

Aprendizagem Computacional Não-Supervisionada Aplicada à Alocação Autônoma de Recursos em Redes 4G LTE

Einar C. Santos¹, Paulo R. Guardieiro¹

¹Faculdade de Engenharia Elétrica – Universidade Federal de Uberlândia (UFU)
Av. João Naves de Ávila 2121 - Campus Santa Mônica
CEP 38408-100 – Uberlândia - MG

Abstract. *The machine learning is an artificial intelligence area whose application extends to several knowledge areas. Its use is ideal for acquiring knowledge in systems where human intervention is undesirable or infeasible. Furthermore, resource allocation is an important procedure for quality of service assurance in LTE 4G networks. Traditional algorithms for such purposes do not possess the necessary logic to adjust themselves due to environment variations, impeding process optimization. This paper presents an autonomous mechanism of resource allocation in LTE 4G networks based on unsupervised machine learning. Results demonstrates good performance of proposal.*

Resumo. *A aprendizagem computacional é uma área da inteligência artificial cuja aplicação estende-se a diversas áreas do conhecimento. Sua utilização é ideal para obtenção de conhecimento em sistemas onde a intervenção humana é indesejada ou impraticável. Outrossim, a alocação de recursos é um procedimento importante para garantia de qualidade de serviço em redes 4G LTE. Algoritmos convencionais com tal finalidade não possuem a lógica necessária para ajustarem-se às variações no ambiente, impedindo a otimização do processo. Este trabalho apresenta um mecanismo autônomo de alocação de recursos em redes 4G LTE baseado em aprendizagem computacional não-supervisionada. Os resultados demonstram o bom desempenho da proposta.*

1. Introdução

A crescente demanda no acesso a redes banda larga sem fio motiva a busca por soluções relacionadas ao problema do compartilhamento de recursos. Além disso, a garantia de qualidade no acesso a conteúdo em alta definição, como a transmissão de vídeos em alta resolução ou de eventos em tempo real, requer melhor aproveitamento da rede. Por esse motivo, o conhecimento sobre o ambiente e o sistema é fundamental para otimizar a utilização dos recursos disponíveis.

A inserção de inteligência artificial em sistemas de comunicação é uma opção interessante para automatizar tarefas exclusivamente atribuídas a seres humanos como organização, otimização e reparação. Nesse contexto, a implementação da aprendizagem computacional não-supervisionada apresenta-se como alternativa para geração de conhecimento ou aprimoramento de habilidades sobre um conjunto de dados de maneira autônoma [Carbonell et al. 1983].

A proposta apresentada em [Petridou et al. 2007] implementa um algoritmo de alocação de recursos em protocolos de multiplexação por divisão de comprimento de

onda, geralmente utilizado em redes de fibra ótica. O algoritmo adota o método de classificação *K-Means* [Lloyd 1982],[MacQueen et al. 1967] para agrupar nós da rede de acordo com seus respectivos dados de demanda de recursos (quantidade de pacotes solicitados).

O *K-Means* é um método simples de aprendizagem computacional não-supervisionada e aplicável a problemas *NP*-difícil. Sua principal limitação encontra-se na necessidade de informar previamente a quantidade de agrupamentos a serem estabelecidos pelo algoritmo [Hamerly and Elkan 2003]. Visando superar essa limitação, um algoritmo de classificação não-paramétrico baseado no *K-Means*, conhecido como *X-Means* [Pelleg et al. 2000], foi desenvolvido com a finalidade de estabelecer automaticamente a quantidade de agrupamentos no processo.

Este trabalho apresenta a modificação do algoritmo *X-Means* e sua aplicação em redes 4G LTE com o objetivo de otimizar a alocação autônoma de recursos em condições de compartilhamento e garantia de qualidade de serviço ou *Quality of Service* (QoS).

2. Algoritmos de Classificação Não-Supervisionada

A classificação não-supervisionada organiza um conjunto de dados distribuídos em um espaço n -dimensional em grupos, baseados na medida de similaridade entre os atributos, sem rotulação ou utilização de amostras de treinamento [Gira et al. 2004]. A similaridade é estabelecida utilizando alguma medida de distância. A mais comum é a euclidiana, apresentada a seguir:

$$d = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (1)$$

Onde n é quantidade de atributos, p_i e q_i são os i -ésimos atributos selecionados. Em alguns casos, substitui-se q_i pela média μ dos atributos, estabelecida por:

$$\mu = \frac{1}{n} \sum_{i=1}^n p_i \quad (2)$$

Escolheu-se o algoritmo *X-Means* pelo fato de ser de fácil implementação, possuir custo computacional relativamente baixo e ser não-paramétrico, eliminando intervenção no sistema. Apesar disso outros algoritmos de classificação não-supervisionada podem ser encontrados na literatura, sendo os principais: *Expectation-Maximization* (não-paramétrico) [Moon 1996]; *Gaussian Mixture Model* (paramétrico) [Reynolds 2009]; *K-Means* (paramétrico); *Dirichlet Process Mixture Model* (não-paramétrico) [Antoniak 1974] e *X-Means* (não-paramétrico).

3. Alocação Autônoma de Recursos em Redes 4G LTE

A alocação de recursos é um dos procedimentos realizados para assegurar QoS, adotado em situações de compartilhamento de recursos. Tal procedimento possui lógica pré-estabelecida pelo desenvolvedor e fornecida pelo fabricante do equipamento a ser utilizado no ambiente de rede. Em situações convencionais, a lógica implementada não

ajusta-se dinamicamente a mudanças no ambiente, impedindo o compartilhamento de maneira otimizada.

Operações autônomas em redes banda larga sem fio pertencem ao conceito de redes cognitivas e auto-organizáveis, tecnologias desenvolvidas com o objetivo de planejar, configurar, gerenciar, otimizar e reparar a rede sem intervenção humana ou de elementos externos. Redes auto-organizáveis e cognitivas geralmente utilizam métodos de inteligência artificial, detectam mudanças e tomam decisões adaptativas baseadas nas informações do sistema [De la Roche et al. 2012],[Bkassiny et al. 2013],[Wang et al. 2015]. Entre as principais funções consideradas, o conceito aborda a capacidade dos equipamentos de utilizarem métricas para melhorar o desempenho da rede de maneira autônoma [3GPP 2012].

4. Unidade de Alocação de Recursos em Redes 4G LTE

Redes 4G LTE utilizam a tecnologia de transmissão *Orthogonal Frequency Domain Multiple Access* (OFDMA) no canal *downlink* e *Single Carrier Frequency Division Multiple Access* (SC-FDMA) no *uplink*.

A menor unidade de alocação de dados em redes 4G LTE é o *Resource Block* (RB), atribuído exclusivamente a um único usuário ou *User Equipment* (UE) no sistema. O RB é composto de 12 subportadoras de 15 kHz cada, totalizando 180 kHz de largura de banda por RB com resolução de 0,5 ms no domínio do tempo (*slot*). Um quadro OFDMA possui duração de 10 ms e é subdividido em 10 subquadros de 1 ms. A quantidade de RBs por quadro OFDMA depende do espectro de largura de banda adotado. Por exemplo, uma largura de banda de 1,4 MHz corresponde a 6 RBs utilizáveis enquanto 20 MHz equivalem a 100 RBs utilizáveis por quadro.

A decisão de alocação de recursos (escalonamento) é realizada na estação base de transmissão e recepção do sinal de rádio do sistema, conhecida como *Evolved Node Base* (eNodeB ou eNB). Além de outras atividades, a eNB é responsável por processar informação sobre a condição individual do canal *downlink* percebida pelos UEs. Essa informação é transmitida periodicamente à eNB e conhecida como *Channel Quality Indicator* (CQI).

5. Algoritmo *X-Means* Modificado para Classificação Não-Supervisionada

O algoritmo de classificação *X-Means* adota o mesmo princípio do *K-Means* para classificação de dados. Entretanto, difere-se apenas no fato de não necessitar da informação sobre a quantidade de classes a serem estabelecidas. Para isso, o *X-Means* utiliza fatores de pontuação dos agrupamentos, sendo dois a escolher: o *Bayesian Information Criterion* (BIC) ou o *Akaike Information Criterion* (AIC) [Pelleg et al. 2000]. Ambos, BIC e AIC são medidas de qualidade para um conjunto de dados estabelecidos. Essa medida de qualidade é obtida pelo cálculo de máxima verossimilhança dos dados em relação a um modelo com distribuição gaussiana [Jones 2011].

A pontuação BIC é obtida pelo seguinte cálculo:

$$BIC(M_j) = \hat{l}_j(D) - \frac{p_j}{2} \cdot \log R \quad (3)$$

Onde $\hat{l}_j(D)$ é a log-verossimilhança obtida no ponto j de máxima verossimilhança do conjunto de dados D , M_j é a quantidade de dimensões ou atributos, p_j é a quantidade de parâmetros em M_j e R é a quantidade de pesos no conjunto de dados D .

A log-verossimilhança dos dados pertencentes ao centroide $m_c(\hat{l}_j(D_c))$ incluindo a máxima verossimilhança estimada é dada por:

$$\hat{l}_j(D_c) = -\frac{R_c}{2} \log(2\pi) - \frac{R_c \cdot M}{2} \log(\hat{\sigma}^2) - \frac{R_c - k}{2} + R_c \log R_c - R_c \log R \quad (4)$$

R_c é a quantidade de pesos do conjunto de dados associado ao centroide m_c . A variância $\hat{\sigma}^2$ estimada para cálculo da máxima verossimilhança é dada por:

$$\hat{\sigma}^2 = \frac{1}{R - k_j} \sum_i (x_i - m_c)^2 \quad (5)$$

Onde x_i são os atributos e k_j é o valor de k estabelecido no algoritmo para a j -ésima iteração.

Basicamente, o *X-Means* é realizado em sucessivas iterações do *K-Means* de acordo com os seguintes passos:

1. Inicialização dos parâmetros k_{min} e k_{max}
2. Particionamento dos dados em k_i centroides
3. Geração das células de Voronoi selecionando os pontos mais próximos aos centroides
4. Iteração dos passos 2 e 3 até convergência (semelhante ao *K-Means*)
5. Particionamento do i -ésimo agrupamento em dois sub-agrupamentos
6. Determinação da pontuação BIC para o agrupamento individual e para os agrupamentos divididos
7. Incremento do valor $k_{selecionado}$ caso pontuação BIC do agrupamento dividido seja maior
8. Iteração dos passos 5 a 7 até o último agrupamento
9. Iteração dos passos 1 a 8 até valor k_i for igual a k_{max} estabelecido
10. Obtenção do valor $k_{selecionado}$, dos centroides e pontos associados

O valor k_{max} inicial estabelecido é arbitrário e definido a critério do desenvolvedor. Entretanto, considerando que a quantidade de parâmetros contida no conjunto de dados informados é desconhecida, é desejável atribuir um valor k_{max} proporcional à quantidade real de classes a serem descobertas, evitando assim a geração de agrupamentos individuais. Alguns critérios podem ser utilizados, como a regra de ouro ou *Rule of Thumb* [Mardia et al. 1979], dada por:

$$k_{max} \approx \sqrt{\frac{R}{2}} \quad (6)$$

Contudo, nas investigações conduzidas na análise da implementação do algoritmo proposto, o cálculo de k_{max} modificado que aproxima-se a uma quantidade máxima ideal é estabelecido por:

$$k_{max} \approx 6 \log M + \sqrt{\frac{R}{\log R}} \quad (7)$$

6. Algoritmo de Alocação Autônoma de Recursos

A proposta de alocação autônoma de recursos é direcionada apenas ao canal *downlink* e caracteriza-se, primeiramente, por um mecanismo de classificação de UEs que estabelece, a partir dos CQIs recebidos pela eNB, a quantidade de classes (agrupamentos) e os UEs pertencentes a cada classe. Após a classificação, estabelece-se uma função de ranqueamento responsável por ordenar as classes de acordo com a prioridade no acesso aos recursos. Finalmente, define-se uma regra para alocação da quantidade de recursos por UE em cada classe.

A eNB recebe os CQIs na forma de matriz a cada *Transmission Time Interval* (TTI) (menor unidade de tempo estabelecida entre transmissões de CQIs pelos UEs). Após recebimento dos CQIs, a eNB executa o algoritmo proposto que acrescenta mais dois parâmetros à nova matriz composta para classificação: a vazão histórica individual e o índice de justiça de Jain [Jain et al. 1999]. O índice de justiça é útil para equilibrar a alocação de recursos entre os diferentes tipos de usuários e demandas de serviço, ajudando a evitar a inanição de recursos a usuários com má condição de canal. O índice de justiça é obtido por:

$$F_i = \frac{(\sum_{i=1}^n r_i)^2}{(n \sum_{i=1}^n r_i^2)} \quad (8)$$

Onde r_i é a vazão média do i -ésimo usuário.

Além disso, para garantir a melhor troca entre índice de justiça e o desempenho do usuário individual em termos de vazão média, levando em consideração a qualidade individual h_i do canal, acrescentam-se os parâmetros na forma:

$$h_i + \sqrt{\frac{r_i^2}{F_i}} \quad (9)$$

Os procedimentos realizados pelo algoritmo proposto são executados de acordo com o fluxograma ilustrado na Figura 1.




Figura 1. Procedimentos realizados pelo algoritmo de alocação proposto

6.1. Ranqueamento das Classes e Cálculo de RBs para Alocação

O ranqueamento das classes é estabelecido na ordem decrescente dos valores dos atributos de cada centroide, semelhante ao mecanismo de ranqueamento estabelecido em [Petridou et al. 2007]. Considera-se portanto as classes com os melhores parâmetros na matriz.

O cálculo de RBs a serem alocados deve ser inteiro, além de considerar a quantidade de classes k obtidas pelo *X-Means* a partir da matriz composta. Portanto, a fórmula estabelecida para obtenção da quantidade de RBs por UE, $RB_{sUE,i}$, em cada classe i correspondente, ordenada de acordo com a prioridade estabelecida no ranqueamento, é:

$$RB_{sUE,i} = \left\lceil \left[10^{\left(\frac{\log k \cdot (i-k)}{(k-1)e^{1,1}} \right)} \right]^{-1} \right\rceil \quad (10)$$

7. Simulação e Resultados

Para efeito de avaliação de proposta, utilizou-se a ferramenta LTE Vienna System Level Simulator [Mehlführer et al. 2011]. Seu uso está em consonância com os termos estabelecidos no acordo de licença acadêmica do produto.

Os cenários considerados para avaliação da proposta são compostos por:

- Três células (*Multi Cell*) c/ raio de 500 m cada;
- 30 UEs/célula;
- Modo *Single Antenna*;
- 20 MHz de largura de banda, totalizando 100 RBs por quadro OFDMA;
- Modelo COST 231 de perda de percurso macroscópico de sinal;
- Modelo aleatório p/ tráfego nos UEs (vídeo, voz e tráfego de *background*);
- 01 cenário com UEs estáticos e 01 cenário com mobilidade dos UEs até 120 Km/h;
- 46 dBm de potência de transmissão da eNB.

Para o restante dos parâmetros, manteve-se os valores padrões estabelecidos no *script* do cenário LTE *Multi Cell* do simulador.

Para efeito de comparação, também foram obtidos resultados da simulação utilizando algoritmos clássicos, como o *Round Robin* (RR), o *Proportional Fair* (PF) e o *Best Channel Quality Indicator* (*Best CQI*).

A Tabela 1 apresenta os resultados das simulações para um cenário com UEs estáticos, enquanto a Tabela 2 apresenta os resultados das simulações para cenário com UEs movendo-se a 120 Km/h:

Tabela 1. Resultados de simulações - Cenário com UEs estáticos

Algoritmo	Vazão Máx./UE	Vazão Média/UE	Vazão Mín./UE	Índice de Justiça
<i>X-Means</i>	1,95 Mbps	1,12 Mbps	0,40 Mbps	0,8507
<i>Proportional Fair</i>	2,89 Mbps	2,25 Mbps	1,33 Mbps	0,9446
<i>Best CQI</i>	10,11 Mbps	2,70 Mbps	0,00 Mbps	0,3816
<i>Round Robin</i>	1,74 Mbps	1,12 Mbps	0,42 Mbps	0,8567

Tabela 2. Resultados de simulações - Cenário com UEs movendo a 120 Km/h

Algoritmo	Vazão Máx./UE	Vazão Média/UE	Vazão Mín./UE	Índice de Justiça
<i>X-Means</i>	2,04 Mbps	0,61 Mbps	0,00 Mbps	0,3334
<i>Proportional Fair</i>	2,91 Mbps	1,01 Mbps	0,06 Mbps	0,3651
<i>Best CQI</i>	3,25 Mbps	1,02 Mbps	0,06 Mbps	0,3653
<i>Round Robin</i>	1,86 Mbps	0,60 Mbps	0,00 Mbps	0,3348

Em termos gerais, percebe-se que os resultados da proposta assemelham-se aos do algoritmo de escalonamento *Round Robin* com um desempenho ligeiramente melhor. Além disso, a pouca variação do índice de justiça em comparação ao *Proportional Fair* e *Round Robin* nos dois cenários avaliados aponta uma estabilidade do algoritmo, diferentemente do que acontece ao *Best CQI*. Neste caso, é necessário investigar outros fatores que possam afetar o desempenho do algoritmo proposto, como a quantidade de UEs por célula, o atraso médio do tráfego analisado, o critério para ranqueamento e também o mecanismo de composição da matriz de classificação.

Apesar de não atingir o objetivo, em termos de otimização na utilização de recursos, a plausibilidade da proposta possibilita análises futuras do mecanismo. Tecnicamente os resultados são considerados bons, embora possam ser melhorados.

8. Conclusão

Este trabalho apresentou um mecanismo autônomo de alocação de recursos em redes 4G LTE baseado em um algoritmo de aprendizagem computacional não-supervisionada visando a otimização do compartilhamento de recursos na garantia de QoS.

A aplicação de técnicas não-supervisionadas atende o critério de automação necessário para se estabelecer redes auto-organizáveis e cognitivas na tecnologia em questão, caracterizando menor intervenção humana e consequente redução de custos nas operações da rede.

Apesar de não atingir os objetivos desejados, os resultados de simulação apresentam um bom desempenho da proposta em comparação a algoritmos clássicos da literatura. Entretanto, espera-se que o ajuste de alguns critérios adotados possam favorecer o desempenho em comparação aos algoritmos considerados. Até onde sabe-se, há poucos riscos relacionados ao estudo proposto, restando apenas a otimização dos resultados, em termos de QoS, para conclusão.

Sugere-se como trabalho futuro o ajuste de alguns critérios, como a inserção e avaliação de funções mais aprimoradas para o ranqueamento de classes de usuários geradas pelo algoritmo *X-Means*.

Referências

- 3GPP (2012). *3GPP TS 36.300 v10.8.0, Technical Specification Group Radio Access Network; Evolved Universal Terrestrial Radio Access (E-UTRA) and Evolved Universal Terrestrial Radio Access Network (E-UTRAN); Overall description; Stage 2 (Release 10)*. 3GPP.
- Antoniak, C. E. (1974). Mixtures of Dirichlet Processes with Applications to Bayesian Nonparametric Problems. *The annals of statistics*, pages 1152–1174.

- Bkassiny, M., Li, Y., and Jayaweera, S. K. (2013). A Survey on Machine-Learning Techniques in Cognitive Radios. *Communications Surveys & Tutorials, IEEE*, 15(3):1136–1159.
- Carbonell, J. G., Michalski, R. S., and Mitchell, T. M. (1983). Machine Learning: A Historical and Methodological Analysis. *AI Magazine*, 4(3):69.
- De la Roche, G., Alayón-Glazunov, A., and Allen, B. (2012). *LTE-Advanced and Next Generation Wireless Networks: Channel Modelling and Propagation*. John Wiley & Sons.
- Grira, N., Crucianu, M., and Boujemaa, N. (2004). Unsupervised and Semi-Supervised Clustering: A Brief Survey. *A Review of Machine Learning Techniques for Processing Multimedia Content*, 1:9–16.
- Hamerly, G. and Elkan, C. (2003). Learning the K in K-Means. In *Advances In Neural Information Processing Systems*, volume 16, page 281. MIT Press.
- Jain, R., Durreesi, A., and Babic, G. (1999). Throughput Fairness Index: An Explanation. Technical report, Tech. rep., Department of CIS, The Ohio State University.
- Jones, R. H. (2011). Bayesian Information Criterion for Longitudinal and Clustered Data. *Statistics in medicine*, 30(25):3050–3056.
- Lloyd, S. P. (1982). Least Squares Quantization in PCM. *Information Theory, IEEE Transactions on*, 28(2):129–137.
- MacQueen, J. et al. (1967). Some Methods for Classification and Analysis of Multivariate Observations. In *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, volume 1, pages 281–297. Oakland, CA, USA.
- Mardia, K. V., Kent, J. T., and Bibby, J. M. (1979). *Multivariate Analysis*. Academic press.
- Mehlführer, C., Ikuno, J. C., Simko, M., Schwarz, S., Wrulich, M., and Rupp, M. (2011). The Vienna LTE Simulators-Enabling Reproducibility in Wireless Communications Research. *EURASIP J. Adv. Sig. Proc.*, 2011:29.
- Moon, T. K. (1996). The Expectation-Maximization Algorithm. *Signal processing magazine, IEEE*, 13(6):47–60.
- Pelleg, D., Moore, A. W., et al. (2000). X-means: Extending K-means with Efficient Estimation of the Number of Clusters. In *ICML*, pages 727–734.
- Petridou, S. G., Sarigiannidis, P. G., Papadimitriou, G. I., and Pomportsis, A. S. (2007). Clustering Based Scheduling: A New Approach to the Design of Scheduling Algorithms for WDM Star Networks. In *Communications and Vehicular Technology in the Benelux, 2007 14th IEEE Symposium on*, pages 1–5. IEEE.
- Reynolds, D. (2009). Gaussian Mixture Models. In *Encyclopedia of Biometrics*, pages 659–663. Springer.
- Wang, W., Kwasinski, A., Niyato, D., and Han, Z. (2015). A Survey on Applications of Model-Free Strategy Learning in Cognitive Wireless Networks. *arXiv preprint arXiv:1504.03976*.