

# Alocação de Recursos para Maximização da EE Sujeita a Restrições de Satisfação

Weskley V. F. Mauricio, F. Rafael M. Lima, Tarcísio F. Maciel e Francisco R. P. Cavalcanti

**Resumo**—Motivado pela crescente demanda por maior eficiência no uso dos recursos energéticos em rede móveis, neste trabalho, estudamos o impacto de métricas de Eficiência Energética (EE) no problema de satisfação de *Quality of Service* (QoS) apresentado em [6] que originalmente teve como objetivo maximizar a eficiência espectral. Formulamos dois problemas: Problema de Minimização da Potência (PMP) e Problema de Maximização da Eficiência Energética (PMEE) que em sua forma original são não lineares. Após algumas manipulações algébricas e inserção de novas variáveis e restrições nos problemas de otimização convertimos os problemas PMP e PMEE para *Integer Linear Program* (ILP) e *Mixed integer linear programming* (MILP), respectivamente. Através de simulações computacionais, estudamos o impacto dessas novas métricas de EE no problema em [6]. Verificamos que a solução PMEE apresenta-se como o melhor compromisso em relação a taxa de dados transmitida e economia de potência quando comparada a solução original em [6] e PMP.

**Palavras-Chave**—Alocação de Recursos de Rádio, Eficiência Energética e Qualidade de Serviço.

**Abstract**—Motivated by the growing demand for more efficient use of energy resources in mobile network, in this work, we study the impact of EE metrics in the QoS satisfaction problem presented in [6] which originally had the objective of maximizing the spectral efficiency. We formulate two problems: PMP and PMEE which in their original form are nonlinear. After some algebraic manipulations and insertion of new variables and constraints in the problems we converted the PMP and PMEE problems on ILP and MILP, respectively. Through computer simulations, we studied the impact of these new EE metrics on the problem in [6]. We verified that PMEE solution presented the best compromise in relation to the transmitted data rate and power saving when compared the original solution in [6] and PMP.

**Keywords**—Radio Resource Allocation, Energy Efficiency and Quality of Service.

## I. INTRODUÇÃO

As comunicações móveis vêm experimentando um incrível desenvolvimento ao longo de 30 anos, desde a Primeira Geração (1G) analógica dos sistemas celulares até os primeiros testes comerciais das redes de Quarta Geração (4G). Atualmente, a rede de Quinta Geração (5G) é alvo de intensa pesquisa na área industrial e acadêmica. As principais motivações para tal interesse são as demandas por melhor *Quality of Service* (QoS), menor latência, maior taxa de dados, novos serviços (multimídia) e maior Eficiência Energética (EE) [1].

Apesar de estudos sobre comunicações com EE terem sua origem há pelo menos duas décadas no contexto de teoria

Emails: aluncardx@gmail.com, {rafaelm,maciel,rodrigo}@gtel.ufc.br. Os autores pertencem ao Grupo de Pesquisa em Telecomunicações Sem Fio da Universidade Federal do Ceará.

da informação, este campo de estudo tornou-se muito ativo na última década. 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 [2].

Alocação de Recursos de Rádio ou do inglês *Radio Resource Allocation* (RRA) consiste 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. Algoritmos de RRA têm sido utilizados com sucesso para otimizar as redes móveis em termos eficiência espectral, satisfação de QoS e aumento da capacidade [3]. Neste artigo, estudamos o impacto na capacidade dos sistemas de diferentes formas de otimizar EE com a presença de requisitos de satisfação e QoS.

## II. ESTADO DA ARTE E PRINCIPAIS CONTRIBUIÇÕES

Em geral, problemas de RRA têm sido estudados na literatura na forma de problemas de otimização [3], [4]. Em sua maioria, estes problemas tinham como filosofia principal aumentar o número de bits transmitidos por Hertz sujeito a diferentes restrições.

Um dos primeiros esforços em direção a um 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. [5]. Estudos mais recentes em EE consideram outras métricas dependendo do sistema empregado e suas características [2]. 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. Independente das métricas utilizadas para contabilizar EE, restrições de QoS que assegurem um provimento adequado dos serviços multimídia devem ser também consideradas. 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 *Signal-to-Noise Ratio* (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 [6], nós estudamos o problema de RRA de maximização de taxa total de dados sujeita a restrições de satisfação mínima

por serviço. Basicamente, nesse problema nós assumimos que as operadoras dos sistemas de comunicação necessitam que uma certa fração de usuários conectados a cada serviço seja satisfeita com o QoS requisitado. Diante da crescente demanda por maior EE, neste artigo, avaliamos o problema de maximização da EE sob a ótica de diferentes métricas sujeito a critérios de satisfação do QoS dos usuários. Estudamos também o impacto e vantagens de diferentes métricas de EE no problema de RRA apresentado em [6] que considerou o antigo conceito de maximização da eficiência espectral. As principais contribuições deste artigo são:

- Formulação matemática de novos problemas de EE com as restrições de satisfação e QoS presentes em [6];
- Caracterização da solução ótima dos problemas de EE formulados;
- Estudo e avaliação do impacto dos novos problemas de EE através de simulações computacionais.

### III. MODELAGEM DO SISTEMA

Consideramos que um número de células setorizadas compõe um sistema celular. Para um dado setor de uma célula, existe um grupo de usuários conectados a uma Estação Rádio Base (ERB). O estudo realizado neste artigo é focado no enlace direto. Assumimos que o acesso ao meio é organizado através de uma combinação de *Orthogonal Frequency Division Multiple Access* (OFDMA) e *Time Division Multiple Access* (TDMA). Assim, um bloco de recurso ou *Resource Block* (RB) é composto por um grupo de subportadoras adjacentes e um número de símbolos *Orthogonal Frequency Division Multiplexing* (OFDM) consecutivos, que representam um intervalo de tempo de transmissão ou do inglês, *Transmission Time Interval* (TTI). Não existe interferência intracelular visto que um mesmo RB não pode ser alocado a diferentes usuários dentro de um mesmo setor. Assumimos a hipótese simplificada que a interferência intercelular é modelada como um additive white Gaussian noise (AWGN) e, assim, a SINR pode ser aproximada para uma expressão de SNR. Ressaltamos que essa suposição se torna cada vez mais válida à medida que o número de ERBs no sistema aumenta [7].

Em um dado TTI, consideramos que  $\mathcal{J} = \{1, \dots, J\}$  e  $\mathcal{N} = \{1, \dots, N\}$  são os conjuntos de usuários e RBs, respectivamente. Consideramos  $\mathcal{S}$  como sendo o conjunto de todos os serviços prestados pela operadora. O conjunto de todos usuários que utilizam o serviço  $s \in \mathcal{S}$  é definido por  $\mathcal{J}_s$  e o número de elementos deste conjunto é dado por  $|\mathcal{J}_s| = J_s$ , em que  $|\cdot|$  é a cardinalidade de um conjunto, cada usuário pode utilizar apenas um serviço.

Assumindo que o RB  $n$  é atribuído ao usuário  $j$ , a SNR  $\gamma_{j,n}$  recebida do usuário  $j$  no RB  $n$  é dada por

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

em que  $\alpha_j$  modela o efeito do ganho de percurso e desvanecimento de longo prazo experimentado no enlace entre a ERB e o terminal  $j$ ,  $h_{j,n}$  é a resposta em frequência de curto prazo do canal do usuário  $j$  no RB  $n$ ,  $\sigma^2$  é a potência média do ruído térmico,  $\|\cdot\|$  representa o valor absoluto e, por fim,  $p_n$

é a potência de transmissão alocada ao RB  $n$ . Assumimos que  $P^{\text{tot}}$  é a potência total disponível na ERB.

Através do uso de adaptação de enlace, um transceptor pode transmitir com diferentes taxas de dados de acordo com a SNR experimentada. Assumimos que o mapeamento entre a SNR e a taxa de dados transmitida seja dada por uma função discreta  $f(\cdot)$ , que modela *Modulation and Coding Schemes* (MCSs) empregadas em redes sem fio práticas. A taxa de dados transmitida quando o RB  $n$  é atribuído ao usuário  $j$  é dada por  $r_{j,n} = f(\gamma_{j,n})$ . Dependendo da SNR experimentada, diferentes taxas de dados podem ser transmitidas. Assumimos que existem  $M$  possíveis níveis de MCSs e portanto,  $M$  não-zero possíveis taxas de dados por RB em que  $v^m$  representa a taxa de dados correspondente ao  $m$ -ésimo nível de MCS.  $\mathcal{M} = \{0, 1, 2, \dots, M\}$  é o conjunto de todas as MCSs. Note que o  $m$ -ésimo nível de MCS é empregado quando a SNR estimada está entre  $\gamma^m$  e  $\gamma^{m+1}$  com  $\gamma^m < \gamma^{m+1}$ .

Note que para transmitir com uma dada MCS  $m$  é suficiente garantir a menor SNR dentro do intervalo de SNRs correspondente a MCS  $m$ ,  $\gamma^m$ . Desta forma, definimos  $\lambda_{j,n,m}$  como a potência de transmissão mínima que pode ser alocada ao usuário  $j$  no RB  $n$  de modo a utilizar a MCS  $m$ . Especificamente,  $\lambda_{j,n,m}$  é dado por

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

Definimos a variável de otimização (binária),  $y_{j,n,m}$ , que assume valor 1 se o RB  $n$  está alocado ao usuário  $j$  e a transmissão é configurada com o  $m$ -ésimo nível de MCS, e 0 caso contrário. Neste caso, a potência alocada para o RB  $n$  assinalado ao usuário  $j$  é igual a  $\lambda_{j,n,m}$ , equação (2).

### IV. FORMULAÇÃO DO PROBLEMA E SOLUÇÃO ÓTIMA

Nesta seção apresentaremos dois problemas que envolvem otimização da energia do sistema sujeito a um número mínimo de usuários satisfeitos por serviço prestado pela operadora em um dado TTI. O primeiro problema consiste no Problema de Maximização da Eficiência Energética (PMEE) que possui como objetivo a maximização da razão entre a taxa total transmitida e a potência total utilizada. O outro problema consiste no Problema de Minimização da Potência (PMP) que busca minimizar a potência total transmitida. Neste artigo, além de alocação de RB, nós consideramos também alocação dinâmica da potência de transmissão.

Antes de apresentar o problema PMEE em termos matemáticos, definimos outras variáveis importantes. Assumimos que, no TTI atual, o usuário  $j$  tem uma taxa de dados requisitada igual a  $t_j$ . A restrição de satisfação mínima para cada serviço é representada pelo parâmetro  $k_s$ , que é o número mínimo de usuários do serviço  $s$  que devem ser satisfeitos. Assumimos que os índices dos usuários em  $y_{j,n,m}$ ,  $r_{j,n}$  e em  $t_j$  são sequencialmente dispostos de acordo com o serviço, por exemplo, os usuários de  $j = 1$  até  $j = J_1$  são do serviço 1, usuários do  $j = J_1 + 1$  até  $j = J_1 + J_2$  são do serviço 2, e assim por diante.

A formulação do problema é apresentada a seguir

$$\min_{y_{j,n,m}} \frac{\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} \lambda_{j,n,m} \cdot y_{j,n,m}}{\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot y_{j,n,m}}, \quad (3a)$$

sujeito a

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

$$y_{j,n,m} \in \{0, 1\}, \quad \forall j \in \mathcal{J}, \forall n \in \mathcal{N} \text{ and } \forall m \in \mathcal{M}, \quad (3c)$$

$$\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} y_{j,n,m} \cdot \lambda_{j,n,m} \leq P^{\text{tot}}, \quad (3d)$$

$$\sum_{j \in \mathcal{J}_s} u \left( \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot y_{j,n,m}, t_j \right) \geq k_s, \quad \forall s \in \mathcal{S}, \quad (3e)$$

$$\sum_{m \in \mathcal{M}} y_{j,n,m} \leq 1, \quad \forall j \in \mathcal{J} \text{ e } \forall n \in \mathcal{N}, \quad (3f)$$

em que  $u(x, b)$  é uma função degrau em  $b$  que assume o valor 1 se  $x \geq b$  e 0 de outra forma. A função objetivo mostrada em (3a) é a razão entre a potência total e a taxa total de dados (eficiência energética). As duas primeiras restrições (3b) e (3c) asseguram que um RB não será alocado a usuários diferentes. A restrição (3d) assegura que a potência total transmitida usada não será maior que a potência total disponível,  $P^{\text{tot}}$ . A restrição (3e) condiciona que um número mínimo de usuários devem ser satisfeitos por cada serviço. Por fim, a restrição (3f) modela o fato de que no máximo uma única MCS deve ser escolhida para cada par escolhido usuário-RB.

O problema (3) pertence a classe dos problemas de otimização combinatoriais ou inteiros. Note contudo que este problema não é linear devido a função objetivo fracionada e à restrição (3e). De modo a linearizar a restrição (3e), introduzimos uma nova variável de otimização. Considere  $\rho_j$  como uma variável de seleção binária que assume o valor 1 se o usuário  $j$  é selecionado para ser satisfeito e 0 caso contrário [4]. Dessa forma, o problema (3) pode ser reformulado substituindo a restrição (3e) por três novas restrições dadas a seguir:

$$\sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot y_{j,n,m} \geq \rho_j t_j, \quad \forall j \in \mathcal{J}, \quad (4a)$$

$$\rho_j \in \{0, 1\}, \quad \forall j \in \mathcal{J}, \quad (4b)$$

$$\sum_{j \in \mathcal{J}_s} \rho_j \geq k_s, \quad \forall s \in \mathcal{S}. \quad (4c)$$

A fim de linearizar a função objetivo, nós introduzimos 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 fazemos a seguinte transformação:  $x_{j,n,m} = y_{j,n,m} \cdot x_0$  [8]. Observe que a substituição das variáveis  $x_0 \in \mathbb{R}$  e  $x_{j,n,m} \in \mathbb{R}$  no problema (3) fará com que seja necessária a adição da seguinte restrição:

$$\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot x_{j,n,m} = 1. \quad (5a)$$

A ideia é portanto resolver o problema (3) substituindo a variável  $y_{j,n,m}$  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 há garantias que a variável  $y_{j,n,m}$  permaneça binária após essa transformação. De

forma a assegurar isso, introduziremos uma nova variável de otimização binária  $z_{j,n,m}$  e determinaremos 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  $f_2 > x_0, \forall j \in \mathcal{J}, \forall n \in \mathcal{N}$  e  $\forall m \in \mathcal{M}$ . Então iremos adicionar ao problema as três restrições abaixo  $\forall j \in \mathcal{J}, \forall n \in \mathcal{N}$  e  $\forall m \in \mathcal{M}$ :

$$x_{j,n,m} \leq f_1 z_{j,n,m}, \quad (6a)$$

$$x_{j,n,m} - x_0 - f_2 z_{j,n,m} \geq -f_2, \quad (6b)$$

$$x_{j,n,m} - x_0 + f_2 z_{j,n,m} \leq f_2. \quad (6c)$$

Observe que quando  $z_{j,n,m} = 0$  então  $x_{j,n,m} = 0$  e quando  $z_{j,n,m} = 1$  então  $x_{j,n,m} = x_0$ . Podemos observar que ao substituirmos as variáveis  $x_0$  e  $x_{j,n,m}$  na restrição (4), esta se tornará não linear, como podemos ver a seguir:

$$\sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot x_{j,n,m} \geq \rho_j t_j x_0, \quad \forall j \in \mathcal{J}, \quad (7a)$$

$$\rho_j \in \{0, 1\}, \quad \forall j \in \mathcal{J}, \quad (7b)$$

$$\sum_{j \in \mathcal{J}_s} \rho_j \geq k_s, \quad \forall s \in \mathcal{S}. \quad (7c)$$

Portanto, iremos definir uma variável de otimização auxiliar  $\beta_j = \rho_j \cdot x_0$  para garantir a linearidade do problema. De forma equivalente a feita anteriormente, introduziremos uma outra variável de otimização binária  $a_j$  para garantirmos que  $\rho_j$  seja binário e definiremos duas novas constantes  $f_3$  e  $f_4$ , em que  $f_3 > \beta_j, \forall j \in \mathcal{J}$  e  $f_4 > x_0, \forall j \in \mathcal{J}$ . Então, teremos três novas restrições adicionadas ao problema:

$$\beta_j \leq f_3 a_j, \quad \forall j \in \mathcal{J}, \quad (8a)$$

$$\beta_j - x_0 - f_4 a_j \geq -f_4, \quad \forall j \in \mathcal{J}, \quad (8b)$$

$$\beta_j - x_0 + f_4 a_j \leq f_4, \quad \forall j \in \mathcal{J}. \quad (8c)$$

Observe que quando  $a_j = 0$  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 :

$$\min_{x_{j,n,m}} \sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} \lambda_{j,n,m} \cdot x_{j,n,m}, \quad (9a)$$

sujeito a

$$\sum_{j \in \mathcal{J}} \sum_{m \in \mathcal{M}} x_{j,n,m} \leq x_0, \quad \forall n \in \mathcal{N}, \quad (9b)$$

$$\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} x_{j,n,m} \cdot \lambda_{j,n,m} \leq P^{\text{tot}} \cdot x_0, \quad (9c)$$

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

$$\sum_{j \in \mathcal{J}_s} \beta_j \geq k_s \cdot x_0, \quad \forall s \in \mathcal{S}, \quad (9e)$$

$$x_0, x_{j,n,m} \geq 0, \quad \forall j \in \mathcal{J}, \forall n \in \mathcal{N} \text{ e } \forall m \in \mathcal{M}, \quad (9f)$$

$$\sum_{m \in \mathcal{M}} x_{j,n,m} \leq x_0, \quad \forall j \in \mathcal{J} \text{ e } \forall n \in \mathcal{N}, \quad (9g)$$

Além de (5), (6), (7) e (8).

O problema (9) é misto, linear e inteiro ou *Mixed integer linear programming* (MILP). Este problema pode ser resolvido por métodos padrões como o algoritmo Branch-and-Bound

TABELA I  
PRINCIPAIS PARÂMETROS DA SIMULAÇÃO.

Parametro	Valor	Unidade
Raio da célula	334	m
Potência total transmitida	5,25	W
Número de subportadoras por RB	12	-
Desvio padrão do sombreamento	8	dB
Perda de Percurso	$35.3 + 37.6 \cdot \log_{10}(d)$	dB
Densidade espectral do ruído	$3.16 \cdot 10^{-20}$	W/Hz
Número de repetições	1000	-
Número de serviços	2	-
Número de terminais por serviço	4	-
Número de RBs	15	-
Número mínimo de usuários satisfeitos	Cenário 1: 3 (serviço 1) e 3 (serviço 2) Cenário 2: 4 (serviço 1) e 4 (serviço 2)	-

(BB) [9]. A complexidade computacional média para obter a solução ótima por este método é menor quando comparada ao método de enumeração completa ou força bruta.

Podemos observar que através da mudança da função objetivo (3a) pela equação:

$$\min_{y_{j,n,m}} \sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} \lambda_{j,n,m} \cdot y_{j,n,m}, \quad (10a)$$

obteremos o problema PMP. Substituindo a restrição (3e) pelas restrições (4a), (4b) e (4c) podemos ver que este torna-se linear e inteiro ou *Integer Linear Program* (ILP).

## V. RESULTADOS

Esta seção é dedicada a avaliação de desempenho das soluções que envolvem EE propostas na seção IV comparada ao Problema de Maximização da Taxa (PMT) proposta em [6]. Na seção V-A apresentamos as principais suposições do cenário utilizado na simulação enquanto que na seção V-B mostraremos e discutiremos os resultados obtidos.

### A. Caracterização da Simulação

As principais premissas apresentadas na seção III foram implementadas em um simulador computacional. De forma a obter resultados válidos estatisticamente, realizamos diferentes repetições de Monte Carlo. Em cada repetição, os usuários foram uniformemente distribuídos dentro de cada setor celular enquanto que os ganhos de canal foram gerados seguindo suas distribuições estatísticas. Cada RB é composto de 12 subportadoras adjacentes no domínio da frequência e 14 símbolos OFDM consecutivos no domínio do tempo [10].

A propagação rádio-móvel é modelada por uma perda de percurso, uma componente de sombreamento log-normal e uma componente de desvanecimento rápido seguindo distribuição *Rayleigh*. Consideramos que a adaptação de enlace é feita baseada em 15 indicadores de qualidade de canal ou, do inglês, *Channel Quality Indicators* (CQIs) usado nos sistemas *Long Term Evolution* (LTE) [11]. Os limiares de SNR para a troca de MCS foram obtidos pelas simulações de nível de enlace de [12]. A TABELA I resume os parâmetros de simulação utilizados.

Os algoritmos simulados são as soluções ótimas dos problemas PMEE, PMT [6] e PMP, identificados nos gráficos por PMEE OPT, PMT OPT, e PMP OPT, respectivamente. As

realizações dos canais são as mesmas para todos os algoritmos simulados de forma a termos comparações justas. A fim de resolver os problemas ILP e MILP, usamos a biblioteca de resolução numérica de problemas de otimização chamada IBM ILOG CPLEX [13]. A escolha do limitado número de usuários, RBs e serviços é devido a alta complexidade computacional para obter soluções ótimas.

Quanto às métricas de avaliação, consideramos duas principais: taxa total de dados e percentual de potência não utilizada. A taxa total de dados é a soma das taxas de dados obtidas por todos os usuários no setor. Já o percentual de potência não utilizado é o percentual da potência que não foi utilizada em relação a total. Por fim, incrementos na carga oferecida ao sistema são emulados através do aumento do requisito de taxa dos usuários.

### B. Avaliação de Resultados

Na Fig. 1 apresentamos o percentual de potência não utilizada versus a taxa de dados requisitada por cada usuário para as soluções PMEE OPT e PMP OPT nos cenários 1 e 2 identificado nos gráficos como CE1 e CE2, respectivamente. Note que a solução PMT OPT não possui como objetivo reduzir a potencia transmitida, e portanto grande parte da potência da ERB é utilizada. Por esta razão, omitimos sua apresentação na Fig. 1. 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 2. 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 consequentemente mais potência de transmissão deve ser utilizada. Outro comportamento esperado é que os percentuais de potência não utilizada das soluções PMEE OPT, PMP OPT e PMT OPT no cenário 2 são menores do que as do cenário 1. No cenário 2, todos os 8 usuários devem ter suas taxas de dados satisfeitas enquanto que no cenário 1, 3 usuários de 4 devem ser satisfeitos por cada serviço.

Comparando o desempenho relativo dos algoritmos na Fig. 1, podemos ver que a solução PMP OPT apresenta uma maior economia de potência comparada a solução PMEE OPT. 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 91% da potência total disponível enquanto que a solução PMEE OPT economiza 88%.

Na Fig. 2 apresentamos a média da taxa total de dados versus taxa de dados requisitada por cada usuário para as soluções PMEE OPT, PMP OPT e PMT OPT nos cenários 1 e 2. Primeiramente podemos ver que a média da taxa de dados total aumenta linearmente com os requisitos de taxa de dados dos usuários para a solução PMP OPT. Isto é esperado visto que a solução PMP OPT busca apenas garantir a taxa requisitada de cada usuário a fim de que a potência total seja economizada. Baseado nesse mesmo raciocínio, podemos entender a maior taxa de dados total no cenário 2 para soluções

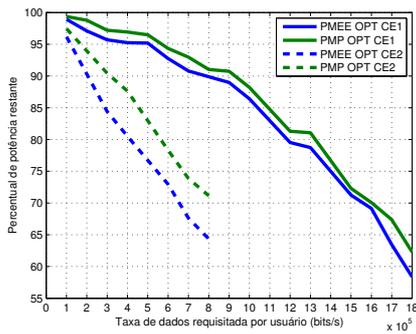


Fig. 1. Percentual de potência não utilizada versus taxa de dados requisitada dos usuários para PMEE OPT, PMP OPT e PMT OPT nos cenários 1 e 2.

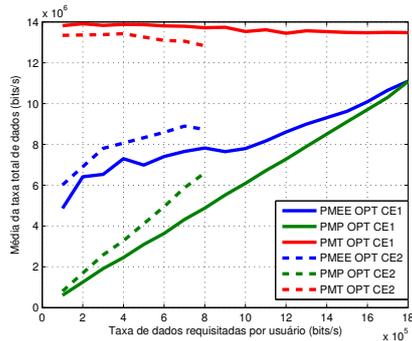


Fig. 2. Média da taxa total de dados versus taxa requisitada dos usuários para PMEE OPT, PMP OPT e PMT OPT nos cenários 1 e 2.

PMEE OPT e PMP OPT, visto que o cenário 2 exige mais usuários satisfeitos que o cenário 1.

Uma comparação relativa entre os três algoritmos mostra que a solução PMT OPT possui a melhor taxa de dados total. Isto é esperado visto que este aspecto está modelado diretamente em sua função objetivo. Contudo, essa maior taxa de dados é obtida sob o custo de um consumo completo da potência de transmissão do sistema. Comparando as soluções PMP e PMEE vemos que a última apresenta ganhos em taxa total comparada a primeira. Para taxa requisitada de 100 kbps, a solução PMEE apresenta um ganho em taxa total de aproximadamente 6 vezes no cenário 2. Importante salientar que esse ganho é obtido com um consumo de potência praticamente igual ao da solução PMP. O ganho em taxa de dados da solução PMEE em relação a PMP diminui à medida que os requisitos de taxa dos usuários aumentam. Isto deve-se ao menor grau de liberdade que a solução PMEE tem para obter ganhos em EE.

## VI. CONCLUSÕES

Neste artigo estudamos o impacto de diferentes métricas de EE no problema de satisfação de QoS em redes móveis apresentado em [6] que teve como foco a maximização da

eficiência espectral. Como contribuição original deste trabalho tivemos a formulação do problema de minimização da potência transmissão sujeito a restrições de satisfação de QoS (PMP) e do problema de maximização da razão entre a taxa total transmitida e a potência total utilizada sujeito a restrições de satisfação de QoS (PMEE). Em especial, o problema PMEE teve que ser reformulado a fim de que a função objetivo fracionada fosse linearizada. Através de simulações computacionais, vimos que a solução PMEE apresenta-se como a melhor solução do ponto de vista de EE visto que foi apta obter altas taxas de dados com um consumo de potência reduzido. Ganhos de até 6 vezes em taxa de dados transmitida foram obtidas com um consumo de potência adicional marginal comparado a solução PMP. Como perspectiva deste estudo, temos o desenvolvimento de soluções de baixa complexidade para o problema PMEE.

## REFERÊNCIAS

- [1] ITU, "Requirements related to technical performance for IMT-Advanced radio interface(s)," International Telecommunication Union, Tech. Rep. ITU-R M.2134, 2008.
- [2] G. Wu, C. Yang, S. Li, and G. Y. Li, "Recent Advances in Energy-Efficient Networks and their Application in 5G Systems," *IEEE Wireless Commun. Mag.*, vol. 22, no. 2, pp. 145–151, Abril 2015.
- [3] M. Bohge, "Dynamic Resource Allocation in Packet-Oriented Multi-Cell OFDMA Systems," Ph.D. dissertation, Berlin Technology University, December 2010.
- [4] F. R. M. Lima, T. F. Maciel, W. C. Freitas, and F. R. P. Cavalcanti, "Resource Assignment for Rate Maximization with QoS Guarantees in Multiservice Wireless Systems," *IEEE Trans. Veh. Technol.*, vol. 61, no. 3, pp. 1318–1332, Mar. 2012.
- [5] C. Y. Wong, R. S. Cheng, K. B. Lataief, and R. D. Murch, "Multiuser OFDM with Adaptive Subcarrier, Bit, and Power Allocation," *IEEE J. Sel. Areas Commun.*, vol. 17, no. 10, pp. 1747–1758, Oct. 1999.
- [6] W. V. F. Maurício, F. R. M. Lima, T. F. Maciel, and F. R. P. Cavalcanti, "Alocação de potência adaptativa para maximização da eficiência espectral sujeita a restrições de satisfação," in *XXXIII Telecommunications Brazilian Symposium - SBt*, Sep. 2015.
- [7] C. Seol and K. Cheun, "A Statistical Inter-Cell Interference Model for Downlink Cellular OFDMA Networks under Log-Normal Shadowing and Multipath Rayleigh Fading," *IEEE Trans. Commun.*, vol. 57, pp. 3069–3077, October 2009. [Online]. Available: <http://dx.doi.org/10.1109/TCOMM.2009.10.080152>
- [8] T. Wu, "A note on a global approach for general 0-1 fractional programming," *European Journal of Operational Research*, vol. 101, pp. 220–223, 1997.
- [9] G. Nemhauser and L. Wolsey, *Integer and Combinatorial Optimization*. Wiley & Sons, 1999.
- [10] 3GPP, "Physical layer aspects for evolved Universal Terrestrial Radio Access (UTRA)," Third Generation Partnership Project, Tech. Rep. TR 25.814 V7.1.0, Sep. 2006.
- [11] —, "Evolved universal terrestrial radio access (e-utra); physical layer procedures," Third Generation Partnership Project, Tech. Rep. TR 36.213 V8.6.0, Mar. 2009.
- [12] C. Mehlführer, M. Wrulich, J. C. Ikuno, D. Bosanska, and M. Rupp, "Simulating the Long Term Evolution Physical Layer," in *Proc. of the European Signal Processing Conf*, Glasgow, Scotland, Aug. 2009. [Online]. Available: [http://publik.tuwien.ac.at/files/PubDat\\_175708.pdf](http://publik.tuwien.ac.at/files/PubDat_175708.pdf)
- [13] IBM, "IBM ILOG CPLEX Optimizer." [Online]. Available: <http://www-01.ibm.com/software/integration/optimization/cplex-optimizer/>