

Otimização Bicritério de Recursos para Redes Sem Fio de Acesso e Rádio sobre Fibra

Pedro Henrique Gomes¹, Nelson L. S. da Fonseca¹, Omar C. Branquinho²

¹Instituto de Computação
Universidade Estadual de Campinas (UNICAMP)
Campinas – SP – Brasil

²Pontifícia Universidade Católica de Campinas (PUC-Campinas)
Campinas – SP – Brasil

psilva@lrc.ic.unicamp.br, nfonseca@ic.unicamp.br
branquinho@puc-campinas.edu.br

Abstract. *This article proposes a radio resource optimization model for mobile wireless networks based on Radio over Fiber (RoF) technology. The optimization model is an integer programming one and adopts a bicriteria objective function. The proposed network architecture is composed of cells in a hierarchical fashion with several layers of antennas; in each layer cells have different radii of coverage to allow the composition of infrastructure dynamically. The optimization algorithm performs a dynamic process of cell splitting to improve network capacity in congested areas and cell merging in areas with low demand to save resources. To apply the model proposed for mobile and dynamic networks it is presented an algorithm based on linear relaxation technique for the rapid computation of suboptimal results. Results obtained can be used as guidelines for planning the infrastructure of wireless networks based on RoF technology.*

Resumo. *Este artigo propõe um modelo de otimização de recursos de rádio para redes móveis sem fio baseadas na tecnologia de Rádio sobre Fibra (RoF). A otimização é baseada em um modelo de programação inteira com uma função objetivo bicritério, que minimiza o custo da rede e maximiza a receita do operador simultaneamente. A arquitetura de rede proposta organiza as células de uma forma hierárquica com várias camadas de antenas, em cada camada, as células possuem raios de cobertura diferentes para prover uma infraestrutura customizável. O algoritmo de otimização executa, de forma dinâmica, o processo de divisão celular para melhorar a capacidade da rede em áreas congestionadas e fusão de células em áreas com baixa demanda para poupar recursos. Para aplicar o modelo proposto em redes móveis introduz-se um algoritmo baseado na técnica de relaxação linear para o cálculo rápido de resultados subótimos. Os resultados obtidos podem ser usados como diretrizes para o planejamento da infraestrutura de redes sem fio baseadas na tecnologia RoF.*

1. Introdução

A tecnologia de Rádio sobre Fibra (RoF) diminui os custos da rede e fornece flexibilidade para a otimização dos recursos de rádio em redes móveis sem fio. Ela integra os meios de

transmissão óptico e sem fio aproveitando o melhor dos dois para o projeto de redes de acesso [Wake et al. 2004]. Em redes RoF, a parte óptica fornece um meio confiável e de alta capacidade, enquanto a parte sem fio permite a mobilidade dos usuários e uma grande capilaridade no acesso a baixo custo. Essa tecnologia envolve uma ou mais Estações Base de Controle (*Base Station Controller - BSCs*) e várias Unidades de Antena Remota (*Remote Antenna Units - RAUs*) interligadas por um backhaul de fibra. A maior parte dos componentes de processamento e controle são centralizadas nas BSCs e as RAUs ficam responsáveis apenas pela conversão eletro-óptica dos sinais de RF. Todos os recursos de rádio, chamados Estações Base (*Base Stations - BSs*), ficam localizados na BSC e podem ser dinamicamente distribuídos ao longo da rede, permitindo que diferentes configurações de células possam ser implantadas [Al-Raweshidy and Komaki 2002]. A arquitetura do RoF é especialmente importante em cenários onde existe mobilidade e as demandas de usuários são dinâmicas, o que está se tornando cada vez mais comum em redes sem fio modernas.

O Gerenciamento de Recursos de Rádio (*Radio Resource Management - RRM*) é uma tarefa desafiadora para as rede sem fio modernas (*beyond-3G*), que devem fornecer acesso com boa relação custo-benefício para um número crescente de usuários móveis e aplicações que requerem altas taxas de dados [Lee 2005]. As redes celulares tradicionais baseiam-se na alocação dos recursos de rádio (BSs), de maneira estática. A alocação estática de recursos não é eficiente, especialmente, em redes dinâmicas e móveis, uma vez que as demandas podem se “mover” ao longo da área de cobertura e ao longo de tempo de operação da rede [Lee 2005]. Recentemente, abordagens centralizadas no usuário (*user-centric*) para a alocação de recursos em redes móveis sem fio [Djukic et al. 2009] têm sido apresentadas. Diferentemente da abordagem tradicional, os novos algoritmos de RRM alocam recursos primeiramente com base nos requisitos dos usuários e, em seguida, procuram a melhor Estação Base para fornecer conectividade aos recursos previamente alocados. Esse tipo de abordagem só é possível com infraestruturas centralizadas como o RoF.

Este artigo apresenta uma solução para a otimização de recursos baseada nas demandas dos usuário. O modelo de otimização é baseado em programação inteira. A rede considerada é constituída de várias RAUs conectados por enlaces ópticos a uma BSC e um número limitado de equipamentos de rádio (BSs) centralizados. O objetivo do problema é encontrar uma distribuição ideal dos recursos de rádio para a RAUs para que o objetivo de otimização possa ser alcançado. Neste artigo, considera-se uma função objetivo bicritério que visa, simultaneamente, a minimização do número de BSs utilizadas e a maximização da receita obtida pelo operador da rede. Ambos critérios representam os mais importantes objetivos a serem otimizados em uma rede sem fio: diminuição do custo e aumento do número de usuários atendidos. A função objetivo bicritério fornece a melhor relação custo x benefício no dimensionamento da rede e possibilita que o operador escolha o objetivo que deseja priorizar, o que não é possível de ser feito com problemas monocritério.

Como a arquitetura proposta permite mobilidade, o algoritmo de otimização está sujeito a limitações de tempo de execução muito rigorosas, o que é difícil de ser lidado com algoritmos ótimos de programação linear inteira. Para contornar este problema, um algoritmo baseado em relaxação linear do modelo de programação linear inteira é pro-

posto, para tornar viável a solução do problema em intervalos de tempo menores. Os resultados apresentados, neste trabalho, podem ser utilizados como diretrizes para o planejamento de redes sem fio, bem como para a otimização de infraestruturas existentes.

Este artigo está organizado da seguinte forma. A Seção 2 apresenta os trabalhos relacionados com o tema. A Seção 3 apresenta a arquitetura proposta. A Seção 4 apresenta a formulação do problema de otimização baseada em programação linear inteira. A Seção 5 mostra o algoritmo baseado na técnica de relaxação linear para a obtenção de soluções rápidas. A Seção 6 apresenta os resultados numéricos do processo de avaliação do modelo proposto e do algoritmo aproximado. Por fim, a Seção 7 conclui o artigo.

2. Trabalhos relacionados

As técnicas de RRM aplicadas à arquiteturas baseadas na tecnologia de Rádio sobre Fibra têm sido alvo de pesquisas recentes. Um problema central para otimização de redes sem fio é o posicionamento das Estações Base (BSs) para uma melhor utilização dos recursos disponíveis na rede e diminuição do seu custo. Soluções para esse problema tradicionalmente são baseadas em métodos estáticos e podem levar ao desperdício de recursos em ambientes dinâmicos, tais como em redes sem fio móveis.

Em [Djukic et al. 2009], os autores argumentam que, devido ao fato dos algoritmos RRM usarem uma abordagem de dividir e conquistar, é possível que haja uma grande ineficiência destes em redes móveis. Novas técnicas de RRM têm sido propostas para redes sem fio; algumas delas consideram o agrupamento dinâmico de usuários [Feng et al. 2005] e adotam uma abordagem centrada que associa os recursos de rede aos usuários antes de posicionar os recursos na área de cobertura. Em [Lee 2005], o controle de potência e de atribuição de BSs são realizados com base na maximização da utilidade da rede para os usuários e da receita da rede.

Os algoritmos de RRM em cenários baseados em RoF ainda não foram totalmente explorados. Em [Sarkar et al. 2006b, Sarkar et al. 2006a], o problema de posicionamento da RAU em redes híbridas *Wireless-Optical* é abordado. Um algoritmo guloso para resolver o problema é proposto em [Sarkar et al. 2006a], que tenta minimizar a distância euclidiana entre as RAUs e os usuários. Em [Sarkar et al. 2006b], uma solução baseada na heurística de arrefecimento simulado (*simulated annealing*) é proposta; os resultados mostram significativa redução de custos. Estas soluções, no entanto, proporcionam o acesso de última milha para usuários fixos e não são adequados para usuários móveis, já que o agrupamento dinâmico dos usuários é desconsiderado.

A solução proposta neste trabalho trata da mobilidade e ainda otimiza os recursos da rede de rádio baseado no agrupamento de usuários. Este trabalho propõe um modelo de otimização baseado em programação inteira e algoritmos aproximados para a obtenção de soluções rápidas, objetivando seu uso em redes móveis.

3. Arquitetura proposta

A arquitetura proposta consiste de um número reduzido de recursos de rádio (*Base Stations* - BSs) centralizados em alguns pontos centrais de gerenciamento (*Base Station Controllers* - BSCs). Esses recursos podem ser dinamicamente distribuídos para um grande número de antenas (*Remote Antenna Units* - RAUs) espalhadas por toda a área de cobertura. As demandas das estações móveis (*Mobile Stations* - MSs) e suas localizações são

contabilizados para a determinação da distribuição ótima dos recursos da rede. A Figura 1 mostra um exemplo de tal arquitetura.

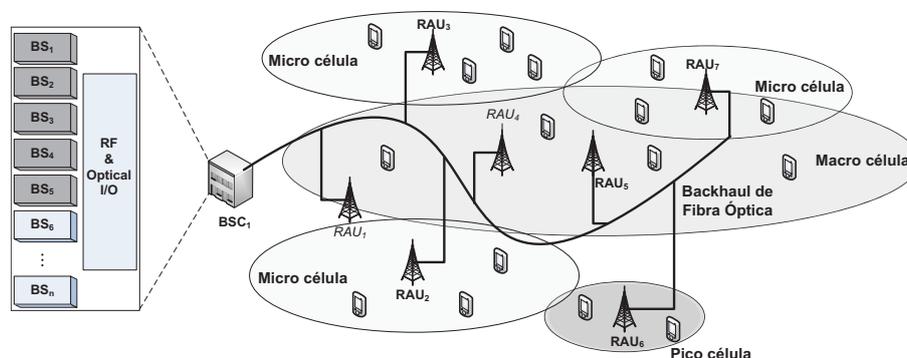


Figura 1. Exemplo de arquitetura proposta. Algumas BSs centralizadas em uma única BSC e um grande número de RAUs espalhadas na área de cobertura.

Na arquitetura considerada, as antenas são dispostas em uma estrutura hierárquica que torna possível a implantação de células com diferentes raios em forma de multi-camadas (Figura 2). O algoritmo na BS realiza divisão celular (*cell splitting*) e fusão celular (*cell merging*) para otimizar o arranjo das células e seus tamanhos. A divisão celular divide as células grandes em menores, aumentando a capacidade da rede e seu custo. O processo de fusão celular une as células pequenas e contíguas em uma maior, diminuindo o número de BSs necessárias, bem como a capacidade total da rede. O processo de divisão forma um cluster de n pequenas células na camada N a partir de células da camada $N - 1$, e o processo de fusão realiza o oposto. Se a RAU em uma camada superior é ativada, todas as RAUs localizadas em sua cobertura em um nível inferior devem ser desativadas, o que evita a sobreposição de canais, facilitando o reuso de frequência.

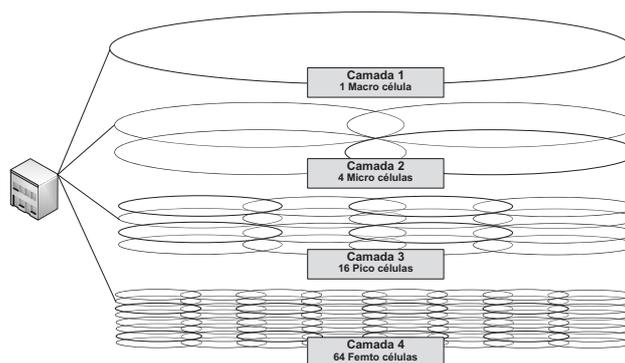


Figura 2. Estrutura multi-camadas de células utilizada na otimização.

4. Modelo de otimização baseado em PLI

O modelo de otimização proposto visa a implantação de pequenas células em áreas congestionadas e células de grande raio em áreas de baixa densidade, de modo que o custo da rede possa ser minimizado e a receita possa ser maximizada. Ele associa os recursos da rede (centralizados na BSC) com as RAUs para configurar dinamicamente a topologia da rede, a fim de lidar com a mobilidade dos usuários. Pressupõe-se que exista um número

suficientemente grande de RAUs instaladas e que estas possam ser dinamicamente associadas ou desassociadas aos recursos da rede, implantando células de forma dinâmica.

As BSCs são representadas pelo conjunto $\mathcal{C} = \{C_1, C_2, \dots, C_p\}$. As BSs são representadas pelo conjunto $\mathcal{B} = \{B_1, B_2, \dots, B_o\}$ e sua principal característica é a capacidade c_i . A capacidade das BSs pode ser expressa pelo número máximo de canais, a vazão máxima ou o número máximo de usuários, dependendo da tecnologia da BS. As RAUs são representadas pelo conjunto $\mathcal{R} = \{R_1, R_2, \dots, R_m\}$. Suas características principais são a localização geográfica (X_{R_i}, Y_{R_i}) e o seu raio de cobertura r_i . As MSs são representadas pelo conjunto $\mathcal{M} = \{M_1, M_2, \dots, M_n\}$ e suas características principais são a localização geográfica (X_{M_i}, Y_{M_i}) , a demanda d_i , que pode corresponder ao número de canais necessários ou à vazão mínima exigida por todos os fluxos da MS M_i , e a classe w_i , que representa o tipo de serviço que M_i está pagando e é proporcional à receita da operadora ao servir a MS M_i .

A solução do problema de otimização determina as BSs que devem funcionar na rede; as BSs que devem estar ativas nas BSCs em funcionamento; as RAUs associadas às BSs ativas; e as MSs que devem ser servidas pelas RAUs associadas.

O problema é formulado através de um modelo de programação linear inteira (PLI). A seguinte notação é utilizada:

- $\mathcal{C} = \{C_1, C_2, \dots, C_p\}$: conjunto de BSCs;
- $\mathcal{B} = \{B_1, B_2, \dots, B_o\}$: conjunto de BSs;
- $\mathcal{R} = \{R_1, R_2, \dots, R_m\}$: conjunto de RAUs;
- $\mathcal{M} = \{M_1, M_2, \dots, M_n\}$: conjunto de MSs;
- v : porcentagem mínima de MSs;
- t : número de camadas de RAUs;
- \mathcal{U}_i : conjunto de RAUs na camada i , $i \leq t$;
- q : número de RAUs por cluster;
- $a_{i,j}$: 1 se a BS B_i está localizada na BSC C_j ; 0 caso contrário;
- c_i : capacidade da B_i ;
- $b_{i,j}$: 1 se a RAU R_i é ligada à BSC C_j ; 0 caso contrário;
- r_i : raio de cobertura da RAU R_i ;
- $P_{R_i} = (X_{R_i}, Y_{R_i})$: localização da RAU R_i ;
- d_i : demanda da MS M_i ;
- $P_{M_i} = (X_{M_i}, Y_{M_i})$: localização da MS M_i ;
- w_i : tipo da classe de MS M_i ;
- $dist_{i,j} = \sqrt{(X_{M_i} - X_{R_j})^2 + (Y_{M_i} - Y_{R_j})^2}$: distância entre a MS M_i e a RAU R_j .

As variáveis de decisão são as seguintes:

- $x_{i,j,k}$: 1 se a RAU R_i é associada à BS B_j , localizada na BSC C_k ; 0 caso contrário;
- $y_{i,j}$: 1 se a MS M_i é servida pela RAU R_j ; 0 caso contrário.

As restrições do problema são as seguintes:

$$x_{i,j,k} \in \{0, 1\} \quad \forall i \in \mathcal{R}, \forall j \in \mathcal{B}, \forall k \in \mathcal{C} \quad (C1)$$

$$y_{i,j} \in \{0, 1\} \quad \forall i \in \mathcal{M}, \forall j \in \mathcal{R} \quad (C2)$$

$$x_{i,j,k} \leq b_{i,k} \quad \forall i \in \mathcal{R}, \forall j \in \mathcal{B}, \forall k \in \mathcal{C} \quad (C3)$$

$$x_{i,j,k} \leq a_{j,k} \quad \forall i \in \mathcal{R}, \forall j \in \mathcal{B}, \forall k \in \mathcal{C} \quad (C4)$$

$$\sum_{j \in \mathcal{B}} \sum_{k \in \mathcal{C}} x_{i,j,k} \leq 1 \quad \forall i \in \mathcal{R} \quad (C5)$$

$$\sum_{i \in \mathcal{R}} \sum_{k \in \mathcal{C}} x_{i,j,k} \leq 1 \quad \forall j \in \mathcal{B} \quad (C6)$$

$$\sum_{j \in \mathcal{R}} y_{i,j} \leq 1 \quad \forall i \in \mathcal{M} \quad (C7)$$

$$\sum_{i \in \mathcal{M}} \sum_{j \in \mathcal{R}} y_{i,j} \geq n.v \quad (C8)$$

$$\sum_{l \in \mathcal{B}} \sum_{k \in \mathcal{C}} x_{j,l,k} \geq y_{i,j} \quad \forall i \in \mathcal{M}, \forall j \in \mathcal{R} \quad (C9)$$

$$y_{i,j} \cdot dist_{i,j} \leq r_j \quad \forall i \in \mathcal{M}, \forall j \in \mathcal{R} \quad (C10)$$

$$\sum_{i \in \mathcal{M}} y_{i,j} \cdot d_i \leq \sum_{l \in \mathcal{B}} \sum_{k \in \mathcal{C}} x_{j,l,k} \cdot c_l \quad \forall j \in \mathcal{R} \quad (C11)$$

$$\sum_{f \in \mathcal{R}} \sum_{g \in \mathcal{C}} (x_{k,f,g} + x_{\mathcal{U}_{\lfloor k/q \rfloor - i}, f, g}) \leq 1$$

$$\forall i, j \in N^+ | i < t, i + 1 < j \leq t, \forall k \in \mathcal{U}_i \quad (C12)$$

As restrições *C1* e *C2* garantem que as variáveis de decisão sejam binárias. A restrição *C3* garante que uma RAU só possa ser associada a uma BS em uma BSC caso haja um link de fibra entre a RAU e a BSC. A restrição *C4* garante que uma RAU só possa ser associada a uma BS em uma determinada BSC se a BS estiver, de fato, localizada na BSC. As restrições *C5* e *C6* estabelecem uma associação um-para-um entre as RAUs e as BSs associadas, o que significa que uma RAU pode ser associada a uma única BS e vice-versa. A restrição *C7* garante que cada MS seja servida por uma única RAU. A restrição *C8* garante que uma porcentagem mínima de MSs seja servida. A restrição *C9* estabelece que apenas as RAUs associadas a alguma BS podem servir usuários. A restrição *C10* estabelece que as RAUs só podem servir MSs na sua área de cobertura. A restrição *C11* limita a demanda agregada de uma célula como menor ou igual à capacidade da BS. Finalmente, a restrição *C12* impede que RAUs de diferentes níveis operem em uma mesma região.

A função objetivo do problema tenta alcançar a minimização de custos e a maximização da receita, simultaneamente. Ela pode ser dividida em dois diferentes objetivos (critérios), dados por:

$$f_1 = \text{Minimize} \sum_{i \in \mathcal{R}} \sum_{j \in \mathcal{B}} \sum_{k \in \mathcal{C}} x_{i,j,k}$$

$$f_2 = \text{Minimize} \sum_{i \in \mathcal{M}} w_i - \sum_{i \in \mathcal{M}} \sum_{j \in \mathcal{R}} y_{i,j} \cdot w_i$$

O critério f_1 representa a minimização do custo operacional. O critério f_2 representa a minimização do desperdício de receita. A primeira soma de f_2 ($\sum_{i \in \mathcal{M}} w_i$) contabiliza a receita máxima da rede e a segunda soma contabiliza as receitas dos usuários servidos; a diferença das duas é igual ao desperdício de receita da rede. Em vez de maximizar a receita, o desperdício de receita foi minimizado para que f_1 e f_2 pudessem ser minimizados, em vez de se ter uma formulação que envolvesse a minimização e a maximização de diferentes métricas.

A função objetivo visa minimizar o custo da rede (f_1) bem como o desperdício de receita (f_2), mas estes dois objetivos são conflitantes, uma vez que a minimização de um leva à maximização do outro. Tal cenário de conflito é comum em problemas de otimização multiobjetivo, nos quais a melhor solução não é uma única, como acontece com problemas mono-objetivo, mas um conjunto de soluções [Talbi 2009]. Uma solução ótima é considerada Pareto ótima quando a melhoria de uma função objetivo resulta necessariamente na piora de pelo menos uma das outras funções objetivo. O conjunto de todas as soluções Pareto ótimas, chamado fronteira de Pareto, representa o melhor compromisso entre os diferentes objetivos contraditórios.

Existem muitas maneiras de se lidar com problemas de otimização multiobjetivo (*Multiobjective Optimization Problem* - MOP). Algoritmos baseados em heurísticas geralmente resultam em bons resultados e soluções rápidas, mas dependem de conhecimento prévio do problema e podem fornecer soluções distante das ótimas. Outra forma de se resolver um MOP, principalmente com problemas ainda não muito bem investigados, como a otimização de recursos em RoF, é através da agregação de todas as funções objetivo, criando-se uma função objetivo agregada (*Aggregated Objective Function* - AOF). A AOF mais comumente utilizada é a soma linear ponderada das funções objetivo: $F(f_1, f_2, \dots, f_n) = \alpha \times f_1 + \beta \times f_2 + \dots + \gamma \times f_n$, onde a soma de todos os pesos (α, β, γ) deve ser igual a 1.

A técnica de otimização bicritério utilizada no presente trabalho baseia-se na agregação das funções objetivo f_1 e f_2 ; e a AOF adotada é:

$$\begin{aligned} F(f_1, f_2) &= \alpha f_1 + (1 - \alpha) f_2 = \\ &\alpha \left(\sum_{i \in \mathcal{R}} \sum_{j \in \mathcal{B}} \sum_{k \in \mathcal{C}} x_{i,j,k} \right) + \\ &(1 - \alpha) \left(\sum_{i \in \mathcal{M}} w_i - \sum_{i \in \mathcal{M}} \sum_{j \in \mathcal{R}} y_{i,j} \cdot w_i \right) \end{aligned}$$

Portanto, a função objetivo do problema é dada por:

$$\text{Minimize } F(f_1, f_2) \tag{1}$$

5. Algoritmo aproximado baseados na relaxação linear do PLI

O problema da alocação de recursos de rádio em RoF é uma extensão do problema clássico de posicionamento de BSs. É, portanto, um problema NP-difícil [Mathar and Niessen 2000]. Soluções ótimas em tempo real só são possíveis para

instâncias pequenas do problema; grandes instâncias exigem o uso de heurísticas ou de aproximações.

Embora a formulação baseada em programação linear inteira (PLI) dê resultados ótimos para o problema, o tempo necessário para que isso ocorra pode ser inviável para a otimização de redes móveis e dinâmicas. Para contornar essa questão de tempo, propõe-se um algoritmo que emprega a técnica de relaxação linear para encontrar soluções subótimas em curtos intervalos de tempo. A relaxação linear consiste na obtenção de soluções parciais e fracionárias, e posterior conversão dessas soluções reais em soluções inteiras. As soluções baseadas em relaxamento pode ser consideradas como valores de probabilidade e, usando técnicas de arredondamento iterativo, é possível transformá-las em valores inteiros que satisfazem às restrições originais e se aproximam das soluções ótimas. O algoritmo de relaxação substitui as restrições $C1$ e $C2$ pelas restrições $C1'$ e $C2'$, transformando o problema linear inteiro (PLI) em um problema linear (PL).

$$x_{i,j,k} \in [0, 1] \quad \forall i \in \mathcal{R}, \forall j \in \mathcal{B}, \forall k \in \mathcal{C} \quad (C1')$$

$$y_{i,j} \in [0, 1] \quad \forall i \in \mathcal{M}, \forall j \in \mathcal{R} \quad (C2')$$

O algoritmo recebe como entrada uma solução da PL. Durante o processo de aproximação outras PLs são resolvidas e cada execução inclui as aproximações anteriores. Desta forma, o algoritmo baseado na relaxação linear refina as soluções reais através da solução de sucessivas PLs, onde cada vez mais os resultados reais são aproximados para resultados inteiros. Esta técnica é eficiente devido ao fato de que o tempo necessário para resolver PLs é muito menor que o tempo necessário para resolver PLIs para instâncias grandes.

No **Algoritmo 1**, a linha 1 corresponde à inicialização da estrutura de dados auxiliar M' , que armazena todas as MSs ordenadas por ordem decrescente de classe (w). Da camada mais alta para a mais baixa (linha 2), todas as RAUs em cada camada são escolhidos de forma aleatória (linha 3). Para cada RAU, sorteia-se uma variável aleatória uniforme $U[0, 1]$ (linha 4) que é usada para a decisão de associar ou não a RAU com a BS com maior valor real (linha 5). Se a solução com maior valor real encontrada pelo otimizador para a RAU escolhida (linha 6) for maior ou igual ao valor estabelecido, então a RAU escolhida é associada, caso contrário não é associada. Se a RAU escolhida é associada, uma nova restrição é acrescentada e outra execução é realizada (linha 7). Uma restrição diferente é adicionada se a RAU escolhida não é associada e outra execução é realizada (linha 13). Como uma tentativa de contornar eventuais decisões errôneas, o algoritmo verifica se o novo problema linear tornou-se infactível após a adição das últimas restrições. Se uma restrição que estabelece que uma determinada RAU deve ser associada a uma BS tornar o problema infactível, essa restrição é removida e outra restrição que evita que a RAU seja associada é adicionada (linhas 8-10 e linhas 22-25). Se durante a iteração uma nova RAU é escolhida para ser associada (linha 19), uma nova execução é realizada e o algoritmo tenta servir o máximo possível de usuários com base no limiar de probabilidade Pr_{thr} . A lista ordenada M' é verificada para encontrar o maior valor de probabilidade para cada MS e em seguida uma nova restrição (linha 23) é adicionada ao problema caso o valor de maior probabilidade encontrada seja maior ou igual a Pr_{thr} . Todas as MSs que foram servidas são, finalmente, removidas da lista M' (linha 24).

Algoritmo 1 Relaxação linear para minimização do custo da rede e maximização da receita do operador

Entrada: L : solução da programação linear (PL).

$Prob_{thr}$: limiar de probabilidade para a escolha das MSs.

Saída: I : solução da programação linear inteira (PLI).

```

1: Definir  $M'$  como uma lista de todas as MSs em ordem decrescente de classe de serviço ( $w$ )
2: para cada camada  $l$  em ordem decrescente de raio faça
3:   para cada RAU  $r$  da camada  $l$  em ordem aleatória faça
4:     Sortear um valor real aleatório entre  $[0, 1]$ 
5:     Encontrar a maior probabilidade  $x_{r,j,k}, \forall j \in \mathcal{B}$  e  $\forall k \in \mathcal{C}$ 
6:     se maior probabilidade  $(x_{r,j,k}) \geq$  valor sorteado então
7:       Adicionar a restrição  $x_{r,j,k} = 1$  e executar novamente a programação linear (PL)
8:     se novo problema é infactível então
9:       Remover a restrição  $x_{r,j,k} = 1$ 
10:      Adicionar a restrição  $\sum_{\forall p \in \mathcal{C}} \sum_{\forall o \in \mathcal{B}} x_{r,o,p} = 0$ 
11:    fim se
12:  senão
13:    Adicionar a restrição  $\sum_{\forall p \in \mathcal{C}} \sum_{\forall o \in \mathcal{B}} x_{r,o,p} = 0$  e executar novamente a programação linear (PL)
14:    se novo problema é infactível então
15:      Remover a restrição  $\sum_{\forall p \in \mathcal{C}} \sum_{\forall o \in \mathcal{B}} x_{r,o,p} = 0$ 
16:      Adicionar a restrição  $x_{r,j,k} = 1$ 
17:    fim se
18:  fim se
19: se a nova RAU não foi associada na iteração atual então
20:   para todas as MSs na lista  $M'$  faça
21:     Encontrar a maior probabilidade  $y_{i,j}, \forall j \in \mathcal{R}$ 
22:     se maior probabilidade  $(y_{i,j}) \geq Prob_{thr}$  então
23:       Adicionar a restrição  $y_{i,j} = 1$ 
24:       Remover a MS  $i$  da lista  $M'$ 
25:     fim se
26:   fim para
27: fim se
28: fim para
29: fim para
30: Executar novamente a programação linear (PL)

```

6. Avaliação do modelo e do algoritmo aproximado

Para se avaliar a eficácia da abordagem proposta, foram avaliados diferentes cenários. Os resultados são discutidos a seguir.

6.1. Cenários utilizados na avaliação

A infraestrutura utilizada nos testes consiste de uma BSC e várias RAUs distribuídas uniformemente em uma área de 2 km x 2 km. As RAUs são organizadas em 4 camadas e em grupos (clusters) de 4 células. A camada mais alta (camada 1) consiste de uma única RAU que compreende uma célula com raio de 1420m. A segunda camada é composta de 4 RAUs com raio de 710m, dispostas em uma grade 2 x 2. A terceira camada tem 16 RAUs com raio de 360m. A camada mais baixa (camada 4) envolve 64 RAUs com raio de 180m. As RAUs de duas camadas diferentes não podem operar simultaneamente para cobrir uma determinada área. No pior dos casos, a rede opera com 64 BSs, o que ocorre quando todas as RAUs da camada mais baixa estiverem ativas. Portanto, a infraestrutura de rede consiste de 1 BSC, 85 RAUs, um número variável de BSs (de 1 até 64), cada BS com capacidade igual a 30 MSs. Todas as BSs podem ser associadas a qualquer um das 85 RAUs, uma vez que todas elas são conectadas por links de fibra. A Figure 3 ilustra a infraestrutura utilizada.

O modelo de otimização foi implementado usando a linguagem de programação C e a biblioteca de otimização FICO Xpress 7.0 [Xpress], que implementa o

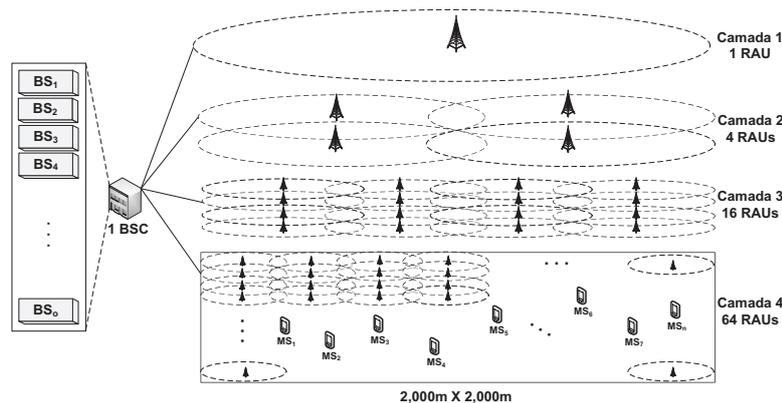


Figura 3. Infraestrutura de Rádio sobre Fibra utilizada na avaliação

algoritmo *LP-based Branch and Bound* para resolver problemas de programação linear inteira. Todos os experimentos foram executados em uma estação de trabalho com processador Intel Quadcore Core 2 de 2,6 GHz, 3 GB de RAM e Debian GNU/Linux kernel 2.6.23.1 como sistema operacional. Para avaliar a rede móvel foi empregado o modelo de mobilidade Random Trip [Le Boudec and Vojnovic 2005] com um cenário urbano com ruas de Houston, Texas/EUA, perto de West University (<http://www.cs.rice.edu/~amsaha/Research/MobilityModel/>). O valor de velocidade média foi definida como 2m/s, o tempo de pausa e o delta do tempo de pausa foram estabelecidos como 20s e 50s, respectivamente. Para cada experimento, pelo menos 10 amostras foram tomadas, considerando diferentes configurações da rede com a mesma infraestrutura e demanda, seguindo o modelo de mobilidade. As estatísticas desejadas foram calculadas com intervalos de confiança de 95%.

Nos experimentos, quatro infraestruturas de redes diferentes foram consideradas: a *Infraestrutura 1*, envolvendo apenas a camada mais baixa de RAUs (64 RAUs); a *Infraestrutura 2*, composta das duas camadas mais baixas (64 + 16 RAUs); a *Infraestrutura 3*, composta pelas três camadas mais inferiores (64 + 16 + 4 RAUs) e a *Infraestrutura 4*, envolvendo todas as quatro camadas (64 + 16 + 4 + 1 RAUs). Ao considerar estas quatro infraestruturas, é possível avaliar os benefícios da estruturação das RAUs de forma hierárquica. Com a ativação de uma RAU em uma camada superior, as RAUs das camadas inferiores deve ser desativadas. Portanto, quanto mais alta a camada, menor é o custo da rede. Infraestruturas que envolvem um maior número de camadas têm mais flexibilidade para reduzir o custo da rede, mas o problema de otimização exige mais esforço computacional.

6.2. Resultados numéricos

Os experimentos foram divididos em duas partes. Inicialmente buscou-se obter as soluções ótimas para o problema bicritério, com o levantamento da fronteira de Pareto. O principal objetivo desse levantamento é obter os valores limites de otimização dos recursos e a melhor relação entre economia de recursos e obtenção de receitas que é possível de ser obtida na rede. A segunda parte dos experimentos focou na otimização de redes móveis, e comparou os resultados ótimos com os subótimos obtidos com o algoritmo aproximado. A qualidade dos resultados e o tempo gasto para a obtenção são comparados para evidenciar os benefícios de se utilizar algoritmos rápidos em redes sem fio dinâmicas.

Para a obtenção dos resultados ótimos considerou-se a função objetivo agregada e o peso α foi variado de 0 a 1 em passos de 0,05. Sabe-se que uma distribuição uniforme dos valores do peso α não produz necessariamente soluções Pareto ótimas uniformemente distribuídas na fronteira de Pareto [Das and Dennis 1997] e que esse método pode não ser capaz de gerar todas as soluções de fronteiras de Pareto não-convexas. Os experimentos mostraram, no entanto, que a fronteira de Pareto para tal problema é convexa e que as soluções ótimas são bem distribuídas no espaço de soluções. Para normalizar o significado da variação do peso para cada objetivo, a função objetivo final foi alterada para:

$$F'(f_1, f_2) = \alpha \left(\frac{f_1 - f_1^{\min}}{f_1^{\max} - f_1^{\min}} \right) + (1 - \alpha) \left(\frac{f_2 - f_2^{\min}}{f_2^{\max} - f_2^{\min}} \right)$$

onde, f_i^{\min} e f_i^{\max} são, respectivamente, os valores mínimo e máximo da função objetivo f_i .

As simulações foram executadas com a função objetivo agregada modificada $F'(f_1, f_2)$ para redes com até 500 MSs e para os 4 tipos diferentes de infraestruturas. Os resultados são mostrados na Figura 4, para *Infraestrutura 1*, e na Figura 5, para *Infraestrutura 3*. Os resultados da *Infraestrutura 4* foram muito semelhantes aos resultados da *Infraestrutura 3*, exceto para as redes com menos de 30 MSs, já que a quarta camada (maior célula) é ativada somente quando a demanda da rede é menor do que a capacidade da BS (30 MSs). Os resultados da *Infraestrutura 2* foram muito similares aos resultados da *Infraestrutura 3* para redes com mais de 100 MSs, e, portanto, não são mostrados aqui por restrição de espaço.

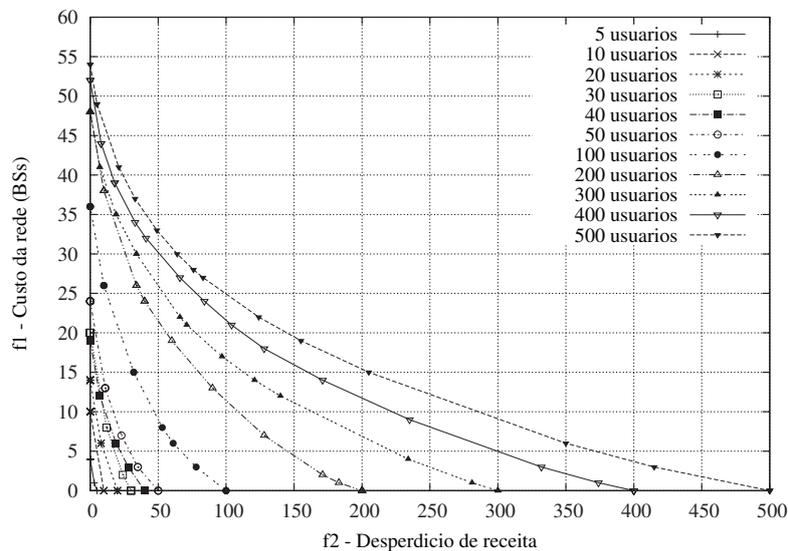


Figura 4. Fronteira Pareto de uma rede com até 500 MSs - *Infraestrutura 1*

O custo operacional de rede (Figura 4) quando se considera a *Infraestrutura 1* contabiliza 55 BSs para redes com 500 MSs, sem desperdício de receita. Ao usar a *Infraestrutura 2* e a *Infraestrutura 3*, é possível obter a mesma receita, mas com apenas 22 BSs (Figura 5). Pode ser notada uma redução de custo superior a 50% para a

mesma receita, quando comparamos as duas últimas infraestruturas com a *Infraestrutura 1* (Figura 4).

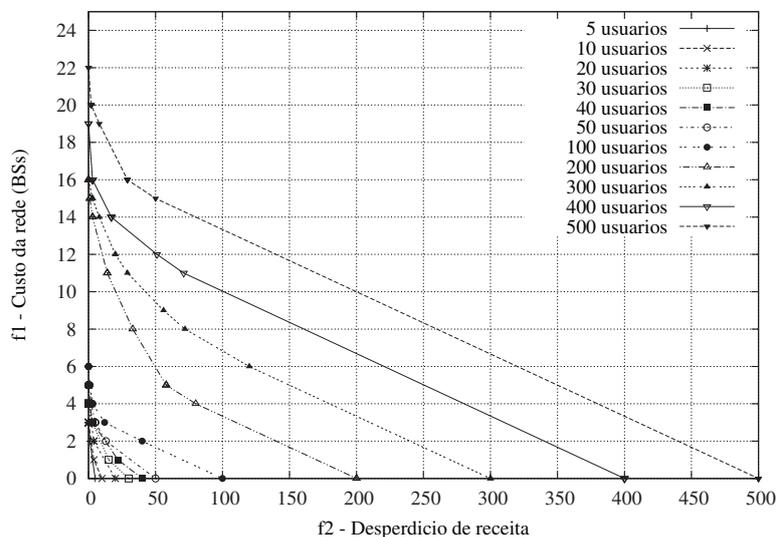


Figura 5. Fronteira de Pareto de uma rede com até 500 MSs - Infraestrutura 3

Para redes com até 100 MSs, no entanto, é possível verificar uma significativa redução de custos (Figura 5). Usando a *Infraestrutura 3*, foi possível atender a todas as MSs (sem desperdício de receita) com apenas 6 BSs, ao mesmo tempo que era exigido até 14 BSs com o uso da *Infraestrutura 2* para redes com até 100 MSs.

A maior redução de custos de rede foi obtida utilizando-se a *Infraestrutura 3*, mas ela demandou maior esforço computacional para encontrar as soluções. O tempo necessário aumenta proporcionalmente com o número de MSs. Para um certo número de MSs, porém, o tempo necessário para obter resultados ótimos depende dos valores do peso α . Pesos próximos de 0 ou 1 exigiam menos tempo para resolver o problema, enquanto os pesos entre 0,3 e 0,7 exigem mais tempo.

O **Algoritmo 1** produziu resultados bastante próximos dos valores ótimos para todas as infraestruturas, com grande redução do tempo de execução. A maior redução foi obtida para a *Infraestrutura 3* e para a *Infraestrutura 4*, quando foi possível obter tempos de execução até 25 vezes menores. A Figura 6 mostra os resultados aproximados, para a *Infraestrutura 3*, e a correspondente fronteira Pareto, para fins de comparação.

Fica claro na Figura 6 que a maioria dos resultados obtidos pelo **Algoritmo 1** está muito perto da fronteira ótima. Para redes com até 200 MSs, os resultados são praticamente os mesmos dos ótimos. Os resultados para redes com 300, 400 e 500 MSs estão localizados acima da fronteira de Pareto, não muito longe dos resultados ótimos.

Finalmente, a Figura 7 mostra para a *Infraestrutura 3* o tempo médio necessário para produzir os resultados ótimos e os resultados aproximados. O cálculo contabiliza os resultados obtidos com diferentes pesos (entre 0 e 1). A Figura 7 mostra resultados com intervalos de confiança de 95%. Para redes com até 100 MSs, ambas soluções exigiram aproximadamente o mesmo tempo de execução, mas para redes com mais de 200 MSs, a grande diferença no tempo de execução necessário é evidente. O algoritmo inteiro de-

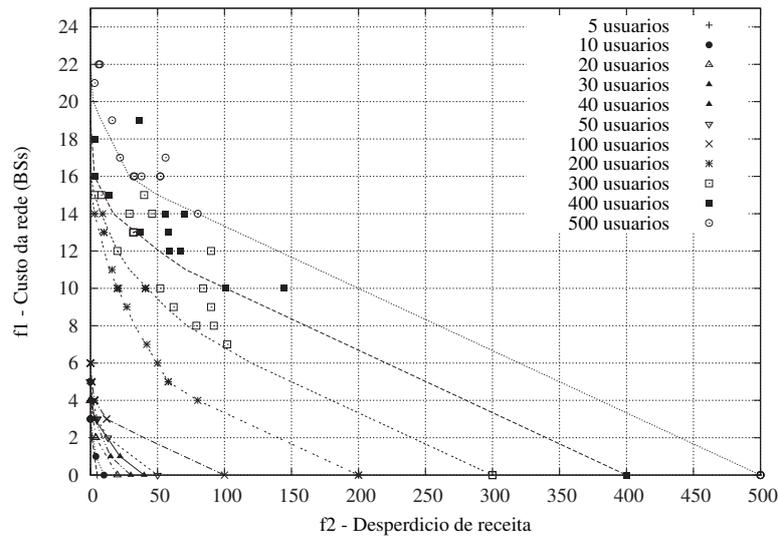


Figura 6. Resultados do algoritmo bicritério baseado em relaxação para redes com até 500 MSs - Infraestrutura 3

mandou tempo até 25 vezes maior do que o tempo do algoritmo baseado em relaxação. É claro, também, que a variação do tempo necessário para produzir resultados do algoritmo inteiro é bastante alto. Como mencionado anteriormente, a computação dos resultados com valores de peso próximo de 0 ou 1 foi facilmente realizada e os cálculos com valores de peso próximo a 0,5 exigiram muito mais tempo.

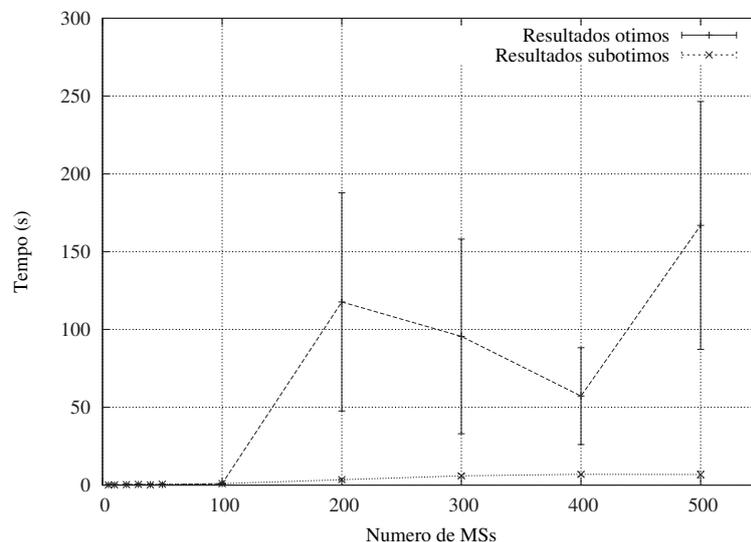


Figura 7. Média do tempo de processamento - Infraestrutura 3

7. Conclusão

Neste artigo, apresentou-se um modelo de otimização de recursos de rádio, que envolve a divisão e a fusão dinâmica de células, em uma infraestrutura de RoF multicamadas. O problema de otimização foi formulado com programação linear inteira e pode ser executado com uma função objetivo bicritério, de minimização dos custos de rede e

maximização da receita. Um algoritmo baseado na técnica de relaxação linear também foi apresentado para que fossem possível obter soluções rápidas.

Os resultados da otimização bicritério apresentaram o melhor compromisso entre as duas últimas funções objetivo. O baixo tempo computacional exigido pelos algoritmos baseados em relaxação mostrou que é viável a otimização de recursos de rádio nas redes móveis em tempo real. Esses resultados podem ser utilizados como diretrizes para a otimização de redes com gerenciamento centralizado de recursos ou para a implantação de novas redes baseadas em RoF.

Referências

- Al-Raweshidy, H. and Komaki, S. (2002). *Radio Over Fiber Technologies for Mobile Communications Networks*. Artech House.
- Das, I. and Dennis, J. E. (1997). A closer look at drawbacks of minimizing weighted sums of objectives for pareto set generation in multicriteria optimization problems. *Structural and Multidisciplinary Optimization*, 14:63–69.
- Djukic, P., Yanikomeroglu, H., and Zhang, J. (2009). User-centric RRM and Optimizable Protocol Design for beyond-4G RANs. In *Proceedings of Wireless World Research Forum Meeting 22 (WWRF22)*, pages 1–5, Paris - France. Carleton University - Canada’.
- Feng, N., Mau, S.-C., and Mandayam, N. (2005). Joint Network-Centric and User-Centric Radio Resource Management in a Multicell System. *IEEE Transactions on Communications*, 53(7):1114–1118.
- Le Boudec, J.-Y. and Vojnovic, M. (2005). Perfect simulation and stationarity of a class of mobility models. In *Proceedings of the 24th Annual Joint Conference of the IEEE Computer and Communications Societies*, pages 2743–2754. IEEE.
- Lee, K. (2005). Radio over Fiber for Beyond 3G. In *Proceedings of the International Topical Meeting on Microwave Photonics*, pages 9–10.
- Mathar, R. and Niessen, T. (2000). Optimum positioning of base stations for cellular radio networks. *Wirel. Netw.*, 6(6):421–428.
- Sarkar, S., Mukherjee, B., and Dixit, S. (2006a). Optimum Placement of Multiple Optical Network Units (ONUs) in Optical-Wireless Hybrid Access Networks. In *Proceedings of the Optical Fiber Communication Conference and Exposition and The National Fiber Optic Engineers Conference*, pages 1–3.
- Sarkar, S., Mukherjee, B., and Dixit, S. (2006b). Towards Global Optimization of Multiple ONU Placement in Hybrid Optical-Wireless Broadband Access Networks. In *Proceedings of the Joint International Conference on Optical Internet and Next Generation Network*, pages 65–67. IEEE.
- Talbi, E.-G. (2009). *Metaheuristics: from design to implementation*. John Wiley & Sons.
- Wake, D., Webster, M., Wimpenny, G., Beacham, K., and Crawford, L. (2004). Radio over fiber for mobile communications. *2004 IEEE International Topical Meeting on Microwave Photonics (IEEE Cat. No.04EX859)*, pages 157–160.
- Xpress. FICO XPress Optimization Suite 7.