa de dados - Velocidade da transferência de dados em uma rede.
- *Jitter* (ou variação de atraso) - Ocorre devido à variação na sequência e no tempo de entrega das informações devido à variação no atraso da rede.
- Vazão - Consiste na quantidade de informação real que é transmitida pelo transmissor que chega ao receptor.
- Latência ou atraso - Consiste na duração do tempo desde a geração da informação pelo transmissor até o seu recebimento no receptor.

Esses quatro fatores formam parâmetros de referência mínima que os sistemas podem utilizar como forma de gerenciamento de QoS. Do ponto de vista do operador é importante servir diferentes serviços com uma qualidade sustentável. Portanto, podemos adotar uma estratégia de gerenciamento de QoS quando quisermos garantir que um conjunto de usuários tenha um desempenho mínimo e satisfatório para atender os requisitos pré-determinados de cada tipo de serviço de telecomunicações. Dessa forma, consideraremos que um dado serviço é servido com qualidade aceitável se conseguirmos satisfazer uma porcentagem mínima dos seus usuários. Como esse desempenho mínimo é definido por cada serviço, os operadores do sistema podem estabelecer uma prioridade hierárquica entre os serviços oferecidos [13]. Nesta dissertação consideraremos que cada serviço deve satisfazer uma quantidade mínima de usuários cada um com uma taxa de dados mínima.

### 1.1.4 Alocação de Recursos de Rádio

A funcionalidade da rede responsável por alocar os recursos de rádio disponíveis entre os usuários do sistema é chamada de RRA. Nos sistemas, celulares podemos

citar como recurso de rádio a largura de banda de frequência, potência de transmissão, *time slots*, entre outros. Esses recursos são escassos e limitam a capacidade do sistema se não forem gerenciados de forma correta.

Além das restrições impostas aos recursos, também temos diferentes objetivos de otimização de desempenho das redes. Como será apresentado na Seção 1.2, podemos citar como exemplo a melhora na eficiência espectral, minimização da potência, maximização da eficiência energética ou assegurar um desempenho mínimo entre os usuários conectados.

O uso de certas informações presentes nas redes sem fio podem tornar as soluções de RRA mais eficazes no alcance dos seus objetivos. Ganhos podem ser obtidos caso exploremos a natureza aleatória da comunicação sem fio. Podemos explorar ganhos de diversidade através da seletividade em frequência. Conhecer o estado do canal de comunicações é de bastante importância para a resolução dos problemas em sistemas celulares. Nesse trabalho abstraímos esse processo e consideramos que o transmissor e o receptor têm total conhecimento do canal de comunicação.

## 1.2 Estado da Arte

Em geral, problemas de RRA têm sido estudados na literatura em forma de problemas de otimização. Um problema de otimização é composto de uma função objetivo, restrições e variáveis de decisão [10, 14, 15]. Como exemplos de funções objetivo em comunicações sem fio podemos mencionar os problemas de maximização da taxa total de dados, o de minimização da potência transmitida e o de maximização da EE. As restrições dos problemas são principalmente usadas para modelar as limitações dos sistemas práticos devido aos problemas da escassez dos recursos de rádio e, também, dos problemas de QoS<sup>1</sup>. Variáveis de decisão são usadas para modelar as alocações de recurso de rádio, tais como recursos de frequência (PRBs, por exemplo) e potência de transmissão.

Em conexões ponto a ponto, o objetivo mais importante é a otimização da potência de transmissão. Uma solução conhecida para alocação de potência chamada de *Water Filling* é capaz de fazer alocação ótima de potência para o problema de maximização da capacidade (relação logarítmica entre qualidade de canal e taxa de dados) em um sistema ponto-a-ponto. Basicamente, a solução *Water Filling* pode ser obtida através de análise de otimização convexa e possui como ideia principal alocar mais potência de transmissão para recursos de frequência com melhor ganho de canal, isto é, aquele que pode usar a potência da forma mais eficiente [16]. Uma limitação da solução *Water Filling* é que ela se baseia em um mapeamento logarítmico e contínuo entre qualidade

---

<sup>1</sup>Problemas de QoS são problemas que buscam definir a configuração de transmissão dos recursos de rádio (alocação de recursos) de forma a garantir que um serviço de dados adequado possa ser prestado pela operadora do sistema. Métricas de QoS podem ser definidas em termos dos parâmetros definidos na seção 1.2.2.

de canal e taxa de dados transmitida. Em sistemas móveis práticos, são usados esquemas de modulação e codificação ou do inglês, MCS (do inglês, *Modulation and Coding Scheme*) discretos e, portanto, as taxas de dados transmitidas e níveis de potência utilizados assumem níveis discretos. Em conexões ponto a ponto, foi mostrado que o algoritmo de carregamento de bits ou *bit loading* chamado Hugues-Hartogs é ótimo quando níveis discretos de transmissão são usados [17].

Em conexões ponto-multiponto tais como as do enlace direto de sistemas celulares, não apenas a alocação de potência transmitida é importante mas também a atribuição de recursos de frequência. A alocação ótima de recursos de rádio neste caso pode ser muito difícil de ser obtida. A dificuldade aumenta quando funções não convexas estão presentes no objetivo ou nas restrições dos problemas de otimização. Nesses casos, uma das formas de obter a solução ótima é usar algoritmos de “força bruta” ou métodos de enumeração completa que consistem em listar sequencialmente todas as possíveis soluções, avaliar sua contribuição para o objetivo e finalmente escolher a melhor de todas. O espaço de procura desses problemas em geral aumenta exponencialmente com o tamanho da entrada do problema. Portanto, o método de “força bruta” não é passível de ser utilizado em casos práticos.

Muitos trabalhos têm abordado RRA para rede OFDMA ponto-multiponto com diferentes objetivos: maximização da taxa total de dados sem restrições [18], *margin adaptive* ou minimização de potência [19, 20], *adaptive rate* ou justiça aprimorada [21, 22], entre outros. Focando em garantias de QoS, destacamos o problema de maximização da taxa total de dados restrita a garantia mínima de taxa de dados (MaxRate-MinReq). Um dos primeiros trabalhos a abordar esse problema foi [23]. Basicamente, os autores dividem o problema original em dois subproblemas: *resource allocation* e *resource assignment*. A parte *resource allocation* determina a quantidade de recursos de frequência e potência para cada terminal enquanto que em *resource assignment* a apropriada atribuição de subportadoras e *bit loading* é realizado baseado nos requisitos e ganhos de canais dos terminais. Contudo, nos resultados de simulações apresentadas em [23] os autores não comparam a sua solução proposta com a solução ótima. Em [24] os autores são capazes de obter a solução ótima baseada em técnicas de ILP assumindo EPA (do inglês, *Equal Power Allocation*) em todos os recursos de frequência. Como as técnicas ILP têm complexidade computacional exponencial no pior caso, os autores propõem uma solução subótima de baixa complexidade para o problema. A solução subótima primeiramente atribui as subportadoras aos terminais que possuem melhor qualidade de canal (alocação de taxa máxima), e então trocam as subportadoras entre os terminais de forma a cumprir os requisitos de taxa de dados (realocação). Embora a solução ótima com EPA seja apresentada em [24], os autores não comparam a taxa de *outage*<sup>2</sup> entre as soluções

---

<sup>2</sup>*outage* é definido como um evento em que o algoritmo não é capaz de encontrar uma solução factível para o problema de otimização, ou seja, uma solução que não é capaz de satisfazer as restrições do

ótima e subótima. Uma melhoria na eficiência espectral sobre a solução subótima de [24] é apresentado por [25]. Modificando a parte de realocação de subportadoras da solução proposta em [24], os autores em [26] são capazes de obter um ganho em taxa de *outage* em comparação com [24].

Em [27] os autores estudam o problema MaxRate-MinReq e fornecem uma aproximação subótima, onde primeiramente assinalam subportadoras dando prioridades aos terminais que precisam de mais potência para alcançar o requisito de taxa mínima. Após assinalar todas as subportadoras, a potência restante é alocada de forma a maximizar a capacidade OFDMA. A limitação de [27] ocorre devido ao uso do mapeamento contínuo entre taxa de dados e SNR (do inglês, *Signal to Noise Ratio*). Em [28] os autores assumem mapeamento discreto entre taxa de dados e SNR fornecendo uma solução para o problema *dual*. Os autores afirmam que embora o problema original não seja convexo, a distância de dualidade tende a zero à medida que o número de subportadoras aumenta. Contudo, em sistemas reais, a quantidade mínima de recursos alocáveis é um grupo de subportadoras, ao invés de subportadoras individuais, desta forma diminuindo a validade dessa hipótese. Apesar dos esforços dos autores em diminuir a complexidade geral usando métodos subgradiente para encontrar os multiplicadores de Lagrange, a complexidade computacional continua alta.

Os autores em [29, 30] propuseram soluções para o problema MaxRate-MinReq baseado em meta heurísticas enquanto [31] apresenta uma solução exata. Em [29] os autores definem a alocação de MCS baseado em Busca Tabu. Contudo, a solução proposta não é comparada com a solução ótima e nenhum resultado de *outage* é fornecido. Em [30], otimização por Enxame de Partículas é usado de forma a realizar alocação de subportadoras e potência. No entanto, o problema é simplificado assumindo mapeamento contínuo entre SNR e taxa de dados transmitida. Uma solução exata para esse problema é fornecida em [31], obtida através da transformação de um problema Misto Não-Linear e Inteiro em um problema MILP. Apesar disso, a complexidade computacional do algoritmo proposto é alta para uso em redes práticas onde decisões de alocação de recursos devem ser tomadas na ordem de milissegundos.

Algumas variantes do problema MaxRate-MinReq têm aparecido em contextos diferentes. Em [32] os autores estudam um problema de otimização para garantir a taxa de dados mínima requisitadas pelos usuários, porém com restrição de justiça<sup>3</sup>. Em [33] os autores estudam o problema MaxRate-MinReq no enlace reverso do LTE (do inglês, *Long Term Evolution*) onde diferentes condições do enlace direto devem ser asseguradas. Em [34], ao invés de garantir ao menos uma taxa mínima para todos os usuários, os autores propõem um problema de RRA onde as taxas de dados dos usuários devem estar contidas

---

problema.

<sup>3</sup>Métricas de justiça são usadas com o intuito de determinar se os usuários estão recebendo uma parcela justa dos recursos do sistema.

em um intervalo máximo e mínimo. Mapeamento contínuo de SNR e taxa de dados é considerado em [33].

Em [35], os autores generalizam o problema MaxRate-MinReq estudando um novo problema de RRA de maximização da taxa de dados total sujeita restrições de satisfação mínima por serviço. Basicamente, neste problemas assumimos que os operadores do sistema exigem que uma certa fração dos terminais conectados de cada serviço devem ser satisfeitos de acordo com o QoS alvo. Nenhum dos trabalhos anteriores havia abordado o cenário multisserviço com garantias de satisfação e QoS.

Existem técnicas capazes de aumentar a EE, tais como alocação de recursos de rádio, planejamento e desenvolvimento de redes, e coleta e transferência de energia [5]. Em relação a RRA, a EE tem provocado uma mudança no antigo paradigma da busca pela maximização da eficiência espectral. Este novo problema precisa de novas ferramentas matemáticas direcionadas a problemas de EE [36]. O planejamento e desenvolvimento de redes é feito através de mudanças da infraestrutura para maximizar a área de cobertura por energia consumida, ao invés de apenas a área de cobertura. Podemos também utilizar esta técnica para reduzir o consumo de energia através de algoritmos *switch-on/switch-off* para ERB (Estação Rádio Base) [37]. A coleta e transferência de energia, como o próprio nome diz, funciona através da coleta de energia do ambiente, e transformando-as em energia elétrica para utilização (instantânea ou não). Esta técnica é considerada uma forma indireta para a redução da energia, visto que é capaz de energizar nossos dispositivos através de fontes limpas e renováveis de energia [38]. As técnicas de RRA surgem como um indicador de desempenho para as redes 5G realizando uma troca entre taxa de dados e energia consumida, a maioria dos ganhos em EE são obtidos por meio da perda de eficiência espectral [39]. Nesta dissertação estaremos focados nos problemas de RRA.

Retirando o foco da maximização da eficiência espectral, um dos primeiros esforços em direção ao uso mais eficiente da energia em sistemas sem fio consistiu na formulação do problema de minimização da potência total transmitida sujeita a restrições de QoS presente no trabalho seminal de Wong et al. [19]. Estudos mais recentes em EE consideram outras métricas dependendo do sistema empregado e suas características [9]. Em cenários urbanos, em que o tráfego de dados é considerável, a métrica mais adequada de EE consiste na razão entre a taxa de dados oferecida em bits por segundos pela potência de transmissão média consumida. A otimização das redes sem fio seguindo esse critério pode possibilitar ganhos de capacidade com aumento do consumo de potência marginal ajudando a viabilização do 5G [6]. Como foi dito anteriormente, espera-se aumentar a capacidade do sistema em 1.000 vezes, porém devemos manter o consumo de energia das redes sem fio semelhante ao atual [40]. Portanto, a EE deve aumentar em um fator de 1.000 ou mais, ou seja, a eficiência com que cada Joule de energia deve ser usado precisa aumentar por um fator de 1.000 ou mais.

Quando falamos de EE podemos considerar duas principais formas para obter ganho de desempenho em redes sem fio: taxa de custo benefício das redes e redes com multiobjetivos [5]. A primeira, taxa de custo benefício das redes, é dada pela razão entre a soma da taxa de dados de cada usuário (individualmente), e a soma da potência total utilizada pela rede. Esta métrica tem forte significado físico e é conhecida como GEE (do inglês, *Global Energy Efficiency*). Alguns estudos tem sido feitos utilizando esta métrica em redes OFDMA como em [41], [42] e [43]. A ideia principal da métrica de redes com multiobjetivos é de podermos escolher maximizar a EE de todos os usuários ou apenas parte deles [5]. Independente das métricas utilizadas para contabilizar EE, restrições de QoS que assegurem um provimento adequado dos serviços multimídia devem ser também consideradas. Em [44] e [45] é estudado o problema de eficiência energética usando a métrica GEE com requisitos de QoS. Em [46] é estudado o problema de eficiência energética utilizando a métrica de multiobjetivos com requisitos de QoS. Observe que nenhum dos trabalhos de EE apresentados até agora, nesta seção, tem abordado cenário de multisserviço com garantias de satisfação.

Dependendo das métricas utilizadas e dos recursos de rádio a serem otimizados, os problemas de RRA possuem diferentes graus de complexidade. Por exemplo, a otimização da potência de transmissão quando considerada adaptação de enlace baseada em curvas contínuas entre taxa de transmissão e SNR (curva da capacidade de Shannon, por exemplo) podem ser resolvidas através da teoria de otimização convexa. Contudo, quando assumimos níveis discretos de transmissão assim como em sistemas práticos, podemos ter problemas de otimização combinatoriais não lineares.

Em [35] os autores consideram apenas alocação de recursos de frequência e assumem que a potência transmitida foi igualmente distribuída entre os recursos de frequência. Nesta dissertação, estendemos o problema de [35] para avaliar os possíveis ganhos de desempenho que podem ser alcançados através da otimização conjunta da alocação de recursos de frequência e potência. Além disso, também nesta dissertação, modificamos a função objetivo do problema de [35] de forma a obtermos variantes de problemas relacionados a EE.

### 1.3 Objetivo da Dissertação e Contribuições

O principal objetivo deste trabalho é contribuir com o estudo de alocação de potência e eficiência energética para a próxima geração de comunicação móvel. Dessa forma, as principais contribuições deste trabalho são:

- Formulação matemática do problema de alocação conjunta de recursos de frequência e potência. A formulação restringe o espaço de solução para atender requisitos de QoS, em termos de taxa de dados, e número de usuários satisfeitos em cada serviço;
- Reformulação do problema original de maximização de taxa pertencente a classe



dos problemas não-lineares e inteiros para à classe de problemas ILP, que podem ser resolvidos de forma ótima por técnicas padrões;

- Avaliação de possíveis ganhos em desempenho que podem ser obtidos quando alocação de potência adaptativa é adicionada ao problema proposto por [35];
- Proposta de uma solução eficiente e de baixa complexidade para o problema de alocação de potência adaptativa;
- Formulação matemática do problema de minimização da potência transmitida. A formulação utiliza alocação conjunta de recursos de frequência e potência e restringe o espaço de solução para atender requisitos de QoS, em termos de taxa de dados, e número de usuários satisfeitos em cada serviço;
- Reformulação do problema original de minimização de potência transmitida pertencente a classe dos problemas não-lineares e inteiros para à classe de problemas ILP, que podem ser resolvidos de forma ótima por técnicas padrões;
- Formulação matemática do problema de maximização de taxa de dados minimizando a potência transmitida. A formulação restringe o espaço de solução para atender requisitos de QoS, em termos de taxa de dados, e número de usuários satisfeitos em cada serviço;
- Reformulação do problema original de maximização da taxa de dados minimizando a potência transmitida pertencente a classe dos problemas não-lineares e inteiros para à classe de problemas ILP, que podem ser resolvidos de forma ótima por técnicas padrões;
- Formulação matemática do problema de maximização da eficiência energética. A formulação utiliza alocação conjunta de recursos de frequência e potência e restringe o espaço de solução para atender requisitos de QoS, em termos de taxa de dados, e número de usuários satisfeitos em cada serviço;
- Reformulação do problema original de eficiência energética pertencente a classe dos problemas não-lineares e inteiros para à classe de problemas MILP, que podem ser resolvidos de forma ótima por técnicas padrões;
- Avaliação de possíveis ganhos que podem ser obtidos principalmente em termos de economia de potência quando propomos a maximização da eficiência energética;
- Proposta de uma solução eficiente e de baixa complexidade para o problema de maximização da eficiência energética;
- Reformulação dos problemas de otimização propostos para uma forma matricial compacta para uso em softwares comerciais.
- Calculo da complexidade computacional dos algoritmos e suas avaliações de desempenho através de simulações computacionais.

### 1.3.1 Produções Científicas

O conteúdo técnico desta dissertação foi aceito e publicado nos seguintes congressos e jornais:

**MAURICIO, W. V. F.;** LIMA, F. RAFAEL M. ; MACIEL, TARCISIO F. ; CAVALCANTI, F. RODRIGO P. . Alocação de Potência Adaptativa para Maximização da Eficiência Espectral Sujeita a Restrições de Satisfação. In: Simpósio Brasileiro de Telecomunicações, 2015, Juiz de Fora. Alocação de Potência Adaptativa para Maximização da Eficiência Espectral Sujeita a Restrições de Satisfação, 2015.

**MAURICIO, W. V. F.;** LIMA, FRANCISCO RAFAEL MARQUES ; MACIEL, TARCISIO F. ; CAVALCANTI, F. R. P. . Alocação de Recursos para Maximização da EE Sujeita à Restrições de Satisfação. In: Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBrT 2016), 2016, Santarém - PA. Anais do XXXIV Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBrT 2016), 2016.

**MAURÍCIO, WESKLEY VINICIUS FERNANDES;** LIMA, FRANCISCO RAFAEL MARQUES ; SOUSA, DIEGO AGUIAR ; MACIEL, TARCÍSIO FERREIRA ; CAVALCANTI, FRANCISCO RODRIGO PORTO . Joint Resource Block Assignment and Power Allocation Problem for Rate Maximization With QoS Guarantees in Multiservice Wireless. Journal of Communication and Information Systems (Online), v. 31, p. 211-223, 2016, doi: 10.14209/jcis.2016.19.

### 1.3.2 Organização da Dissertação

Essa dissertação é organizada como descrito a seguir. No Capítulo 2 é apresentada a modelagem do sistema e as formulações dos problemas estudados nesta dissertação. Mais especificamente o capítulo descreve os principais aspectos do sistema como o critério de QoS adotado e explicações sobre a interface entre enlace e simulação sistêmica. Por último ela descreve as formulações dos problemas PMT (Problema de Maximização da Taxa), PMEE, PMP e PMDTP.

O Capítulo 3 é responsável pela solução ótima do problema PMT, uma solução de baixa complexidade e os resultados de desempenho. Mais especificamente, na Seção 3.1, usaremos de técnicas matemáticas para tornarmos o problema formulado capaz de ser resolvido de forma ótima por técnicas computacionais conhecidas na literatura. Nestas seções também é feita uma transformação, com o intuito de compactação, para uma forma matricial. Apresentaremos uma simplificação da solução ótima do PMT e a heurística do problema PMT na Seção 3.2. Por fim, na Seção 3.3 apresentaremos considerações para as simulações computacionais e as análises de resultados os algoritmos propostos, neste capítulo.

O Capítulo 4 é responsável pelas soluções ótimas dos problemas PMEE, PMP e PMDTP, uma solução de baixa complexidade para o problema PMEE e os resultados de desempenho. Mais especificamente nas Seções 4.1, 4.2 e 4.3 usaremos de técnicas matemáticas para tornarmos o problema formulado capaz de ser resolvido de forma ótima por técnicas computacionais conhecidas na literatura. Nestas seções também é feita uma transformação, com o intuito de compactação, para uma forma matricial. Apresentaremos uma simplificação da solução ótima do PMEE e a heurística do problema PMEE na Seção 4.4. Por fim, na Seção 4.5 apresentaremos considerações para as simulações computacionais e as análises de resultados os algoritmos propostos, neste capítulo.

No Capítulo 5, as principais conclusões obtidas ao longo desta dissertação de mestrado são apresentadas. Alguns direcionamentos para a continuidade da pesquisa no contexto deste trabalho são propostos. Finalmente, nos apêndices A e B são apresentados os pseudocódigos das soluções subótimas propostas e a complexidade computacional das soluções ótimas e subótimas.

## 2 MODELAGEM DO SISTEMA E PROBLEMAS ABORDADOS

Este capítulo aborda os principais aspectos do sistema e os problemas de otimização estudados nesta dissertação. A Seção 2.1 aborda a modelagem do sistema em seus aspectos gerais e específicos. A formulação do problema de maximização de taxa de dados sujeito a restrições de satisfação com alocação de potência adaptativa é demonstrado na Seção 2.2. Nas Seções 2.3, 2.4 e 2.5 são formulados três problemas de eficiência energética. O primeiro busca maximizar a eficiência energética, o segundo minimizar a potência de transmissão e o terceiro maximizar a diferença entre taxa de dados transmitida e a potência total consumida.

### 2.1 Modelagem do Sistema

Consideremos um sistema celular no modo *downlink* composto de um número fixo de células setorizadas. Para um dado setor de uma célula, existe um grupo de terminais conectados a uma estação base. O sistema combina OFDMA e TDMA (do inglês, *Time Division Multiple Access*), seus recursos disponíveis são arranjados em uma grade de recursos tempo-frequência. Denotamos RB (do inglês, *Resource Block*) como o mínimo recurso alocável que é definido como um grupo de 12 subportadoras adjacentes e 7 símbolos OFDM consecutivos no domínio do tempo, que representa um TTI (do inglês, *Transmission Time Interval*). Os terminais de um setor podem ser simultaneamente servidos pela atribuição de diferentes RBs ortogonais em relação a tempo-frequência e, dessa forma, não existirá interferência intracelular (entre os terminais do mesmo setor). É importante mencionar que esta análise feita neste estudo é também válida para outros

esquemas sem fio de múltiplo acesso capazes de assegurar a não existência de interferência intracelular.

Assumiremos a hipótese simplificadora que a interferência intercelular é adicionada ao ruído térmico na expressão da SNR. Destacamos que essa suposição torna-se cada vez mais válida à medida que a carga do setor e o número de estações base no sistema aumenta [47]. Basicamente, como o número de fontes interferentes aumentam, o teorema do limite central pode ser aplicado. Obviamente, nossa aproximação de única célula pode ser diretamente aplicada em cenários multicelulares onde a interferência intercelular pode ser predita com confiança aceitável. Contudo, espera-se uma maior complexidade devido ao aumento de escala do problema. Como a interferência pode ser estimada, as taxas de dados também podem ser estimadas antes da alocação de recurso. Portanto, a alocação de recursos em cada setor de sistemas multicelulares podem ser resolvido como problemas de alocação de recursos com células única. Neste caso, estaríamos assumindo sistemas totalmente centralizados onde os nós transmissores, por exemplo, ERB ou AP (do inglês, *Access Point*), são conectados através de *links* com alta velocidade e decisões de RRA são tomadas no nó central. Redes centralizadas são um dos pontos dos conceitos modernos 5G's C-RAN (do inglês, *Cloud - Radio Access Network*) [48].

Nossa aproximação de célula única é também um modelo válido para 3GPP (do inglês, *3<sup>rd</sup> Generation Partnership Project*) em que esquemas de coordenação de interferência tais como ICIC (do inglês, *Intercell Interference Coordination*) (Release 8) [49] e eICIC (do inglês, *Enhanced ICIC*) (Release 10) [50, 51] podem ser aplicadas no topo das estratégias de alocação de recursos de forma a mitigar os efeitos da interferência. Uma das estratégias mais simples é o de bloquear alguns dos RBs disponíveis nas células de modo a evitar o reuso de RBs em células vizinhas ao mesmo tempo. Observe que as soluções propostas nesta dissertação podem ser aplicadas nestes casos apenas redefinindo os RBs disponíveis em cada setor.

Em um dado TTI,  $J$  terminais ativos são candidatos a receber RBs. Assumimos que existem  $N$  RBs disponíveis. Além disso,  $\mathcal{J}$  e  $\mathcal{N}$  são os conjuntos de terminais ativos e RBs disponíveis, respectivamente. Como estamos assumindo um cenário multiserviço iremos considerar que o número de serviços providos pelo operador do sistema é  $S$  e que  $\mathcal{S}$  é o conjunto de todos os serviços. Consideramos que o conjunto de terminais que utilizam o serviço  $s \in \mathcal{S}$  é  $\mathcal{J}_s$  e que  $|\mathcal{J}_s| = J_s$ , em que  $|\cdot|$  indica a cardinalidade de um conjunto neste contexto. Quando este operador é usado em um escalar ele indica o valor absoluto. Observe que  $\bigcup_{s \in \mathcal{S}} \mathcal{J}_s = \mathcal{J}$ ,  $\sum_{s \in \mathcal{S}} J_s = J$  e os conjuntos  $\mathcal{J}_s \forall s$  são mutuamente exclusivos e exaustivos.

Definimos  $\mathbf{X}$  como uma matriz  $J \times N$  de atribuição com elementos  $x_{j,n}$  que assume o valor 1 se o RB  $n \in \mathcal{N}$  é atribuído ao terminal  $j \in \mathcal{J}$  e 0 de outra forma. Como iremos mostrar na Seção 2.2, algumas restrições devem ser impostas na matriz de forma a assegurar que não haverá interferência intracelular. Assumindo que o RB  $n$  é atribuído

Tabela 1: Mapeamento geral entre SNR e taxa de dados transmitida por RB.

Região de SNR	Taxa de dados transmitida por RB
$\gamma_{j,n} < \gamma^1$	0
$\gamma^1 \leq \gamma_{j,n} < \gamma^2$	$v^1$
$\gamma^2 \leq \gamma_{j,n} < \gamma^3$	$v^2$
$\vdots$	$\vdots$
$\gamma^{M-1} \leq \gamma_{j,n} < \gamma^M$	$v^{M-1}$
$\gamma_{j,n} \geq \gamma^M$	$v^M$

ao terminal  $j$ , a SNR recebida  $\gamma_{j,n}$  do terminal  $j$  no RB  $n$  é dada por

$$\gamma_{j,n} = \frac{\alpha_j p_n |h_{j,n}|^2}{\sigma_j^2} = p_n \cdot \eta_{j,n}, \quad (1)$$

onde  $\alpha_j$  modela o efeito conjunto da perda de percurso e desvanecimento de longo prazo experimentado no *link* entre a ERB e o terminal  $j$ ,  $h_{j,n}$  é a resposta em frequência de curto prazo do canal experimentado pelo terminal  $j$  no RB  $n$ ,  $\sigma_j^2$  é a potência do ruído no terminal  $j$  no RB  $n$ , e por fim  $p_n$  é a potência transmitida alocada ao RB  $n$ . Assumimos que  $\mathbf{p}$  é um vetor com dimensão  $N \times 1$  composto pelos elementos  $p_n$ . Assumimos também que  $P^{\text{tot}}$  é a potência total disponível na ERB.

Através do uso de mecanismo de adaptação de enlace, um terminal pode transmitir utilizando taxas de dados diferentes de acordo com seu estado do canal, potência alocada e ruído/interferência percebida. Assumimos que o mapeamento entre a SNR alcançada e a taxa de dados transmitida é realizada através da função  $f(\cdot)$ . Consideramos que MCSs discretas são empregadas como em redes sem fio práticas. A taxa de dados transmitida quando o RB  $n$  é atribuído ao terminal  $j$ ,  $r_{j,n}$ , é dada por:

$$r_{j,n} = f(\gamma_{j,n}) = f(p_n \cdot \eta_{j,n}). \quad (2)$$

Sem perda de generalidade, assumimos uma adaptação de enlace baseada em uma BLER (do inglês, *Block Error Rate*) para uma dada SNR, o nível de MCS escolhido é aquele que possui maior taxa de transmissão que garante uma BLER estimada menor que a BLER fixa alvo. Portanto, dependendo do intervalo de SNR diferentes taxas de dados podem ser alcançadas. Isto é mostrado na Tabela 1.

De acordo com a Tabela 1, assumimos que existem  $M$  possíveis níveis de MCSs para transmitir e, portanto,  $M$  possíveis taxas de dados diferentes de zero por RB, em que  $v^m$  representa a taxa de dados transmitida correspondente ao  $m^{\text{ésimo}}$  nível de MCS. Observe que o  $m^{\text{ésimo}}$  nível de MCS é empregado quando a SNR estimada está entre  $\gamma^m$  e  $\gamma^{m+1}$  em que  $\gamma^m < \gamma^{m+1}$ .

A seguir, iremos definir algumas outras variáveis importantes. Assumimos que, em um dado TTI, terminal  $j$  tem uma taxa de dados requerida igual a  $t_j$ . É importante mencionar aqui que os requisitos de taxas a longo prazo podem ser mapeados como requisitos de taxa de dados instantâneos [13]. A restrição de satisfação mínima para cada

serviço é representada pelo parâmetro  $k_s$  que consiste no número de terminais do serviço  $s$  que devem ser satisfeitos. Assumimos que os índices dos terminais em  $x_{j,n}$ ,  $r_{j,n}$  e  $t_j$  são dispostos sequencialmente de acordo com o serviço, por exemplo, os terminais de  $j = 1$  até  $j = J_1$  são pertencentes ao serviço 1, terminais do serviço  $j = J_1 + 1$  até  $j = J_1 + J_2$  são pertencentes ao serviço 2, e assim por diante.

## 2.2 Fomulação do Problema PMT

Como apresentado na Seção 1.2, o problema considerado neste trabalho foi baseado em [35]. Em [35], o problema tem como objetivo a maximização da taxa de dados agregada por setor restrita pelo número de terminais satisfeitos por serviço em um dado TTI. Em [35], apenas atribuição de RB é considerada e é assumido alocação de potência igualitária por RB. Nesta dissertação, além de alocação de RB, iremos considerar também alocação de potência transmitida. Chamaremos o novo problema de PMT.

De acordo com as considerações anteriores, a formulação do PMT é dada a seguir:

$$\max_{\mathbf{X}, \mathbf{p}} \sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} f(p_n \cdot \eta_{j,n}) \cdot x_{j,n}, \quad (3a)$$

sujeito a

$$\sum_{j \in \mathcal{J}} x_{j,n} \leq 1, \quad \forall n \in \mathcal{N}, \quad (3b)$$

$$x_{j,n} \in \{0, 1\}, \quad \forall j \in \mathcal{J} \text{ e } \forall n \in \mathcal{N}, \quad (3c)$$

$$\sum_{n \in \mathcal{N}} p_n \leq P^{\text{tot}}, \quad (3d)$$

$$\sum_{j \in \mathcal{J}_s} u\left(\sum_{n \in \mathcal{N}} f(p_n \cdot \eta_{j,n}) \cdot x_{j,n}, t_j\right) \geq k_s, \quad \forall s \in \mathcal{S}, \quad (3e)$$

$$p_n \in \mathbb{R}, \quad \forall n \in \mathcal{N}, \quad (3f)$$

em que  $u(x, b)$  é uma função degrau onde  $u$  assume o valor 1 se  $x \geq b$  e 0 de outra forma. A função objetivo (3a) é taxa de dados total transmitida no modo *downlink* pela ERB. As duas primeiras restrições (3b) e (3c) asseguram que um RB não irá ser compartilhado por terminais diferentes, ou seja, não existe interferência intracelular. A restrição (3d) assegura que a potência total transmitida usada não será maior que a total disponível  $P^{\text{tot}}$ . Por fim, (3e) assegura que um número mínimo de terminais devem ser satisfeitos por cada serviço.

O problema de otimização (3) é um problema de otimização misto com variáveis inteiras (binárias)  $x_{j,n}$  e variáveis reais  $p_n$ . Devido a natureza inteira de  $x_{j,n}$ , a combinação

convexa de duas soluções viáveis não necessariamente resulta em outra solução viável. Portanto, o espaço de soluções viáveis não é convexo [52]. Esta classe de problemas é muito difícil de ser resolvida de forma ótima. Em geral, a solução ótima pode ser obtida através da realização exaustiva de busca sobre todas as possíveis alocações de RB e para cada uma, tentar resolver o problema de otimização contínua correspondente ao problema de alocação de potência. A alocação de RB e potência que maximiza a função objetivo é a ótima. A complexidade do problema (3) é aumentada especialmente por causa das funções não lineares e não convexas presentes na função objetivo (3a) (veja equações (1) e (2)) e na restrição(3e). Na Seção 3.1 iremos apresentar diferentes transformações para esse problema de otimização de forma a obter um método para a solução ótima.

### 2.3 Formulação do Problema PMEE

Nesta seção, formulamos o problema de maximização da eficiência energética sujeito a requisitos de satisfação, chamado de PMEE. De acordo com as considerações anteriores o problema formulado é dado a seguir:

$$\min_{\mathbf{x}, \mathbf{p}} \frac{\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} p_n \cdot x_{j,n}}{\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} f(p_n \cdot \eta_{j,n}) \cdot x_{j,n}}, \quad (4a)$$

sujeito a

$$\sum_{j \in \mathcal{J}} x_{j,n} \leq 1, \quad \forall n \in \mathcal{N}, \quad (4b)$$

$$x_{j,n} \in \{0, 1\}, \quad \forall j \in \mathcal{J} \text{ e } \forall n \in \mathcal{N}, \quad (4c)$$

$$\sum_{n \in \mathcal{N}} p_n \leq P^{\text{tot}}, \quad (4d)$$

$$\sum_{j \in \mathcal{J}_s} u \left( \sum_{n \in \mathcal{N}} f(p_n \cdot \eta_{j,n}) \cdot x_{j,n}, t_j \right) \geq k_s, \quad \forall s \in \mathcal{S}, \quad (4e)$$

$$p_n \in \mathfrak{R}, \quad \forall n \in \mathcal{N}. \quad (4f)$$

Observe que a função objetivo (4a) consiste na razão entre a potência total usada na ERB dividida pela taxa total transmitida no enlace direto. O objetivo é minimizar esta métrica. As restrições do problema (4) são as mesmas já descritas para o problema (3).

O problema (4), assim como o problema (3) é muito difícil de ser resolvido de forma ótima. A complexidade do problema (4) é aumentada especialmente por causa da função fracionada presente no objetivo do problema em (4a), e a restrição não linear presente na equação (4e). Na Seção 4.1 iremos apresentar diferentes transformações para esse problema de otimização de forma a obter um método para a solução ótima.

## 2.4 Formulação do Problema PMP

Nesta seção, iremos formular o problema de minimização de potência sujeito a requisitos de satisfação, chamado de PMP. De acordo com as considerações anteriores o problema formulado é dado a seguir:

$$\min_{\mathbf{X}, \mathbf{p}} \sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} p_n \cdot x_{j,n}, \quad (5a)$$

sujeito a

$$\sum_{j \in \mathcal{J}} x_{j,n} \leq 1, \quad \forall n \in \mathcal{N}, \quad (5b)$$

$$x_{j,n} \in \{0, 1\}, \quad \forall j \in \mathcal{J} \text{ e } \forall n \in \mathcal{N}, \quad (5c)$$

$$\sum_{n \in \mathcal{N}} p_n \leq P^{\text{tot}}, \quad (5d)$$

$$\sum_{j \in \mathcal{J}_s} u \left( \sum_{n \in \mathcal{N}} f(p_n \cdot \eta_{j,n}) \cdot x_{j,n}, t_j \right) \geq k_s, \quad \forall s \in \mathcal{S}, \quad (5e)$$

$$p_n \in \mathfrak{R}, \quad \forall n \in \mathcal{N}. \quad (5f)$$

A função objetivo (5a) consiste na potência total transmitida pela ERB e deve ser minimizada. As restrições do problema (5) são as mesmas já descritas para o problema (3).

O problema (5), assim como o problema (3) é muito difícil de ser resolvido de forma ótima. O problema(5), assim como o problema (3), apresenta funções não lineares e não convexas na função objetivo (5a) e na restrição (5e). Na Seção 4.2 iremos apresentar diferentes transformações para esse problema de otimização de forma a obter um método para a solução ótima.

## 2.5 Formulação do Problema PMDTP

Nesta seção, formulamos o problema de maximização da diferença entre a taxa total e potência total normalizadas sujeito a requisitos de satisfação, chamado de PMDTP. De acordo com as considerações anteriores o problema formulado é dado a seguir:



$$\max_{\mathbf{X}, \mathbf{p}} \frac{\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} f(p_n \cdot \eta_{j,n}) \cdot x_{j,n}}{\sum_{n \in \mathcal{N}} v^M} - \frac{\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} p_n \cdot x_{j,n}}{P^{\text{tot}}}, \quad (6a)$$

sujeito a

$$\sum_{j \in \mathcal{J}} x_{j,n} \leq 1, \quad \forall n \in \mathcal{N}, \quad (6b)$$

$$x_{j,n} \in \{0, 1\}, \quad \forall j \in \mathcal{J} \text{ e } \forall n \in \mathcal{N}, \quad (6c)$$

$$\sum_{n \in \mathcal{N}} p_n \leq P^{\text{tot}}, \quad (6d)$$

$$\sum_{j \in \mathcal{J}_s} u \left( \sum_{n \in \mathcal{N}} f(p_n \cdot \eta_{j,n}) \cdot x_{j,n}, t_j \right) \geq k_s, \quad \forall s \in \mathcal{S}, \quad (6e)$$

$$p_n \in \mathfrak{R}, \quad \forall n \in \mathcal{N}. \quad (6f)$$

A função objetivo (6a) é a diferença entre a taxa total transmitida pela ERB normalizada pela máxima taxa possível a ser transmitida no enlace direto, e a potência total transmitida pela ERB normalizada pela potência máxima a ser transmitida pela ERB. As restrições do problema (6) são as mesmas já descritas para o problema (3).

O problema (6), assim como o problema (3) é muito difícil de ser resolvido de forma ótima. O problema (6), assim como o problema (3), apresenta funções não lineares e não convexas na função objetivo (6a) e na restrição (6e). Na Seção 4.3 iremos apresentar diferentes transformações para esse problema de otimização de forma a obter um método para a solução ótima.

### 3 SOLUÇÃO ÓTIMA PARA PMT E HEURÍSTICA

Este capítulo aborda a solução ótima do problema formulado na seção 2.2, uma solução de baixa complexidade para este problema e apresenta os resultados de desempenho. Mais especificamente, na seção 3.1 apresentamos transformações do problema abordado de forma a tornar viável a aplicação de *softwares* comerciais de resolução de problemas de otimização. A heurística proposta neste trabalho para a solução deste problema de otimização é descrita na seção 3.2. Por fim, na seção 3.3, são apresentados os resultados de desempenho dos algoritmos propostos comparando-os com a solução em [35] que utiliza EPA.

#### 3.1 Solução Ótima

De forma a simplificar a estrutura do problema (3), primeiramente precisamos unificar as variáveis de otimização  $\mathbf{X}$  e  $\mathbf{p}$ . Observe que, desde que MCSs discretas são em-

pregadas, a potência transmitida pode também ser modelada como uma variável discreta. Como comentado nas Seções 1.2 e 2.1, o mecanismo de adaptação de enlace baseado em BLER alvo seleciona a MCS usada na transmissão baseado nas regiões de SNR. Portanto, é razoável dizer que a potência transmitida pode ser definida como o valor mínimo que é capaz de alcançar a menor SNR que satisfaz o requisito de BLER. Em outras palavras, para transmitir com uma dada MCS é suficiente garantir a SNR mínima da sua região de MCS correspondente. Considerando o terminal  $j$  e RB  $n$ , definimos  $\lambda_{j,n,m}$  como a potência mínima de transmissão que deve ser alocada ao terminal  $j$  no RB  $n$  para ser empregada a MCS  $m$ . Especificamente,  $\lambda_{j,n,m}$  é dado por

$$\lambda_{j,n,m} = \frac{\gamma^m \sigma_j^2}{\alpha_j |h_{j,n}|^2}. \quad (7)$$

Portanto, podemos reformular o PMT assumindo uma nova variável de otimização (binária)  $y_{j,n,m}$  que assume o valor 1 se o RB  $n$  é atribuído ao terminal  $j$  e a transmissão é configurada com o  $m^{\text{ésimo}}$  nível de MCS. Neste caso, a potência alocada ao RB  $n$  pertencente ao terminal  $j$  é igual a  $\lambda_{j,n,m}$  dado pela equação (7). O problema estudado pode ser reformulado como segue

$$\max_{y_{j,n,m}} \sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot y_{j,n,m}, \quad (8a)$$

sujeito a

$$\sum_{j \in \mathcal{J}} \sum_{m \in \mathcal{M}} y_{j,n,m} \leq 1, \quad \forall n \in \mathcal{N}, \quad (8b)$$

$$y_{j,n,m} \in \{0, 1\}, \quad \forall j \in \mathcal{J}, \forall n \in \mathcal{N} \text{ e } \forall m \in \mathcal{M}, \quad (8c)$$

$$\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} y_{j,n,m} \cdot \lambda_{j,n,m} \leq P^{\text{tot}}, \quad (8d)$$

$$\sum_{j \in \mathcal{J}_s} u \left( \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot y_{j,n,m}, t_j \right) \geq k_s, \quad \forall s \in \mathcal{S}, \quad (8e)$$

$$\sum_{m \in \mathcal{M}} y_{j,n,m} \leq 1, \quad \forall j \in \mathcal{J} \text{ e } \forall n \in \mathcal{N}. \quad (8f)$$

em que  $u(x, b)$  é uma função degrau onde  $u$  assume o valor 1 se  $x \geq b$  e 0 de outra forma. A função objetivo (8a) é taxa de dados total transmitida no modo *downlink* pela ERB. As duas primeiras restrições (8b) e (8c) asseguram que um RB não irá ser compartilhado por terminais diferentes, ou seja, não existe interferência intracelular. A restrição (8d) assegura que a potência total transmitida usada não será maior que a total disponível  $P^{\text{tot}}$ . A restrição (8e) assegura que um número mínimo de terminais devem ser satisfeitos por cada serviço. Por fim, a restrição (8f) assegura que não teremos mais de um nível de MCS em cada RB.

O problema (8) pertence a classe dos problemas de otimização combinatoriais ou inteiros. Contudo, ele permanece não linear devido a restrição (8e). De forma a linearizar a restrição (8e), iremos introduzir uma nova variável de otimização. Considere  $\rho_j$  como uma variável binária de seleção que assume o valor de 1 se o terminal  $j$  é selecionado para ser satisfeito e 0 se não. Observe que  $\boldsymbol{\rho} = [\rho_1 \cdots \rho_J]^T$ . Desta forma, o problema (8) pode ser reformulado substituindo a restrição (8e) pelas três restrições a seguir:

$$\sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot y_{j,n,m} \geq \rho_j t_j, \quad \forall j \in \mathcal{J}, \quad (9a)$$

$$\rho_j \in \{0, 1\}, \quad \forall j \in \mathcal{J}, \quad (9b)$$

$$\sum_{j \in \mathcal{J}_s} \rho_j \geq k_s, \quad \forall s \in \mathcal{S}. \quad (9c)$$

De modo a escrever este novo problema de uma maneira compacta iremos representar as variáveis do problema e entradas em forma de vetor e matriz. A seguir iremos utilizar linhas verticais e horizontais quando definirmos vetores e matrizes para fácil compreensão de sua estrutura. Considere as definições a seguir:

$$\mathbf{v} = \begin{bmatrix} 0 & v^1 & \cdots & v^M \end{bmatrix}^T,$$

$$\boldsymbol{\lambda}_j = \begin{bmatrix} \lambda_{j,1,1} & \cdots & \lambda_{j,1,M} & | \cdots | & \lambda_{j,N,1} & \cdots & \lambda_{j,N,M} \end{bmatrix}^T,$$

$$\mathbf{y}_j = \begin{bmatrix} y_{j,1,1} & \cdots & y_{j,1,M} & | \cdots | & y_{j,N,1} & \cdots & y_{j,N,M} \end{bmatrix}^T,$$

$$\mathbf{k} = \begin{bmatrix} k_1 & \cdots & k_S \end{bmatrix}^T \text{ e}$$

$$\mathbf{y} = \begin{bmatrix} \mathbf{y}_1^T & \cdots & \mathbf{y}_J^T \end{bmatrix}^T.$$

Definimos a variável de otimização como  $\mathbf{z} = \begin{bmatrix} \mathbf{y}^T & | & \boldsymbol{\rho}^T \end{bmatrix}^T$ . Observe que os vetores  $\mathbf{y}$  e  $\boldsymbol{\rho}$  podem ser obtidos a partir de  $\mathbf{z}$  através do uso das relações a seguir:  $\mathbf{y} = \mathbf{A}_1 \mathbf{z}$  e  $\boldsymbol{\rho} = \mathbf{A}_2 \mathbf{z}$ , onde  $\mathbf{A}_1 = \begin{bmatrix} \mathbf{I}_{JNM} & | & \mathbf{0}_{JNM \times J} \end{bmatrix}$  e  $\mathbf{A}_2 = \begin{bmatrix} \mathbf{0}_{J \times JNM} & | & \mathbf{I}_J \end{bmatrix}$  onde  $\mathbf{I}_a$  é uma matriz identidade com dimensão  $a \times a$  e  $\mathbf{0}_{a \times b}$  é uma matriz com dimensão  $a \times b$  composta de 0's.

A função objetivo do problema (8a) pode ser escrita como  $\mathbf{a}^T \mathbf{A}_1 \mathbf{z}$  onde  $\mathbf{a} = \begin{bmatrix} \underbrace{\mathbf{v}^T \cdots \mathbf{v}^T}_{JN \text{ vezes}} \end{bmatrix}^T$ .

A restrição (8b) pode ser escrita na forma matricial como  $\mathbf{BA}_1\mathbf{z} \leq \mathbf{1}_N$  com

$$\mathbf{B} = \left[ \underbrace{\text{diag} \left( \underbrace{\mathbf{1}_M^T, \dots, \mathbf{1}_M^T}_{N \text{ vezes}} \right)}_{J \text{ vezes}} \mid \dots \mid \underbrace{\text{diag} \left( \underbrace{\mathbf{1}_M^T, \dots, \mathbf{1}_M^T}_{N \text{ vezes}} \right)}_{J \text{ vezes}} \right], \quad (10)$$

em que  $\mathbf{1}_a$  é um vetor coluna de tamanho  $a$  composto de 1's e  $\text{diag}(\mathbf{u}_1, \mathbf{u}_2, \dots)$  é um bloco de matriz diagonal com  $\mathbf{u}_1$  na primeira posição da diagonal principal,  $\mathbf{u}_2$  na segunda posição da diagonal principal, e assim por diante. Observe que os argumentos de  $\text{diag}(\cdot)$  podem ser escalares, vetores ou matrizes.

A restrição (8d) é escrita como  $\mathbf{c}^T \mathbf{A}_1 \mathbf{z} \leq P^{\text{tot}}$  com  $\mathbf{c} = [\lambda_1^T \dots \lambda_J^T]^T$ .

A restrição do problema (9a) é representado como  $\mathbf{DA}_1 \mathbf{z} \geq \mathbf{EA}_2 \mathbf{z} \Rightarrow (\mathbf{EA}_2 - \mathbf{DA}_1) \mathbf{z} \leq$

$$\mathbf{0}_J \text{ onde } \mathbf{D} = \text{diag} \left( \underbrace{\left[ \underbrace{\mathbf{v}^T \dots \mathbf{v}^T}_{N \text{ vezes}} \right]}_{J \text{ vezes}}, \dots, \underbrace{\left[ \underbrace{\mathbf{v}^T \dots \mathbf{v}^T}_{N \text{ vezes}} \right]}_{J \text{ vezes}} \right) \text{ e } \mathbf{E} = \text{diag}(t_1, \dots, t_J).$$

As restrições (9c) podem ser representados em forma de matriz como  $-\mathbf{FA}_2 \mathbf{z} \leq -\mathbf{k}$  onde  $\mathbf{F} = \text{diag}(\mathbf{1}_{J_1}^T, \dots, \mathbf{1}_{J_S}^T)$ .

Por fim, a restrição do problema (8f) pode ser escrita como  $\mathbf{GA}_1 \mathbf{z} \leq \mathbf{1}_{JN}$  com

$$\mathbf{G} = \text{diag} \left( \underbrace{\mathbf{1}_M^T, \dots, \mathbf{1}_M^T}_{JN \text{ vezes}} \right).$$

Portanto, arranjando as expressões desenvolvidas até agora temos

$$\max_{\mathbf{z}} (\mathbf{o}^T \mathbf{z}), \quad (11a)$$

$$\text{sujeito a } \mathbf{Pz} \leq \mathbf{q}, \quad (11b)$$

$$\mathbf{z} \text{ é um vetor binário}, \quad (11c)$$

em que as novas variáveis são definidas a seguir:  $\mathbf{o} = \mathbf{A}_1^T \mathbf{a}$  e

$$\mathbf{P} = \left[ (\mathbf{BA}_1)^T (\mathbf{c}^T \mathbf{A}_1)^T (\mathbf{EA}_2 - \mathbf{DA}_1)^T (-\mathbf{FA}_2)^T (\mathbf{GA}_1)^T \right]^T$$

$$\text{, e } \mathbf{q} = [\mathbf{1}_N^T \quad P^{\text{tot}} \quad \mathbf{0}_{J^T} \quad -\mathbf{k}^T \quad \mathbf{1}_{JN}^T]^T.$$

Baseado no que foi desenvolvido anteriormente nós transformamos o problema (3) em um problema ILP. Este problema pode ser resolvido por métodos padrões, como o algoritmo BC (do inglês, *Branch and Cut*) (também conhecido como BB (do inglês, *Branch and Bound*)) [52]. A complexidade computacional média para obter a solução ótima através destes métodos é muito menor do que usando força bruta (enumeração

completa de todas as alocações de RB possíveis). Apesar disso, a complexidade do método BC cresce exponencialmente com o número de restrições e variáveis. A forma linear do problema PMT tem  $JNM + J$  variáveis de otimização e  $JN + J + N + S + 1$  restrições, que podem assumir grandes valores mesmo para uma quantidade pequena de terminais, RBs, MCSs e serviços. Veja o apêndice 5 para mais detalhes sobre a complexidade da solução ótima do PMT.

## 3.2 Heurística

Nesta seção, iremos apresentar nosso algoritmo proposto que é uma solução alternativa de baixa complexidade para o problema PMT. Antes de apresentarmos o algoritmo proposto, iremos mostrar que o PMT pode ser simplificado sem perda substancial de otimalidade.

### 3.2.1 Comportamento de Solução ILP: Seleção de Usuários

De forma similar à aproximação feita por [53], realizamos simulações com a solução ótima apresentada na seção 3.1 a fim de observar o comportamento da solução ILP. Os aspectos principais apresentados na seção 2.1 foram modelados nessa simulação e mais detalhes sobre o cenário de simulação pode ser encontrado na seção 3.3. Por uma questão de clareza, iremos apresentar os parâmetros mais importantes. Assumimos 8 terminais em um setor ( $J = 8$ ) que pertencem a um mesmo tipo de serviço <sup>4</sup> ( $S = 1$ ) e 15 RBs ( $N = 15$ ). Como consideramos apenas um serviço nesta seção, deixaremos de lado o índice das variáveis  $s$ . A simulação consiste em distribuímos uniformemente os terminais na área de cobertura do setor em 3.000 realizações independentes. O canal foi modelado assumindo uma perda de percurso dependente da distância, com um fator de sombreamento e desvanecimento de curto prazo, como detalhado na seção 3.3. O resultado considerado aqui é o de taxa de *outage* que consiste na frequência relativa em que um algoritmo não é capaz de achar uma solução factível para o problema PMT, ou seja, o algoritmo não é capaz de satisfazer às restrições do problema de otimização (8). A carga do sistema é emulada pelo aumento das taxas de dados requisitada pelos usuários. Assumimos que todos os usuários exigem a mesma taxa de dados.

O objetivo principal dessa investigação é de avaliar o impacto do descarte de alguns terminais do conjunto  $\mathcal{J}$  na taxa de outage da solução ótima. Na figura 2 considere que o algoritmo “original PMT” é a solução ótima obtida de acordo com a seção 3.1 assumindo todos os terminais do problema (8). Também, assumo que o algoritmo “PMT selec.” é a solução ótima obtida de acordo com a seção 3.1 assumindo apenas  $k$  terminais (o número mínimo de terminais que devem ser satisfeitos por serviço) que foram

---

<sup>4</sup>Apesar de aqui assumirmos apenas um serviço, cenários com múltiplos serviços serão considerados na avaliação dos resultados na seção 3.3

selecionados para resolver o problema (8). O processo de seleção consiste em escolher os  $k$  terminais dentre  $J$  com a maior razão entre a média de taxa de dados  $\bar{r}_j$  e a taxa de dados requisitada  $t_j$ . A taxa de dados média é obtida através do mapeamento da SNR média do terminal para taxa de dados através da função de adaptação de enlace que segue:

$$\bar{r}_j = f \left( \frac{\frac{P^{\text{tot}}}{N} \cdot \frac{\sum_{n \in \mathcal{N}} (\alpha_j \cdot |h_{j,n}|^2)}{N}}{\sigma_j^2} \right). \quad (12)$$

A ideia principal de descartar os terminais com menor razão entre  $\bar{r}_j/t_j$  é a de retirar do processo de alocação os terminais que são mais difíceis de satisfazer, por exemplo, terminais com alta taxa de dados requisitada e pior qualidade de canal. Mostramos na Figura 2 a taxa de *outage* versus a taxa de dados requisitada por terminal para as soluções PMT original e PMT selec. considerando  $J = 8$  e  $k = 4$  rotulado como 4/8 e  $J = 8$  e  $k = 6$  rotulado como 6/8 na Figura 2. Nesta figura podemos ver que a solução ótima considerando todos os terminais e a solução ótima com os  $k$  melhores terminais têm aproximadamente o mesmo desempenho em ambos os cenários. A perda de desempenho do PMT original em relação ao PMT selec. é mais notável no cenário 4/8 devido a maior liberdade para selecionar terminais comparado ao cenário 6/8. Contudo, observe que em geral a taxa de satisfação requisitada definida pelos operadores do sistema em geral são maiores que 80% enquanto no cenário 4/8 temos uma taxa de satisfação de 50% [54].

Importante observar que este processo de seleção quase ótimo pode ser generalizado para o cenário com multisserviços através da seleção dos  $k_s$  terminais terminais de cada serviço  $s \in \mathcal{S}$ . Assuma que  $\tilde{\mathcal{J}}_s$  é o novo conjunto de terminais com tamanho  $\tilde{J}_s$  após a seleção dos melhores terminais a partir de  $\mathcal{J}_s$ , e que  $\tilde{\mathcal{J}} = \bigcup_{s \in \mathcal{S}} \tilde{\mathcal{J}}_s$  e  $\tilde{J} = \sum_{s \in \mathcal{S}} \tilde{J}_s$ . A vantagem deste processo de redução é da ordem e complexidade do problema. De fato, selecionando os melhores  $k_s$  terminais de cada serviço  $s \in \mathcal{S}$ , reduzimos o número de variáveis de otimização já que diminuimos a quantidade de terminais do problema além de descartar a variável  $\rho_j$  e a restrição (9c) do problema  $\rho_j$ . Na próxima seção, iremos incorporar esta estratégia a nossa solução proposta de baixa complexidade.

### 3.2.2 Descrição do Algoritmo

A solução de baixa complexidade proposta para o PMT é composta de duas partes. As partes 1 e 2 são mostradas nas Figuras 3 e 4, respectivamente. Na parte 1 da solução proposta, realizamos uma alocação inicial de RBs assumindo uma hipótese simplificadora: os terminais são capazes de transmitir com a maior MCS possível nos RBs. Cada terminal é alocado com apenas o número mínimo de RBs de acordo com a hipótese simplificadora e os requisitos de taxa de dados de cada terminal. Na parte 2

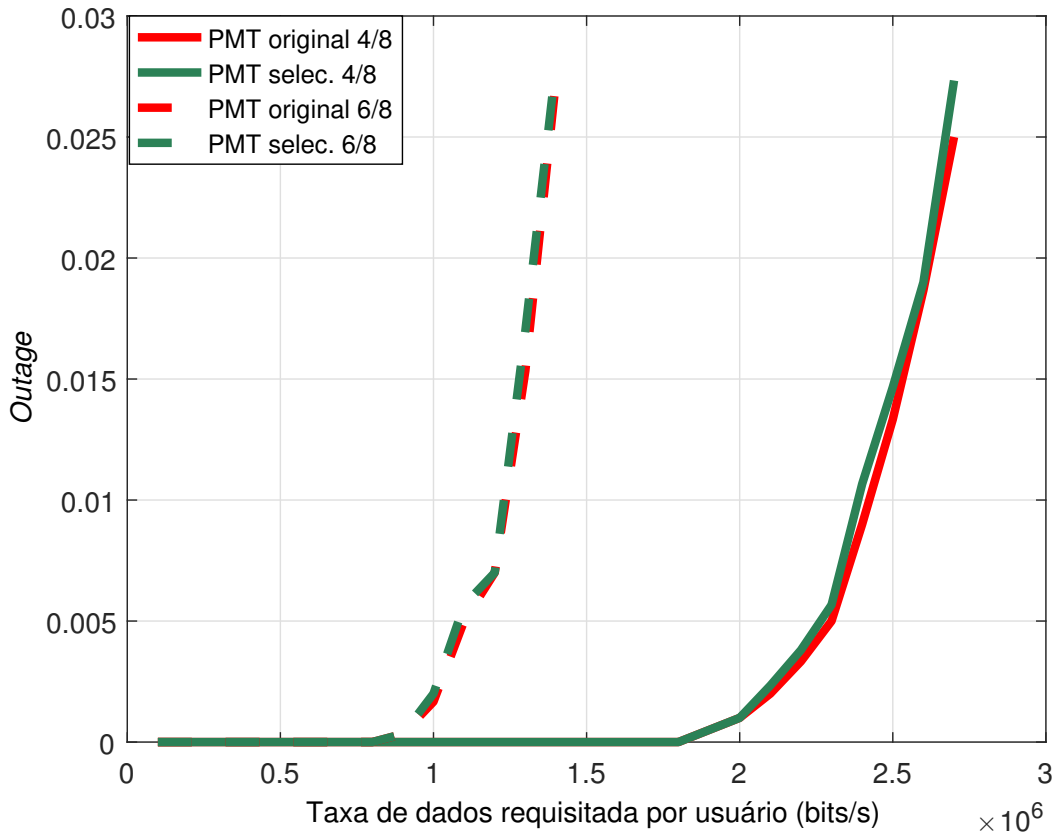


Figura 2: Comportamento ILP : Taxa de *outage* versus taxa de dados requisitada para a solução original PMT e a solução PMT após a seleção dos melhores terminais  $k_s$ .

do algoritmo alocamos os RBs restantes e aplicamos alocação de potência adaptativa nos RBs para melhorar o desempenho do sistema.

No passo 1 da primeira parte da solução proposta, aplicamos o processo de seleção de usuário descrita na seção 3.2.1, ou seja, selecionamos para cada serviço  $s \in \mathcal{S}$  os  $k_s$  terminais com maiores valores para a razão  $\bar{r}_j/t_j$ . Os terminais selecionados compõem o conjunto Auxiliar,  $\mathcal{A}$ . No passo 2, definimos o conjunto  $\mathcal{B}$  como o conjunto de todos RBs. Então, no passo 3, estimamos o número de RBs necessários para cada terminal alcançar a taxa de dados requisitada assumindo que eles são capazes de transmitir com a melhor MCS possível, por exemplo, taxa de dados  $v^M$  em cada RB. Portanto, o número mínimo de RBs necessários para satisfazer o requisito do terminal  $j$  é dado pelo limitante superior da relação  $t_j/v^M$ . A ideia principal do passo 3 é de ter uma estimativa otimista do número de RBs necessários para cada terminal. Passos 4 e 5 checam se o conjunto Auxiliar e o conjunto RB estão vazios ou não. No passo 6, escolhemos o terminal do conjunto Auxiliar com menor razão  $\bar{r}_j/t_j$  para receber primeiro os RBs. A motivação aqui é priorizar os terminais com pior qualidade de canal deixando eles escolherem seus melhores RBs. Terminais com boa qualidade de canal em geral tem mais RBs em boas condições, diferentemente dos terminais com pior qualidade de canal.

No passo 7, escolhemos para o terminal selecionado no passo 6 seu melhor RB. O RB selecionado é retirado do conjunto  $\mathcal{B}$ . No passo 8, avaliaremos se o terminal selecionado já possui o número mínimo de RBs, calculado no passo 3. Se assim for, este terminal é retirado do conjunto  $\mathcal{A}$  no passo 9 e outro terminal irá receber RBs. Se não, será alocado mais RBs ao terminal selecionado até o número mínimo de RBs ser atingido. Importante observar que se durante o processo de alocação todos os RBs forem assinalados e ainda existir terminais sem o número mínimo de RBs, o algoritmo não será capaz de satisfazer as restrições do problema (3). No final desta seção, discutimos algumas formas de contornar esse problema.

No fim da primeira parte da solução proposta, cada terminal tem um número mínimo de RBs alocados e possivelmente existem RBs disponíveis. O primeiro passo da parte 2 apresentado na Figura 4, consiste em aplicar a alocação de potência de transmissão de acordo com o algoritmo HH (Hughes-Hartogs) nos RBs de cada terminal individualmente sem obedecer a restrição de potência total definida na equação (8d). Basicamente, o algoritmo HH aloca potência de transmissão aos RBs e conseqüentemente aumenta os níveis de MCS até cumprir as taxas de dados de transmissão requisitada por cada terminal do conjunto  $\mathcal{A}$ . Observe que possivelmente a soma da potência de transmissão utilizada de cada terminal (potência de transmissão total utilizada) pode violar a restrição de potência total na ERB, tornando a solução impraticável. Isto é avaliado no passo 2, onde testamos se a potência de transmissão total utilizada (somatório da potência de transmissão alocada aos RBs de todos os terminais) é menor ou igual a restrição de potência total da ERB,  $P^{\text{tot}}$ . Em caso afirmativo, temos uma solução factível para o problema PMT e uma otimização adicional é feita no passo 9 onde os RBs restantes serão alocados ao usuários com a melhor qualidade de canal. O algoritmo HH é executado novamente com objetivo de distribuir a potência de transmissão restante para os RBs. Neste caso, o algoritmo HH aumenta os níveis de MCS dos RBs que precisam de menos potência para aumentar o nível de MCS. Se após o passo 1 a potência total utilizada é maior que a potência total disponível na ERB, iremos avaliar se os conjuntos  $\mathcal{A}$  e  $\mathcal{B}$  estão vazios (passo 3). Se sim, o algoritmo não é capaz de encontrar uma solução que obedeça às restrições do problema (3). Mais a frente, iremos discutir como procedemos neste caso. No passo 4, o terminal do conjunto Auxiliar  $\mathcal{A}$  com menor razão  $\bar{r}_j/t_j$  seleciona o RB do conjunto de RBs,  $\mathcal{B}$ , com melhor qualidade de canal. A ideia aqui é a mesma apresentada nos passos 6 e 7 da parte 1 da solução proposta. No passo 5, refazemos a alocação de potência transmitida (algoritmo HH) para os terminais selecionados no passo 4 considerando os RBs alocados e o RB selecionado no passo 4. A solução HH é executada até o terminal alcançar a taxa de dados requisitada sem a restrição de potência total. Se o RB selecionado está com qualidade de canal satisfatória, é provável que a potência total alocada ao terminal irá diminuir caso o RB selecionado seja alocado ao terminal. Portanto, no passo 6 avaliaremos se a potência total alocada ao terminal selecionado irá decrescer com a adição do novo



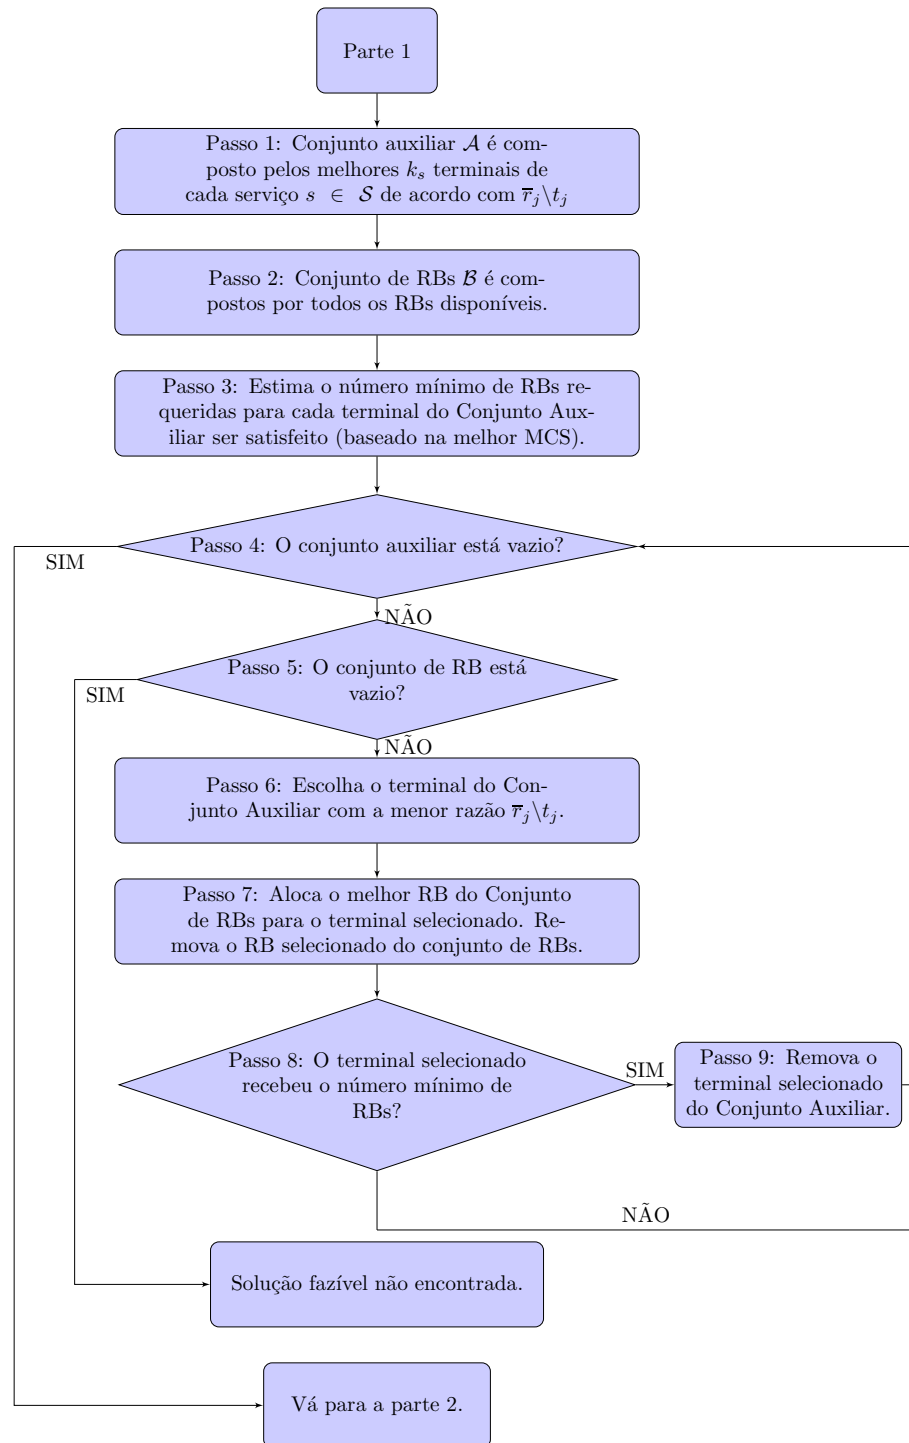


Figura 3: Primeira parte da solução subótima para o problema PMT.

RB. Caso afirmativo, o novo RB é alocado ao terminal e a potência total utilizada pela ERB é atualizada. Em caso contrário, o RB não é alocado ao terminal e este terminal é removido do conjunto Auxiliar  $\mathcal{A}$ . Este terminal é retirado do processo de alocação porque nenhuma economia de potência poderá ser obtida através da alocação de novos RBs a ele. O algoritmo continua testando se a adição de novos RBs é capaz de decrescer a

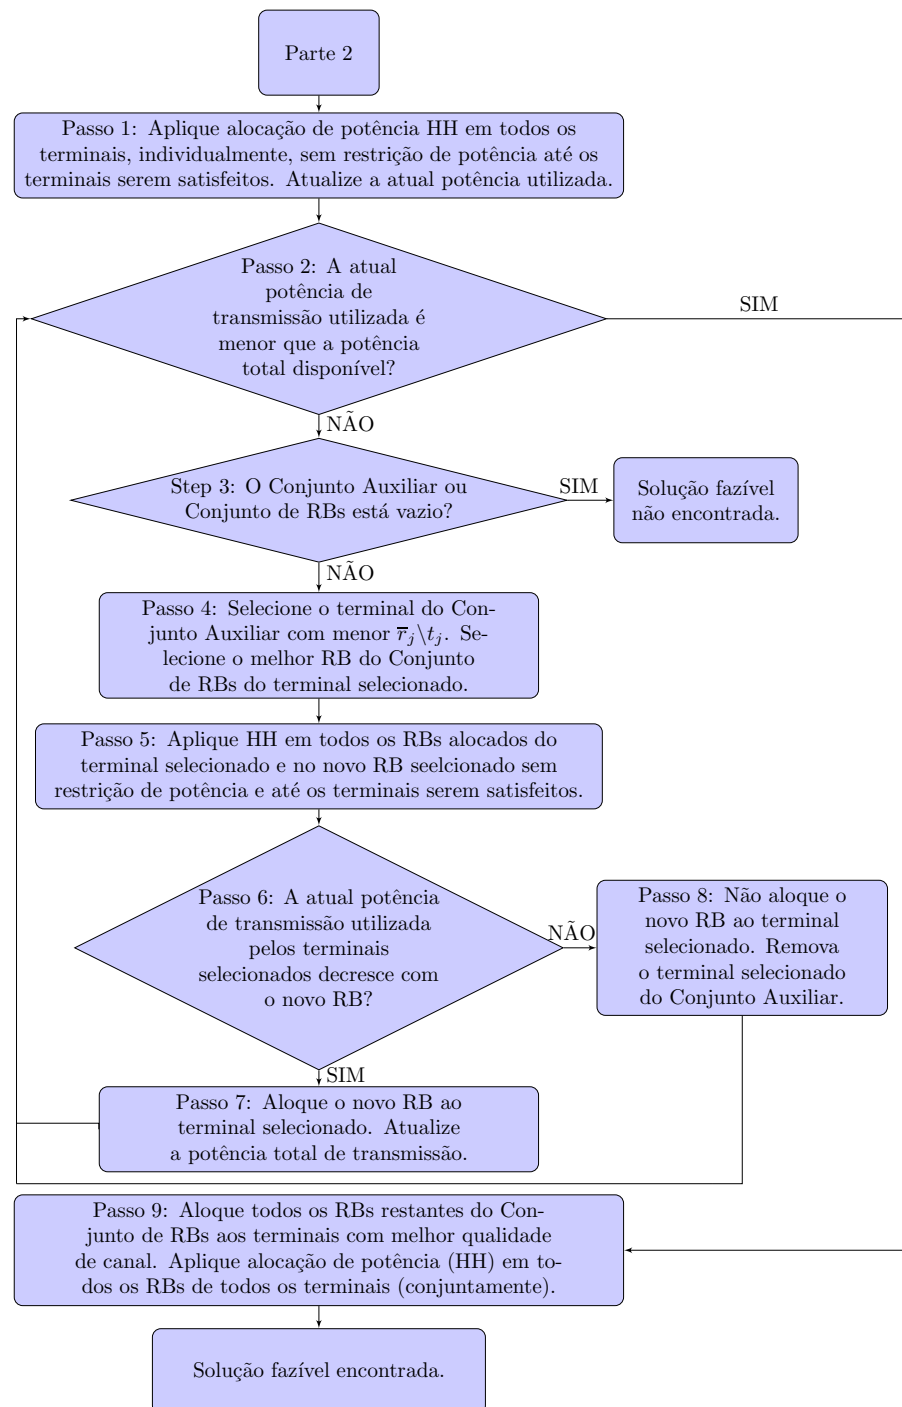


Figura 4: Segunda parte da solução subótima para o problema PMT.

potência total utilizada. O algoritmo termina quando a potência total utilizada é menor ou igual a potência total disponível na ERB, dessa forma obteremos uma solução factível.

Como comentado anteriormente, a solução proposta pode falhar em obter uma solução factível para o problema PMT. Isto significa que o algoritmo não é capaz de satisfazer às restrições do problema (3). Nossa proposta aqui é decrescer suavemente a restrição de taxa de dados requisitada pelos terminais por um fator arbitrário de  $\beta$  com

$\beta < 1$ . Então, nossa solução proposta pode ser executada novamente de forma a avaliar se as novas taxas de dados requisitadas podem ser satisfeitas. Dependendo do valor de  $\beta$ , esperamos satisfazer o QoS com um número limitado de RBs e de potência de transmissão disponível. A avaliação do impacto desta proposta consiste em uma das perspectivas deste estudo.

### 3.3 Resultados de Desempenho

Esta seção é dedicada à avaliação do desempenho da solução ótima e subótima do problema PMT. O objetivo principal é avaliar os ganhos de desempenho que podem ser obtidos a partir da alocação conjunta de RB e potência sobre a estratégia de alocação de RB com alocação de potência de potência igualitária (sem alocação adaptativa de potência) presente em [35] e quão perto a solução subótima proposta está da solução ótima do problema PMT. Na seção 3.3.1 apresentamos as principais suposições da simulação enquanto que na seção 3.3.2 mostramos e discutimos sobre os resultados de simulação.

#### 3.3.1 Parâmetros de Simulação

Utilizamos um simulador computacional onde foram implementadas as principais premissas apresentadas neste capítulo e no capítulo 2. Consideramos o modo *downlink* de um setor hexagonal implantado em um sistema celular. Os resultados foram obtidos através da realização de vários *snapshots* (TTI) independentes de forma a obter um resultado válido do ponto de vista estatístico. Em cada *snapshot*, os terminais são distribuídos uniformemente dentro de um setor, cujo ERB é localizada no canto da célula. Consideramos que os recursos estão dispostos em uma grade tempo e frequência, com cada RB composta de um grupo de 12 subportadoras adjacentes na frequência e 14 símbolos OFDM no tempo, seguindo as especificações em [55].

O modelo de propagação utilizado é composto de perda de percurso, uma componente de sombreamento log-normal e uma componente de desvanecimento Rayleigh de curto prazo. De forma específica, a componente de desvanecimento rápido do ganho do canal de um dado usuário é considerada independente para cada RB. Essa hipótese é coerente já que, em geral, os RBs tem largura de banda na ordem da banda de coerência do canal. Assumimos que a adaptação de enlace é realizada baseada na informação de 15 CQIs (do inglês, *Channel Quality Indicators*) discretas utilizada pelo sistema LTE [56]. Os limiares de SNRs para mudança de MCS foram obtidas pelas simulações de nível de *link* de [57]. Os parâmetros de simulação são resumidos na Tabela 2.

A solução ótima do problema PMT (identificado como PMT OPT) é comparada à solução ótima do mesmo problema com alocação de RB mas com alocação igualitária de potência (identificada como RAP que representa *Resource Assignment Problem*) [35]. A solução subótima proposta para o problema PMT é identificada como

Tabela 2: Principais parâmetros de simulação.

Parâmetros	Valores	Unidade
Raio da célula	334	m
Potência total transmitida	$0.35 \cdot N$	W
Número de subportadoras por RB	12	-
Número de níveis de MCS	15	-
Desvio padrão do sombreamento	8	dB
Perda de percurso <sup>(2)</sup>	$35.3 + 37.6 \cdot \log_{10}(d)$	dB
Densidade espectral do ruído	$3.16 \cdot 10^{-20}$	W/Hz
Número de <i>snapshots</i>	3000	-

Tabela 3: Esquemas de codificação e modulação.

MCS	Modulação	Taxa de Codificação [ $\times 1024$ ]	Taxa [Bits/TTI]
MCS-1	QPSK	78	25
MCS-2	QPSK	120	39
MCS-3	QPSK	193	63
MCS-4	QPSK	308	101
MCS-5	QPSK	449	147
MCS-6	QPSK	602	197
MCS-7	16-QAM	378	248
MCS-8	16-QAM	490	321
MCS-9	16-QAM	616	404
MCS-10	64-QAM	466	458
MCS-11	64-QAM	567	558
MCS-12	64-QAM	666	655
MCS-13	64-QAM	772	759
MCS-14	64-QAM	873	859
MCS-15	64-QAM	948	933

Fonte: Adaptado do relatório [58].

PROP. As realizações de canal são as mesmas para todos os algoritmos simulados, dessa maneira teremos uma comparação justa entre eles. De forma a resolver os problemas ILP usamos o IBM ILOG CPLEX *Optimizer* [59]. A escolha do número de terminais, RBs e serviços é limitado pela complexidade computacional para obter as soluções ótimas.

Consideramos duas métricas de desempenho: a taxa de *outage* e a taxa de dados total. Um evento de *outage* acontece quando o algoritmo não é capaz de encontrar uma solução que satisfaça todas as restrições do problema (8). Observe que dependendo das posições dos terminais dentro do setor, ganhos de canais e requisitos de taxa de dados dos terminais, o problema em si pode ser inviável. A taxa de *outage* é definida como a razão entre o número de *snapshots* em *outage* e o número total de *snapshots* simulados. Portanto, esta métrica de desempenho mostra a capacidade dos algoritmos em encontrar uma solução para o problema. A taxa total de dados é a soma das taxas de dados obtidas por todos os terminais de um setor em um dado *snapshot*. Por fim, incrementos na carga são emulados através do aumento das taxas de dados requisitadas dos terminais.

Para avaliar nossa proposta sob diferentes condições, nos resultados, apresentamos alguns cenários de simulação em que os principais parâmetros do nosso modelo são

Tabela 4: Parâmetros dos cenários considerados para simulações computacionais.

Cenário	$S$	$J_1$	$J_2$	$J_3$	$J_4$	$k_1$	$k_2$	$k_3$	$k_4$	$N$	Taxa de dados requisitada
1	2	4	4	-	-	3	3	-	-	15	Todos os terminais requisitam a mesma taxa de dados
2	2	4	4	-	-	4	3	-	-	15	Todos os terminais requisitam a mesma taxa de dados
3	2	4	4	-	-	4	4	-	-	15	Todos os terminais requisitam a mesma taxa de dados
4	3	3	3	3	-	3	3	2	-	15	Todos os terminais requisitam a mesma taxa de dados
5	3	3	3	3	-	3	3	2	-	15	Terminais do serviço 3 requisitam uma taxa de dados 125 kbps maior que a dos terminais dos serviços 1 e 2
6	3	3	3	3	-	3	3	2	-	15	Terminais do serviço 3 requisitam uma taxa de dados 250 kbps maior que a dos terminais dos serviços 1 e 2
7	4	3	3	3	3	3	3	2	2	20	Todos os terminais requisitam a mesma taxa de dados
8	4	3	3	3	3	3	3	3	2	20	Todos os terminais requisitam a mesma taxa de dados
9	4	3	3	3	3	3	3	3	3	20	Todos os terminais requisitam a mesma taxa de dados
10	4	3	3	3	3	3	3	3	2	20	Terminais do serviço 4 requisitam uma taxa de dados 250 kbps maior que a dos terminais dos serviços 1, 2 e 3
11	4	3	3	3	3	3	3	3	2	20	Terminais do serviço 4 requisitam uma taxa de dados 500 kbps maior que a dos terminais dos serviços 1, 2 e 3

modificados. Os cenários são descritos na Tabela 4.

### 3.3.2 Resultados

Nas figuras que seguem, denotamos o  $i^{\text{ésimo}}$  cenário como SCE  $i$ . Na Figura 5 mostramos a taxa de *outage* versus a taxa de dados requisitada por terminal para o algoritmo PMT OPT, RAP OPT e PROP nos cenários 1 a 3. Como esperado, a taxa de *outage* aumenta com a taxa de dados requisitada pelo usuário. Além disso, podemos observar que o todos os algoritmos apresentam um melhor desempenho conforme mudamos do cenário 3 para o 1. Este é também um comportamento esperado desde que o número requisitado de terminais satisfeitos,  $k_s$  aumenta do cenário 1 ao 3.

Focando no desempenho relativo entre os algoritmos, uma primeira observação interessante é que a otimização conjunta de alocação de RBs e potência apresenta um ganho de desempenho significativo em taxa de *outage* sobre a otimização de alocação de RBs com alocação de potência igualitária, nos cenários apresentados. Quando a solução PMT OPT alcança a taxa de *outage* de 10%, a diferença em taxa de *outage* entre PMT OPT e RAP OPT são de 22,4%, 16,1% e 17,25% nos cenários 1 a 3, respectivamente. Diferentemente das conclusões de [18], a otimização de potência conjunto com alocação de RBs levam a ganhos importantes sobre a otimização de RBs unicamente (sem alocação

<sup>5</sup> $d$  é a distância entre a ERB e o terminal em metros.

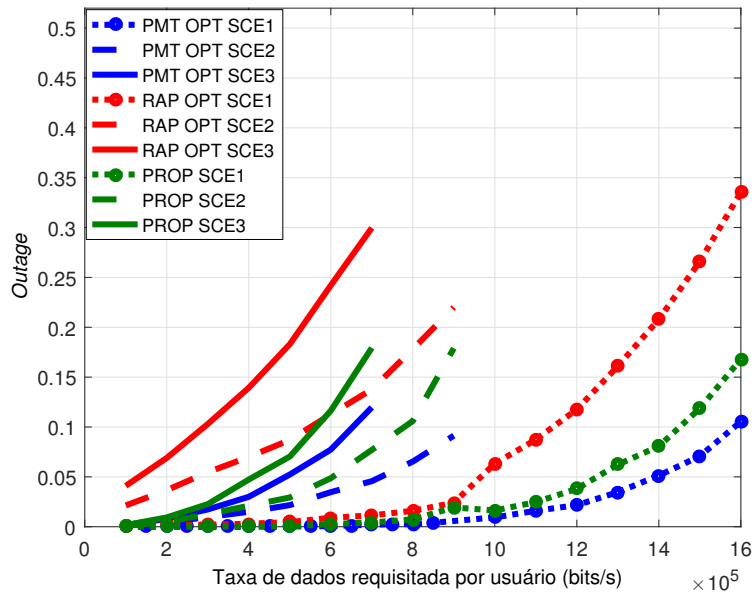


Figura 5: Taxa de *outage* versus taxa de dados requisitada para os algoritmos PMT OPT, RAP OPT e PROP com dois serviços ( $S = 2$ ). Assumimos os cenários 1 a 3 e avaliamos o impacto da variável  $k_s$ .

de potência adaptativa). A principal diferença nas conclusões é que o problema de RRA considerado em [18], não considera QoS ou restrições de satisfação. O problema de maximização de taxa sem restrição de satisfação/QoS considerado em [17] em geral permite que os terminais com melhor qualidade de canal possuam a maioria dos RBs. Consequentemente, os RBs são em geral configurados para transmitir com o maior nível de MCS possível mesmo quando é utilizada a alocação de potência igualitária. Portanto, não existe margem para ganho de desempenho com o uso de alocação de potência adaptativa com intuito de aumentar a taxa de dados transmitida. Por outro lado, quando QoS ou restrições de satisfação são consideradas no problema de maximização da taxa de dados, os RBs precisam ser alocados a terminais com qualidade de canal média ou ruim, uma vez que as restrições do problema devem ser satisfeitas. Consequentemente, alguns dos RBs alocados são configurados com os níveis de MCS pequeno ou médio, e neste caso existe espaço para otimização da taxa de dados através da alocação de potência adaptativa.

Uma segunda observação que pode ser obtida a partir da Figura 5 é sobre o desempenho da solução PROP. A solução PROP supera a solução RAP OPT mostrando que ganhos de desempenho podem ser obtidos, mesmo com soluções subótimas, quando consideramos alocação de potência de transmissão adaptativa. Portanto, a solução PROP supera ambas as soluções ótimas e subótimas propostas em [35] onde apenas alocação de RB é assumida (sem alocação de potência adaptativa). Além disso, a solução PROP apresenta uma pequena degradação de desempenho comparada a solução PMT OPT para cargas pequenas e moderadas<sup>6</sup> nos cenários apresentados. Quando a solução PMT OPT

<sup>6</sup>Assumimos que a taxa de *outage* máxima aceitável em um sistema é de 10%.

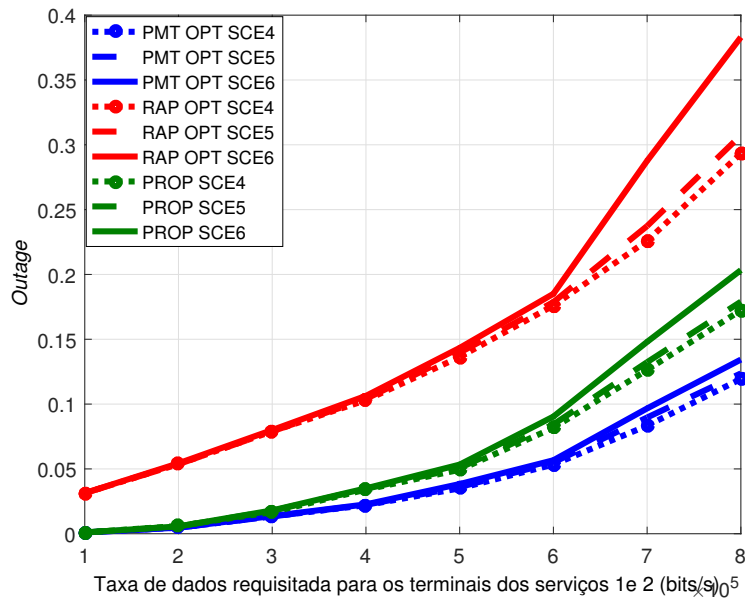


Figura 6: Taxa de *outage* versus taxa de dados requisitada para os algoritmos PMT OPT, RAP OPT e PROP com três serviços ( $S = 3$ ). Cenários 4 a 6 e o impacto da variável  $t_j$ .

alcança a taxa de *outage* de 10%, a diferença em desempenho da taxa de *outage* entre a solução subótima proposta e PMT OPT são de 6,1%, 6,9%, e 5% nos cenários 1 a 3, respectivamente.

Na Figura 6, estudamos o impacto das taxas de dados requisitadas pelos terminais,  $t_j$ . Nesta figura mostramos a taxa de *outage* versus a taxa de dados requisitada por terminal para os algoritmos PMT OPT, RAP OPT e PROP nos cenários 4 a 6. Observe que nestes cenários temos três serviços e os terminais do serviço 3 nos cenários 5 e 6 requisitam taxas de dados de 125 kbps e 250 kbps a mais que as requisitadas para os serviços 1 e 2, respectivamente. A taxa de dados pedida por todos os terminais do cenário 4 são as mesmas. De acordo com a Figura 6 podemos ver que quanto maior a taxa de dados requisitada para o serviço 3, maior será a taxa de *outage* para todos os algoritmos. De fato, como a demanda por taxa de dados dos terminais é aumentada, o problema de satisfazer os  $k_s$  terminais de cada serviço  $s$  se torna mais difícil.

Nas Figuras 7 e 8 apresentamos a taxa de dados versus a taxa de dada requisitada por terminal para os algoritmos PMT OPT, RAP OPT e PROP nos cenários 7 a 9 e 8, 10 e 11, respectivamente, em que todos os cenários consideram quatro serviços,  $S = 4$ . Na Figura 7 o número mínimo de terminais satisfeitos por serviço,  $k_s$ , é variado, enquanto na Figura 8 mudamos a taxa de dados requisitada por terminal,  $t_j$ , ao longo dos terminais. As principais conclusões obtidas até agora podem ser resumidas nestes cenários com mais serviços: as variáveis  $k_s$  e  $t_j$  têm um importante impacto na taxa de *outage* de todos os algoritmos. Além do mais, a solução PMT OPT apresenta ganhos importantes em taxa de *outage* comparada com à solução RAP OPT, destacando à importância da alocação adaptativa de potência. Também, a solução PROP apresenta uma

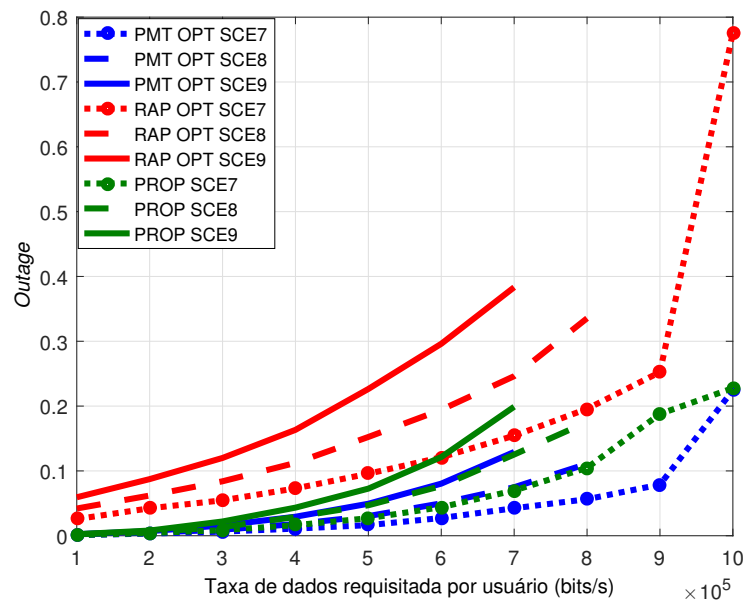


Figura 7: Taxa de *outage* versus taxa de dados requisitada para os algoritmos PMT, RAP OPT e PROP com quatro serviços ( $S = 4$ ). Assumimos os cenários 7 a 9 e avaliamos o impacto da variável  $k_s$ .

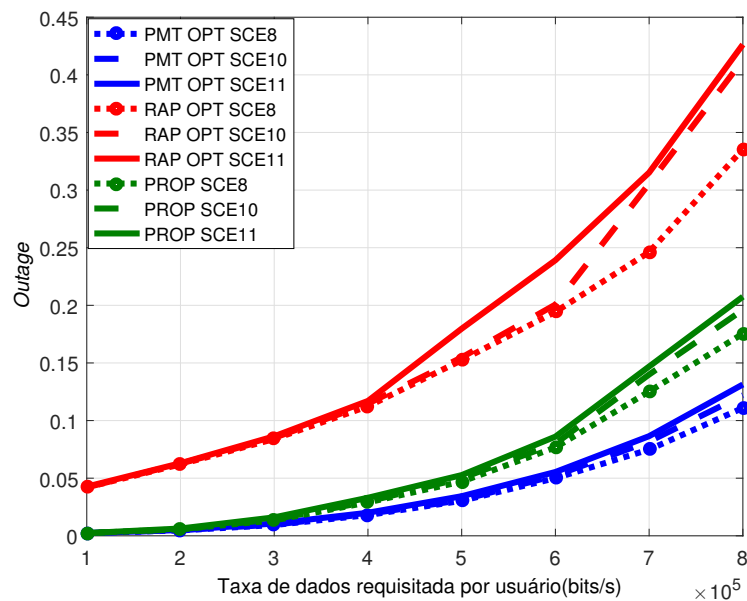
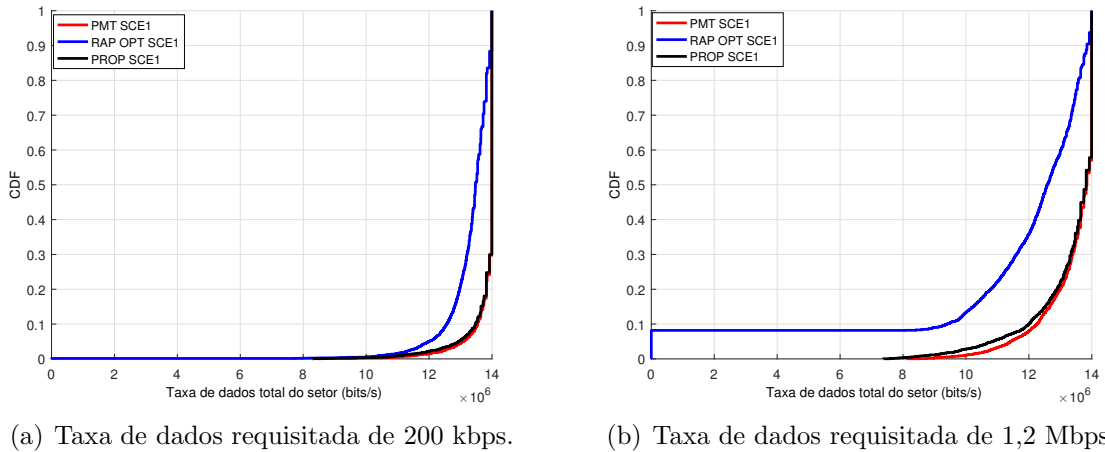


Figura 8: Taxa de *outage* versus taxa de dados requisitada para os algoritmos PMT OPT, RAP OPT e PROP com quatro serviços ( $S = 4$ ). Assumimos os cenários 8, 10 e 11, e avaliamos o impacto da variável  $t_j$ .

pequena perda de desempenho em relação à solução PMT OPT em pequenas e médias cargas, enquanto que ele supera a solução RAP OPT mesmo com o aumento do número de serviços.

A métrica taxa de *outage* mostra a capacidade do algoritmo em encontrar uma solução factível para o problema PMT. Com objetivo de analisar os algoritmos de





(a) Taxa de dados requisitada de 200 kbps.

(b) Taxa de dados requisitada de 1,2 Mbps.

Figura 9: CDF da taxa de dados total para um requisito de taxa de dados específico no cenário 1 para os algoritmos PMT OPT, RAP OPT, e PROP com dois serviços ( $S = 2$ ).

outro ponto de vista, nas figuras restantes, mostraremos a CDF da taxa total de dados para requisitos de taxa de dados específicos considerados no eixo x das figuras, relativo ao desempenho de *outage*. A taxa de dados total representa a função objetivo do nosso problema de otimização. Para uma carga e cenário específico, as CDFs de todos os algoritmos são construídas com amostras de *snapshots* em que PMT OPT, RAP OPT e PROP são capazes de encontrar uma solução factível ou viável.

Nas Figuras 9(a) e 9(b), apresentamos as CDFs das taxas total de dados para todos os algoritmos no cenário 1 para a taxa requisitada de 200 kbps e 1.200 kbps. Uma observação geral para todas às figuras restantes é que o algoritmo RAP OPT fornece as menores taxas de dados. As perdas de desempenho no 50<sup>ésimo</sup> percentil da taxa total de dados da solução RAP OPT para a solução PMT OPT são de 4% e 9,5% nas figuras 9(a) e 9(b), respectivamente. Observe que à solução PROP é capaz de manter uma perda pequena de desempenho comparada à solução PMT OPT que pode ser alcançada mesmo para elevados requisitos de taxa de dados.

Nas Figuras 10(a) e 10(b) apresentamos as CDFs das taxas de dados total para todos os algoritmos nos cenários 4 e 6 para a taxa requisitada de 400 kbps e 900 kbps, respectivamente. O objetivo é mostrar o impacto da taxa de dados requisitada,  $t_j$ . Basicamente, podemos ver que a variação de  $t_j$  entre os terminais de diferentes serviços não apresenta impacto significativo nas taxas de dados totais exceto para o algoritmo RAP OPT na Figura 10(b). A solução proposta apresenta um desempenho quase ótimo na Figura 10(a) enquanto que nos percentis mais baixos uma perda de desempenho pequena pode ser vista na Figura 10(b).

Nas Figuras 11(a) e 11(b) apresentamos a taxa de dados total para todos os algoritmos nos cenários 7 e 9 para as taxas de dados requisitadas de 400 kbps e 800 kbps, respectivamente. O objetivo é mostrar o impacto no número mínimo de terminais satisfeitos por serviço,  $k_s$ . Novamente, a solução RAP OPT apresenta a maior diferença de

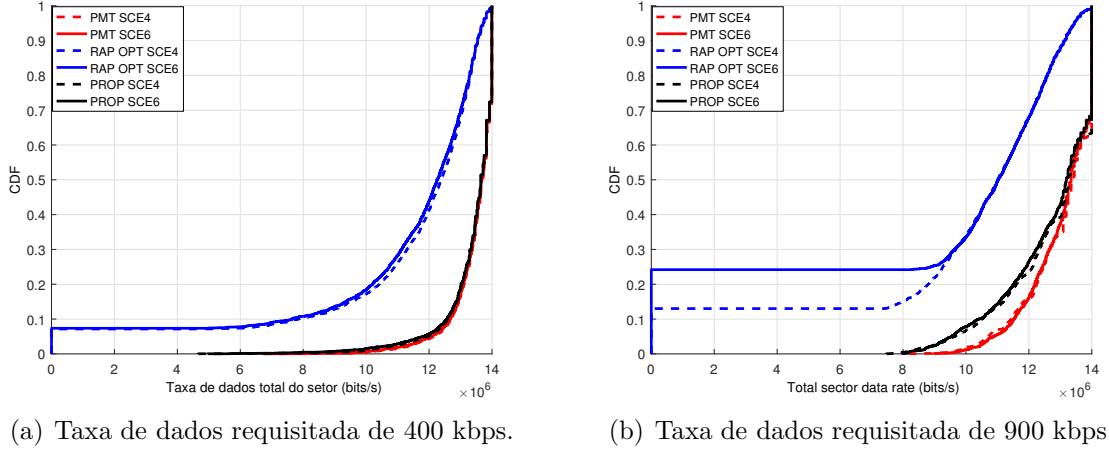


Figura 10: CDF da taxa de dados total para um requisito de taxa de dados específico para os algoritmos PMT OPT, RAP OPT, e PROP com três serviços ( $S = 3$ ). Assumindo os cenários 4 e 6 e avaliamos o impacto da variável  $t_j$ .

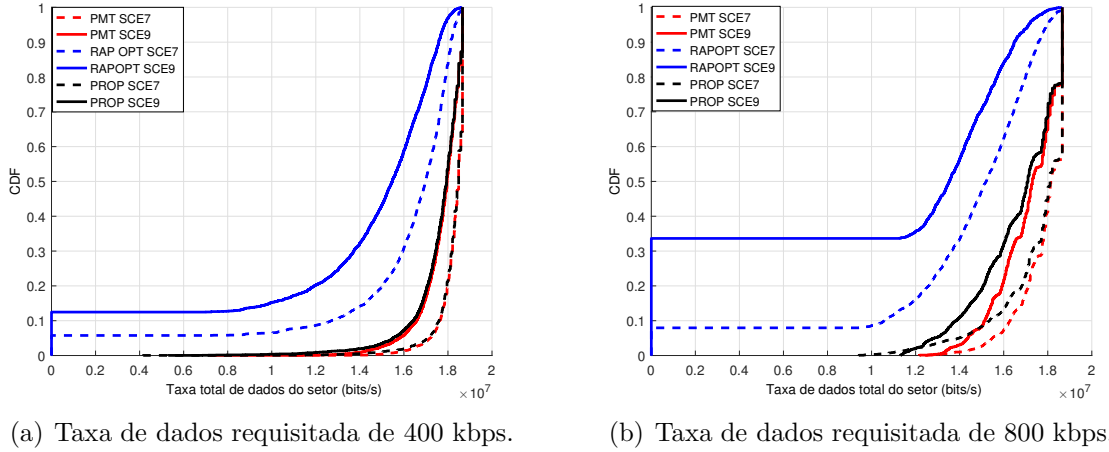


Figura 11: CDF da taxa de dados total para um requisito específico de taxa de dados para os algoritmos PMT OPT, RAP OPT, e PROP com quatro serviços ( $S = 4$ ). Assumimos os cenários 7 e 9 e avaliamos o impacto da variável  $k_s$ .

desempenho entre os algoritmos quando variamos a variável  $k_s$ . As soluções PROP e PMT OPT apresentam um decréscimo moderado em taxa de dados total quando variamos a variável  $k_s$  na taxa de dados requisitada de 800 kbps. Basicamente, a diferença entre a taxa de dados total quando variamos a variável  $k_s$  é mais nítido quando a taxa de *outage* é alta (veja a Figura 8).

Em resumo, a partir da análise dos resultados das Figuras 5 – 11(b), podemos ver que nossa solução proposta possui desempenho próximo do ótimo considerando as restrições e o objetivo do problema nas cargas pequenas e médias. Como estamos lidando com algoritmos, é importante fazer uma análise da complexidade computacional das soluções apresentadas.

A complexidade computacional no pior caso para obter a solução ótima utilizando o algoritmo BC é de  $(\sqrt{2})^{(JNM)}$ , como explicado no Apêndice 5. A complexidade

computacional no pior caso do algoritmo PROP, que é calculada no apêndice 5, é de  $\mathcal{O}(J(M \times N \times \log_2 N))$ , e é uma complexidade polinomial. Como podemos observar, a complexidade da solução subótima é polinomial e portanto bem menor que a complexidade da solução ótima que é exponencial em termos das variáveis do problema. De acordo com [35], a complexidade computacional no pior caso da solução RAP OPT é também exponencial. Portanto, analisando a complexidade computacional e desempenho do algoritmo PROP, concluimos que ele possui um bom compromisso entre desempenho e complexidade quando comparada com as estratégias RAP OPT e PMT OPT.

## 4 SOLUÇÃO ÓTIMA PARA PROBLEMAS DE EFICIÊNCIA ENERGÉTICA E HEURÍSTICA

Este capítulo apresenta à solução ótima do problema formulado nas Seções 2.3, 2.4 e 2.5, uma solução de baixa complexidade para o problema PMEE e os resultados de desempenho. Mais especificamente, nas Seções 4.1, 4.2 e 4.3, é detalhada uma aplicação do método para linearização dos problemas formulados nas Seções 2.3, 2.4 e 2.5, respectivamente, e manipulações algébricas para reformulação dos problemas são aplicadas para elaboração de uma versão matricial e compacta para uso em softwares comerciais. A heurística proposta neste trabalho para à solução do problema de otimização PMEE é descrita na Seção 4.4. Por fim, na Seção 4.5 são apresentados os resultados de desempenho em relação a taxa de dados, a potência não utilizada e eficiência energética comparando as soluções ótimas dos problemas PMEE, PMP e PMDTP, e a heurística proposta para o problema PMEE.

### 4.1 Solução Ótima para o Problema PMEE

Assim como foi feito na Seção 3.1 devemos simplificar a estrutura do problema (4) unificando as variáveis de otimização  $\mathbf{X}$  e  $\mathbf{p}$ . Isso é feito através da variável  $\lambda_{j,n,m}$ . Dessa forma, podemos reformular o problema PMEE assumindo uma nova variável de otimização (binária)  $y_{j,n,m}$  que assume o valor 1 se o RB  $n$  é atribuído ao terminal  $j$  e a transmissão é configurada com o  $m^{\text{ésimo}}$  nível de MCS. Neste caso, a potência alocada ao RB  $n$  pertencente ao terminal  $j$  é igual a  $\lambda_{j,n,m}$  dado pela equação (7). O problema estudado pode ser reformulado como segue

$$\min_{y_{j,n,m}} \frac{\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} \lambda_{j,n,m} \cdot y_{j,n,m}}{\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot y_{j,n,m}}, \quad (13a)$$

sujeito a

$$\sum_{j \in \mathcal{J}} \sum_{m \in \mathcal{M}} y_{j,n,m} \leq 1, \quad \forall n \in \mathcal{N}, \quad (13b)$$

$$y_{j,n,m} \in \{0, 1\}, \quad \forall j \in \mathcal{J}, \forall n \in \mathcal{N} \text{ e } \forall m \in \mathcal{M}, \quad (13c)$$

$$\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} y_{j,n,m} \cdot \lambda_{j,n,m} \leq P^{\text{tot}}, \quad (13d)$$

$$\sum_{j \in \mathcal{J}_s} u \left( \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot y_{j,n,m}, t_j \right) \geq k_s, \quad \forall s \in \mathcal{S}, \quad (13e)$$

$$\sum_{m \in \mathcal{M}} y_{j,n,m} \leq 1, \quad \forall j \in \mathcal{J} \text{ e } \forall n \in \mathcal{N}, \quad (13f)$$

O problema (13) pertence a classe dos problemas de otimização inteiros ou combinatoriais. Contudo, ele continua não linear devido a função objetivo (13a) e a restrição (13e). De forma a linearizar a restrição (13e), da mesma forma que foi feito na seção 3.1, iremos introduzir uma nova variável de otimização. Considere  $\rho_j$  como uma variável binária de seleção que assume os valores 1 se o terminal  $j$  é selecionado para ser satisfeito e 0 de outra forma. Observe que  $\boldsymbol{\rho} = [\rho_1 \cdots \rho_J]^T$ . Dessa forma, o problema (13) pode ser reformulado substituindo a restrição (13e) pelas três restrições (9), dadas anteriormente.

Com objetivo de linearizar a função objetivo (13a), iremos introduzir uma nova variável de otimização  $x_0 = \frac{1}{\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot y_{j,n,m}}$  e a seguinte transformação:  $x_{j,n,m} = y_{j,n,m} \cdot x_0$  [60]. Observe que a substituição das variáveis  $x_0 \in \mathbb{R}$  e  $x_{j,n,m} \in \mathbb{R}$  no problema (13) irá tornar necessária a adição da restrição a seguir:

$$\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot x_{j,n,m} = 1. \quad (14a)$$

A ideia principal é resolver o problema (13) substituindo as variáveis  $y_{j,n,m}$  pelas variáveis  $x_{j,n,m}$  e  $x_0$ . Após a resolução do novo problema e de posse dos valores das variáveis  $x_{j,n,m}$  e  $x_0$  podemos calcular  $y_{j,n,m}$ . Contudo, não existe garantia de que a variável  $y_{j,n,m}$  permanecerá binária após estas transformações. De forma a assegurar isto, introduziremos uma nova variável de otimização binária  $z_{j,n,m}$  e iremos determinar duas constantes: uma  $f_1$  tal que seu valor seja  $f_1 > x_{j,n,m}, \forall j \in \mathcal{J}, \forall n \in \mathcal{N}$  e  $\forall m \in \mathcal{M}$ ; e outra constante  $f_2$  tal que seu valor seja  $f_2 > x_0$ . Então iremos adicionar três novas restrições

ao problema  $\forall j \in \mathcal{J}, \forall n \in \mathcal{N}$  and  $\forall m \in \mathcal{M}$ :

$$x_{j,n,m} \leq f_1 z_{j,n,m}, \quad (15a)$$

$$x_{j,n,m} - x_0 - f_2 z_{j,n,m} \geq -f_2, \quad (15b)$$

$$x_{j,n,m} - x_0 + f_2 z_{j,n,m} \leq f_2. \quad (15c)$$

Observe que se  $z_{j,n,m} = 0$  então  $x_{j,n,m} = 0$  e se  $z_{j,n,m} = 1$  então  $x_{j,n,m} = x_0$ . Ao substituírmos as variáveis  $x_0$  e  $x_{j,n,m}$  na restrição (13e) modificada, ela tornou-se não linear, como segue:

$$\sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot x_{j,n,m} \geq \rho_j t_j x_0, \quad \forall j \in \mathcal{J}, \quad (16a)$$

$$\rho_j \in \{0, 1\}, \quad \forall j \in \mathcal{J}, \quad (16b)$$

$$\sum_{j \in \mathcal{J}_s} \rho_j \geq k_s, \quad \forall s \in \mathcal{S}. \quad (16c)$$

Portanto, iremos criar uma nova variável de otimização auxiliar  $\beta_j = \rho_j \cdot x_0$  para assegurar a linearidade do problema. De forma equivalente a feita anteriormente, iremos introduzir outra variável de otimização binária  $a_j$  para assegurar que  $\rho_j = \frac{\beta_j}{x_0} \quad \forall j \in \mathcal{J}$  seja binária e iremos definir duas novas constantes  $f_3$  e  $f_4$ , em que  $f_3 > \beta_j, \forall j \in \mathcal{J}$  e  $f_4 > x_0$ . Portanto, iremos ter três novas restrições adicionadas ao problema:

$$\beta_j \leq f_3 a_j, \quad \forall j \in \mathcal{J}, \quad (17a)$$

$$\beta_j - x_0 - f_4 a_j \geq -f_4, \quad \forall j \in \mathcal{J}, \quad (17b)$$

$$\beta_j - x_0 + f_4 a_j \leq f_4, \quad \forall j \in \mathcal{J}. \quad (17c)$$

Observe que se  $a_j = 0$  então  $\beta_j = 0$  e quando  $a_j = 1$  então  $\beta_{j,n,m} = x_0$ . O novo problema PMEE pode ser reformulado como segue:

$$\min_{x_{j,n,m}, x_0, \beta_j, z_{j,n,m}, a_j} \sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} \lambda_{j,n,m} \cdot x_{j,n,m}, \quad (18a)$$

sujeito a

$$\sum_{j \in \mathcal{J}} \sum_{m \in \mathcal{M}} x_{j,n,m} \leq x_0, \quad \forall n \in \mathcal{N}, \quad (18b)$$

$$\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} x_{j,n,m} \cdot \lambda_{j,n,m} \leq P^{\text{tot}} \cdot x_0, \quad (18c)$$

$$\sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot x_{j,n,m} \geq \beta_j t_j, \quad \forall j \in \mathcal{J}, \quad (18d)$$

$$\sum_{j \in \mathcal{J}_s} \beta_j \geq k_s \cdot x_0, \quad \forall s \in \mathcal{S}, \quad (18e)$$

$$x_0, x_{j,n,m} \geq 0, \quad \forall j \in \mathcal{J}, \quad \forall n \in \mathcal{N} \text{ e } \forall m \in \mathcal{M}, \quad (18f)$$

$$\sum_{m \in \mathcal{M}} x_{j,n,m} \leq x_0, \quad \forall j \in \mathcal{J} \text{ e } \forall n \in \mathcal{N}, \quad (18g)$$

$$\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot x_{j,n,m} = 1, \quad (18h)$$

$$x_{j,n,m} \leq f_1 z_{j,n,m}, \quad \forall j \in \mathcal{J}, \quad \forall n \in \mathcal{N} \text{ e } \forall m \in \mathcal{M}, \quad (18i)$$

$$x_{j,n,m} - x_0 - f_2 z_{j,n,m} \geq -f_2, \quad \forall j \in \mathcal{J}, \quad \forall n \in \mathcal{N} \text{ e } \forall m \in \mathcal{M}, \quad (18j)$$

$$x_{j,n,m} - x_0 + f_2 z_{j,n,m} \leq f_2, \quad \forall j \in \mathcal{J}, \quad \forall n \in \mathcal{N} \text{ e } \forall m \in \mathcal{M}, \quad (18k)$$

$$\beta_j \leq f_3 a_j, \quad \forall j \in \mathcal{J}, \quad (18l)$$

$$\beta_j - x_0 - f_4 a_j \geq -f_4, \quad \forall j \in \mathcal{J}, \quad (18m)$$

$$\beta_j - x_0 + f_4 a_j \leq f_4, \quad \forall j \in \mathcal{J}. \quad (18n)$$

De modo a escrever o novo problema de uma maneira compacta iremos representar as variáveis e entradas do problema em forma de vetores e matrizes. A seguir iremos utilizar linhas verticais e horizontais quando definirmos vetores e matrizes para fácil compreensão de sua estrutura. Considere as definições a seguir:

$$\boldsymbol{\lambda}_j = \left[ \lambda_{j,1,1} \quad \cdots \quad \lambda_{j,1,M} \quad | \cdots | \quad \lambda_{j,N,1} \quad \cdots \quad \lambda_{j,N,M} \right]^T,$$

$$\mathbf{x}_j = \left[ x_{j,1,1} \quad \cdots \quad x_{j,1,M} \quad | \cdots | \quad x_{j,N,1} \quad \cdots \quad x_{j,N,M} \right]^T,$$

$$\mathbf{z}_j = \left[ z_{j,1,1} \quad \cdots \quad z_{j,1,M} \quad | \cdots | \quad z_{j,N,1} \quad \cdots \quad z_{j,N,M} \right]^T,$$

$$\mathbf{v} = \left[ v^1 \quad \cdots \quad v^M \right]^T,$$

$$\mathbf{x} = \left[ \mathbf{x}_1^T \quad \cdots \quad \mathbf{x}_J^T \right]^T,$$

$$\mathbf{z} = \begin{bmatrix} \mathbf{z}_1^T & \cdots & \mathbf{z}_J^T \end{bmatrix}^T,$$

$$\boldsymbol{\beta} = \begin{bmatrix} \boldsymbol{\beta}_1^T & \cdots & \boldsymbol{\beta}_J^T \end{bmatrix}^T \text{ e}$$

$$\mathbf{a} = \begin{bmatrix} a_1^T & \cdots & a_J^T \end{bmatrix}^T.$$

Definimos a variável de otimização como  $\mathbf{b} = \left[ \mathbf{x}^T \mid x_0^T \mid \mathbf{z}^T \mid \boldsymbol{\beta}^T \mid \mathbf{a}^T \right]^T$ . Observe que o escalar  $x_0$  e os vetores  $\mathbf{x}$ ,  $\mathbf{z}$ ,  $\boldsymbol{\beta}$  e  $\mathbf{a}$  podem ser obtidos a partir de  $\mathbf{b}$  através do uso das seguintes relações:  $\mathbf{x} = \mathbf{A}_1 \mathbf{b}$ ,  $x_0 = \mathbf{A}_2 \mathbf{b}$ ,  $\mathbf{z} = \mathbf{A}_3 \mathbf{b}$ ,  $\boldsymbol{\beta} = \mathbf{A}_4 \mathbf{b}$  e  $\mathbf{a} = \mathbf{A}_5 \mathbf{b}$  com

$$\mathbf{A}_1 = \begin{bmatrix} \mathbf{I}_{JNM} & \mathbf{0}_{JNM \times 1} & \mathbf{0}_{JNM \times JNM} & \mathbf{0}_{JNM \times J} & \mathbf{0}_{JNM \times J} \end{bmatrix},$$

$$\mathbf{A}_2 = \begin{bmatrix} \mathbf{0}_{1 \times JNM} & 1 & \mathbf{0}_{1 \times JNM} & \mathbf{0}_{1 \times J} & \mathbf{0}_{1 \times J} \end{bmatrix},$$

$$\mathbf{A}_3 = \begin{bmatrix} \mathbf{0}_{JNM \times JNM} & \mathbf{0}_{JNM \times 1} & \mathbf{I}_{JNM} & \mathbf{0}_{JNM \times J} & \mathbf{0}_{JNM \times J} \end{bmatrix},$$

$$\mathbf{A}_4 = \begin{bmatrix} \mathbf{0}_{J \times JNM} & \mathbf{0}_{J \times 1} & \mathbf{0}_{J \times JNM} & \mathbf{I}_J & \mathbf{0}_{J \times J} \end{bmatrix} \text{ e}$$

$$\mathbf{A}_5 = \begin{bmatrix} \mathbf{0}_{J \times JNM} & \mathbf{0}_{J \times 1} & \mathbf{0}_{J \times JNM} & \mathbf{0}_{J \times J} & \mathbf{I}_J \end{bmatrix},$$

em que  $\mathbf{I}_a$  onde  $\mathbf{I}_a$  é uma matriz identidade com dimensão  $a \times a$  e  $\mathbf{0}_{a \times b}$  é uma matriz  $a \times b$  compostas de 0's.

A função objetivo (18a) pode ser escrita como  $\mathbf{B}_1 \mathbf{A}_1 \mathbf{b}$  em que  $\mathbf{B}_1 = [\boldsymbol{\lambda}_1^T \cdots \boldsymbol{\lambda}_J^T]^T$  com dimensão  $JNM \times 1$ .

A restrição (18b) pode ser escrita em forma matricial como  $(\mathbf{B}_2 \mathbf{A}_1 - \mathbf{B}_3 \mathbf{A}_2) \mathbf{b} \leq \mathbf{0}_N$  with  $\mathbf{B}_3 = (1, \dots, 1_N)^T$  e

$$\mathbf{B}_2 = \underbrace{\left[ \text{diag} \left( \underbrace{\mathbf{1}_M^T, \dots, \mathbf{1}_M^T}_{N \text{ vezes}} \right) \mid \cdots \mid \text{diag} \left( \underbrace{\mathbf{1}_M^T, \dots, \mathbf{1}_M^T}_{N \text{ vezes}} \right) \right]}_{J \text{ vezes}}, \quad (19)$$

em que  $\mathbf{1}_a$  é um vetor coluna de tamanho  $a$  composto de 1's e  $\text{diag}(\mathbf{u}_1, \mathbf{u}_2, \dots)$  é um bloco de matriz diagonal com  $\mathbf{u}_1$  na primeira posição da diagonal principal,  $\mathbf{u}_2$  na segunda posição da diagonal principal, e assim por diante. Observe que os argumentos de  $\text{diag}(\cdot)$  podem ser escalares, vetores ou matrizes.

A restrição (18c) é escrita como  $(\mathbf{B}_1 \mathbf{A}_1 - P^{\text{tot}} \mathbf{A}_2) \mathbf{b} \leq 0$ .

A restrição (18d) é representada como  $(\mathbf{B}_5 \mathbf{A}_4 - \mathbf{B}_4 \mathbf{A}_1) \mathbf{b} \leq 0$ , em que  $\mathbf{B}_4 = \text{diag} \left( \underbrace{\left[ \underbrace{\mathbf{v}^T \cdots \mathbf{v}^T}_{N \text{ vezes}} \right], \dots, \left[ \underbrace{\mathbf{v}^T \cdots \mathbf{v}^T}_{N \text{ vezes}} \right]}_{J \text{ vezes}} \right)$  e  $\mathbf{B}_5 = \text{diag}(t_1, \dots, t_J)$ .

Restrição (18e) pode ser representada em forma de matriz como  $(\mathbf{B}_7 \mathbf{B}_8 \mathbf{A}_2 - \mathbf{B}_6 \mathbf{A}_4) \mathbf{b} \leq \mathbf{0}_{1 \times S}$ , em que  $\mathbf{B}_6 = \text{diag}(\mathbf{1}_{J_1}^T, \dots, \mathbf{1}_{J_S}^T)$ ,  $\mathbf{B}_7 = \text{diag}(t_1, \dots, t_J)$  e  $\mathbf{B}_8 = \mathbf{1}_{S \times 1}$ .

A restrição (18g) pode ser escrita como  $(\mathbf{B}_{14}\mathbf{A}_1 - \mathbf{B}_{15}\mathbf{A}_2)\mathbf{b} \leq \mathbf{0}_{JN \times 1}$  em que  $\mathbf{B}_{14} = \text{diag} \left( \underbrace{\mathbf{1}_M^T, \dots, \mathbf{1}_M^T}_{JN \text{ vezes}} \right)$  e  $\mathbf{B}_{15} = \mathbf{1}_{JN \times 1}$ .

A restrição (18h) pode ser escrita como  $\mathbf{B}_{13}\mathbf{A}_1\mathbf{b} = 1$  em que  $\mathbf{B}_{13} = \underbrace{[\mathbf{v}^T \dots \mathbf{v}^T]^T}_{JNM \text{ vezes}}$ .

A restrição (18i) é escrita como  $(\mathbf{B}_9\mathbf{A}_1 - f_1\mathbf{B}_9\mathbf{A}_3)\mathbf{b} \leq \mathbf{0}_{1 \times JNM}$  em que  $\mathbf{B}_9 = \mathbf{I}_{JNM}$  e um  $f_1$  com dimensão  $1 \times JNM$

A restrição (18j) é escrita como  $(-\mathbf{B}_9\mathbf{A}_1 + \mathbf{B}_{10}\mathbf{A}_2 + f_2\mathbf{B}_9\mathbf{A}_3)\mathbf{b} \leq f_2\mathbf{B}_{10}$  onde  $\mathbf{B}_{10} = \mathbf{1}_{JMN \times 1}$  e um  $f_2$  com dimensão  $1 \times JNM$ .

A restrição (18k) é escrita como  $(\mathbf{B}_9\mathbf{A}_1 - \mathbf{B}_{10}\mathbf{A}_2 + f_2\mathbf{B}_9\mathbf{A}_3)\mathbf{b} \leq f_2\mathbf{B}_{10}$ .

A restrição (18l) é escrita como  $(\mathbf{B}_{11}\mathbf{A}_4 - f_3\mathbf{B}_{11}\mathbf{A}_5)\mathbf{b} \leq \mathbf{0}_{J \times 1}$  onde  $\mathbf{B}_{11} = \mathbf{I}_J$  e um  $f_3$  com dimensão  $1 \times JNM$ .

A restrição (18m) é escrita como  $(-\mathbf{B}_{11}\mathbf{A}_4 + \mathbf{B}_{12}\mathbf{A}_2 + f_4\mathbf{B}_{11}\mathbf{A}_5)\mathbf{b} \leq f_4\mathbf{B}_{12}$  onde  $\mathbf{B}_{12} = \mathbf{I}_{JNM}$  e um  $f_4$  com dimensão  $1 \times JNM$ .

A restrição (18n) é escrita como  $(\mathbf{B}_{11}\mathbf{A}_4 - \mathbf{B}_{12}\mathbf{A}_2 + f_4\mathbf{B}_{11}\mathbf{A}_5)\mathbf{b} \leq f_4\mathbf{B}_{12}$ .

Portanto, arranjando as expressões desenvolvidas anteriormente temos

$$\min_{\mathbf{b}} (\mathbf{B}_1\mathbf{A}_1\mathbf{b}), \quad (20a)$$

$$\text{sujeito a } \mathbf{P}\mathbf{b} \leq \mathbf{q}, \quad (20b)$$

$$\mathbf{b} \text{ é um vetor binário}, \quad (20c)$$

onde as novas variáveis são definidas a seguir:

$$\mathbf{P} = [\mathbf{R}_1 \ \mathbf{R}_2 \ \mathbf{R}_3 \ \mathbf{R}_4 \ \mathbf{R}_5 \ \mathbf{R}_6 \ \mathbf{R}_7 \ \mathbf{R}_8 \ \mathbf{R}_9 \ \mathbf{R}_{10} \ \mathbf{R}_{11} \ \mathbf{R}_{12} ], \text{ onde}$$

$$\mathbf{R}_1 = (\mathbf{B}_2\mathbf{A}_1 - \mathbf{B}_3\mathbf{A}_2)^T, \ \mathbf{R}_2 = (\mathbf{B}_1\mathbf{A}_1 - P^{\text{tot}}\mathbf{A}_2)^T, \ \mathbf{R}_3 = (\mathbf{B}_5\mathbf{A}_4 - \mathbf{B}_4\mathbf{A}_1)^T, \ \mathbf{R}_4 =$$

$$(\mathbf{B}_7\mathbf{B}_8\mathbf{A}_2 - \mathbf{B}_6\mathbf{A}_4)^T, \ \mathbf{R}_5 = (\mathbf{B}_9\mathbf{A}_1 - f_1\mathbf{B}_9\mathbf{A}_3)^T, \ \mathbf{R}_6 = (-\mathbf{B}_9\mathbf{A}_1 + \mathbf{B}_{10}\mathbf{A}_2 + f_2\mathbf{B}_9\mathbf{A}_3)^T,$$

$$\mathbf{R}_7 = (\mathbf{B}_9\mathbf{A}_1 - \mathbf{B}_{10}\mathbf{A}_2 + f_2\mathbf{B}_9\mathbf{A}_3)^T, \ \mathbf{R}_8 = (\mathbf{B}_{11}\mathbf{A}_4 - f_3\mathbf{B}_{11}\mathbf{A}_5)^T, \ \mathbf{R}_9 = (-\mathbf{B}_{11}\mathbf{A}_4 +$$

$$\mathbf{B}_{12}\mathbf{A}_2 + f_4\mathbf{B}_{11}\mathbf{A}_5)^T, \ \mathbf{R}_{10} = (\mathbf{B}_{11}\mathbf{A}_4 - \mathbf{B}_{12}\mathbf{A}_2 + f_4\mathbf{B}_{11}\mathbf{A}_5)^T, \ \mathbf{R}_{11} = (\mathbf{B}_{13}\mathbf{A}_1)^T, \ \mathbf{R}_{12} =$$

$$(\mathbf{B}_{14}\mathbf{A}_1 - \mathbf{B}_{15}\mathbf{A}_2)^T \text{ e}$$

$$\mathbf{q} = [\mathbf{0}_N^T \ 0 \ \mathbf{0}_J^T \ \mathbf{0}_S^T \ \mathbf{0}_{JNM}^T \ \mathbf{f}_2^T \ \mathbf{f}_2^T \ \mathbf{0}_J^T \ \mathbf{f}_4^T \ \mathbf{f}_4^T \ 1^T \ \mathbf{0}_{JN}^T].$$

Baseado no desenvolvimento anterior transformamos o problema (4) em um MILP. Este problema pode ser resolvido através de métodos padrões como o algoritmo BC (também conhecido como BB) [52]. A complexidade computacional média para obter à solução ótima através destes métodos é muito menor do que usando força bruta (enumeração completa de todas as alocações de RB e MCSs possíveis). Apesar disso, a complexidade do método BC cresce exponencialmente com o número de restrições e variáveis. A forma linear do PMEE tem  $JNM + 1 + JNM + J + J$  variáveis de otimização e  $N + 1 + J + S + JNM + JNM + JNM + J + J + J + 1 + JN$  restrições, que podem assumir grandes valores mesmo para uma quantidade pequena de terminais, RBs,



MCSs e serviços.

## 4.2 Solução Ótima para o Problema PMP

O problema (5) pode ser simplificado e linearizado da mesma forma da Seção 3.1. Essa simplificação pode ser feita através da unificação das variáveis de otimização  $\mathbf{X}$  e  $\mathbf{p}$ , e uma linearização da restrição (5e). Portanto o problema PMP linearizado pode ser reescrito como segue

$$\min_{y_{j,n,m}, \rho_j} \sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} \lambda_{j,n,m} \cdot y_{j,n,m}, \quad (21a)$$

sujeito a

$$\sum_{j \in \mathcal{J}} \sum_{m \in \mathcal{M}} y_{j,n,m} \leq 1, \quad \forall n \in \mathcal{N}, \quad (21b)$$

$$y_{j,n,m} \in \{0, 1\}, \quad \forall j \in \mathcal{J}, \forall n \in \mathcal{N} \text{ and } \forall m \in \mathcal{M}, \quad (21c)$$

$$\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} y_{j,n,m} \cdot \lambda_{j,n,m} \leq P^{\text{tot}}, \quad (21d)$$

$$\sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot y_{j,n,m} \geq \rho_j t_j, \quad \forall j \in \mathcal{J}, \quad (21e)$$

$$\rho_j \in \{0, 1\}, \quad \forall j \in \mathcal{J}, \quad (21f)$$

$$\sum_{j \in \mathcal{J}_s} \rho_j \geq k_s, \quad \forall s \in \mathcal{S}. \quad (21g)$$

$$\sum_{m \in \mathcal{M}} y_{j,n,m} \leq 1, \quad \forall j \in \mathcal{J} \text{ e } \forall n \in \mathcal{N}. \quad (21h)$$

De modo a escrever este novo problema de uma maneira compacta iremos representar as variáveis do problema e entradas em forma de vetor e matriz. A seguir iremos utilizar linhas verticais e horizontais quando definirmos vetores e matrizes para fácil compreensão de sua estrutura. Considere as definições a seguir:

$$\mathbf{v} = \begin{bmatrix} 0 & v^1 & \dots & v^M \end{bmatrix}^T,$$

$$\boldsymbol{\lambda}_j = \begin{bmatrix} \lambda_{j,1,1} & \dots & \lambda_{j,1,M} & | \dots | & \lambda_{j,N,1} & \dots & \lambda_{j,N,M} \end{bmatrix}^T,$$

$$\mathbf{y}_j = \begin{bmatrix} y_{j,1,1} & \dots & y_{j,1,M} & | \dots | & y_{j,N,1} & \dots & y_{j,N,M} \end{bmatrix}^T,$$

$$\mathbf{k} = \begin{bmatrix} k_1 & \dots & k_S \end{bmatrix}^T \text{ e}$$

$$\mathbf{y} = \begin{bmatrix} \mathbf{y}_1^T & \dots & \mathbf{y}_J^T \end{bmatrix}^T.$$

Definimos a variável de otimização como  $\mathbf{z} = [\mathbf{y}^T \mid \boldsymbol{\rho}^T]^T$ , onde  $\boldsymbol{\rho}$  foi definido na Seção 3.1. Observe que os vetores  $\mathbf{y}$  e  $\boldsymbol{\rho}$  podem ser obtidos a partir de  $\mathbf{z}$  através do uso das relações a seguir:  $\mathbf{y} = \mathbf{A}_1\mathbf{z}$  e  $\boldsymbol{\rho} = \mathbf{A}_2\mathbf{z}$ , onde  $\mathbf{A}_1 = [\mathbf{I}_{JNM} \mid \mathbf{0}_{JNM \times J}]$  e  $\mathbf{A}_2 = [\mathbf{0}_{J \times JNM} \mid \mathbf{I}_J]$  em que  $\mathbf{I}_a$  é uma matriz identidade com dimensões  $a \times a$  e  $\mathbf{0}_{a \times b}$  é uma matriz  $a \times b$  composta de 0's.

A função objetivo do problema (21a) pode ser escrita como  $\mathbf{a}^T \mathbf{A}_1 \mathbf{z}$  onde  $\mathbf{a} = \left[ \underbrace{\lambda_1^T \cdots \lambda_J^T}_{N \text{ vezes}} \right]^T$ .

A restrição (21b) pode ser escrita na forma matricial como  $\mathbf{B} \mathbf{A}_1 \mathbf{z} \leq \mathbf{1}_N$  com

$$\mathbf{B} = \left[ \underbrace{\text{diag} \left( \underbrace{\mathbf{1}_M^T, \dots, \mathbf{1}_M^T}_{N \text{ vezes}} \right) \mid \dots \mid \text{diag} \left( \underbrace{\mathbf{1}_M^T, \dots, \mathbf{1}_M^T}_{N \text{ vezes}} \right)}_{J \text{ vezes}} \right], \quad (22)$$

onde  $\mathbf{1}_a$  é um vetor coluna de tamanho  $a$  composto de 1's e  $\text{diag}(\mathbf{u}_1, \mathbf{u}_2, \dots)$  é um bloco de matriz diagonal com  $\mathbf{u}_1$  na primeira posição da diagonal principal,  $\mathbf{u}_2$  na segunda posição da diagonal principal, e assim por diante. Observe que os argumentos de  $\text{diag}(\cdot)$  podem ser escalares, vetores ou matrizes.

A restrição (21d) é escrita como  $\mathbf{c}^T \mathbf{A}_1 \mathbf{z} \leq P^{\text{tot}}$  com  $\mathbf{c} = [\lambda_1^T \cdots \lambda_J^T]^T$ .

A restrição do problema (21e) é representado como  $\mathbf{D} \mathbf{A}_1 \mathbf{z} \geq \mathbf{E} \mathbf{A}_2 \mathbf{z} \Rightarrow (\mathbf{E} \mathbf{A}_2 - \mathbf{D} \mathbf{A}_1) \mathbf{z} \leq$

$$\mathbf{0}_J \text{ em que } \mathbf{D} = \text{diag} \left( \underbrace{\left[ \underbrace{\mathbf{v}^T \cdots \mathbf{v}^T}_{N \text{ vezes}} \right]}_{J \text{ vezes}}, \dots, \underbrace{\left[ \underbrace{\mathbf{v}^T \cdots \mathbf{v}^T}_{N \text{ vezes}} \right]}_{J \text{ vezes}} \right) \text{ e } \mathbf{E} = \text{diag}(t_1, \dots, t_J).$$

As restrições (21g) podem ser representados em forma de matriz como  $-\mathbf{F} \mathbf{A}_2 \mathbf{z} \leq -\mathbf{k}$  where  $\mathbf{F} = \text{diag}(\mathbf{1}_{J_1}^T, \dots, \mathbf{1}_{J_S}^T)$ .

Por fim, a restrição do problema (21h) pode ser escrita como  $\mathbf{G} \mathbf{A}_1 \mathbf{z} \leq \mathbf{1}_{JN}$

$$\text{com } \mathbf{G} = \text{diag} \left( \underbrace{\mathbf{1}_M^T, \dots, \mathbf{1}_M^T}_{JN \text{ vezes}} \right).$$

Portanto, arranjando as expressões desenvolvidas até agora temos

$$\min_{\mathbf{z}} (\mathbf{o}^T \mathbf{z}), \quad (23a)$$

$$\text{sujeito a } \mathbf{P} \mathbf{z} \leq \mathbf{q}, \quad (23b)$$

$$\mathbf{z} \text{ é um vetor binário}, \quad (23c)$$

Onde as novas variáveis são definidas a seguir:  $\mathbf{o} = \mathbf{A}_1^T \mathbf{a}$  e

$$\mathbf{P} = \left[ (\mathbf{B}\mathbf{A}_1)^T (\mathbf{c}^T \mathbf{A}_1)^T (\mathbf{E}\mathbf{A}_2 - \mathbf{D}\mathbf{A}_1)^T (-\mathbf{F}\mathbf{A}_2)^T (\mathbf{G}\mathbf{A}_1)^T \right]^T$$

$$\text{e } \mathbf{q} = [\mathbf{1}_N^T \quad P^{\text{tot}} \quad \mathbf{0}_J^T \quad -\mathbf{k}^T \quad \mathbf{1}_{JN}^T]^T.$$

Desta forma nós transformamos o problema (5) em um problema ILP. Este problema pode ser resolvido por métodos padrões, como o algoritmo BC (também conhecido como BB) [52]. A complexidade computacional média para obter a solução ótima através destes métodos é muito menor do que usando força bruta (Enumeração completa de todas as alocações de RB possíveis). Apesar disso, a complexidade do método BC cresce exponencialmente com o número de restrições e variáveis. A forma linear do PMP tem  $JNM + J$  variáveis de otimização e  $JN + J + N + S + 1$  restrições, que podem assumir grandes valores mesmo para uma quantidade pequena de terminais, RBs, MCSs e serviços.

### 4.3 Solução Ótima para o Problema PMDTP

O problema (6) pode ser simplificado e linearizado da mesma forma da seção 3.1. Para realizar tal simplificação, unificamos as variáveis  $\mathbf{X}$  e  $\mathbf{p}$  e linearizamos a restrição (6e). Portanto o problema PMDTP linearizado pode ser reescrito como segue:

$$\max_{y_{j,n,m}, \rho_j} \frac{\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot y_{j,n,m}}{\sum_{n \in \mathcal{N}} v^M} - \frac{\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} \lambda_{j,n,m} \cdot y_{j,n,m}}{P^{\text{tot}}}, \quad (24a)$$

sujeito a

$$\sum_{j \in \mathcal{J}} \sum_{m \in \mathcal{M}} y_{j,n,m} \leq 1, \quad \forall n \in \mathcal{N}, \quad (24b)$$

$$y_{j,n,m} \in \{0, 1\}, \quad \forall j \in \mathcal{J}, \forall n \in \mathcal{N} \text{ and } \forall m \in \mathcal{M}, \quad (24c)$$

$$\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} y_{j,n,m} \cdot \lambda_{j,n,m} \leq P^{\text{tot}}, \quad (24d)$$

$$\sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot y_{j,n,m} \geq \rho_j t_j, \quad \forall j \in \mathcal{J}, \quad (24e)$$

$$\rho_j \in \{0, 1\}, \quad \forall j \in \mathcal{J}, \quad (24f)$$

$$\sum_{j \in \mathcal{J}_s} \rho_j \geq k_s, \quad \forall s \in \mathcal{S}. \quad (24g)$$

$$\sum_{m \in \mathcal{M}} y_{j,n,m} \leq 1, \quad \forall j \in \mathcal{J} \text{ e } \forall n \in \mathcal{N}. \quad (24h)$$

De modo a escrever este novo problema de uma maneira compacta iremos representar as variáveis do problema e entradas em forma matricial. A seguir, iremos utilizar

linhas verticais e horizontais quando definirmos vetores e matrizes para fácil compreensão de sua estrutura. Considere as definições a seguir:

$$\begin{aligned}\mathbf{v} &= \begin{bmatrix} 0 & v^1 & \dots & v^M \end{bmatrix}^T, \\ \boldsymbol{\lambda}_j &= \begin{bmatrix} \lambda_{j,1,1} & \dots & \lambda_{j,1,M} & | \dots | & \lambda_{j,N,1} & \dots & \lambda_{j,N,M} \end{bmatrix}^T, \\ \mathbf{y}_j &= \begin{bmatrix} y_{j,1,1} & \dots & y_{j,1,M} & | \dots | & y_{j,N,1} & \dots & y_{j,N,M} \end{bmatrix}^T, \\ \mathbf{k} &= \begin{bmatrix} k_1 & \dots & k_S \end{bmatrix}^T \text{ e} \\ \mathbf{y} &= \begin{bmatrix} \mathbf{y}_1^T & \dots & \mathbf{y}_J^T \end{bmatrix}^T.\end{aligned}$$

Definimos a variável de otimização como  $\mathbf{z} = \begin{bmatrix} \mathbf{y}^T & | & \boldsymbol{\rho}^T \end{bmatrix}^T$  onde  $\boldsymbol{\rho}$  foi definido na Seção 3.1. Observe que os vetores  $\mathbf{y}$  e  $\boldsymbol{\rho}$  podem ser obtidos a partir de  $\mathbf{z}$  através do uso das relações a seguir:  $\mathbf{y} = \mathbf{A}_1 \mathbf{z}$  e  $\boldsymbol{\rho} = \mathbf{A}_2 \mathbf{z}$ , onde  $\mathbf{A}_1 = \begin{bmatrix} \mathbf{I}_{JNM} & | & \mathbf{0}_{JNM \times J} \end{bmatrix}$  e  $\mathbf{A}_2 = \begin{bmatrix} \mathbf{0}_{J \times JNM} & | & \mathbf{I}_J \end{bmatrix}$  onde  $\mathbf{I}_a$  é uma matriz identidade com dimensões  $a \times a$  e  $\mathbf{0}_{a \times b}$  é uma matriz  $a \times b$  composta de 0's.

A função objetivo do problema (24a) pode ser escrita como  $(\mathbf{a}^T \mathbf{A}_1 \mathbf{z} / b) - \mathbf{c}^T \mathbf{A}_1 \mathbf{z} / P^{tot}$  onde  $\mathbf{a} = \underbrace{\begin{bmatrix} \mathbf{v}^T \dots \mathbf{v}^T \end{bmatrix}^T}_{JN \text{ vezes}}$ ,  $b = \sum_{n \in \mathcal{N}} v^M$  e  $\mathbf{c} = \underbrace{\begin{bmatrix} \lambda_1^T \dots \lambda_J^T \end{bmatrix}^T}_{N \text{ vezes}}$ .

A restrição (24b) pode ser escrita na forma matricial como  $\mathbf{B} \mathbf{A}_1 \mathbf{z} \leq \mathbf{1}_N$  com

$$\mathbf{B} = \underbrace{\left[ \text{diag} \left( \underbrace{\mathbf{1}_M^T, \dots, \mathbf{1}_M^T}_{N \text{ vezes}} \right) \mid \dots \mid \text{diag} \left( \underbrace{\mathbf{1}_M^T, \dots, \mathbf{1}_M^T}_{N \text{ vezes}} \right) \right]}_{J \text{ vezes}}, \quad (25)$$

onde  $\mathbf{1}_a$  é um vetor coluna de tamanho  $a$  composto de 1's e  $\text{diag}(\mathbf{u}_1, \mathbf{u}_2, \dots)$  é um bloco de matriz diagonal com  $\mathbf{u}_1$  na primeira posição da diagonal principal,  $\mathbf{u}_2$  na segunda posição da diagonal principal, e assim por diante. Observe que os argumentos de  $\text{diag}(\cdot)$  podem ser escalares, vetores ou matrizes.

A restrição (24d) é escrita como  $\mathbf{c}^T \mathbf{A}_1 \mathbf{z} \leq P^{tot}$  com  $\mathbf{c} = \begin{bmatrix} \lambda_1^T \dots \lambda_J^T \end{bmatrix}^T$ .

A restrição do problema (24e) é representado como  $\mathbf{D} \mathbf{A}_1 \mathbf{z} \geq \mathbf{E} \mathbf{A}_2 \mathbf{z} \Rightarrow (\mathbf{E} \mathbf{A}_2 - \mathbf{D} \mathbf{A}_1) \mathbf{z} \leq$

$$\mathbf{0}_J \text{ onde } \mathbf{D} = \text{diag} \left( \underbrace{\begin{bmatrix} \mathbf{v}^T \dots \mathbf{v}^T \end{bmatrix}}_{N \text{ vezes}}, \dots, \underbrace{\begin{bmatrix} \mathbf{v}^T \dots \mathbf{v}^T \end{bmatrix}}_{N \text{ vezes}} \right) \text{ e } \mathbf{E} = \text{diag}(t_1, \dots, t_J).$$

As restrições (24g) podem ser representados em forma matricial como  $-\mathbf{F} \mathbf{A}_2 \mathbf{z} \leq$

$-\mathbf{k}$  where  $\mathbf{F} = \text{diag}(\mathbf{1}_{J_1}^T, \dots, \mathbf{1}_{J_S}^T)$ .

Por fim, a restrição do problema (24h) pode ser escrita como  $\mathbf{G}\mathbf{A}_1\mathbf{z} \leq \mathbf{1}_{JN}$

com  $\mathbf{G} = \text{diag} \left( \underbrace{\mathbf{1}_M^T, \dots, \mathbf{1}_M^T}_{JN \text{ vezes}} \right)$ .

Portanto, arranjando as expressões desenvolvidas até agora temos

$$\max_{\mathbf{z}} (\mathbf{o}^T \mathbf{z}), \quad (26a)$$

$$\text{sujeito a } \mathbf{P}\mathbf{z} \leq \mathbf{q}, \quad (26b)$$

$$\mathbf{z} \text{ é um vetor binário}, \quad (26c)$$

Onde as novas variáveis são definidas a seguir:  $\mathbf{o} = (\mathbf{A}_1^T \mathbf{a}/b - \mathbf{A}_1^T \mathbf{c}/P^{tot})$  e

$$\mathbf{P} = \left[ (\mathbf{B}\mathbf{A}_1)^T (\mathbf{c}^T \mathbf{A}_1)^T (\mathbf{E}\mathbf{A}_2 - \mathbf{D}\mathbf{A}_1)^T (-\mathbf{F}\mathbf{A}_2)^T (\mathbf{G}\mathbf{A}_1)^T \right]^T$$

$$\text{e } \mathbf{q} = [\mathbf{1}_N^T \quad P^{tot} \quad \mathbf{0}_J^T \quad -\mathbf{k}^T \quad \mathbf{1}_{JN}^T]^T.$$

Baseado no que foi desenvolvido anteriormente nós transformamos o problema (6) em um problema ILP. Este problema pode ser resolvido por métodos padrões, como o algoritmo BC (também conhecido como BB) [52]. A complexidade computacional média para obter a solução ótima através destes métodos é muito menor do que usando força bruta (Enumeração completa de todas as alocações de RB possíveis). Apesar disso, a complexidade do método BC cresce exponencialmente com o número de restrições e variáveis. A forma linear do problema PMDTP tem  $JNM + J$  variáveis de otimização e  $JN + J + N + S + 1$  restrições, que podem assumir grandes valores mesmo para uma quantidade pequena de terminais, RBs, MCSs e serviços.

#### 4.4 Heurística

Nesta seção, iremos apresentar nosso algoritmo proposto que é uma solução alternativa de baixa complexidade para o problema PMEE. Antes de apresentarmos o algoritmo proposto, iremos mostrar que o PMEE pode ser simplificado sem perdas significante de otimalidade.

##### 4.4.1 Comportamento da Solução MILP: Seleção de Usuários

De forma similar a aproximação feita na seção 3.2.1, realizamos alguns testes em termos de simulações com a solução ótima do problema PMEE com o intuito de simplificá-lo. Os aspectos principais apresentados na seção 2.1 foram modelados nas simulações aqui apresentadas e mais detalhes sobre o cenário de simulação podem ser encontrados

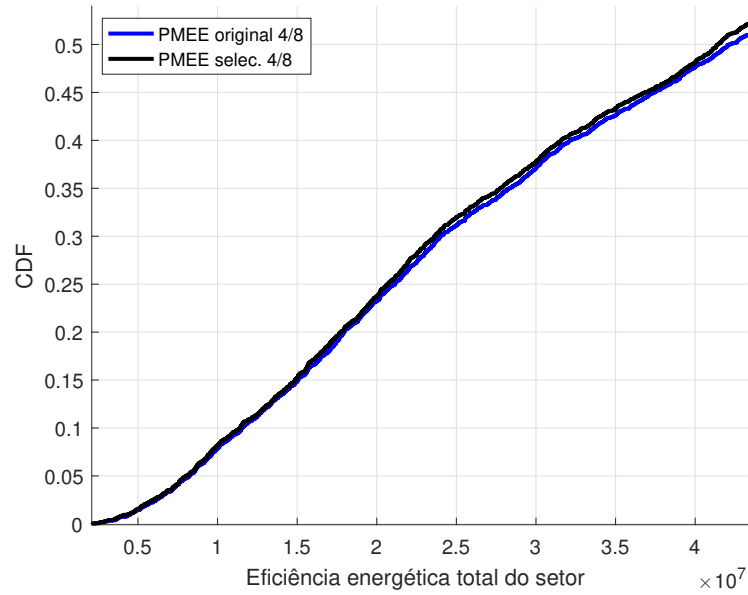
na seção 3.2. Por uma questão de clareza, reproduzimos a seguir os parâmetros mais importantes. Assumimos 8 terminais em um setor ( $J = 8$ ) que pertencem a um mesmo tipo de serviço <sup>7</sup> ( $S = 1$ ) e 15 RBs ( $N = 15$ ). Como consideramos apenas um serviço nesta seção, omitiremos o índice  $s$  que representa o índice dos serviços. A simulação consiste em distribuímos uniformemente os terminais na área de cobertura do setor em 3.000 realizações independentes. O canal foi modelado assumindo uma perda de percurso dependente da distância, com um fator de sombreamento e desvanecimento a curto prazo, como detalhado na seção 4.5. O resultado considerado aqui é a porcentagem da potência não utilizada e a taxa de dados transmitida. Observe que na seção 3.2.1 foi considerada a taxa de *outage*, porém ao observarmos as soluções ótimas dos problemas PMT e PMEE (8) e (18), respectivamente, vemos que possuem restrições com a mesma finalidade (garantir que não exista interferência intracelular, assegurar um limiar de potência, QoS e garantir que cada RB possua no máximo uma MCS). As demais restrições do problema PMEE são de transformação ou para garantir a binaridade, dessa forma, podemos considerar que o *outage* do problema PMEE pode ser considerado o mesmo do problema PMT. Em outras palavras, o espaço de soluções dos problemas PMDTP e PMEE é a mesma. Portanto, não consideramos análise de *outage* para o problema PMEE.

O objetivo principal dessa investigação é de avaliar o impacto na eficiência energética, através do descarte de alguns terminais do conjunto de terminais  $\mathcal{J}$ . Considere que o “PMEE original” é a solução ótima obtida de acordo com a seção 4.1 assumindo todos os terminais do problema (18). Também, assumamos que o “PMEE selec.” é a solução ótima obtida de acordo com a seção 4.1 assumindo apenas  $k$  terminais (o número mínimo de terminais que devem ser satisfeitos por serviço) foram selecionados para resolver o problema (18). O processo de seleção consiste em escolher os  $k$  terminais pertencentes a  $J$  (retirando-os) com a maior razão entre a média de taxa de dados  $\bar{r}_j$  e a taxa de dados requerida  $t_j$ . A taxa de dados média é obtida através do mapeamento da SNR média do terminal para taxa de dados através da função de adaptação de *link* apresentadas na equação (12).


A ideia principal de descartar os terminais com menor razão entre  $\bar{r}_j/t_j$  é a de retirar do processo de alocação os terminais que são mais difíceis de satisfazer, ou seja, terminais com alta taxa de dados requisitada e pior qualidade de canal. Mostramos nas Figuras 12(a), 12(b), 13(a) e 13(b) as CDFs da eficiência energética para o “PMEE original” e “PMEE selec.” considerando  $J = 8$  e  $k = 4$  rotulado como 4/8 e  $J = 8$  e  $k = 6$  rotulado como 6/8. Nestas figuras podemos ver que a solução ótima considerando todos os terminais e a solução ótima com os melhores terminais  $k$  tem praticamente o mesmo desempenho em ambos os cenários. Não há uma perda de desempenho substancial do PMEE original em relação ao PMEE após a seleção dos  $k_s$  terminais.

---

<sup>7</sup>Apesar de aqui assumirmos apenas um serviço, cenários com múltiplos serviços serão considerados na avaliação dos resultados na seção 4.5



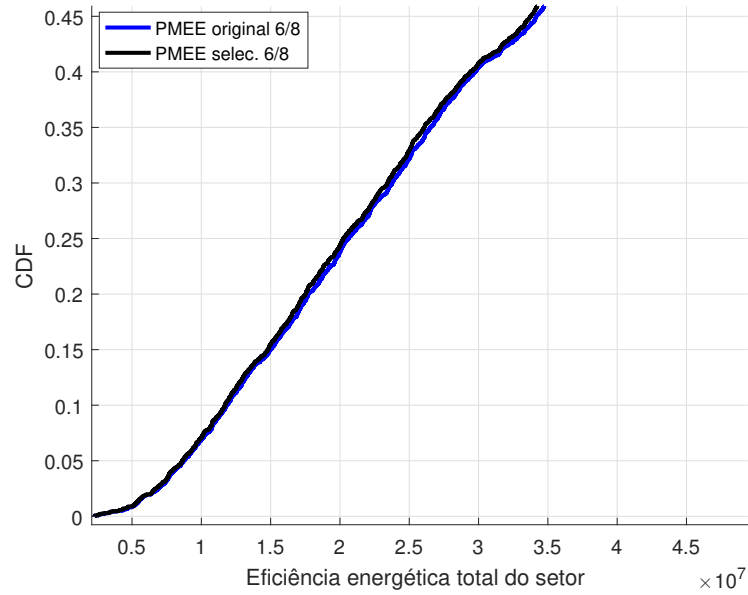
(a) Taxa de dados requisitada de 1,5 Mbps.



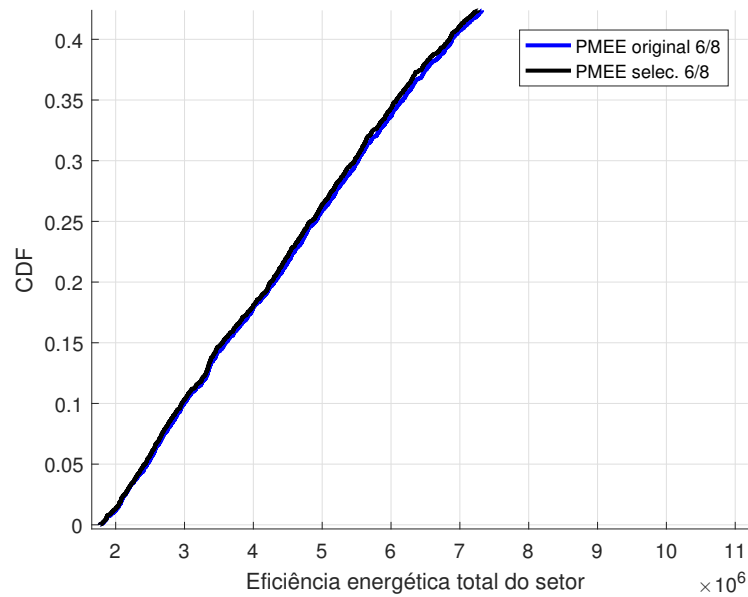
(b) Taxa de dados requisitada de 2,5 Mbps.

Figura 12: Comportamento MILP: CDF da eficiência energética total para um requisito de taxa de dados específico considerando 4 usuários satisfeitos de 8 para os algoritmos PMEE original e PMEE após a seleção dos  $k_s$  terminais com um único serviço ( $S = 1$ ).

Importante observar que este processo de seleção quase ótimo pode ser generalizado para o cenário com multisserviços através da seleção dos  $k_s$  terminais de cada serviço  $s \in \mathcal{S}$ . Assuma que  $\tilde{\mathcal{J}}_s$  é o novo conjunto de terminais com tamanho  $\tilde{J}_s$  após a seleção dos melhores terminais a partir de  $\mathcal{J}_s$ , e que  $\tilde{\mathcal{J}} = \bigcup_{s \in \mathcal{S}} \tilde{\mathcal{J}}_s$  e  $\tilde{J} = \sum_{s \in \mathcal{S}} \tilde{J}_s$ . A vantagem deste processo de redução é da ordem e complexidade do problema. De fato, selecionando os melhores  $k_s$  terminais de cada serviço  $s \in \mathcal{S}$ , reduzimos o número de variáveis de



(a) Taxa de dados requisitada de 0,5 Mbps.



(b) Taxa de dados requisitada de 1,5 Mbps.

Figura 13: Comportamento MILP: CDF da eficiência energética total para um requisito de taxa de dados específico considerando 6 usuários satisfeitos de 8 para os algoritmos PMEE original e PMEE após a seleção dos  $k_s$  terminais com um único serviço ( $S = 1$ ).

otimização já que diminuimos a quantidade de terminais do problema além de descartar a variável  $\rho_j$  e as restrições (18e), (18l), (18m) e (18n) do problema, tornando  $\beta_j = x_0$  na restrição (18d). Na próxima seção, iremos incorporar esta estratégia a nossa solução proposta de baixa complexidade.



#### 4.4.2 Descrição do Algoritmo

A solução de baixa complexidade proposta para o PMEE é uma adaptação da solução apresentada na seção 3.2 e é composta de três partes. As partes 1, 2 e 3 são mostradas nas Figuras 14, 15 e 16, respectivamente. Na parte 1 da solução proposta, iremos realizar uma alocação inicial de RBs assumindo uma hipótese simplificadora: os terminais são capazes de transmitir com a MCS de maior taxa de dados em todos RBs. Cada terminal é alocado com apenas o número mínimo de RBs de acordo com a hipótese simplificadora e os requisitos de taxa de dados de cada terminal. Na parte 2 do algoritmo alocamos uma parte ou todos os RBs e aplicamos alocação de potência adaptativa nos RBs com objetivo de satisfazer a restrição de QoS com o consumo mínimo possível de potência de transmissão. Por fim, na parte 3, alocamos os RBs remanescentes aos usuários com melhor qualidade de canal e aplicamos alocação de potência adaptativa nos RBs, individualmente, com objetivo de maximizar a eficiência energética.

No passo 1 da primeira parte da solução proposta, aplicaremos o processo de seleção de usuário descrita na seção 4.4.1, ou seja, selecionaremos para cada serviço  $s \in \mathcal{S}$  os  $k_s$  terminais com maiores valores para a relação  $\bar{r}_j/t_j$ . Os terminais selecionados compõem o conjunto Auxiliar,  $\mathcal{A}$ . No passo 2, definimos o conjunto  $\mathcal{B}$  como sendo formado inicialmente por todos os RBs disponíveis. Então, no passo 3, estimamos o número de RBs necessários para cada terminal alcançar a taxa de dados requerida assumindo que eles são capazes de transmitir com a melhor MCS possível, ou seja, taxa de dados  $v^M$  em cada RB. Portanto, o número mínimo de RBs necessários a satisfazer o requisito do terminal  $j$  é dado pelo limitante superior  $t_j/v^M$ . A ideia principal do passo 3 é de ter uma estimativa otimista do número de RBs necessárias para cada terminal. Passos 4 e 5 checam se o conjunto Auxiliar e o conjunto de RBs estão vazios ou não. No passo 6, escolheremos o terminal do conjunto Auxiliar com menor razão  $\bar{r}_j/t_j$  para receber primeiro os RBs. A motivação aqui é a de priorizar os terminais com pior qualidade de canal deixando-os escolherem seus melhores RBs. Terminais com boa qualidade de canal em geral tem mais RBs em boas condições, diferentemente dos terminais com pior qualidade de canal. No passo 7, escolheremos para o terminal selecionado no passo 6 seu melhor RB. O RB selecionado é retirado do conjunto  $\mathcal{B}$ . No passo 8, avaliamos se o terminal já obteve o número mínimo de RBs, calculado no passo 3. Se assim for, este terminal é retirado do conjunto  $\mathcal{A}$  no passo 9 e outro terminal irá receber RBs. Se não, será alocado mais RBs ao terminal selecionado até o número mínimo de RBs ser atingido. Importante observar que se durante o processo de alocação todos os RBs forem assinalados e ainda existir terminais sem o número mínimo de RBs, o algoritmo não será capaz de satisfazer as restrições do problema (4). Ainda nesta seção, iremos discutir como o algoritmo poderia atuar nestes casos.

No fim da primeira parte da solução proposta, cada terminal tem o número

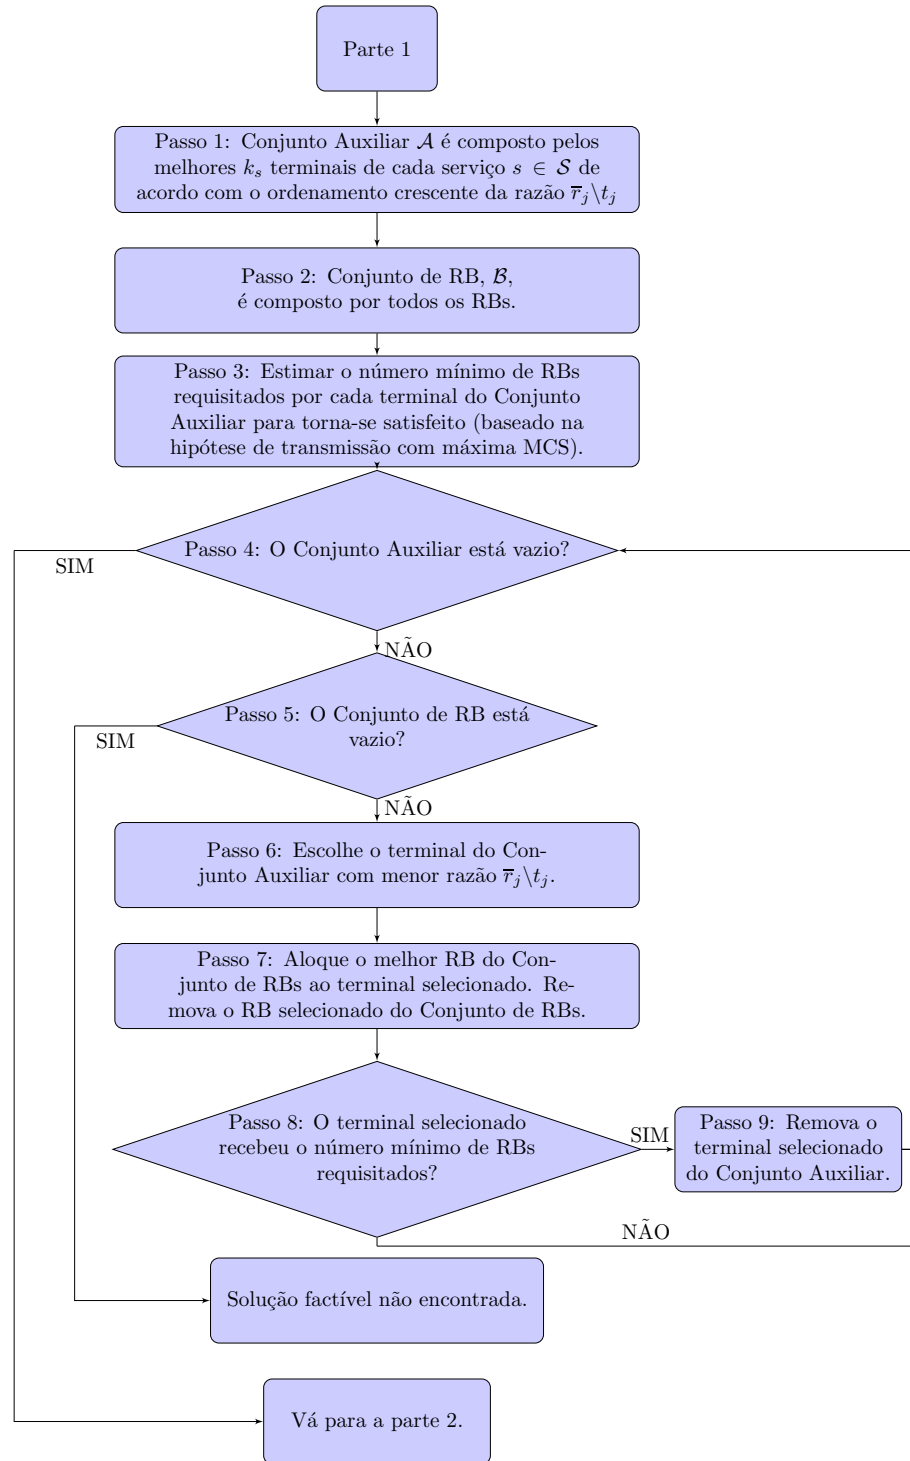


Figura 14: Primeira parte da solução subótima para o problema PMEE.

mínimo de RBs alocados e possivelmente existem RBs disponíveis. O primeiro passo da parte 2 apresentado na Figura 15, consiste em aplicar a alocação de potência de transmissão de acordo com o algoritmo HH nos RBs de cada terminal individualmente sem a restrição de potência total (4d). Basicamente, o algoritmo HH aloca potência de transmissão aos RBs e conseqüentemente aumenta os níveis de MCS até cumprir as

taxas de dados de transmissão requisitadas por cada terminal do conjunto  $\mathcal{A}$ . Observe que possivelmente a soma da potência de transmissão utilizada por todos os terminais (potência de transmissão total utilizada) pode violar a restrição de potência total na ERB, tornando a solução impraticável. Isto é avaliado no passo 2, em que testamos se a potência de transmissão total utilizada (somatório da potência de transmissão alocada aos RBs de todos os terminais) é menor ou igual a restrição de potência total da ERB,  $P^{\text{tot}}$ . Em caso afirmativo, iremos para a parte 3 da solução. Se após o passo 2 a potência total utilizada é maior que a potência total disponível na ERB, avaliamos se os conjuntos  $\mathcal{A}$  e  $\mathcal{B}$  estão vazios (passo 3). Se sim, o algoritmo não é capaz de encontrar uma solução que obedeça às restrições do problema (4). Ainda nesta seção, iremos discutir como proceder neste caso. No passo 4, o terminal do conjunto Auxiliar  $\mathcal{A}$  com menor razão  $\bar{r}_j/t_j$  seleciona o RB do conjunto de RBs,  $\mathcal{B}$ , com melhor qualidade de canal. A ideia aqui é a mesma apresentada nos passos 6 e 7 da parte 1 da solução proposta. No passo 5, refazemos a alocação de potência transmitida (algoritmo HH) para o terminal selecionado no passo 4 considerando os RBs alocados e o RB selecionado no passo 4. A solução HH é executada até o terminal alcançar a taxa de dados requisitada sem a restrição de potência total. Se o RB selecionado está com qualidade de canal satisfatória, é provável que a potência total alocada ao terminal irá diminuir caso o RB selecionado seja assinalado a este terminal. Portanto, no passo 6 avaliaremos se a potência total alocada ao terminal selecionado irá decrescer com a adição do novo RB. Em caso afirmativo, o novo RB é alocado ao terminal e a potência total utilizada pela ERB é atualizada no passo 7. Em caso contrário, o RB não é alocado ao terminal e este terminal é removido do conjunto Auxiliar  $\mathcal{A}$  no passo 8. Este terminal é retirado do processo de alocação porque nenhuma economia de potência poderá ser obtida através da alocação de novos RBs a ele. O algoritmo continua testando se a adição de novos RBs é capaz de decrescer a potência total utilizada. Esta parte do algoritmo termina quando a potência total utilizada é menor ou igual a potência total disponível na ERB, dessa forma, iremos para a parte 3 da solução.

No fim da segunda parte do algoritmo, cada terminal tem uma certa quantidade de RBs alocados, possivelmente existem RBs disponíveis, e a restrição de QoS (4e) está sendo obedecida com uma quantidade mínima de potência de transmissão. O primeiro passo da parte 3 apresentado na Figura 16, consiste em alocar os RBs remanescentes aos terminais com melhor qualidade de canal neles. No passo 2 utilizaremos alocação de potência adaptativa para selecionar a MCS (ou aumentar a taxa de dados) do RB que possa melhorar a eficiência energética, o nível de MCS não pode decrescer, isso ocorre devido a segunda parte da solução subótima que satisfaz as restrições do problema utilizando a menor quantidade de recursos possíveis, ou seja, nesse passo só podemos aumentar a eficiência energética através do aumento da taxa de dados transmitida e do consumo de potência. O passo 3 é responsável por testar se a nova alocação de potência viola a restrição de potência total disponível, (4d). Caso essa afirmativa seja verdadeira,

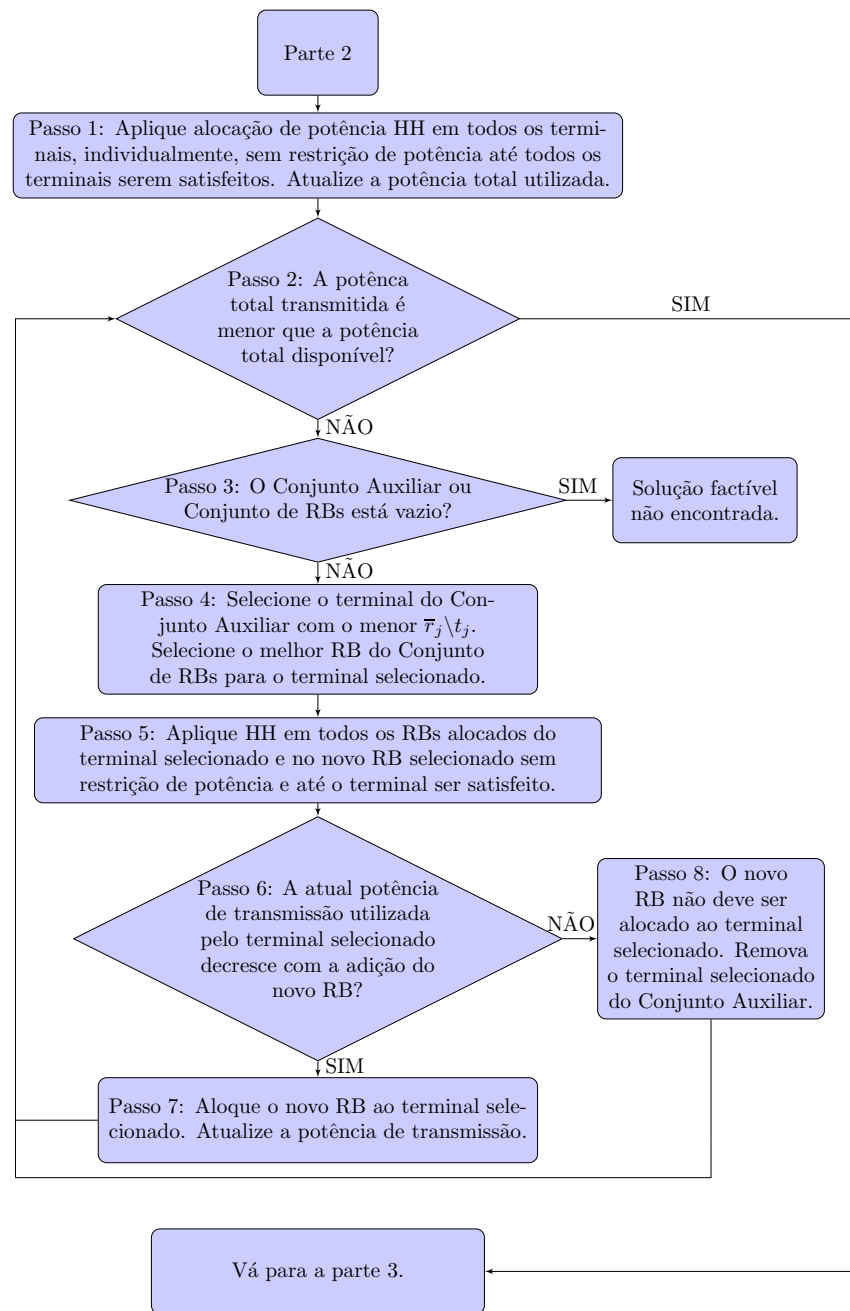


Figura 15: Segunda parte da solução subótima para o problema PMEE.

o algoritmo termina sem efetuar o aumento do nível de MCS e uma solução factível é encontrada. Caso contrário, no passo 7, testaremos se essa nova alocação de potência e MCS são capazes de aumentar a eficiência energética total do sistema, ou seja, veremos se a potência total utilizada no sistema é usada de forma mais eficiente do que potência total utilizada anteriormente. Caso essa afirmação seja verdadeira, alocaremos a nova MCS selecionada ao RB selecionado e o algoritmo continua testando se é possível aumentar a

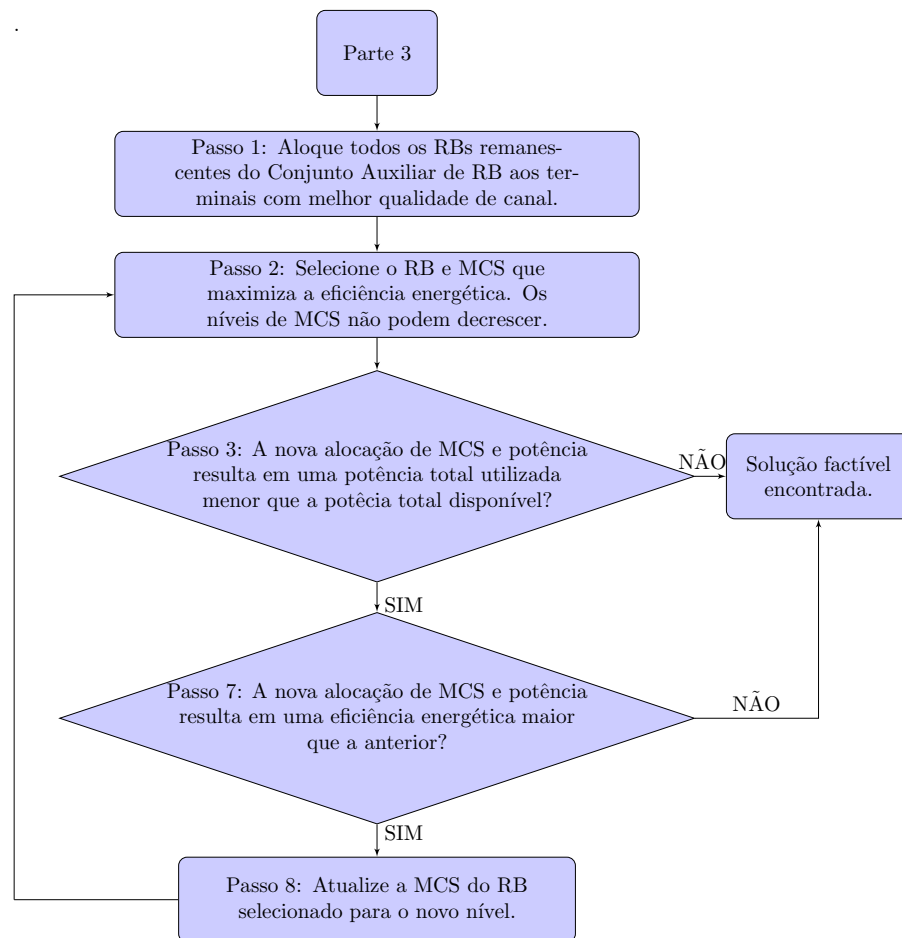


Figura 16: Terceira parte da solução subótima para o problema PMEE.

eficiência energética através da alocação de MCSs e potência adaptativa. Caso contrário, o algoritmo irá terminar e uma solução factível é retornada. Observe que se o algoritmo chegou na parte 3 ele sempre retornará uma solução factível.

Como comentado anteriormente, a solução proposta pode falhar em obter uma solução factível para o problema PMEE. Isto significa que o algoritmo não é capaz de satisfazer às restrições do problema (4). Nossa proposta aqui é decrescer suavemente a restrição de taxa de dados requisitada pelos terminais por um fator arbitrário de  $\beta$  com  $\beta < 1$ . Então, nossa solução proposta pode ser executada novamente de forma a avaliar se as novas taxas de dados requisitadas podem ser satisfeitas. Dependendo do valor de  $\beta$ , esperamos satisfazer o QoS com um número limitado de RBs e de potência de transmissão disponível. A avaliação do impacto desta proposta consiste em uma das perspectivas deste estudo.

Tabela 5: Principais parâmetros de simulação.

Parâmetros	Valores	Unidade
Raio da célula	334	m
Potência total transmitida	$0.35 \cdot N$	W
Número de subportadoras por RB	12	-
Número de níveis de MCS	15	-
Desvio padrão do sombreamento	8	dB
Perda de percurso <sup>(2)</sup>	$35.3 + 37.6 \cdot \log_{10}(d)$	dB
Densidade espectral do ruído	$3.16 \cdot 10^{-20}$	W/Hz
Número de <i>snapshots</i>	3.000	-

## 4.5 Resultados de Desempenho

Esta seção é dedicada a avaliação do desempenho das soluções ótimas dos problemas apresentados neste capítulo assim como a solução subótima para o problema PMEE. O objetivo principal é avaliar os ganhos de desempenho que podem ser obtidos através do uso da eficiência energética pura em relação com algumas variações dos problemas de eficiência energética, assim como mensurar quão perto a solução subótima proposta está da solução ótima. Na Seção 4.5.1 apresentamos as principais suposições da simulação enquanto que na Seção 4.5.2 mostramos e discutimos os resultados de simulação.

### 4.5.1 Parâmetros de Simulação

Utilizamos um simulador computacional em que foram implementadas as principais premissas apresentadas neste capítulo e no capítulo 2. Consideramos o modo *downlink* de um setor hexagonal implantado em um sistema celular. Os resultados foram obtidos através da realização de vários *snapshots* (TTI) independentes de forma a obter um resultado válido do ponto de vista estatístico. Em cada *snapshot*, os terminais são distribuídos uniformemente dentro de um setor, cuja ERB é localizada no canto da célula. Consideramos que os recursos estão dispostos em uma grade tempo e frequência, com cada RB composto de um grupo de 12 subportadoras adjacentes na frequência e 14 símbolos OFDM no tempo, seguindo as especificações em [55].

O modelo de propagação utilizado é composto de perda de percurso, uma componente de sombreamento log-normal e componente de desvanecimento Rayleigh de curto prazo. De forma específica, a componente de desvanecimento rápido do ganho do canal de um dado usuário é considerada independente para cada RB. Essa hipótese é coerente já que, em geral, os RBs tem largura de banda na ordem de largura de banda do canal. Assumimos que a adaptação de *link* é realizada baseada na informação de 15 CQIs discretas utilizada pelo sistema LTE [56]. Os limiares de SNRs para mudança de MCS foram obtidas pelas simulações de nível de *link* de [57]. Os parâmetros de simulações são resumidos na Tabela 5.

A solução ótima do problema PMEE é identificada como PMEE OPT, a

<sup>8</sup> $d$  é a distância entre a ERB e o terminal em metros.

Tabela 6: Esquemas de modulação e codificação.

MCS	Modulação	Taxa de Codificação [ $\times 1024$ ]	Taxa [Bits/TTI]
MCS-1	QPSK	78	25
MCS-2	QPSK	120	39
MCS-3	QPSK	193	63
MCS-4	QPSK	308	101
MCS-5	QPSK	449	147
MCS-6	QPSK	602	197
MCS-7	16-QAM	378	248
MCS-8	16-QAM	490	321
MCS-9	16-QAM	616	404
MCS-10	64-QAM	466	458
MCS-11	64-QAM	567	558
MCS-12	64-QAM	666	655
MCS-13	64-QAM	772	759
MCS-14	64-QAM	873	859
MCS-15	64-QAM	948	933

Fonte: Adaptado do relatório [58].

solução ótima do problema PMP é identificada como PMP OPT, a solução ótima do problema PMDTP é identificada como PMDTP OPT e a solução subótima proposta para o problema PMEE é identificada como PROP2. As realizações de canal são as mesmas para todos os algoritmos simulados, dessa maneira teremos uma comparação justa entre eles. De forma a resolver os problema MILP usamos o IBM ILOG CPLEX *Optimizer* [59]. A escolha do número de terminais, RBs e serviços é limitado pela complexidade computacional para obter as soluções ótimas.

Consideramos três métricas de desempenho: o percentual de potência não utilizada, a taxa de dados total e a eficiência energética total. O percentual de potência não utilizada é a razão entre a potência não utilizada pela ERB para transmissão e a potência total disponível, tudo multiplicado por 100. A taxa total de dados é a soma das taxas de dados obtidas por todos os terminais de um setor em um dado *snapshot*. A eficiência energética total é a soma das eficiências energéticas obtidas por todos os terminais de um setor em um dado *snapshot*. Observe que a formulação dos problemas PMEE, PMP e PMDTP que possuem as mesmas restrições com uma função objetivo diferente, portanto o desempenho em termos de *outage* das soluções ótimas é o mesmo da solução PMT, reforçando o motivo para não analisarmos o *outage* para estes problemas. Por fim, incrementos na carga são emulados através do aumento das taxa de dados requisitadas pelos terminais.

Para avaliar nossa proposta sobre diferentes condições, nos resultados, apresentamos alguns cenários de simulação em que os principais parâmetros do nosso modelo são mudados. Os cenários são descritos na Tabela 7.

Tabela 7: Parâmetros dos cenários considerados para simulações computacionais.

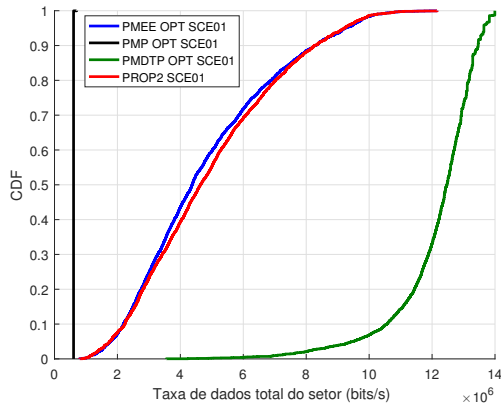
Cenário	$S$	$J_1$	$J_2$	$J_3$	$J_4$	$k_1$	$k_2$	$k_3$	$k_4$	$N$	Taxa de dados requisitada
1	2	4	4	-	-	3	3	-	-	15	Todos os terminais requisitam a mesma taxa de dados
2	2	4	4	-	-	4	3	-	-	15	Todos os terminais requisitam a mesma taxa de dados
3	2	4	4	-	-	4	4	-	-	15	Todos os terminais requisitam a mesma taxa de dados
4	3	3	3	3	-	3	3	2	-	15	Todos os terminais requisitam a mesma taxa de dados
5	3	3	3	3	-	3	3	2	-	15	Terminais do serviço 3 requisitam uma taxa de dados 125 kbps maior que a dos terminais dos serviços 1 e 2
6	3	3	3	3	-	3	3	2	-	15	Terminais do serviço 3 requisitam uma taxa de dados 250 kbps maior que a dos terminais dos serviços 1 e 2
7	4	3	3	3	3	3	3	2	2	20	Todos os terminais requisitam a mesma taxa de dados
8	4	3	3	3	3	3	3	3	2	20	Todos os terminais requisitam a mesma taxa de dados
9	4	3	3	3	3	3	3	3	3	20	Todos os terminais requisitam a mesma taxa de dados
10	4	3	3	3	3	3	3	3	2	20	Terminais do serviço 4 requisitam uma taxa de dados 250 kbps maior que a dos terminais dos serviços 1, 2 e 3
11	4	3	3	3	3	3	3	3	2	20	Terminais do serviço 4 requisitam uma taxa de dados 500 kbps maior que a dos terminais dos serviços 1, 2 e 3

#### 4.5.2 Resultados

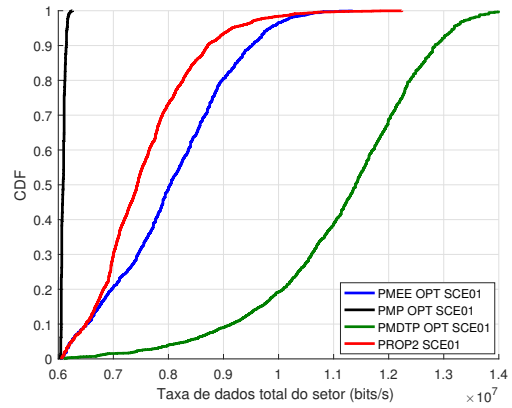
Nas figuras que seguem, denominamos  $i^{\text{ésimo}}$  cenário como SCE  $i$ . Nas Figuras 17(a) e 17(b), apresentamos as CDFs das taxas total de dados para todos os algoritmos no cenário 1 para a taxa requisitada de 200 kbps e 1.000 kbps. Uma observação geral para todas as figuras restantes é que o algoritmo PMP OPT fornece as menores taxas de dados, e isto ocorre devido a função objetivo do problema PMP OPT que tem como objetivo somente minimizar a potência total e não de maximizar a taxa de transmissão. Os ganhos de desempenho no 50<sup>ésimo</sup> percentil da taxa total de dados das soluções PMEE OPT, PROP2 e PMDTP OPT para a solução PMP OPT são de 629%, 675% e 1976%, e 31%, 21% e 86% nas figuras 17(a) e 17(b), respectivamente. Observe que a solução PROP2 é capaz de manter um desempenho próximo a solução PMEE OPT que pode ser alcançada mesmo para elevados requisitos de taxa de dados.

Nas Figuras 18(a) e 18(b) apresentamos as CDFs das taxas de dados total para todos os algoritmos deste capítulo nos cenários 4 e 6 para a taxa requisitada de 100 kbps e 600 kbps, respectivamente. O objetivo é mostrar o impacto da taxa de dados requisitada,  $t_j$ . Basicamente, podemos ver que a variação de  $t_j$  entre os terminais de diferentes serviços não apresenta impacto significativo nas taxas de dados totais exceto para o algoritmo PMP OPT. A solução proposta apresenta um desempenho quase ótimo na Figura 18(a) enquanto que uma perda de desempenho pode ser vista na Figura 18(b).






(a) Taxa de dados requisitada de 100 kbps.

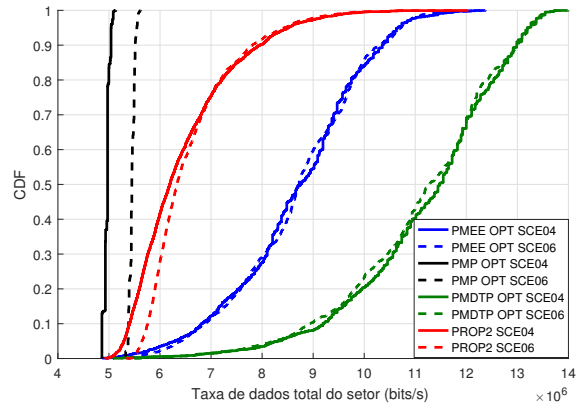


(b) Taxa de dados requisitada de 1 Mbps.

Figura 17: CDF da taxa de dados total para um requisito de taxa de dados específico no cenário 1 para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com dois serviços ( $S = 2$ ).



(a) Taxa de dados requisitada de 100 kbps.



(b) Taxa de dados requisitada de 600 kbps.

Figura 18: CDF da taxa de dados total para um requisito de taxa de dados específico para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com três serviços ( $S = 3$ ). Assumindo os cenários 4 e 6 e avaliamos o impacto da variável  $t_j$ .

Nas Figuras 19(a) e 19(b) apresentamos a taxa de dados total para todos os algoritmos apresentados neste capítulo nos cenários 7 e 9 para as taxas de dados requisitadas de 100 kbps e 600 kbps, respectivamente. O objetivo é mostrar o impacto no número mínimo de terminais satisfeitos por serviço,  $k_s$ . As soluções PMP OPT, PMEE OPT e PROP2 apresentam um crescimento moderado em taxa de dados total quando variamos a variável  $k_s$  em ambos os cenários. Este crescimento ocorre devido a necessidade de aumentar o número de usuários satisfeitos, ou seja, teremos um limitante mínimo de taxa de dados do sistema maior no cenário 9 em relação ao cenário 7. A solução PMDTP OPT é a única que sofre um decrescimento moderado em taxa de dados total quando variamos a variável  $k_s$  em ambos os cenários. Isto ocorre devido ao maior uso de potência para satisfazer mais usuários, dessa forma teremos menos espaço para aumentar a diferença entre a taxa de dados e potência modelada na sua função objetivo (6a).

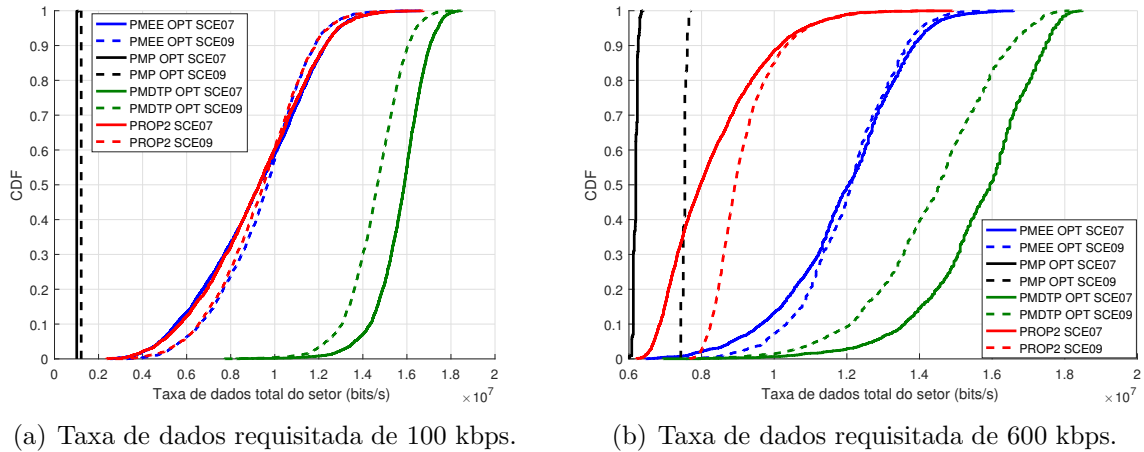


Figura 19: CDF da taxa de dados total para um requisito específico de taxa de dados para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com quatro serviços ( $S = 4$ ). Assumimos os cenários 7 e 9 e avaliamos o impacto da variável  $k_s$ .

Em resumo, a partir da análise dos resultados das Figuras 17 – 19, podemos ver que no quesito taxa de dados nossa solução proposta possui desempenho próximo da solução PMEE OPT considerando as restrições e o objetivo do problema nas cargas pequenas. Uma observação importante é que a solução PMP OPT tende a alcançar as demais soluções em cargas mais elevadas. Outro fato observado a partir destas figuras é que o algoritmo PMDTP OPT sempre possui a maior taxa de dados, contudo veremos mais na frente que esse ganho em taxas de dados resultará na utilização de mais potência.

Nas Figuras 20(a) e 20(b) apresentamos o percentual de potência não utilizada versus a taxa de dados requisitada por cada usuário para as soluções PMEE OPT, PMP OPT, PMDTP OPT e PROP2 nos cenários 1 a 3. Uma observação geral, e esperada, para todas as figuras restantes do mesmo tipo é que o algoritmo PMP OPT fornece o melhor desempenho em termos de potência não utilizada, isto deve-se ao fato de que a economia e potência estar diretamente modelada no objetivo do problema conforme mostrado na equação (5a). Primeiramente podemos ver que o percentual de potência não utilizada diminui com os requisitos de taxa de dados dos usuários. Isto é esperado desde que quanto maiores são as demandas dos usuários em termos de QoS, mais difícil é a tarefa de satisfazer as restrições do problema estudado e conseqüentemente mais potência de transmissão deve ser utilizada. Contudo, esse uso otimizado da potência de transmissão para o problema PMP reflete em baixas taxas de dados, como foi visto em resultados anteriores, e também afetará o desempenho em termos de eficiência energética, como será visto mais adiante. Outro comportamento esperado é que os percentuais de potência não utilizada das soluções PMEE OPT, PMP OPT e PMDTP OPT no cenário 2 são menores do que as do cenário 1, e do cenário 3 são menores que do cenário 2, que conseqüentemente também é menor que do cenário 1. Isto ocorre devido ao fato que no cenário 2, 4 usuários do serviço 1 e 3 usuários do serviço 2 devem ter suas taxas de dados satisfeitas enquanto




Figura 20: Potência não utilizada versus taxa de dados requerida para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com dois serviços ( $S = 2$ ). Cenários 1 a 3 e o impacto da variável  $k_s$

que no cenário 1, 3 usuários de 4 devem ser satisfeitos por cada serviço. No cenário 3 todos 4 usuários de cada serviço devem ser satisfeitos.

Comparando o desempenho relativo dos algoritmos nas Figuras 20(a) e 20(b), podemos ver que a solução PMP OPT apresenta uma maior economia de potência comparada as demais soluções. Considerando a taxa de dados requisitada por usuário de 800 kbps para o cenário 1, vemos que a solução PMP OPT é capaz de economizar 90,5% da potência total disponível enquanto que as soluções PMEE OPT, PROP2 e PMDTP OPT economizam 87,7%, 87,6% e 77,3%, respectivamente. Portanto, vemos que as altas taxas de dados vistas anteriormente da solução PMTDP OPT afetou diretamente o desempenho em termos de potência de transmissão. Mais adiante veremos também o impacto negativo que isso acarretará em termos de eficiência energética. Podemos ver uma perda de desempenho da solução PROP2 ao ultrapassar o requisito de taxa de dados de 900 kbps. Isto ocorre pois esta é a última taxa requisitada por usuários em que ainda é necessário apenas um RB para satisfazer os usuários visto que a máxima taxa em um RB é de 933 kbps na máxima MCS. Na taxa requisitada de 1.000 kbps podemos ver que há um incremento no consumo de potência para esses algoritmos uma vez que inevitavelmente mais um RB deve ser alocada por usuário, permitindo um aumento no consumo de potência. Além disso, as simulações foram realizadas até as taxas requisitadas em que as restrições dos problemas de otimização puderam ser obedecidas. Essa é a razão de termos menos pontos para o cenário 3.

Nas Figuras 21(a) e 21(b) estudamos o impacto das taxas de dados requisitadas pelos terminais,  $t_j$ . Nestas figuras mostramos a porcentagem da potência não utilizada versus a taxa de dados requisitada por terminal para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 nos cenários 4 a 6. Observe que nestes cenários temos três serviços e os terminais do serviço 3 nos cenários 5 e 6 requisitam taxas de dados de 125

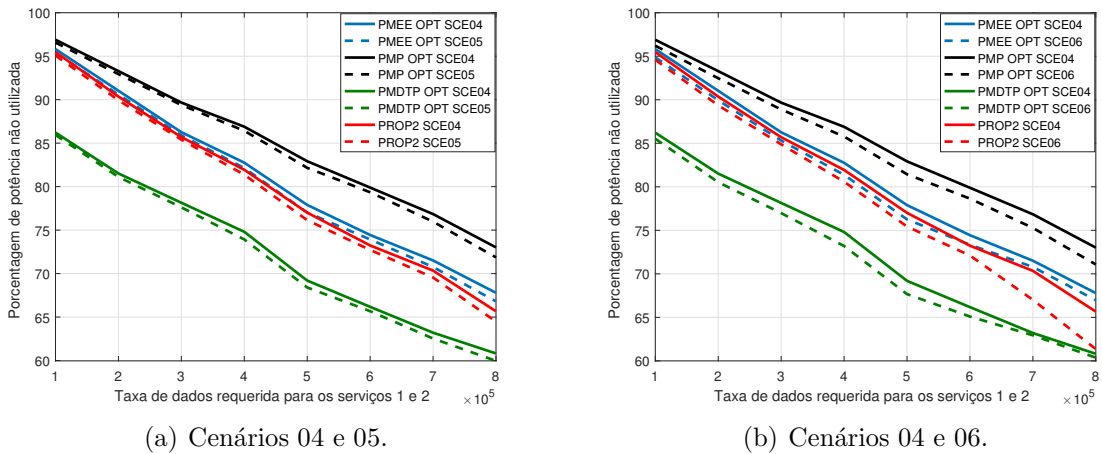
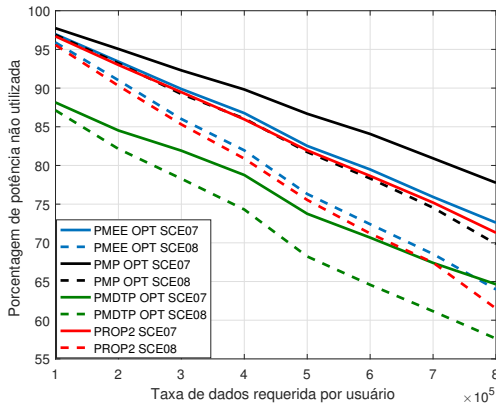



Figura 21: Potência não utilizada versus taxa de dados requerida para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com três serviços ( $S = 3$ ). Cenários 4 a 6 e o impacto da variável  $t_j$

kbps e 250 kbps a mais que as requisitadas para os serviços 1 e 2, respectivamente. A taxa de dados solicitada por todos os terminais do cenário 4 são as mesmas. Uma primeira observação que pode ser feita a respeito das Figura 21(a) e 21(b) é que a solução PMP OPT e PMDTP OPT possuem o menor e o maior consumo de potência, respectivamente, para todos os cenários. De acordo com as figuras 21(a) e 21(b) podemos ver que quanto maior a taxa de dados requisitada para os terminais do serviço 3, maior será a potência consumida para todas as soluções. Isso ocorre devido a maior necessidade de taxa de dados para satisfazer o sistema. Uma segunda observação é que quando estudamos os ganhos de desempenho em taxa de dados a solução PMDTP OPT era sempre a melhor solução, contudo podemos ver que esse ganho de desempenho em taxa de dados é refletido na potência tornando-o a pior solução quando o assunto é economia de potência.

Observe que a solução PROP2 consegue obter uma porcentagem de potência não utilizada aproximadamente igual ao da solução PMEE OPT para cargas leves e moderadas, o qual por sua vez é o algoritmo que possui o desempenho mais próximo ao da solução PMP OPT. Dessa forma, a solução PROP2 possui um desempenho satisfatório em relação aos algoritmos que menos consomem potência. Podemos ver que o consumo de potência em ambos cenários é muito similar. Portanto, considerando a taxa requisitada para os usuários 1 e 2 de 500 kbps para o cenário 04, vemos que as soluções PMP OPT, PMEE OPT, PROP2 e PMTTP OPT são capazes de economizar 82,9%, 77,9%, 77% e 69,2%, respectivamente. Observe que esse consumo de potência um pouco maior das soluções PMEE e PROP2 em relação ao problema PMP é diretamente refletido nas análises de desempenho de taxa de dados transmitida vistas anteriormente. Conforme visto antes, as soluções PMEE e PROP2 conseguem manter um baixo consumo de potência e aumentar consideravelmente a taxa de dados. O ganho em taxa de dados pode ser 675% vezes maior que o PMP OPT conforme visto em resultados anteriores.

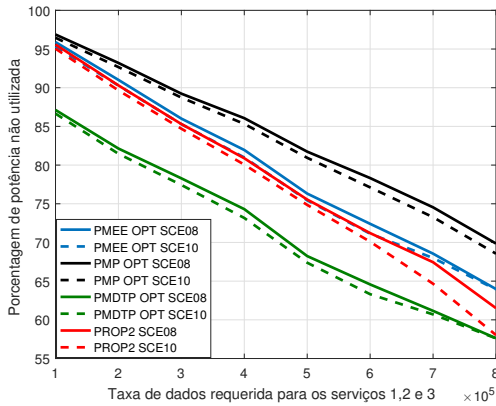


(a) Cenários 07 e 08.




(b) Cenários 07 e 09.

Figura 22: Potência não utilizada versus taxa de dados requerida para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com quatro serviços ( $S = 4$ ). Assumimos os cenários 7 a 9 e avaliamos o impacto da variável  $k_s$ .



(a) Cenários 08 e 10.



(b) Cenários 08 e 11.

Figura 23: Potência não utilizada versus taxa de dados requerida para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com quatro serviços ( $S = 4$ ). Assumimos os cenários 8, 10 e 11, e avaliamos o impacto da variável  $t_j$ .

Nas Figuras 22 e 23 apresentamos a taxa de dados versus a taxa de dados requisitada por terminal para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 nos cenários 7 a 9, e 8, 10 e 11, respectivamente, em que todos os cenários consideram quatro serviços,  $S = 4$ . Na Figura 22 o número mínimo de terminais satisfeitos por serviço,  $k_s$ , é variado, enquanto na Figura 23 mudamos a taxa de dados requisitada por terminal,  $t_j$ , ao longo dos terminais. As principais conclusões obtidas até agora podem ser resumidas nestes cenários com mais serviços: as variáveis  $k_s$  e  $t_j$  têm um importante impacto na potência de transmissão de todos os algoritmos. Além do mais, a solução PROP2 apresenta uma pequena perda de desempenho para a solução PMEE OPT em pequenas e médias cargas, enquanto que ele supera a solução PMDTP OPT em pequenas e médias cargas mesmo com o aumento do número de serviços.

Até agora analisamos os algoritmos do ponto de vista da potência não uti-

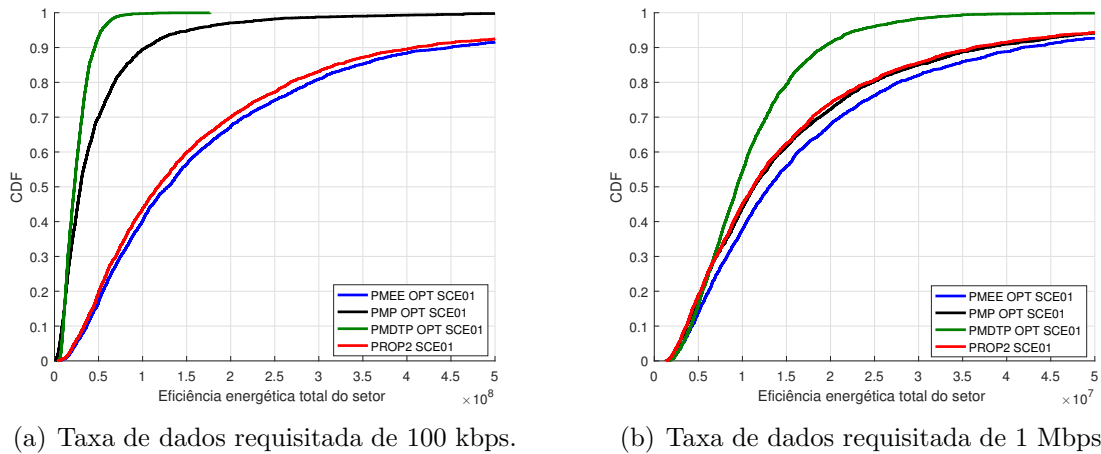


Figura 24: CDF da eficiência energética para um requisito de taxa de dados específico no cenário 1 para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com dois serviços ( $S = 2$ ).

lizada e da taxa de dados total. De forma à analisar os algoritmos de outro ponto de vista, nas figuras restantes, mostraremos a CDF da eficiência energética para requisitos de taxa de dados específicos. A eficiência energética representa a função objetivo do nosso problema PMEE. Para uma carga e cenário específico, as CDFs de todos os algoritmos são construídas com amostras de *snapshots* em que PMEE OPT, PMP OPT, PMDTP OPT e PROP2 são capazes de encontrar uma solução factível ou viável.

Nas Figuras 24(a) e 24(b) apresentamos as CDFs da eficiência energética total para todos os algoritmos apresentados neste capítulo no cenário 1. Uma observação geral, e esperada, para todas às figuras restantes do mesmo tipo é que o algoritmo PMEE OPT fornece o melhor desempenho em termos de eficiência energética. Isso ocorre devido ao aspecto de maximização da taxa de dados modelado diretamente em sua função objetivo (4a). Os ganhos de desempenho no 50<sup>ésimo</sup> percentil da eficiência energética da solução PMEE OPT para as soluções PMDTP OPT, PMP OPT e PROP2 são de 467%, 335% e 9,7%, e 39,7%, 15,6% e 16,2% nas figuras 24(a) e 24(b), respectivamente. Observe que a solução PROP é capaz de manter uma perda pequena de desempenho comparada a solução PMEE OPT que pode ser alcançada mesmo para elevados requisitos de taxa de dados. Outra observação importante é que a solução PMP OPT tende a se tornar a solução PMEE OPT para cargas muito elevadas. A razão para isso é que para altas taxas requisitadas por usuário, o espaço de soluções dos problemas de otimização PMEE e PMP passam a ficar menores e portanto há menor margem de otimização para o aumento da eficiência espectral. Assim, os dois problemas convergem para soluções similares.

Nas Figuras 25(a) e 25(b) apresentamos as CDFs da eficiência energética para todos os algoritmos nos cenários 4 e 6 para a taxa requisitada de 100 kbps e 600 kbps, respectivamente. O objetivo é mostrar o impacto da taxa de dados requisitada,  $t_j$ . Basicamente, podemos ver que a variação de  $t_j$  entre os terminais de diferentes serviços apresenta

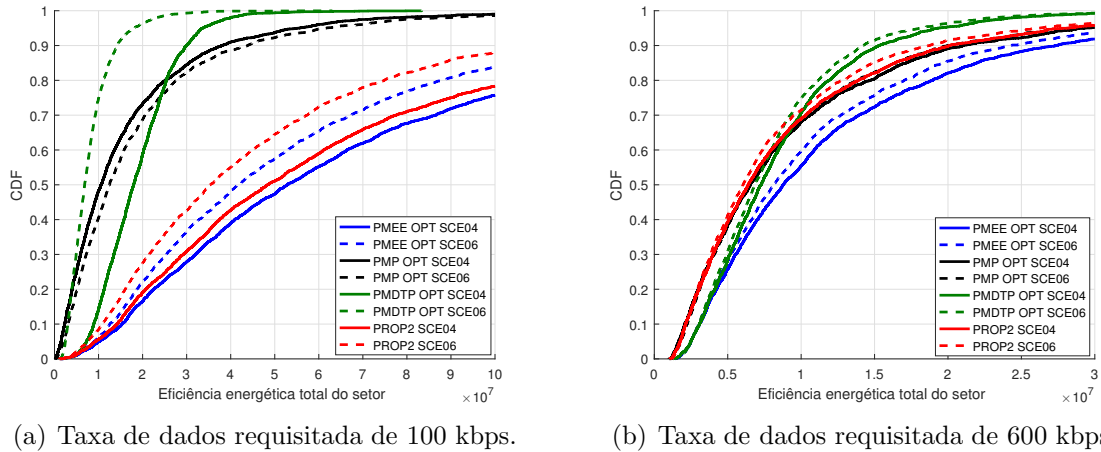


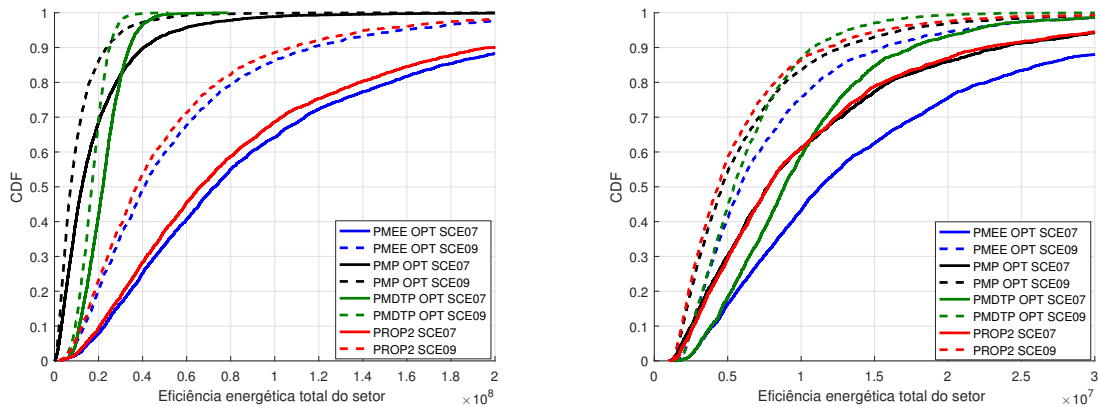
Figura 25: CDF eficiência energética para um requisito de taxa de dados específico para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com três serviços ( $S = 3$ ). Assumindo os cenários 4 e 6 e avaliamos o impacto da variável  $t_j$ .

impacto significativo na eficiência energética, exceto para o algoritmo PMP OPT na Figura 25(a). Os ganhos de desempenho no 50<sup>ésimo</sup> percentil da eficiência energética da solução PMEE OPT para as soluções PMDTP OPT, PMP OPT e PROP2 no cenário 04 são de 463,5%, 366,4% e 9,3%, e 20%, 34% e 37% nas Figuras 25(a) e 25(b), respectivamente. A solução proposta apresenta um desempenho quase ótimo na Figura 25(a) enquanto que uma perda de desempenho pode ser vista na Figura 25(b).

Nas Figuras 26(a) e 26(b) apresentamos a eficiência energética para todos os algoritmos deste capítulo nos cenários 7 e 9 para as taxas de dados requisitadas de 100 kbps e 600 kbps, respectivamente. O objetivo é mostrar o impacto no número mínimo de terminais satisfeitos por serviço,  $k_s$ . Todas as soluções apresentam um decréscimo considerável em eficiência energética total quando variamos a variável  $k_s$  na taxa de dados requisitada de 600 kbps. Basicamente, a diferença entre a eficiência energética total quando variamos a variável  $k_s$  é mais nítido quando a taxa de *outage* é alta (veja a Figura 8). Os ganhos de desempenho no 50<sup>ésimo</sup> percentil da eficiência energética da solução PMEE OPT para as soluções PMDTP OPT, PMP OPT e PROP2 no cenário 07 são de 231%, 508% e 10%, e 28,4%, 45,8% e 45,2% nas figuras 26(a) e 26(b), respectivamente. A solução proposta apresenta um desempenho quase ótimo na Figura 26(a) enquanto que uma perda de desempenho pode ser visto na Figura 26(b).

Em resumo, a partir da análise dos resultados das Figuras 17 – 26, podemos ver que nossa solução proposta possui desempenho próximo do ótimo considerando as restrições e o objetivo do problema nas cargas pequenas e médias. Como estamos lidando com algoritmos, é importante fazer uma análise da complexidade computacional das soluções apresentadas.

A complexidade computacional no pior caso para obter as soluções PMEE, PMP e PMDTP utilizando o algoritmo BC é de  $O(2^{JNM})$  para todos os algoritmos ótimos,



(a) Taxa de dados requisitada de 100 kbps.

(b) Taxa de dados requisitada de 600 kbps.

Figura 26: CDF da eficiência energética total para um requisito específico de taxa de dados para os algoritmos PMEE OPT, PMP OPT, PMDTP OPT e PROP2 com quatro serviços ( $S = 4$ ). Assumimos os cenários 7 e 9 e avaliamos o impacto da variável  $k_s$ .

como explicado nos apêndices ???. A complexidade computacional no pior caso do algoritmo PROP2, que é calculada no apêndice 5, é de  $\mathcal{O}(J(M \times N \times \log_2 N))$ . Como podemos observar, a complexidade da solução subótima é polinomial e portanto bem menor que a complexidade da solução ótima que é exponencial em termos das variáveis do problema. Portanto, analisando a complexidade computacional e desempenho do algoritmo PROP2, concluímos que ele possui um bom compromisso entre desempenho e complexidade quando comparada com as estratégias PMEE OPT, PMP OPT e PMDTP OPT.

## 5 CONCLUSÕES DA DISSERTAÇÃO

Ao longo desta dissertação de mestrado estudamos diferentes problemas de RRA. Mais especificamente, estudamos o problema de maximização da taxa de dados e eficiência energética sujeitos a QoS e restrições de satisfação. Como apresentado no Capítulo 1, estes são problemas importantes para serem resolvidos em redes sem fio modernas onde diferentes serviços com demandas de QoS heterogêneas estão presentes. No capítulo 2, abordamos a modelagem que foi utilizada nos problemas estudados e apresentamos os problemas em termos gerais.

No Capítulo 3, estudamos o problema de maximização da taxa de dados sujeito a QoS e restrições de satisfação. Este problema foi estudado anteriormente apenas na perspectiva de alocação de RBs. Nesta dissertação, estudamos o uso da alocação de RBs e potência de transmissão conjuntamente. Do ponto de vista computacional, este é um problema bem mais desafiador comparado ao seu antecessor. O problema formulado é um problema de otimização inteira e não linear. Conseguimos converter este problema em um problema ILP através da adição de novas variáveis. Consequentemente, a solução ótima para o problema pode ser obtida através de técnicas padrões. Motivado pela alta



complexidade computacional destes métodos, propomos uma nova heurística de baixa complexidade para o problema como solução subótima.

Os resultados de simulação mostraram que a solução subótima proposta tem um desempenho próximo da solução ótima para requisitos de taxa de dados pequenas e moderadas. Portanto, analisando a complexidade computacional e desempenho do algoritmo subótimo proposto, concluímos que ele apresenta uma boa troca de desempenho por complexidade quando comparada com a solução ótima do problema PMT. Estudamos também o impacto das variáveis do problema no desempenho dos algoritmos envolvidos.

No Capítulo 4, estudamos problemas que envolvem a otimização dos recursos energéticos sujeito a QoS e restrições de satisfação. Mais especificamente, estudamos os problemas de maximização da eficiência energética, minimização da potência de transmissão e subtração entre a taxa de dados total e a potência total utilizada. Todos esses problemas são inteiros e não lineares. Conseguimos converter o problema PMEE em um problema MILP e os demais problemas em problemas ILPs, através da adição de novas variáveis. Consequentemente, a solução ótima para estes problemas podem ser obtidas através de técnicas padrões. Motivado pela alta complexidade computacional destes métodos, propomos uma nova heurística de baixa complexidade para o problema de maximização da eficiência energética como solução subótima.

Os resultados de simulação mostraram que o problema PMEE consegue atingir elevadas taxas de dados utilizando uma quantidade de potência de transmissão mínima, ou seja, próxima da potência utilizada pela solução ótima do problema PMP. Portanto, o problema PMEE se apresenta como uma boa solução quando queremos elevar as taxas de dados em troca de potência de transmissão. Outra importante conclusão é que o desempenho das soluções PMP e PMEE tornam-se similares à medida que a carga no sistema aumenta. A razão para tal deve-se ao fato que para altas cargas, os recursos disponíveis de potência de transmissão e RBs devem ser todos alocados a fim de satisfazer o QoS dos usuários e não há margem para otimização da eficiência energética. A solução PROP2 consegue obter um desempenho próximo ao ótimo em cargas leves médias e há uma perda maior de desempenho em cargas elevadas. Outra análise da solução PROP2 nos permite ver que ela alcança taxas de dados até 6 vezes maior que a solução PMP e utiliza uma potência próxima a dos problemas PMP e PMEE. Dessa forma, a solução PROP2 tem um desempenho próximo da ótima para requisitos de taxa de dados pequenas e moderadas. Estudamos também o impacto das variáveis do problema no desempenho dos algoritmos envolvidos. A pequena degradação observada na desempenho pode ser compensada pela baixa complexidade do algoritmo PROP2 comparada com os métodos para a solução ótima. Portanto, fazendo análise da complexidade computacional e desempenho do algoritmo PROP2, concluímos que ele leva a uma boa troca de desempenho por complexidade quando comparada com as estratégias de eficiência energética apresentadas nesta dissertação.

Como lidamos com algoritmos nesta dissertação de mestrado, nos apêndices ?? e ?? apresentamos uma análise da complexidade computacional de pior caso para as soluções propostas. Em termos gerais, podemos verificar que às heurísticas propostas possuem complexidade polinomial enquanto os métodos para obter a solução ótima tem complexidade computacional exponencial no pior caso. Portanto, através de uma análise conjunta dos resultados de simulação e da complexidade, acreditamos que fornecemos contribuições importantes para área de RRA das redes sem fio.

O trabalho desenvolvido nesta dissertação de mestrado abriu novas linhas de pesquisa a serem investigadas. A seguir mencionamos algumas delas:

- Aspectos de modelagem do sistema mais detalhados: Ao longo do nosso trabalho nós consideramos algumas hipóteses simplificadoras como CSI (do inglês, *Channel State Information*) perfeita no transmissor/receptor e interferência intracelular modelada como ruído. Um possível estudo que pode ser desenvolvido a partir desta dissertação de mestrado é a avaliação do impacto da modelagem destes aspectos no desempenho. Esperamos que resultados relativos entre os algoritmos não mudem significativamente, diferentemente do desempenho absoluto que pode ser deteriorado.
- Inviabilidade de soluções: Como comentado ao longo deste dissertação de mestrado, as heurísticas propostas podem terminar sem encontrar uma solução factível. Isto pode acontecer devido a duas razões. A primeira é que a solução do problema já é inviável por si só, em outras palavras, não é possível satisfazer as restrições de satisfação com as condições de canal dadas e requisitos de QoS. A outra razão é devido a subotimalidade das soluções propostas que em alguns casos não é capaz de achar uma solução factível. Ao longo dos capítulos, tecemos alguns comentários de ideias para proceder quando uma solução factível não é encontrada. Uma possível solução é relaxar os requisitos de satisfação, em outras palavras, em um dado serviço diminuir a quantidade mínima de terminais satisfeitos. Outra opção, é de relaxar a taxa de dados requisitadas pelos terminais. Este problema é posto aqui como perspectiva deste trabalho.
- Menor complexidade computacional: Nesta dissertação de mestrado propomos heurísticas com complexidade computacional polinomial no pior caso. A redução desta complexidade computacional fica como perspectiva deste trabalho.
- Análise temporal dos problemas: Ao longo da dissertação analisamos os problemas em um dado TTI. Contudo, em sistemas práticos, a dinâmica de tráfego e entrada/saída de terminais no sistema podem apresentar novas conclusões. Acreditamos que as soluções e algoritmos apresentados aqui podem ser adaptados e generalizados para este novo cenário.

## REFERÊNCIAS

- [1] B, Cravid A. G. G.; Pires D. R.; Sousa H. K. S.: *Tv digital em portugal*. [http://www.img.lx.it.pt/fp/cav/ano2006\\_2007/MEEC/Trab\\_17/artigo\\_divulgacao\\_ficheiros/Page1274.html](http://www.img.lx.it.pt/fp/cav/ano2006_2007/MEEC/Trab_17/artigo_divulgacao_ficheiros/Page1274.html). Acessado em: 29/10/2016.
- [2] Fallgren, A. Osseiran; F. Boccardi; V. Braun; K. Kusume; P. Marsch; M. Maternia; O. Queseth; M. Schellmann; H. Schotten; H. Taoka; H. Tullberg; M. A. Uusitalo; B. Timus; M.: *Scenarios for 5G Mobile and Wireless Communications: the Vision of the METIS Project*. IEEE Communications Magazine, 52(5):26–35, Maio 2014, ISSN 0163-6804.
- [3] ITU: *Requirements related to technical performance for IMT-Advanced radio interface(s)*. Relatório Técnico ITU-R M.2134, International Telecommunication Union, 2008.
- [4] Le, T. E. Bogale; L. B.: *Massive MIMO and mmWave for 5G Wireless HetNet: Potential Benefits and Challenges*. IEEE Vehicular Technology Magazine, 11(1):64–75, Março 2016, ISSN 1556-6072.
- [5] Zappone, S. Buzzi; C. L. I; T. E. Klein; H. V. Poor; C. Yang; A.: *A Survey of Energy-Efficient Techniques for 5G Networks and Challenges Ahead*. IEEE Journal on Selected Areas in Communications, 34(4):697–709, Abril 2016, ISSN 0733-8716.
- [6] challenge, The 1000x data: *Qualcomm, Tech. Rep.*, Nov. 2016, [online] Disponível : <http://www.qualcomm.com/1000x>.  
[online]Dispon~A\penalty\@M\hskip\z@skip\discretionary{-}{-}{-}\penalty\@M\hskip\
- [7] Biczok, A. Fehske; G. Fettweis; J. Malmudin; G.: *The global footprint of mobile communications: The ecological and economic perspective*. IEEE Communications Magazine, 49(8):55–62, Agosto 2011, ISSN 0163-6804.
- [8] Fehske, G. Auer; V. Giannini; C. Desset; I. Godor; P. Skillermark; M. Olsson; M. A. Imran; D. Sabella; M. J. Gonzalez; O. Blume; A.: *How much energy is needed to run a wireless network?* IEEE Wireless Communications, 18(5):40–49, Outubro 2011, ISSN 1536-1284.
- [9] Li, G. Wu; C. Yang; S. Li; G. Y.: *Recent advances in energy-efficient networks and their application in 5G systems*. IEEE Wireless Communications, 22(2):145–151, Abril 2015, ISSN 1536-1284.
- [10] Bohge, Mathias: *Dynamic Resource Allocation in Packet-Oriented Multi-Cell OFDMA Systems*. Tese de Doutorado, Berlin Technology University, Dezembro 2010.

- [11] Beming, J. S. E. Dahlman; S. Parkvall; P.: *3G Evolution: HSPA and LTE for Mobile Broadband, 1st ed.* Academic Press, Julho 2007.
- [12] Goldsmith, Andrea: *Wireless Communications.* Cambridge University Press, 1st edição, 2005.
- [13] Freitas, F. R. M. Lima; S. Wänstedt; F. R. P. Cavalcanti; W. C.: *Scheduling for Improving System Capacity in Multiservice 3GPP LTE.* Journal of Electrical and Computer Engineering, (819729), 2010.
- [14] Raahemifar, S. Sadr; A. Anpalagan; K.: *Radio Resource Allocation Algorithms for the Downlink of Multiuser OFDM Communication Systems.* IEEE Communications Surveys Tutorials, 11(3):92–106, rd 2009, ISSN 1553-877X.
- [15] Luise, F. Shams; G. Bacci; M.: *A Survey on Resource Allocation Techniques in OFDM(A) Networks.* Computer Networks, 65:129–150, Março 2014.
- [16] Thomas, T. M. Cover; J. A.: *Elements of Information Theory.* Editora WILEY, 1991.
- [17] Hughes-Hartogs, D.: *Telebit Corporation. Ensemble Modem Structure for Imperfect Transmission Media, US 4833706,* Maio 1989.
- [18] Lee, Jiho Jang; Kwang Bok: *Transmit Power Adaptation for Multiuser OFDM Systems.* IEEE Journal on Selected Areas in Communications, 21(2):171–178, Janeiro 2003, ISSN 0733-8716.
- [19] Murch, Cheong Yui Wong; R. S. Cheng; K. B. Lataief; R. D.: *Multiuser OFDM with Adaptive Subcarrier, Bit, and Power Allocation.* IEEE Journal on Selected Areas in Communications, 17(10):1747–1758, Outubro 1999, ISSN 0733-8716.
- [20] Liu, D. Kivanc; Hui: *Subcarrier Allocation and Power Control for OFDMA.* Em *Conference Record of the Thirty-Fourth Asilomar Conference on Signals, Systems and Computers*, volume 1, 2000.
- [21] Cioffi, W. Rhee; J. M.: *Increase in Capacity of Multiuser OFDM System Using Dynamic Subchannel Allocation.* Em *VTC2000-Spring. 2000 IEEE 51st Vehicular Technology Conference Proceedings*, volume 2, páginas 1085–1089, Maio 2000.
- [22] Zukang Shen; Andrews, J. G.; B. L. Evans: *Adaptive Resource Allocation in Multiuser OFDM Systems with Proportional Rate Constraints.* IEEE Transactions on Wireless Communications, 4(6):2726 – 2737, Novembro 2005.
- [23] Liu, H. Yin; H.: *An Efficient Multiuser Loading Algorithm for OFDM-based Broadband Wireless Systems.* Em *Global Telecommunications Conference, 2000. GLOBECOM '00. IEEE*, volume 1, páginas 103–107, Dezembro 2000.

- [24] Letaief, Ying Jun Zhang; K. B.: *Multiuser Adaptive Subcarrier-and-Bit Allocation with Adaptive Cell Selection for OFDM Systems*. IEEE Transactions on Wireless Communications, 3(5):1566–1575, Setembro 2004, ISSN 1536-1276.
- [25] Yang, Wei Xu; Chunming Zhao; Peng Zhou; Yijin: *Efficient Adaptive Resource Allocation for Multiuser OFDM Systems with Minimum Rate Constraints*. Em *2007 IEEE International Conference on Communications*, páginas 5126–5131, Junho 2007.
- [26] Gidlund, M.: *A Radio Resource Allocation Scheme for Multi-Traffic Broadband Wireless Access Systems*. Em *2008 European Conference on Wireless Technology*, páginas 61–64, Outubro 2008.
- [27] Wang, W. Zhao; S.: *Joint Subchannel and Power Allocation in Multiuser OFDM Systems with Minimum Rate Constraints*. International Journal of Communication systems, 27:1–12, Março 2012.
- [28] Abbasfar, A. Sani; M. M. Feghhi; A.: *Discrete Bit Loading and Power Allocation for OFDMA Downlink with Minimum Rate Guarantee for Users*. International Journal of Electronics and Communications, 68:602–610, Janeiro 2014.
- [29] Chih-Lin, S. Bian; J. Song; M. Sheng; Z. Shao; J. He; Y. Zhang; Y. Li; I.: *Sum-Rate Maximization in OFDMA Downlink Systems: A Joint Subchannels, Power, and MCS Allocation Approach*. Em *2014 IEEE 25th Annual International Symposium on Personal, Indoor, and Mobile Radio Communication (PIMRC)*, páginas 1073–1077, Setembro 2014.
- [30] Zeng, J. Du; L. Zhao; J. Xin; J. M. Wu; J.: *Using Joint Particle Swarm Optimization and Genetic Algorithm for Resource Allocation in TD-LTE Systems*. Em *2015 11th International Conference on Heterogeneous Networking for Quality, Reliability, Security and Robustness (QSHINE)*, páginas 171–176, Agosto, 2015.
- [31] Zhong, A. Letchford; Q. Ni; Z.: *An Exact Algorithm for a Resource Allocation Problem in Mobile Wireless Communications*. Relatório Técnico, Department of Management Science, Lancaster University, UK, 2016.  
[http://www.optimization-online.org/DB\\_HTML/2016/05/5429.html](http://www.optimization-online.org/DB_HTML/2016/05/5429.html).
- [32] Liang, X. Lei; Z.: *Joint Time-Frequency-Power Resource Allocation Algorithm for OFDMA Systems*. Em *2015 IEEE 5th International Conference on Electronics Information and Emergency Communication*, Maio 2015.
- [33] Al-Dweik, M. Kalil; A. Shami; A.: *QoS-Aware Power-Efficient Scheduler for LTE Uplink*. IEEE Transactions on Mobile Computing, 14(8):1672–1685, Agosto 2015.
- [34] Ma, S. Chen; Z. Ren; B. Hu; W.: *Resource Allocation in Downlink OFDM Wireless Systems with User Rate Allowed Regions*. Wireless Personal Communications,

80(1):429–445, 2015, ISSN 1572-834X.  
<http://dx.doi.org/10.1007/s11277-014-2019-1>.

- [35] Cavalcanti, F. R. M. Lima; T. F. Maciel; W. C. Freitas; F. R. P.: *Resource Assignment for Rate Maximization with QoS Guarantees in Multiservice Wireless Systems*. IEEE Transactions on Vehicular Technology, 61(3):1318 –1332, Março 2012, ISSN 0018-9545.
- [36] Jorswieck, A. Zapone; E.: *Energy Efficiency in Wireless Networks via Fractional Programming Theory*. Em *Foundations and Trends in Communications and Information Theory*, volume 11, 2015.
- [37] Krishnamachari, E. Oh; K. Son; B.: *Dynamic Base Station Switching-On/Off Strategies for Green Cellular Networks*. IEEE Transactions on Wireless Communications, 12(5), Maio 2013, ISSN 1536-1276.
- [38] 5G-PPP: *5G manifesto*. Em *Mobile World Congress*, 2016.
- [39] Ni, H. Pervaiz; L. Musavian; Q.: *Joint user association and energy-efficient resource allocation with minimum-rate constraints in two-tier HetNets*. Em *2013 IEEE 24th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC)*, páginas 1634–1639, Setembro 2013.
- [40] Zhang, J. G. Andrews; S. Buzzi; W. Choi; S. V. Hanly; A. Lozano; A. C. K. Soong; J. C.: *What Will 5G Be?* IEEE Journal on Selected Areas in Communications, 32(6):1065–1082, Junho 2014, ISSN 0733-8716.
- [41] Schober, D. W. K. Ng; E. S. Lo; R.: *Energy-Efficient Resource Allocation in Multi-Cell OFDMA Systems with Limited Backhaul Capacity*. IEEE Transactions on Wireless Communications, 11(10):3618–3631, Outubro 2012, ISSN 1536-1276.
- [42] Buzzi, L. Venturino; A. Zappone; C. Risi; S.: *Energy-Efficient Scheduling and Power Allocation in Downlink OFDMA Networks With Base Station Coordination*. IEEE Transactions on Wireless Communications, 14(1):1–14, Janeiro 2015, ISSN 1536-1276.
- [43] Almeida Amazonas; T. Abrao, A. e Souza; J. de: *Power and Subcarrier Allocation Strategies for Energy-efficient Uplink OFDMA Systems*. IEEE Journal on Selected Areas in Communications, PP(99):1–1, 2016, ISSN 0733-8716.
- [44] Sanguinetti, G. Bacci; E. V. Belmega; P. Mertikopoulos; L.: *Energy-Aware Competitive Power Allocation for Heterogeneous Networks Under QoS Constraints*. IEEE Transactions on Wireless Communications, 14(9):4728–4742, Setembro 2015, ISSN 1536-1276.
- [45] Hanzo, T. Abrao; L. D. H. Sampaio; S. Yang; K. T. K. Cheung; P. J. E. Jeszensky;

- L.: *Energy Efficient OFDMA Networks Maintaining Statistical QoS Guarantees for Delay-Sensitive Traffic*. IEEE Access, 4:774–791, 2016, ISSN 2169-3536.
- [46] Ding, H. Pervaiz; L. Musavian; Q. Ni; Z.: *Energy and Spectrum Efficient Transmission Techniques Under QoS Constraints Toward Green Heterogeneous Networks*. IEEE Access, 3:1655–1671, 2015, ISSN 2169-3536.
- [47] Seol, Changkyu; Cheun, Kyungwhoon: *A Statistical Inter-Cell Interference Model for Downlink Cellular OFDMA Networks under Log-Normal Shadowing and Multipath Rayleigh Fading*. IEEE Transactions on Communications, 57:3069–3077, Outubro 2009, ISSN 0090-6778.  
<http://dx.doi.org/10.1109/TCOMM.2009.10.080152>.
- [48] Yang, R. Wang; H. Hu; X.: *Potentials and Challenges of C-RAN Supporting Multi-RATs Toward 5G Mobile Networks*. IEEE Access, 2:1187–1195, 2014, ISSN 2169-3536.
- [49] Roche; J. Zhang, D. Lopez Perez; A. Valcarce; G. de la: *OFDMA Femtocells: A Roadmap on Interference Avoidance*. IEEE Communications Magazine, 47(9):41–48, Setembro 2009, ISSN 0163-6804.
- [50] Vasudevan, S., R. N. Pupala e K. Sivanesan: *Dynamic eICIC - A Proactive Strategy for Improving Spectral Efficiencies of Heterogeneous LTE Cellular Networks by Leveraging User Mobility and Traffic Dynamics*. 12(10):4956–4969, Outubro 2013, ISSN 1536-1276.
- [51] Frederiksen, K. I. Pedersen; Y. Wang; B. Soret; F.: *eICIC Functionality and Performance for LTE HetNet Co-Channel Deployments*. Em *2012 IEEE Vehicular Technology Conference (VTC Fall)*, páginas 1–5, Setembro 2012.
- [52] Wosley, George Nemhauser; Laurence: *Integer and Combinatorial Optimization*. Editora WILEY, 1999.
- [53] Lee, I. Kim; I. S. Park; Y. H.: *Use of Linear Programming for Dynamic Subcarrier and Bit Allocation in Multiuser OFDM*. IEEE Transactions on Vehicular Technology, 55(4):1195–1207, Julho 2006, ISSN 0018-9545.
- [54] Furuskär, A.: *Radio Resource Sharing and Bearer Service Allocation for Multi-Bearer Service, Multi-Access Wireless Networks*. Tese de Doutorado, Royal Institute of Technology (KTH), Radio Communication Systems, Abril 2003.
- [55] 3GPP: *Physical layer aspects for evolved Universal Terrestrial Radio Access (UTRA)*. Relatório Técnico TR 25.814 V7.1.0, Third Generation Partnership Project, Setembro 2006.
- [56] 3GPP: *Evolved universal terrestrial radio access (E-UTRA); physical layer*

*procedures*. Relatório Técnico TR 36.213 V8.6.0, Third Generation Partnership Project, Março 2009.

- [57] Bosanska, C. Mehlführer; M. Wrulich; J. C. Ikuno; D. e M. Rupp: *Simulating the Long Term Evolution Physical Layer*. Em *2009 17th European Signal Processing Conference*, Glasgow, Scotland, Agosto 2009.  
[http://publik.tuwien.ac.at/files/PubDat\\_175708.pdf](http://publik.tuwien.ac.at/files/PubDat_175708.pdf).
- [58] 3GPP: *Evolved Universal Terrestrial Radio Access (E-UTRA) TR 36.213*. Relatório Técnico, março 2009.
- [59] IBM: *IBM ILOG CPLEX Optimizer*.  
<http://www-01.ibm.com/software/integration/optimization/cplex-optimizer/>.
- [60] Wu, T.: *A note on a global approach for general 0-1 fractional programming*. *European Journal of Operational Research*, 101:220–223, 1997.
- [61] Sierksma, G.: *Linear and Integer Programming*. New York: Marcel Dekker, 2009.



## APÊNDICE A – COMPLEXIDADE COMPUTACIONAL E PSEUDOCÓDIGO DOS ALGORITMOS DO CAPÍTULO 3

### Complexidade Computacional para Obter a Solução Ótima do PMT

Assim como em [24] e [25], consideramos somatórios, multiplicações, e comparações como as operações mais relevantes do ponto de vista computacional e que consomem mais tempo de processamento. A complexidade computacional considerada aqui é a de pior caso que nos dá um limitante superior dos recursos computacionais requisitados por um algoritmo e é representada pela notação assintótica  $O(\cdot)$ . Para obter a solução ótima do problema PMT, usamos o algoritmo BC. Para um número arbitrário de variáveis inteiras  $l$ , o número de subproblemas de programação linear para ser resolvido é pelo menos  $(\sqrt{2})^l$  [61]. Entretanto, o número de iterações necessárias para resolver um problema de programação linear com  $m$  restrições e  $l$  variáveis é aproximadamente  $2(m + l)$ , e cada iteração engloba  $(lm - m)$  multiplicações,  $(lm - m)$  somatórios, e  $(l - m)$  comparações [24, 61]. Como no problema (11) existem  $JNM + J$  variáveis de otimização e  $JN + J + N + S + 1$  restrições. Portanto, a complexidade computacional no pior caso para obter a solução ótima é  $O(\sqrt{2}^{(JNM+J)})$ . Retendo-se o termo de maior ordem, temos que a complexidade computacional é de  $O(2^{JNM})$ .

### Pseudocódigo e Complexidade Computacional para Obter a Solução Subótima do PMT

Assumindo a mesma hipótese anterior, nesta seção iremos calcular a complexidade computacional no pior caso da solução apresentada na Seção 3.2. Nos algoritmos 1 e 2 representamos a heurística proposta em forma de pseudocódigo de forma a calcular o número de operações de cada passo do algoritmo. Assuma que  $\mathcal{O}(M \times N \times \log_2 N)$  é a complexidade do algoritmo HH [18] e a lista de variáveis consideradas nesta análise são apresentadas na Tabela 8.

Para a primeira parte da solução subótima, no pior caso o laço principal repetirá  $N + J$  vezes. Portanto, as linhas 2, 4, 5, 7 e 12 irão fazer  $5(N + J)$  comparações. Já na linha 8

Tabela 8: Descrição dos parâmetros utilizados nos algoritmos.

Variável	Definição
$N$	Número de RBs no problema
$J$	Número de usuários no sistema
$J_s$	Número de usuários usando o serviço $s$
$S$	Número de serviços
$k_s$	Número de usuários satisfeitos no serviço $s$
$\mathcal{A}$	Conjunto composto pelos melhores $k_s$ terminais de acordo com $(\bar{r}_j/t_j)$
$\mathcal{N}$	Conjunto composto pelos RBs disponíveis no sistema
$\mathcal{B}$	Conjunto composto pelos número mínimo de RBs necessários para cada usuário $\in A$ ser satisfeito

**Algorithm 1** Solução subótima: primeira parte

```

1: Enquanto verdadeiro faça
2:   se  $\mathcal{A} = \emptyset$  então
3:     Vá para a segunda parte da Solução Subótima.
4:   se não
5:     se  $\mathcal{N} = \emptyset$  então
6:       Solução Factível Não Encontrada
7:     se não
8:        $S_1 \leftarrow$  terminal  $\in \mathcal{A}$  com  $\min\{\frac{\bar{r}_i}{t_j}\}$ 
9:        $S_2 \leftarrow$  melhor RB  $\in \mathcal{N}$  do terminal  $S_1$ 
10:      Aloque o RB  $S_2$  ao terminal  $S_1$ 
11:      Remova  $S_2$  do conjunto  $\mathcal{N}$  .
12:      se Número de RBs de  $S_1$  for igual a  $\mathcal{B}\{S_1\}$  então
13:        Remova  $S_1$  do conjunto  $\mathcal{A}$ 
14:      fim do se
15:    fim do se
16:  fim do se
17: fim do enquanto

```

iremos procurar pelo valor mínimo do vetor de tamanho  $J$ , em outras palavras, iremos ter  $J(N + J)$  comparações. O mesmo ocorre na linha 9, contudo, para um vetor de tamanho  $N$ . Deste modo teremos  $N(N + J)$  comparações. A complexidade total do algoritmo é  $(N + J)(5 + J + N)$  que após simplificado volta a ser  $(N + J)(N + J)$ .

Para segunda parte do algoritmo subótimo, nas linhas 1 – 4, o algoritmo HH é aplicado  $J$  vezes, o que nos fornece uma complexidade de  $\mathcal{O}(J(M \times N \times \log_2 N))$ , Na linha 5 começa o laço principal que irá se repetir  $N + J$  vezes. Cada uma das linhas 6, 8, 9, 11, 12, 14, 19 e 22 fazem uma comparação. As linhas 15 e 16 fazem comparações para encontrar o valor mínimo e máximo de vetores com tamanhos  $J$  e  $N$ , respectivamente, a

---

**Algorithm 2** Solução Subótima: segunda parte
 

---

```

1: Para  $i$  até  $J$  faça
2:   aplique HH nos terminais  $i$  com RBs  $N_i$  até o terminal  $i$  ser satisfeito sem restrição
   de potência.
3:    $P^{\text{atual}_1} \leftarrow$  atualize a potência total.
4: fim do para
5: enquanto verdadeiro faça
6:   se  $P^{\text{atual}_1} \leq P^{\text{tot}}$  então
7:     Solução Factível Encontrada.
8:   se não
9:     se  $\mathcal{N} = \emptyset$  se não
10:      Solução Factível Não Encontrada.
11:    se não
12:      se  $\mathcal{A} = \emptyset$  então
13:        Solução Factível Não Encontrada.
14:      se não
15:         $S_1 \leftarrow$  terminal com  $\min\{\frac{\bar{r}_j}{t_j}\}$ 
16:         $S_2 \leftarrow$  melhor RB  $\in \mathcal{N}$  do terminal  $S_1$ 
17:        aplique HH em  $S_1$  com  $\mathcal{N}_{S_1}$  e  $S_2$  RBs até o terminal  $S_1$  ser satisfeito sem
        restrição de potência.
18:         $P^{\text{atual}_2} \leftarrow$  Potência total utilizada
19:        se  $P^{\text{atual}_2} < P^{\text{atual}_1}$  então
20:          Aloque o RB  $S_2$  ao terminal  $S_1$ 
21:           $P^{\text{atual}_1} \leftarrow$  Potência total utilizada
22:        se não
23:          Remova  $S_1$  do conjunto  $\mathcal{A}$ 
24:        fim do se
25:      fim do se
26:    fim do se
27:  fim do se
28: fim do enquanto
29: if Solução Factível Encontrada então
30:   Faça Max Rate
31: fim do se

```

---

linha 17 aplica o algoritmo HH nos usuários selecionados e a linha 30 maximiza a taxa de dados através da aplicação do algoritmo HH uma vez. Portanto, a complexidade total do algoritmo é  $\mathcal{O}(J(M \times N \times \log_2 N) + (N + J)(8 + J + N + 2(M \times N \times \log_2 N)))$  que após simplificação teremos  $\mathcal{O}(J(M \times N \times \log_2 N) + (N + J)(J + N + 2(M \times N \times \log_2 N)))$ .

Dessa forma a complexidade da solução proposta no pior caso é  $\mathcal{O}(J \times N \times M \times \log(N))$ .

## APÊNDICE B – COMPLEXIDADE COMPUTACIONAL E PSEUDOCÓDIGO DOS ALGORITMOS DO CAPÍTULO 4

### Complexidade computacional para obter a solução ótima do PMEE

Assumindo as mesmas considerações do Apêndice A, a solução ótima do problema de maximização de eficiência energética 20 pode ser obtida através do uso do algoritmo BC. Como no problema existem  $JNM + 1 + JNM + J + J$  variáveis de otimização e  $N + 1 + J + S + JNM + JNM + JNM + J + J + J + 1 + JN$  restrições, a complexidade computacional no pior caso para obter a solução ótima é  $O(\sqrt{2}^{(JNM+1+JNM+J+J)})$ . Retendo-se o termo de maior ordem, temos que a complexidade computacional é de  $O(2^{JNM})$ .

### Complexidade computacional para obter a solução ótima do PMP

Assumindo as mesmas considerações do Apêndice A, a solução ótima do problema de minimização de potência (23) pode ser obtida através do uso do algoritmo BB. Como no problema existem  $JNM + J$  variáveis de otimização e  $JN + J + N + S + 1$  restrições, a complexidade computacional no pior caso para obter a solução ótima é  $O(\sqrt{2}^{(JNM+J)})$ . Retendo-se o termo de maior ordem, temos que a complexidade computacional é de  $O(2^{JNM})$ .

### Complexidade Computacional para Obter a Solução Ótima do PMDTP

Assumindo as mesmas considerações do Apêndice A, a solução ótima do problema de maximização diferença entre taxa total e potência (26) pode ser obtida através do uso do algoritmo BB. Como no problema existem  $JNM + J$  variáveis de otimização e  $JN + J + N + S + 1$  restrições, a complexidade computacional no pior caso para obter a solução ótima é  $O(\sqrt{2}^{(JNM+J)})$ . Retendo-se o termo de maior ordem, temos que a complexidade computacional é de  $O(2^{JNM})$ .

## Pseudocódigo Complexidade Computacional para Obter a Solução Subótima do PMEE

Assumindo a mesma hipótese do Apêndice A, nesta seção iremos calcular a complexidade computacional de pior caso da solução apresentada na Seção 4.4. Nos algoritmos 3, 4 e 5 apresentamos a heurística proposta em forma de pseudocódigo de forma a calcular o número de operações de cada passo do algoritmo. Assuma que  $\mathcal{O}(M \times N \times \log_2 N)$  é a complexidade do algoritmo HH [18] e a lista de variáveis consideradas nesta análise são apresentadas na Tabela 9.

Tabela 9: Descrição dos parâmetros utilizados nos algoritmos.

Variável	Definição
$N$	Número de RBs no problema
$J$	Número de usuários no sistema
$J_s$	Número de usuários usando o serviço $s$
$S$	Número de serviços
$k_s$	Número de usuários satisfeitos no serviço $s$
$\mathcal{A}$	Conjunto composto pelos melhores $k_s$ terminais de acordo com $(\bar{r}_j/t_j)$
$\mathcal{N}$	Conjunto composto pelos RBs disponíveis no sistema
$\mathcal{B}$	Conjunto composto pelos número mínimo de RBs necessários para cada usuário $\in \mathcal{A}$ ser satisfeito

---

### Algorithm 3 Solução subótima PMEE: primeira parte

---

```

1: Enquanto verdadeiro faça
2:   se  $\mathcal{A} = \emptyset$  então
3:     Vá para a segunda parte da Solução Subótima.
4:   se não
5:     se  $\mathcal{N} = \emptyset$  então
6:       Solução Factível Não Encontrada
7:     se não
8:        $S_1 \leftarrow$  terminal  $\in \mathcal{A}$  com  $\min\{\frac{\bar{r}_j}{t_j}\}$ 
9:        $S_2 \leftarrow$  melhor RB  $\in \mathcal{N}$  do terminal  $S_1$ 
10:      Aloque o RB  $S_2$  ao terminal  $S_1$ 
11:      Remova  $S_2$  do conjunto  $\mathcal{N}$ .
12:      se Número de RBs de  $S_1$  for igual a  $\mathcal{B}\{S_1\}$  então
13:        Remova  $S_1$  do conjunto  $\mathcal{A}$ 
14:      fim do se
15:    fim do se
16:  fim do se
17: fim do enquanto

```

---

A primeira parte da solução subótima consiste na mesma da especificada no apêndice 5 e possui complexidade no pior caso de  $(N + J)(N + J)$ .

---

**Algorithm 4** Solução Subótima PMEE: segunda parte

---

```

1: Para  $i$  até  $J$  faça
2:   aplique HH nos terminais  $i$  com RBs  $N_i$  até o terminal  $i$  ser satisfeito sem restrição
   de potência.
3:    $P^{\text{atual}_1} \leftarrow$  atualize a potência total.
4: fim do para
5: enquanto verdadeiro faça
6:   se  $P^{\text{atual}_1} \leq P^{\text{tot}}$  então
7:     Vá para a terceira parte da solução subótima.
8:   se não
9:     se  $\mathcal{N} = \emptyset$  se não
10:      Solução Factível Não Encontrada.
11:    se não
12:      se  $\mathcal{A} = \emptyset$  então
13:        Solução Factível Não Encontrada.
14:      se não
15:         $S_1 \leftarrow$  terminal com  $\min\{\frac{\bar{r}_j}{t_j}\}$ 
16:         $S_2 \leftarrow$  melhor RB  $\in \mathcal{N}$  do terminal  $S_1$ 
17:        aplique HH em  $S_1$  com  $\mathcal{N}_{S_1}$  e  $S_2$  RBs até o terminal  $S_1$  ser satisfeito sem
        restrição de potência.
18:         $P^{\text{atual}_2} \leftarrow$  Potência total utilizada
19:        se  $P^{\text{atual}_2} < P^{\text{atual}_1}$  então
20:          Aloque o RB  $S_2$  ao terminal  $S_1$ 
21:           $P^{\text{atual}_1} \leftarrow$  Potência total utilizada
22:        se não
23:          Remova  $S_1$  do conjunto  $\mathcal{A}$ 
24:        fim do se
25:      fim do se
26:    fim do se
27:  fim do se
28: fim do enquanto

```

---

Para segunda parte do algoritmo subótimo, nas linhas 1 – 4, o algoritmo HH é aplicado  $J$  vezes, o que nos fornece uma complexidade de  $\mathcal{O}(J(M \times N \times \log_2 N))$ , Na linha 5 começa o laço principal que irá se repetir  $N + J$  vezes. Cada uma das linhas 6, 8, 9, 11, 12, 14, 19 e 22 fazem uma comparação. As linhas 15 e 16 fazem comparações para encontrar o valor mínimo e máximo de vetores com tamanhos  $J$  e  $N$ , respectivamente, a linha 17 aplica o algoritmo HH nos usuários selecionados. Portanto, a complexidade total do algoritmo é  $\mathcal{O}(J(M \times N \times \log_2 N) + (N + J)(8 + J + N + (M \times N \times \log_2 N)))$  que após simplificação teremos  $\mathcal{O}(J(M \times N \times \log_2 N) + (N + J)(J + N + (M \times N \times \log_2 N)))$ .

Para a terceira parte da solução subótima, no pior caso o laço principal repetirá  $N + M$

---

**Algorithm 5** Solução subótima PMEE: primeira parte
 

---

```

1: Aloque os RBs do conjunto  $\mathcal{N}$  aos melhores terminais de  $\mathcal{J}$ .
2: enquanto verdadeiro faça
3:    $S_1$  e  $S_2 \leftarrow$  RB e MCS que maximiza a eficiência energética do sistema, respectivamente. Nível de MCS do RB não pode decrescer.
4:   se nova alocação de MCSs é menor  $P^{tot}$ 
5:     se Eficiência energética com nova alocação de MCS  $\geq$  eficiência energética atual
6:       Atualize a MCS do RB  $S_2$  para a MCS  $S_1$ .
7:     se não
8:       Solução factível encontrada.
9:     fim do se
10:  se não
11:    Solução factível encontrada.
12:  fim do se
13: fim do enquanto

```

---

vezes. Dessa forma, na linha 3 iremos percorrer uma matriz de  $N \times J$ , portanto teremos  $(N \times J)(N + M)$  operações. Nas linhas 4, 5, 7 e 9 iremos fazer  $4(N + M)$  comparações. Desse modo, a complexidade total do algoritmo é  $(N + M)(4 + (N \times J))$ , simplificando teremos  $(N + M)(N \times J)$ .

Dessa forma a complexidade da solução proposta no pior caso é  $\mathcal{O}(J \times N \times M \times \log(N))$ .

## APÊNDICE C – PSEUDOCÓDIGO DO ALGORITMO DE ALOCAÇÃO DE POTÊNCIA HH

### Pseudocódigo do Algoritmo de Alocação de Potência HH

---

#### Algorithm 6 Algoritmo HH

---

- 1: Calcule a matriz de potência incremental, consistindo nos valores  $\Delta\lambda_{j,n,m} = \lambda_{j,n,m} - \lambda_{j,n,m-1}$
  - 2:  $P^{tot} = 0$
  - 3: **enquanto**  $P^{tot} \leq P_{max}$  **então**
  - 4: Procure na matriz de potência incremental pelo menor  $\Delta\lambda_{j,n,1}$
  - 5: **Se**  $\Delta\lambda_{j,n,1}$  **é o menor** **então**
  - 6: Incremente em 1 o nível de MCS do RB  $n$  do usuário  $j$
  - 7: Incremente  $P^{tot} = P^{tot} + \Delta\lambda_{j,n,1}$
  - 8: Atualize a matriz de potência incremental por  $\Delta\lambda_{j,n,m} = \Delta\lambda_{j,n,m+1}$
  - 9: **fim do se**
  - 10: **fim do enquanto**
-