

Proposta Alternativa para Obtenção da Solução Ótima do Problema de Maximização da Eficiência Energética com Restrições de QoS

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

Resumo—Neste artigo revisitamos o problema de *Radio Resource Allocation* (RRA) para maximização da razão entre a taxa total transmitida e a potência total utilizada sujeito a restrições de satisfação de QoS. Ele foi anteriormente estudado em [1] e uma solução ótima foi obtida. Contudo, essa solução tem um custo computacional muito elevado. Neste artigo, iremos fazer uso do algoritmo proposto em [2] para obter uma solução ótima para o problema com um custo computacional muito menor do que o da solução proposta anteriormente. Veremos ganhos elevados em termos de complexidade computacional e um pequeno número de iterações necessárias para obtenção da solução ótima através da solução proposta.

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

Abstract—In this article we revisit the *Radio Resource Allocation* (RRA) problem of maximizing the ratio from the total data rate and the total utilized power subject to the QoS satisfaction (PMEE). It was previously studied in [1] and one optimal solution was obtained. However, that solution has a very elevated computational cost. In this article, we will use the algorithm proposed in [2] to obtain a optimal solution to the problem with a very low computational cost compared to that previously proposed solution. We will see high gains in terms of computational complexity and a low iteration number of necessary iteration to obtain the optimal solution through the proposal solution.

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 à implantação comercial das redes de Quarta Geração (4G) em diversos países. Atualmente, a rede de Quinta Geração (5G) é alvo de intensa pesquisa na área industrial e acadêmica [3]. Os principais agentes motivadores para desenvolvimento desta nova tecnologia consistem na busca por melhor Qualidade de Serviço (QoS), menor latência, maiores taxas de transmissão de dados, novos serviços (multimídia), maior Eficiência Energética (EE) e evolução/massificação da tecnologia digital com novos dispositivos cada vez mais poderosos [4]. Atualmente, observa-se que a demanda por tráfego de dados apresenta um aumento exponencial e cada vez mais diferentes dispositivos móveis conectam-se a rede, compondo assim um cenário desafiador para a evolução das comunicações móveis.

Emails: {weskley,rafaelm,maciel,rodrigo}@gtel.ufc.br. Os autores pertencem ao Grupo de Pesquisa em Telecomunicações Sem Fio da Universidade Federal do Ceará e o Rafael M. Lima é professor do curso de Engenharia da Computação na UFC - Sobral.

EE consiste em um importante pilar das redes 5G. Isso deve-se ao fato que o aumento no número de dispositivos conectados, *Internet of Things* (IoT) por exemplo, e da taxa de transmissão não devem ser acompanhados de um maior uso de energia ou potência de transmissão. Atender as demandas da 5G com o atual quantidade de Watts por bits/s aumentaria drasticamente a emissão de dióxido de carbono desta indústria. Sabe-se que sistemas de tecnologia e informação são responsáveis por cerca de 5% da emissão global de dióxido de carbono [5]. Além das preocupações a respeito do meio ambiente, uma maior EE levaria a reduções drásticas nos custos operacionais das redes.

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 *Radio Resource Allocation* (RRA) como uma das funcionalidades mais importante das redes móveis 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 [6].

II. ESTADO DA ARTE

Em geral, problemas de RRA têm sido estudados na literatura na forma de problemas de otimização [6], [7]. Em sua maioria, estes problemas tinham como filosofia principal aumentar o numero 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.* [8]. 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. 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 de forma ótima e eficiente 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 que em sua maioria são NP-Difíceis [10].

Em [1], estudamos o problema de RRA de maximização da eficiência energética sujeita a restrições de satisfação mínima por serviço. Para a resolução desse problema de forma ótima foi necessária a linearização do mesmo. Contudo, o método utilizado transformou o problema original em um problema misto linear e inteiro ou *Mixed Integer Linear Problem* (MILP) através da adição de novas variáveis de otimização e novas restrições ao problema. Assim, um alto custo computacional é demandando a fim de obter a solução ótima do problema. Diante deste problema, neste artigo, avaliamos outro método de resolver o problema estudado em [1] através do algoritmo introduzido por Yuchiro Anzai em [2] que propõe resolver um problema inteiro linear fracionário através de uma sequência de subproblemas *Integer Linear Problems* (ILPs). As principais contribuições deste artigo são:

- Caracterização da solução ótima do problema de EE formulado;
- Análise da complexidade da solução proposta neste artigo e comparação com a apresentada em [1];

III. MODELAGEM DO SISTEMA

Consideramos que um número de células setorizadas compõem 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 *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 simplificadora que a interferência intercelular é adicionada ao ruído térmico na expressão da SNR. Ressaltamos que essa suposição se torna cada vez mais válida à medida que o número de ERBs no sistema aumenta [11].

Em um dado TTI, consideramos que J usuários são candidatos a receber recursos de rádio. Admitimos que existam N RBs disponíveis. \mathcal{J} e \mathcal{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.

TABELA I

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 |

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 α_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 experimentado pelo usuário j no RB n , σ^2 é a potência média do ruído térmico, $\|\cdot\|$ representa o valor absoluto do seu argumento e, por fim, p_n é a potência de transmissão alocada pela ERB ao RB n . Assumimos que P^{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 o estado do canal, potência alocada e ruído/interferência percebida. Assumimos que o mapeamento entre a SNR e a taxa de dados transmitida seja dada por uma função $f(\cdot)$ que modela o uso de *Modulation and Coding Schemes* (MCSs) em redes práticas. A taxa de dados transmitida quando o RB n é atribuído ao usuário j , $r_{j,n}$, é dada por

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

Sem perda de generalidade, assumimos uma adaptação de enlace baseada em taxa de erro de bit ou do inglês, *Bit Error Rate* (BER) em que para uma dada SNR, o nível de MCS escolhido é o primeiro com a maior taxa de dados transmitida que assegura uma BER estimada menor que a BER alvo. Consequentemente, dependendo do intervalo da SNR, diferentes taxas de dados podem ser transmitidas. Isto pode ser visto na TABELA I. Note que 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 γ^m e γ^{m+1} com $\gamma^m < \gamma^{m+1}$.

Conforme o modelo apresentado na TABELA I, para transmitir com uma dada MCS é suficiente garantir a menor SNR dentro da região de SNR correspondente a essa dada MCS. 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

$$\lambda_{j,n,m} = \frac{\gamma^m \sigma^2}{\alpha_j \|h_{j,n}\|^2}. \quad (3)$$

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 $\lambda_{j,n,m}$ dado pela equação (3).

IV. FOMULAÇÃO DO PROBLEMA E SOLUÇÃO ÓTIMA

Nesta seção apresentamos o problema que envolve otimização da energia do sistema sujeito a um número mínimo de usuários satisfeitos por serviço prestado pela operadora em um dado TTI. O 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. 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

$$\min_{y_{j,n,m}} \frac{\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} \lambda_{j,n,m} \cdot y_{j,n,m}}{\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot y_{j,n,m}}, \quad (4a)$$

sujeito a

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

$$y_{j,n,m} \in \{0, 1\}, \quad \forall j \in \mathcal{J}, \forall n \in \mathcal{N} \text{ and } \forall m \in \mathcal{M}, \quad (4c)$$

$$\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} y_{j,n,m} \cdot \lambda_{j,n,m} \leq P^{\text{tot}}, \quad (4d)$$

$$\sum_{j \in \mathcal{J}_s} u \left(\sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot y_{j,n,m}, t_j \right) \geq k_s, \quad \forall s \in \mathcal{S}, \quad (4e)$$

$$\sum_{m \in \mathcal{M}} y_{j,n,m} \leq 1, \quad \forall j \in \mathcal{J} \text{ e } \forall n \in \mathcal{N}, \quad (4f)$$

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 (4a) é a razão entre a potência total e a taxa total de dados (eficiência energética). As duas primeiras restrições (4b) e (4c) asseguram que um RB não será alocado a usuários diferentes. A restrição (4d) assegura que a potência total transmitida usada não será maior que a potência total disponível, P^{tot} . A restrição (4e) condiciona que um número mínimo de usuários devem ser satisfeitos por cada serviço. Por fim, a restrição (4f) modela o fato de que no máximo uma única MCS deve ser escolhida para cada par usuário-RB escolhido.

O problema (4) 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 (4e). De modo a linearizar a restrição (4e), introduzimos uma nova variável de otimização. Considere ρ_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 [7]. Dessa forma, o problema (4) pode ser reformulado substituindo a restrição (4e) por três novas restrições dadas a seguir:

$$\sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot y_{j,n,m} \geq \rho_j t_j, \quad \forall j \in \mathcal{J}, \quad (5a)$$

$$\rho_j \in \{0, 1\}, \quad \forall j \in \mathcal{J}, \quad (5b)$$

$$\sum_{j \in \mathcal{J}_s} \rho_j \geq k_s, \quad \forall s \in \mathcal{S}. \quad (5c)$$

A fim de encontrar uma solução ótima para o problema iremos utilizar o algoritmo [2] para linearizar a função objetivo fracionária. De acordo com esse método, a função objetivo fracionária pode ser substituída por uma diferença entre o numerador e o denominador ponderado por um peso. O problema fica da seguinte forma:

$$\min_{y_{j,n,m}} P - \alpha \cdot V, \quad (6a)$$

sujeito a

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

$$y_{j,n,m} \in \{0, 1\}, \quad \forall j \in \mathcal{J}, \forall n \in \mathcal{N} \text{ and } \forall m \in \mathcal{M}, \quad (6c)$$

$$\sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} y_{j,n,m} \cdot \lambda_{j,n,m} \leq P^{\text{tot}}, \quad (6d)$$

$$\sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot y_{j,n,m} \geq \rho_j t_j, \quad \forall j \in \mathcal{J}, \quad (6e)$$

$$\rho_j \in \{0, 1\}, \quad \forall j \in \mathcal{J}, \quad (6f)$$

$$\sum_{j \in \mathcal{J}_s} \rho_j \geq k_s, \quad \forall s \in \mathcal{S}. \quad (6g)$$

$$\sum_{m \in \mathcal{M}} y_{j,n,m} \leq 1, \quad \forall j \in \mathcal{J} \text{ e } \forall n \in \mathcal{N}, \quad (6h)$$

em que α é um peso, $P = \sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} \lambda_{j,n,m} \cdot y_{j,n,m}$ e $V = \sum_{j \in \mathcal{J}} \sum_{n \in \mathcal{N}} \sum_{m \in \mathcal{M}} v^m \cdot y_{j,n,m}$. De acordo com o trabalho [2], existe um valor para o peso, α , tal que a solução ótima do problema (6) corresponde a solução ótima do problema (4). O mesmo trabalho apresenta um algoritmo iterativo para obtenção do valor de α .

O problema (6) é um ILP. Este problema pode ser resolvido por métodos padrões como o algoritmo *Branch and Bound* (BB) [12]. 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 utilizar o algoritmo proposto em [2] para resolver o problema (4) de forma ótima. Segue os passos do algoritmo:

- 1) Para a primeira iteração utilize $\alpha = M$, onde M é um número suficientemente grande.
- 2) Encontre a solução ótima para o problema (6), $y_{j,n,m}^*$. Se a função objetivo (6a) for positiva, pare o algoritmo. $y_{j,n,m}^*$ é uma solução ótima para o problema (4) e consequentemente (6). De outra forma, vá para o passo 3.

TABELA II
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 | 3000 | - |
| Número de serviços | 2 | - |
| Número de terminais por serviço | 4 | - |
| Número de RBs | 15 | - |
| Número mínimo de usuários satisfeitos | 4 (serv. 1) e 4 (serv. 2) | - |

3) Atualize α para $\alpha = \frac{P}{V}$ e volte para o passo 2.

V. RESULTADOS

Esta seção é dedicada a avaliação de desempenho da solução de EE propostas na seção IV comparada a solução proposta em [1]. 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 [13].

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) [14]. Os limiares de SNR para a troca de MCS foram obtidos pelas simulações de nível de enlace de [15]. A TABELA II resume os parâmetros de simulação utilizados.

Os algoritmos simulados são as soluções ótimas do problema PMEE proposto neste artigo na seção IV e a proposta no artigo [1], identificados nos gráficos por "Proposta" e solução [1], respectivamente. As realizações das variáveis aleatórias que representam o posicionamento dos terminais e ganhos de canal 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 [16]. A escolha do limitado número de usuários, RBs e serviços é devido a alta complexidade computacional para obter as soluções ótimas.

Quanto às métricas de avaliação, consideramos duas principais: a complexidade computacional e o número de iterações do algoritmo. A complexidade computacional é o número de operações necessárias para se obter a solução considerando

o pior caso. O número de iterações do algoritmo é dada pela quantidade de vezes necessária do problema ILP para obtenção da solução ótima. Por fim, incrementos na carga oferecida ao sistema são emulados através do aumento do requisito de taxa dos usuários.

B. Avaliação de Resultados

Primeiramente iremos tratar da complexidade computacional, assim como em [17] e [18], 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 deste artigo e do problema em [1], foi utilizado o algoritmo BB. Para um número arbitrário de variáveis inteiras l , o número de subproblemas de programação linear para ser resolvido é pelo menos $(\sqrt{2})^l$ [19]. 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 [17], [19]. Retendo somente ao termo exponencial da complexidade, como no problema (6), deste artigo, existem $JNM+J$ variáveis de otimização e $JN+J+N+S+1$ restrições, portanto a complexidade computacional de pior caso para obter a solução ótima é $O(\sqrt{2}^{(JNM+J)})$ para o problema (6). Contudo, o algoritmo proposto em [2] obtém a solução ótima com no máximo $3 \times I$ iterações, onde I é o número de restrições. Como nosso problema tem $JN+J+N+S+1$ restrições, então no pior caso a complexidade será de $(JN+J+N+S+1) \times O(\sqrt{2}^{(JNM+J)})$.

Como no problema de [1] 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 $O(\sqrt{2}^{(JNM+1+JNM+J+J)})$. Dessa forma, podemos dizer que a complexidade no pior caso do problema em [1] é dada por $O(\frac{B}{JN+J+N+S+1} \times \sqrt{2}^{(JNM+J+1)})$, onde B é a complexidade da solução proposta neste artigo.

Na Fig. 1 ilustramos a complexidade de [1] em relação a solução proposta. As simulações foram realizadas na escala logarítmica devido a seu crescimento exponencial. Um resultado esperado é o crescimento da complexidade a medida que aumentamos as variáveis do problema. Podemos ver que o número de operações necessárias para a obtenção da solução ótima através da solução proposta é consideravelmente menor que o número de operações necessárias na solução proposta em [1].

Na Fig. 2 ilustramos a quantidade média de iterações necessárias para a solução proposta alcançar a solução ótima versus a taxa de dados requerida por serviço. As simulações foram realizadas até as taxas requisitadas em que as restrições dos problemas de otimizações puderam ser obedecidas. Primeiramente podemos ver que é necessário no máximo em média 5 iterações do algoritmo para encontrarmos a solução ótima, o que é muito menor do que o máximo considerado em

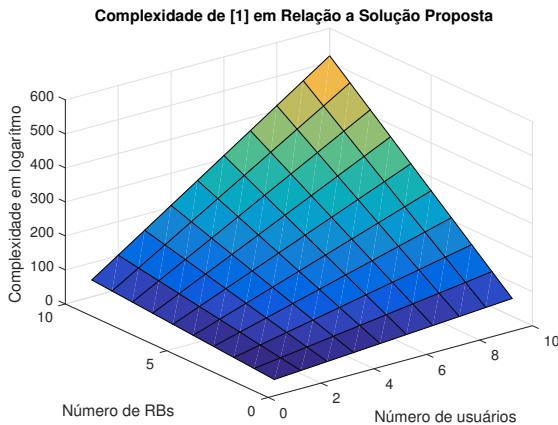


Fig. 1. Complexidade de [1] em relação a solução proposta.

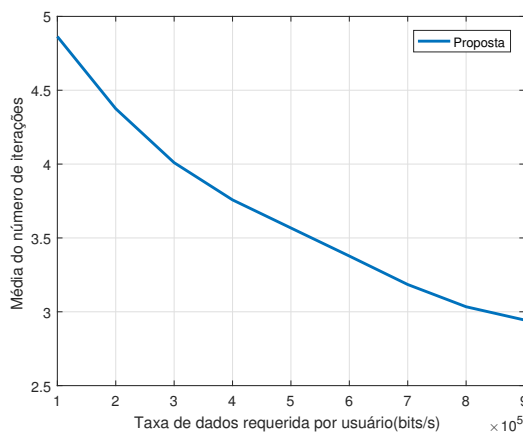


Fig. 2. Número de iterações em média necessárias para alcançar a solução ótima versus a taxa de dados requerida por usuário.

[2] que para esse cenário seria de 438 iterações. Analisando o comportamento do gráfico observamos que o número de iterações diminui com os requisitos de taxa de dados dos usuários. Isto acontece devido a diminuição do espaço de busca a medida que os requisitos de taxa de dados por usuário aumentam.

VI. CONCLUSÕES

Neste artigo estudamos o problema de maximização da taxa total transmitida e a potência total utilizada sujeito a restrições de satisfação de QoS (PMEE). Como contribuição original deste trabalho tivemos a reformulação deste problema baseado no artigo [2], em que o problema não linear é resolvido através da resolução de uma sequência de problemas inteiros e lineares. A solução aqui apresentada foi então confrontada com outra solução proposta anteriormente em [1] para o mesmo problema. Através da análise da complexidade computacional de pior caso e de simulações computacionais, vimos que a solução proposta neste artigo possui uma complexidade consideravelmente menor que a solução proposta em [1] e que é necessário um número pequeno de iterações do algoritmo para a obtenção da solução ótima, no máximo 5 iterações no cenário estudado. Como perspectiva deste estudo, elencamos o desenvolvimento de soluções de baixa complexidade para o problema PMEE.

VII. AGRADECIMENTOS

Os autores agradecem o apoio técnico-financeiro da Ericsson Research, Wireless Access Network Department, Suécia e do Ericsson Innovation Center, Brasil, com relação ao Contrato de Coperação Técnica EDB/UFC.44. Francisco Rafael Marques Lima e Weskley Vinicius Fernandes Mauricio gostariam de agradecer pelo apoio financeiro da FUNCAP (Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico) pela bolsa concedida.

REFERÊNCIAS

- [1] W. V. F. Maurício, F. R. M. Lima, T. F. Maciel, and F. R. P. Cavalcanti, "Alocação de Recursos para Maximização da EE Sujeita a Restrições de Satisfação," Sep. 2016.
- [2] Y. Anzai, "On Integer Fractional Programming," *J. Operations Research Soc. of Japan*, vol. 17, no. 1, pp. 49–66, 1974.
- [3] 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, and M. Fallgren, "Scenarios for 5g mobile and wireless communications: the vision of the metis project," *IEEE Commun. Mag.*, vol. 52, no. 5, pp. 26–35, May 2014.
- [4] ITU, "Requirements related to technical performance for IMT-Advanced radio interface(s)," International Telecommunication Union, Tech. Rep. ITU-R M.2134, 2008.
- [5] A. F. G. F. J. M. G. Biczok, "The global footprint of mobile communications: The ecological and economic perspective," *IEEE Communications Magazine*, vol. 49, no. 8, pp. 55–62, Agosto 2011.
- [6] M. Bohge, "Dynamic Resource Allocation in Packet-Oriented Multi-Cell OFDMA Systems," Ph.D. dissertation, Berlin Technology University, December 2010.
- [7] 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.
- [8] 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.
- [9] 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.
- [10] D. S. Hochbaum, "Complexity and Algorithms for Nonlinear Optimization Problems," *Annals of Operations Research*, vol. 153, no. 1, pp. 257–296, 2007.
- [11] 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>
- [12] G. Nemhauser and L. Wolsey, *Integer and Combinatorial Optimization*. Wiley & Sons, 1999.
- [13] 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.
- [14] —, "Evolved universal terrestrial radio access (e-utra); physical layer procedures," Third Generation Partnership Project, Tech. Rep. TR 36.213 V8.6.0, Mar. 2009.
- [15] 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
- [16] IBM, "IBM ILOG CPLEX Optimizer." [Online]. Available: <http://www-01.ibm.com/software/integration/optimization/cplex-optimizer/>
- [17] Y. J. Zhang and K. B. Letaief, "Multiuser Adaptive Subcarrier-and-Bit Allocation with Adaptive Cell Selection for OFDM Systems," *IEEE Trans. Commun.*, vol. 3, no. 5, pp. 1566–1575, September 2004.
- [18] W. Xu, C. Zhao, P. Zhou, and Y. Yang, "Efficient Adaptive Resource Allocation for Multiuser OFDM Systems with Minimum Rate Constraints," in *Proc. of the IEEE Internat. Conf. on Commun. (ICC)*, Jun. 2007, pp. 5126–5131.
- [19] G. Sierksma, "Linear and integer programming," New York: Marcel Dekker, 2009.