

Algoritmo Genético Aplicado à Configuração Adaptativa da Potência de Transmissão de Antenas no 5G

Albert Einstein C. dos Santos¹, Diego L. Cardoso¹, Ermínio Augusto R. da Paixão¹

¹Instituto de Tecnologia – Universidade Federal do Pará (UFPA)
Belém, PA – Brazil

diego@ufpa.br, {alber.santos, erminio.paixao}@itec.ufpa.br

Abstract. *This work proposes an implementation called GA4PC (Genetic Algorithm for Power Configuration), based on the genetic algorithm, to minimize the total energy consumption of the Small Cells Base Station (BS) by switching off and decreasing the antennas transmission power. The results show that on a daily average GA4PC saved 26.43% of energy compared to LTE-A while maintaining the minimum required QoS.*

Resumo. *Este trabalho propõe uma implementação denominada GA4PC (Genetic Algorithm for Power Configuration), baseada no algoritmo genético, para minimizar o consumo total de energia das Small Cells Base Station (BS) por meio do desligamento e diminuição da potência de transmissão das antenas. Os resultados demonstram que na média diária o GA4PC economizou 26.43% de energia em relação ao LTE-A enquanto manteve o QoS mínimo exigido.*

1. Introdução

Estima-se que o número de smartphones em 2023 corresponderá a 46% do total do tráfego [Cisco 2020]. Devido a este aumento e aos avanços do 5G novas problemáticas são geradas para os provedores de serviço. O principal desafio é gerenciar os recursos disponíveis de forma a obter ótimos retornos sobre o investimento e suprir as demandas de serviço do usuário proporcionando níveis de QoS (Quality Of Service) aceitáveis.

Uma solução para atender a alta demanda de dados no 5G é a densificação de Small Cells BS (Base Stations) que são células de baixa potência que aumentam a capacidade de cobertura, aproximando a rede dos usuários visto que o sinal não precisa se propagar por longas distâncias para alcançá-los. Contudo, aproximadamente 60% do gasto de energia da rede é gerado pelas BSs [Chen and Duan 2011]. Portanto, é essencial otimizar a utilização dos recursos da rede, incluindo as BSs.

O número de BSs normalmente é definido para atender o tráfego de pico. Porém, se todas BSs permanecerem ativas independente da carga haverá desperdício de energia e ociosidade de recursos em períodos de baixo tráfego. Devido à locomoção diária das pessoas que utilizam os serviços da rede, ocorre um desequilíbrio na distribuição de cargas nos domínios espacial e temporal. Sendo assim, é possível economizar energia significativamente desligando ou diminuindo a potência de transmissão das BSs subutilizadas.

Diante do exposto, este trabalho propõe uma otimização denominada Genetic Algorithm for Power Configuration (GA4PC), baseada no algoritmo genético (AG), para otimizar a utilização de BSs por meio da configuração de níveis de potência de transmissão. O objetivo principal do GA4PC é diminuir o gasto total de energia mantendo o QoS (Quality of Service) mínimo dos usuários.

2. Metodologia

Devido à natureza espacial e temporal dinâmica do tráfego, o comportamento dos usuários é modelado de acordo com a base de dados reais da cidade de Nova York coletados por uma LBSN (Location-Based Social Networking) [Kylasa et al. 2015]. A partir disso, a quantidade de usuários em cada hora foi normalizada no intervalo de 0.1 a 1.

Para determinar a perda de de propagação em ambientes urbanos foi utilizado o modelo Stanford University Interim (SUI). A Equação 1 apresenta a modelagem da relação SINR (Signal to Interference plus Noise Ratio) para um determinado usuário k conectado a uma RRH (Remote Radio Head) n :

$$SINR_k = \frac{P_r(k)}{\alpha^2 + I_k} \quad (1)$$

Em que $P_r(k)$ é a potência recebida pelo usuário k , α^2 é a potência de ruído térmico e I_k é a interferência intercelular das RRHs vizinhas. A potência recebida pelo usuário considera a perda de propagação obtida pelo SUI-Tipo A.

A taxa de dados de cada usuário k é estimada de acordo com a capacidade de Shannon expressa na Equação 2, sendo B a largura de banda do sistema.

$$C_k = B * \log_2(1 + SINR_k) \quad (2)$$

O objetivo da otimização é determinar o menor valor de consumo total de energia das RRHs implementadas no cenário que proporcione uma taxa de usuários bloqueados igual a zero. Para isso foi criado um vetor $L = \{0, 0.1, 0.251, 2\}$ contendo os valores de potência de transmissão em Watts que as RRHs podem assumir. Cada posição do vetor L é considerada um nível de potência. O nível 1 (0 W) significa que a RRH será desligada e o nível 7 (2 W) representa a potência máxima que a RRH pode assumir. Portanto, o número total de níveis TL é igual a 4.

Foi definido um vetor $r = \{r_1, r_2, r_3, \dots, r_N\}$ que representa o nível de potência de cada RRH sendo N o número total de RRHs e $r_n \in \{1, 2, 3, \dots, TL\}$. A expressão $r_n = l$ indica que a RRH_n está configurada com o nível l . Nota-se que o vetor r pode assumir inúmeras combinações, ou seja, há inúmeras possibilidades de configurações em relação aos níveis de potência de transmissão das RRHs.

O consumo total das RRHs considera a potência de transmissão e o consumo de energia da RRH ao estar ligada ou em modo sleep. Uma RRH consome em média 130W ligada e 75W em modo sleep [Guo et al. 2016]. O consumo total P_{RRH} é calculado segundo a Equação 3:

$$P_{RRH} = \sum_{n=1}^N P_n \quad (3)$$

$$P_n = \begin{cases} L(r_n) + 75, & \text{se } L(r_n) = 0 \\ L(r_n) + 130, & \text{caso contrário} \end{cases} \quad (4)$$

Sendo P_n o valor de consumo de energia da RRH_n de acordo com o nível r_n de potência de transmissão mais o gasto para estar ligada ou desligada. A taxa de usuários bloqueados BR é calculada de acordo com a Equação 5.

$$BR = [1 - \frac{\sum_{n=1}^N \sum_{k=1}^K I_{n,k}}{K}] * 100 \quad (5)$$

Sendo K o número total de usuários na rede e $I_{n,k}$ é um indicador binário de forma que $I_{n,k} = 1$ se o usuário k está conectado à RRH_n .

O AG utiliza uma população inicial Pop onde cada indivíduo é uma solução representada pelo vetor r . Dado uma função objetivo, o AG busca minimizar esse valor encontrando a melhor solução $\{r_1, r_2, r_3, \dots, r_N\}$. O AG termina a execução após o critério de parada estabelecido ser atingido que nesse caso é o número máximo de iterações G_{max} .

Inicialmente ocorre a verificação da BR utilizando somente a MBS (Macro Base Station). Se apenas a MBS for suficiente para alocar todos os usuários, o AG não é executado e todas RRHs são desligadas. Senão, o AG inicia uma população com valores inteiros aleatórios entre 1 e TL . Após o término da execução do AG, a rede é reconfigurada de acordo com o melhor vetor r encontrado que modificará o valor de potência das RRHs.

O crossover heurístico foi utilizado no AG com arredondamento do valor final para obter apenas valores inteiros entre 1 e TL . A mutação é um modo de gerar um novo vetor filho a partir de um único vetor pai. O processo de mutação envolve escolher uma posição no vetor r e atribuir um nível aleatório de potência. A seleção por torneio foi utilizada para selecionar os melhores indivíduos de uma população antes de efetuar o processo de crossover e mutação. *Offspring* é a população gerada após o crossover e a mutação. A *Pop* e *offspring* são combinadas em ordem crescente em relação à f sendo que apenas os T primeiros indivíduos sobrevivem.

A função objetivo do AG é definida pela Equação 6. O valor dessa função é configurado como inf para soluções em que $BR \neq 0$. Dessa forma, o AG aceitará como melhor solução apenas aquelas em que todos os usuários foram conectados.

$$f = \begin{cases} \sum_{n=1}^N P_n, & \text{se } BR = 0 \\ inf, & \text{caso contrário} \end{cases} \quad (6)$$

3. Resultados

Para analisar a performance do GA4PC foi implementado no Matlab uma arquitetura H-CRAN [Guizani and Hamdi 2017] com 1 MRRH (Macro Remote Radio Head) sobreposta por 36 RRHs. A largura de banda foi considerada como 10Mhz e há até 900 UE (User Equipment) no total posicionados aleatoriamente em um cenário de 500m. A taxa mínima para considerar um UE conectado é de 400kbps. A alocação das RRHs segue o formato de grade. Cada RRH possui 50 PRBs (Physical Resource Block), 6m de altura e possui 33dBm de potência máxima de transmissão. A MRRH possui 100 PRBs, 20m de altura e 43 dBm de potência de transmissão. Em relação ao AG foi definido $T = 10$, $G_{max} = 500$. Os parâmetros $cb = 0.8$, $mb = 0.2$ correspondem a probabilidade de ocorrer crossover e mutação, respectivamente. Dada a natureza estocástica do AG, foram realizadas 30 execuções.




Figura 1. Quantidade de RRHs por nível de potência de transmissão durante 24h

A Figura 1 apresenta a quantidade média de RRHs que foram ligadas em cada hora. A média considera os 30 melhores vetores r de cada execução do AG. Outrossim, é possível analisar a quantidade média de RRHs em cada nível de potência de transmissão. No intervalo de 7h a 11h foram ligadas mais RRHs no nível mínimo pois a quantidade de UE é menor. A hora 24 é o período em que há mais UE e por isso foram ligadas mais RRHs do que em outros momentos. Comparado com o LTE-A, cenário em que todas as RRHs são ligadas na potência máxima, o GA4PC economiza 26.43% de energia em watts ao longo de 24h. Isso ocorre pois o GA4PC consegue adaptar a quantidade de RRHs ligadas e a potência de transmissão de acordo com o fluxo dos usuários.

4. Conclusão

Os resultados apresentados neste trabalho constataam que o algoritmo proposto GA4PC, baseado no AG, é uma solução eficiente para diminuir o consumo de energia da rede por meio do desligamento e diminuição da potência de transmissão das RRHs. Além disso, o GA4PC consegue esta economia de energia mantendo o QoS mínimo dos usuários. Ou seja, o GA4PC é uma abordagem viável para ser utilizada em arquiteturas voltadas ao 5G pois evita desperdícios de energia sem deixar de atender a alta demanda de tráfego dos usuários.

Referências

- Chen, K. and Duan, R. (2011). C-ran the road towards green ran. *China Mobile Research Institute, white paper, 2*.
- Cisco, U. (2020). Cisco annual internet report (2018–2023) white paper. *Cisco: San Jose, CA, USA*.
- Guizani, Z. and Hamdi, N. (2017). Cran, h-cran, and f-ran for 5g systems: Key capabilities and recent advances. *International Journal of Network Management, 27(5):e1973*.
- Guo, X., Niu, Z., Zhou, S., and Kumar, P. (2016). Delay-constrained energy-optimal base station sleeping control. *IEEE Journal on Selected Areas in Communications, 34(5):1073–1085*.
- Kylasa, S. B., Kollias, G., and Grama, A. (2015). Social ties and checkin sites: connections and latent structures in location based social networks. pages 194–201.