

Classificação de tráfego em redes móveis inteligentes usando abordagem de aprendizado de máquina

Raimundo G. Saraiva Jr, Kaline K. L. Oliveira e Francisco A. O. Nascimento.

Resumo— Diversos recentes trabalhos têm demonstrado a contribuição que a inteligência artificial tem trazido para a construção de redes inteligentes. Neste trabalho, utilizamos um modelo de aprendizado de máquina para classificar os tráfegos *ultra-reliable and low latency communication, enhanced mobile broadband e machine-type communications* de uma rede móvel a partir das métricas operacionais obtidas junto aos *user equipments*, em cenários de proximidade, com e sem mobilidade. A acurácia é usada como medida de desempenho, tendo atingido resultados superiores a 97%. Discutimos a possibilidade de implantação deste classificador de tráfego como um *rApp*, operando no *non real-time RAN intelligent controller*, previsto em redes Open RAN e que operam em *loops* de controle superiores a 1 segundo.

Palavras-Chave— Open RAN, aprendizado de máquina, classificador de tráfego.

Abstract— Several recent works have demonstrated the contribution that artificial intelligence has brought to the construction of intelligent networks. In this work, we use a machine learning model to classify the ultra-reliable and low latency communication, enhanced mobile broadband, and machine-type communications traffic of a mobile network from the operational metrics obtained from the user equipment, in proximity scenarios, with and without mobility. The accuracy is used as a performance measure, having achieved results greater than 97%. We discuss the possibility of deploying this traffic classifier as a *rApp*, operating in the non real-time RAN intelligent controller, expected in Open RAN networks, and operating in control loops longer than 1 second.

Keywords— Open RAN, machine learning, traffic classifier.

I. INTRODUÇÃO

Novas tecnologias estão sendo amplamente incorporadas ao ambiente industrial, causando aumento de eficiência e de produtividade, num movimento que é chamado Indústria 4.0. Também o setor de telecomunicações se beneficia com o uso de tecnologias como inteligência artificial e computação em nuvem. As redes se tornam inteligentes, dinâmicas, novos modelos de negócios surgem, beneficiando consumidores e operadoras de telefonia.

Em 2018 surgiu a **O-RAN Alliance**¹ com o objetivo de reformar a indústria *radio access network (RAN)* para tornar as redes móveis mais inteligentes, abertas, virtualizadas e totalmente interoperáveis, incorporando as novas tecnologias

Raimundo Guimarães Saraiva Junior, ENE, UnB, Brasília-DF, e-mail: junior.saraiva@ifce.edu.br; Kaline Kelle Lima de Oliveira, CPI, IFCE, Limoeiro do Norte-CE, e-mail: kalinekelle@gmail.com, Francisco Assis de Oliveira Nascimento, ENE, UnB, Brasília-DF, e-mail: assis@ene.unb.br.

¹www.o-ran.org

ao ambiente das telecomunicações móveis. Atualmente a **O-RAN Alliance** conta com a contribuição da comunidade mundial de operadoras móveis, fornecedores, instituições de pesquisa e desenvolvimento de várias partes do mundo.

A **O-RAN Alliance** vem trabalhando nas especificações de uma nova arquitetura de redes móveis, chamada **Open RAN** ou **O-RAN** [1], incorporando novas tecnologias e procurando atingir aos seguintes objetivos:

- conduzir a indústria para interfaces abertas e interoperáveis, virtualização de **RAN**, *big data* e *artificial intelligence/machine learning (AI/ML)*, permitindo implantação de inteligência na **RAN**;
- maximizar a utilização de *hardware common-off-the-shelf* e *merchant silicon*, e minimizar o *hardware* proprietário;
- especificação de APIs e interfaces abertas, e uso de *open source*, quando possível.

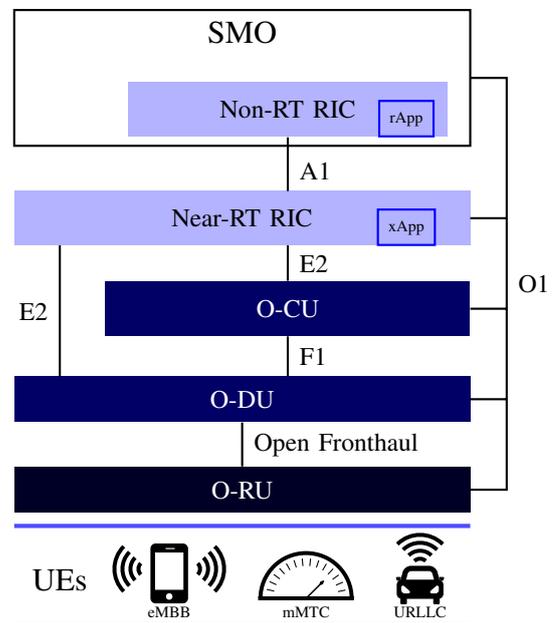


Fig. 1: Resumo da arquitetura **Open RAN**. Figura adaptada das especificações O-RAN Alliance.

A Figura 1 mostra um digrama esquemático resumido da arquitetura **Open RAN**.

Na arquitetura **Open RAN**, a *base station (BS)* foi desmembrada em unidades funcionais menores (**O-CU**, **O-DU** e **O-RU**), foram introduzidos dois *RAN Intelligent Controller (RIC)*, conectados por interfaces abertas.

Os blocos funcionais da **Open RAN** podem ser descritos como:

- **A1, E2, F1, O1 e Open Fronthaul**: interfaces abertas;
- **SMO**: serviço de gerenciamento e orquestração;
- **O-CU**: unidade central, onde normalmente residem as funções de processamento de pacotes menos sensíveis ao tempo;
- **O-DU**: unidade distribuída, onde residem as funções de processamento de banda base em tempo real;
- **O-RU**: unidade de rádio, onde os sinais de radiofrequência são transmitidos, recebidos, amplificados e digitalizados;
- **Non-RT RIC**: *O-RAN Non-Real-Time RAN Intelligent Controller*;
- **Near-RT RIC**: *O-RAN Near-Real-Time RAN Intelligent Controller*;
- **rApps**: aplicações modulares que implementam funcionalidades no **Non-RT RIC**.
- **xApp**: aplicações concebidas para funcionar no **Near-RT RIC**.

A configuração e gestão da rede móvel 5G, ou em redes *zero touch networks* [18], auto-configuráveis, auto-gerenciáveis, auto-curáveis, podem prover vários tipos de serviços, como *enhanced mobile broadband (eMBB)*, *ultra-reliable low latency communication (URLLC)* e *machine-type communication (MTC)*, dependendo das demandas dos diferentes *user equipments (UEs)*.

A **Open RAN** faz referência ao caso de uso de número 12 [2], onde os serviços **eMBB**, **URLLC** e **MTC** estão sendo provisionados, feito o monitoramento de métricas operacionais das **UEs** de *upload* e *download*, para avaliação, tomada de decisão e melhor alocação de recursos, geridos pela inteligência da rede.

A. Inteligência artificial em redes móveis

Diversos são os estudos [5]–[14] que estão propondo avanços no uso da inteligência artificial em redes móveis, dotando-as de inteligência.

Em [5], os autores apresentaram uma metodologia para a geração de dados de propagação em cenários de mobilidade em redes 5G com uso de *deep learning (DL)*.

Casos de uso promissores foram apresentados em [8], utilizando técnicas **AI/ML** para fornecer ações de controle na **RAN**, melhorando o desempenho da rede celular.

Long short-term memory (LSTM) recurrent neural network (RNN) foi utilizado em [7] para aprender e prever o padrão de tráfego de uma rede celular do mundo real, numa área densamente povoada de Mumbai, Índia, a fim de identificar potenciais células congestionadas.

Agentes *deep reinforcement learning (DRL)* foram utilizados em [6], apoiados pelos **xApps** que operam no *near-real-time RIC*, para otimizar as políticas de escalonamento em slices, utilizando as interfaces abertas **Open RAN** para recolher dados na borda da rede.

Em [9], os autores procuraram demonstrar que quando funções de rede são dinamicamente alocadas com base em

requisitos de serviços, usando técnicas de *reinforcement learning*, ganhos em largura de banda e latência podem ser atingidos.

A maximização da taxa de *downlink* e a alocação de potência em redes *next generation heterogeneous wireless networks (HetNets)* foi abordado em [10], tendo sido proposto uma *hierarchical multi-agent DRL*, chamado de **DeepRAT** pelos autores.

A plataforma **Open RAN Gym** foi proposta em [11], que corresponde a um ferramental prático e aberto que permite o teste de controle da **RAN** em sistemas **Open RAN** de próxima geração. Foi dado o exemplo de duas aplicações **xApps** controlando uma rede com **7 BSs** e **42 UEs** implantados no *Colosseum testbed*.

O estudo [12] apresentou 2 casos de uso para implantação da técnica de **DL** em **Open RAN**. Adicionalmente, foi introduzido o conceito de *ML system operations (MLOps)*, que promete assegurar desempenho estável na implantação dos modelos.

Também fazendo uso do *Colosseum testbed*, o estudo [13] fez uma proposta de calcular automaticamente o conjunto ótimo de algoritmos orientados por dados e o seu local de execução (por exemplo, na nuvem, ou na borda) para alcançar as intenções especificadas. A este sistema os autores deram o nome de **OrchestRAN**.

Ainda apoiados pelo *Colosseum testbed*, os autores em [14] propuseram o **CoIORAN**, como uma plataforma aberta para desenvolvimento de aplicações em **ML** utilizando componentes **Open RAN**, **BSs** programáveis, com grande capacidade de geração de dados. O **CoIORAN** e bases de dados já geradas serão disponibilizadas para outros pesquisadores, segundo os autores.

B. Classificação de tráfego usando aprendizado de máquina

A classificação de tráfego pode implementar um mecanismo para diferenciação de serviços que classifica o fluxo de tráfego de acordo com o tipo de aplicação (isto é, *streaming*, *voice over ip*) [15]. Assim, os recursos podem ser atribuídos com base nos requisitos da aplicação, tais como largura de banda e atraso, garantindo assim o apoio de *quality of service (QoS)*.

A classificação do tráfego baseada em algoritmos de aprendizagem de máquinas tem atraído interesse, tendo em conta a sua precisão e eficiência alcançadas. Em [16] quatro variantes de redes neurais são utilizados para categorizar o tráfego por aplicação. O método proposto é avaliado em 4 cenários: *feedforward*, *multilayer perceptron (MLP)*, *NARX (levenberg-marquardt)* e *NARX (naïve bayes)*, com acurácia de 95,6%, 97%, 97% e 97,6%, respectivamente. Em [17], o algoritmo *decision tree* apresentou a maior acurácia média (99,18%) e o algoritmo *k-nearest neighbors* apresentou acurácia de menor valor (97,16%).

Neste trabalho a nossa hipótese é de que é possível prever os tráfegos **URLLC**, **eMBB** e **MTC** em função das métricas operacionais obtidas junto às **UEs**. Para atingir este objetivo utilizamos dados gerados em [6], que realizou uma simulação com **40 UEs** desenvolvendo os diferentes tráfegos (**eMBB**, **URLLC** e **MTC**) num ambiente de rede móvel e operando em diversos cenários de mobilidade e proximidade.

Na próxima sessão são apresentados os materiais e métodos, dando ênfase nas características do banco de dados utilizado, nos cenários a serem estudados, na seleção de atributos, no algoritmo de classificação e na abordagem de validação cruzada aninhada.

II. MATERIAIS E MÉTODOS

Os dados primários utilizados neste estudo foram derivados de estudo anterior [6], publicamente disponibilizados para uso em outras pesquisas, que gerou um banco de dados de 5,7 GB pela emulação de uma rede 5G, com a implementação em software da arquitetura **Open RAN** integrada ao emulador de rede *Colosseum*. O *Colosseum* contém 128 nós de computação, denominados *standard radio nodes*, equipados com USRP X310 *software-defined radio* que podem ser usados para executar pilhas de protocolos genéricos. Estes estão ligados em topologia *mesh* ao *massive channel emulator* para emular cenários realistas de rádio frequência. A rede foi configurada para controlar 3 *slices* de rede instanciados em 4 **BSs**, servindo a 40 **UEs**, no cenário urbano denso de Roma, Itália. As **UEs** foram alocadas para as **BSs** e configuradas para desempenhar os tráfegos **eMBB**, **URLLC** e **MTC**, individualizados em cada *slice*, conforme mostrado na Tabela I.

TABELA I:
Alocação das **UEs** por **BSs** e *slices*/tráfego.

BS	Slice	Tráfego	Equipamentos			
BS I	0	eMBB	UE2	UE5	UE8	
	1	MTC	UE3	UE6	UE9	
	2	URLLC	UE1	UE4	UE7	UE10
BS II	0	eMBB	UE12	UE15	UE18	
	1	MTC	UE13	UE16	UE19	
	2	URLLC	UE11	UE14	UE17	UE20
BS III	0	eMBB	UE22	UE25	UE28	
	1	MTC	UE23	UE26	UE29	
	2	URLLC	UE21	UE24	UE27	UE30
BS IV	0	eMBB	UE32	UE35	UE38	
	1	MTC	UE33	UE36	UE39	
	2	URLLC	UE31	UE34	UE37	UE40

O componente "srsLTE"² foi utilizado para implementar uma parte em software da rede emulada. Este componente de código aberto, que foi recentemente renomeado "srsRAN" para refletir um novo foco para a *5G New Radio*, proporciona uma implementação completa de **BSs** e **UEs**, bem como uma leve estrutura de núcleo de rede. Também em [6], os controladores **O-RAN near real-time RIC** e o **O-RAN non real-time RIC** foram implementados em software, e executam o treinamento e inferência de agentes **DRL** para controlar a política de escalonamento para cada *slice*, entre *round-robin*, *waterfilling* ou *proportionally fair*, buscando otimizar os parâmetros dos tráfegos.

Os dados operacionais foram gerados em diferentes cenários de mobilidade e de proximidade das **UEs** com relação as respectivas **BSs**, conforme a Tabela II.

Na busca da comprovação da nossa hipótese de pesquisa, estes dados nos permitiram associar as métricas operacionais

TABELA II:

Cenários de operação das **UEs** com relação a proximidade das **BSs** e mobilidade.

Cenário	Mobilidade	Proximidade
CN I	Parado	< 20 metros
CN II	Parado	< 50 metros
CN III	Parado	< 100 metros
CN IV	3 metros/s	< 20 metros

das **UEs** com o tráfego desenvolvido por elas, nos diferentes cenários operacionais, sendo possível construir bases de dados para treinar modelos de **ML** que nos permitiram a avaliação da classificação do tráfego desenvolvido por cada **UE**.

A. Pré-processamento

Cada experimento realizado em [6], para cada cenário de operação (Tabela II), resultou em 7 minutos e 33 segundos de dados de tráfego sobre cada **UE**, com 19 diferentes métricas, disponibilizadas pelo componente "srsLTE", registradas a cada 249 milissegundos.

Admitimos a hipótese de utilizar cada registro como sendo uma instância e as métricas como atributos para a formação das bases de dados de avaliação da classificação. Assim, as bases de dados iniciais foram montadas re-amostrando, a cada 2 segundos, os dados das 10 **UEs** de cada **BS**, pertencentes ao cenário I, e agrupando em um único arquivo, com o respectivo rótulo de classificação do tráfego desenvolvido por cada **UE**. Foram eliminados registros incompletos ou com dados faltantes, tendo resultado nas dimensões das bases de dados iniciais como descritos na Tabela III.

TABELA III:

Dimensões das bases de dados iniciais para cada **BS** no experimento do **CN I**.

BS	Instâncias	Atributos
BS I	2256	19
BS II	2296	19
BS III	2298	19
BS IV	2340	19

B. Base de dados e algoritmo de classificação

A partir das bases de dados iniciais, realizamos alguns testes preliminares de classificação do tráfego avaliando o desempenho com os algoritmos supervisionados *k-nearest neighbors* (**KNN**) [4] e o *random forest* (**RF**) [19]. O **KNN** e o **RF** são algoritmos clássicos de **ML**, tendo o **KNN** baixa complexidade computacional, o que facilita a implantação em ambiente de produção.

No sentido de encontrar os atributos que melhor representam os resultados de classificação, redução de dimensionalidade, simplificação do modelo, realizamos uma seleção de atributos utilizando o algoritmo *shapley additive explanations* (**SHAP**) [3], que revelou o impacto de cada atributo com o

²www.srslte.com

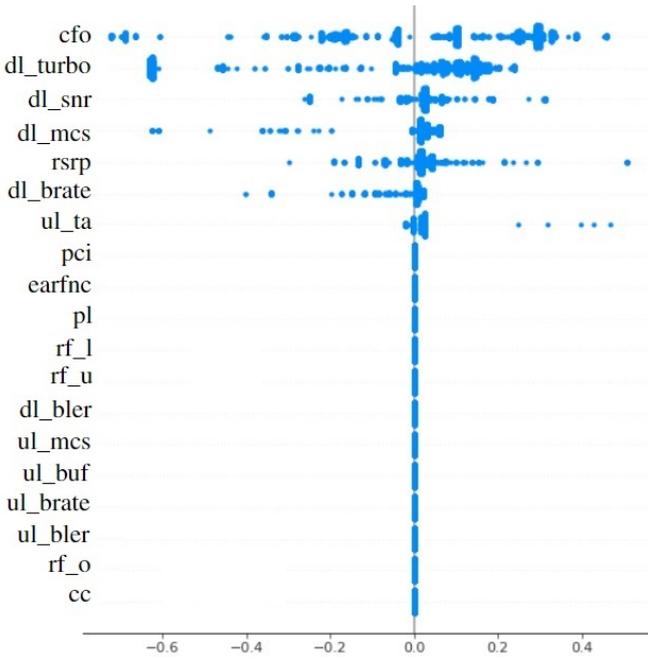


Fig. 2: Valores SHAP relativos para cada atributo.

resultado do modelo da classificação, conforme mostrado na Figura 2.

Portanto, os 19 atributos iniciais³ foram reduzidos para os 7 atributos de maior impacto e descritos na Tabela IV.

TABELA IV:
Atributos finais selecionados.

Atributo	Descrição
cfo	Carrier Frequency Offset (Hz)
dl_turbo	Average number of turbo decoder iterations (download)
dl_snr	Signal-to-Noise Ratio (dB) (download)
dl_mcs	Modulation and coding scheme (0-28) (download)
rsrp	Reference Signal Receive Power (dBm)
dl_brata	Bitrate (bits/sec) (download)
ul_ta	Timing advance (uS) (upload)

C. Validação cruzada aninhada

Dado que as bases de dados não são de elevada dimensionalidade, fica viável a utilização da validação cruzada aninhada como uma abordagem eficaz de se avaliar o desempenho dos modelos sobre as bases de dados geradas. A validação cruzada aninhada é uma técnica para otimização de hiper-parâmetros e treino de modelos que tenta superar o problema de ajuste excessivo do conjunto de dados de treinamento.

Assim, o procedimento foi ajustado para realizar 10-Fold no laço externo e 3-Fold no laço interno. O laço interno foi utilizado para ajuste de hiper-parâmetros do modelo e o laço externo foi utilizado para treinar o modelo e realizar a estimativa das métricas de desempenho.

³A descrição dos atributos pode ser encontrada em: https://docs.srsran.com/en/latest/usermanuals/source/srsue/source/6_ue_comm_andref.html

III. RESULTADOS

Considerando o cenário I (CN I), quando todas as UEs estão estáticas e próximas das respectivas BS, fizemos o treinamento dos classificadores KNN e RF, e avaliamos a classificação dos tráfegos eMBB, MTC e URLLC para cada BS. Os resultados estão explicitados na Tabela V, tendo a acurácia média macro em porcentagem como medida de desempenho. Foi avaliado o intervalo de confiança para o nível de confiança de 95%.

TABELA V:
Desempenho dos modelos KNN e RF treinados para cada BS no cenário I.

BS	Modelo	eMBB	MTC	URLLC
BS I	KNN	99,05±0,50	98,67±0,54	98,40±0,59
	RF	99,56±0,26	99,03±0,38	98,67±0,47
BS II	KNN	99,17±0,43	98,00±0,84	97,52±0,70
	RF	99,43±0,39	99,74±0,22	99,43±0,37
BS III	KNN	99,17±0,48	98,83±0,62	98,78±0,55
	RF	99,61±0,17	99,70±0,29	99,65±0,20
BS IV	KNN	99,02±0,52	98,46±0,44	97,65±0,84
	RF	99,44±0,26	99,74±0,26	99,44±0,29

Também foi feita a avaliação do desempenho de inferência do tráfego em todos os cenários e diferentes condições de treinamento, apenas utilizando os dados da BS I e para o modelo KNN. Estes resultados estão mostrados na Tabela VI. Na primeira linha constam os resultados da acurácia na inferência do tráfego em todos os cenários mas com o treinamento do modelo feito apenas na base de dados do CN I. Na segunda linha a acurácia na inferência do tráfego foi obtida pelo modelo treinado em cada um dos 4 cenários individualmente.

TABELA VI:
Inferência do tráfego em todos os cenários, avaliados em diferentes condições de treinamento.

Treinamento	CN I	CN II	CN III	CN IV
Apenas no CN I	99,78%	80,50%	49,44%	59,63%
Em cada CN	99,78%	99,42%	99,73%	97,62%

Finalmente foi feita a avaliação da evolução temporal dos tráfegos URLLC, eMBB e MTC, das UE1, UE2 e UE3, no cenário CN I, e no intervalo de tempo de dados disponíveis (7:33 minutos). A Figura 3 mostra este resultado.

IV. DISCUSSÃO

Nos dados da Tabela V fica evidente que os modelos KNN e RF performaram muito bem junto as bases de dados montadas, com a acurácia superior a 97% em todos os casos e com reduzida dispersão. Adicionalmente, a possibilidade de utilizar o modelo KNN deve refletir favoravelmente na redução de complexidade computacional numa eventual implementação prática do classificador de tráfego.

A seleção de atributos realizada, com os resultados explicitados na Tabela IV, nos permite afirmar quais foram as métricas mais relevantes para o fim de classificação do tráfego, para este caso estudado.

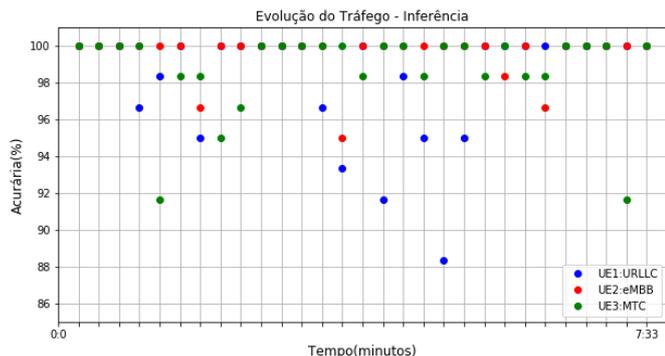


Fig. 3: Evolução temporal da previsão do tráfego para as UE1, UE2 e UE3.

Com a avaliação do tráfego realizado nos vários cenários, evidenciados na Tabela VI, mostrou-se que a inferência realizada com o modelo treinado apenas no cenário **CN I** não resultou em bons resultados de classificação do tráfego nos demais cenários. Nota-se com clareza que o desempenho foi reduzindo do cenário **CN I** até o **CN III**, a medida que as **UEs** foram se distanciando das **BSs** ou quando elas entraram em movimento (**CN IV**). A acurácia voltou a superar os 97% quando o modelo foi treinado a cada cenário e avaliado o seu desempenho. Os resultados estão coerentes com o impacto dos eventuais efeitos de *mobility*, *path loss*, *fading*, *inter-cell interference* e outros motivos de variabilidade que as **UEs** podem sofrer na rede móvel. Uma estrutura em *loop* de aprendizado e inferência já está prevista na arquitetura **Open RAN**, através do **RAN Intelligent Controller (RIC)**, suportando a necessidade de se retrainar o modelo periodicamente, acompanhando as variabilidades das métricas das **UEs**.

Neste trabalho as métricas das **UEs** foram amostradas a cada 2 segundos, sugerindo que o classificador de tráfego possa ter o treinamento e a inferência realizados como um **rApp** no *non-real-time RIC*, que incorpora inteligência ao projeto do sistema para realizar tarefas de gerenciamento de rede e funciona para *loops* de controle superiores a 1 segundo.

A evolução temporal da classificação do tráfego pode ser feita de forma individualizada, como mostrado na Figura 3, ou em grupo, sendo possível construir ferramentas de visualização para efeitos de gestão.

V. CONCLUSÕES

Os resultados se mostraram promissores para a comprovação da hipótese de que seria possível prever os tráfegos **URLLC**, **eMBB** e **MTC** em função das métricas operacionais obtidas junto às **UEs**. Com o modelo treinado para cada cenário analisado, foi possível atingir mais de 97% de acurácia no desempenho do classificador de tráfego.

Os atributos selecionados contribuíram para os bons resultados, reduziram a dimensionalidade e demonstraram ser adequados para uso no modelo **KNN**, até mesmo numa eventual implementação prática, pela baixa complexidade computacional deste modelo.

Pelos cenários analisados acredita-se na necessidade de retraino em *loop* do modelo de aprendizado, acompanhando a

dinâmica da operação das **UEs** na rede, estando em harmonia com a arquitetura da **Open RAN**, que prevê a implantação de aplicações inteligentes (**rApps**) no *non-real-time RIC*.

AGRADECIMENTOS

Os autores agradecem aos pesquisadores do estudo [6] por disponibilizarem e autorizarem o uso dos dados primários utilizados neste trabalho.

REFERÊNCIAS

- [1] O-RAN Working Group 1, "O-RAN-Architecture-Description-v06.00", Technical Specification, march 2022.
- [2] O-RAN Working Group 1, "Use Cases Detailed Specification-v07.00", Technical Specification, march 2022.
- [3] Lundberg, S. M., e S. Lee. "A unified approach to interpreting model predictions." *Advances in Neural Information Processing Systems*, 2017.
- [4] T. Cover and P. Hart, "Nearest neighbor pattern classification," in *IEEE Transactions on Information Theory*, vol. 13, no. 1, pp. 21-27, January 1967, doi: 10.1109/TIT.1967.1053964.
- [5] A. Klautau, P. Batista, N. González-Prelcic, Y. Wang e R. W. Heath, "5G MIMO Data for Machine Learning: Application to Beam-Selection Using Deep Learning", *Information Theory and Applications Workshop (ITA)*, 2018, pp. 1-9, doi: 10.1109/ITA.2018.8503086.
- [6] L. Bonati, S. D'Oro, M. Polese, S. Basagni e T. Melodia, "Intelligence and Learning in O-RAN for Data-driven NextG Cellular Networks," *IEEE Communications Magazine*, 2021.
- [7] S.Niknam et al, "Intelligent O-RAN for Beyond 5G and 6G Wireless Networks", arXiv, January 2020, doi:10.48550/ARXIV.2005.08374.
- [8] B. Balasubramanian et al, "RIC: A RAN Intelligent Controller Platform for AI-Enabled Cellular Networks", *IEEE Computer Society*, 202, doi: 10.1109/MIC.2021.3062487.
- [9] S. Mollahasani, M. Erol-Kantarci and R. Wilson, "Dynamic CU-DU Selection for Resource Allocation in O-RAN Using Actor-Critic Learning," 2021 IEEE Global Communications Conference (GLOBECOM), 2021, pp. 1-6, doi: 10.1109/GLOBECOM46510.2021.9685837.
- [10] A. Alwarafy, B. S. Ciftler, M. Abdallah, M. Hamdi and N. Al-Dhahir, "Hierarchical Multi-Agent DRL-Based Framework for Joint Multi-RAT Assignment and Dynamic Resource Allocation in Next-Generation Het-Nets," in *IEEE Transactions on Network Science and Engineering*, 2022, doi: 10.1109/TNSE.2022.3164648.
- [11] . Bonati, M. Polese, S. D'Oro, S. Basagni, and T. Melodia, "OpenRAN Gym: An Open Toolbox for Data Collection and Experimentation with AI in O-RAN," in *Proceedings of IEEE WCNC Workshop on Open RAN Architecture for 5G Evolution and 6G*, Austin, TX, USA, April 2022.
- [12] B. Brik, K. Boutiba and A. Ksentini, "Deep Learning for B5G Open Radio Access Network: Evolution, Survey, Case Studies, and Challenges," in *IEEE Open Journal of the Communications Society*, vol. 3, pp. 228-250, 2022, doi: 10.1109/OJCOMS.2022.3146618.
- [13] S. D'Oro, L. Bonati, M. Polese, and T. Melodia, "OrchestRAN: Network Automation through Orchestrated Intelligence in the Open RAN", *IEEE International Conference on Computer Communications (INFOCOM) 2022*, 2022.
- [14] M. Polese, L. Bonati, S. D'Oro, Stefano B. and T. Melodia, "CoIO-RAN: Developing Machine Learning-based xApps for Open RAN Closed-loop Control on Programmable Experimental Platforms", submitted to the IEEE for possible publication, 2022
- [15] A. Dainotti, A. Pescapè and K. C. Claffy, "Issues and future directions in traffic classification," in *IEEE Network*, vol. 26, no. 1, pp. 35-40, January-February 2012, doi: 10.1109/MNET.2012.6135854.
- [16] M. R. Parsaei, M. J. Sobouti, S. R. khayami and R. Javidan, "Network Traffic Classification using Machine Learning Techniques over Software Defined Networks", *International Journal of Advanced Computer Science and Applications (IJACSA)*, 2017.
- [17] R. M. AlZoman and M. J. F. Alenazi, "A Comparative Study of Traffic Classification Techniques for Smart City Networks", *Sensors*, 2020, 21, 4677. <https://doi.org/10.3390/s21144677>.
- [18] B. Angui, R. Corbel, V. Q. Rodriguez and E. Stephan, "Towards 6G zero touch networks: The case of automated Cloud-RAN deployments," 2022 IEEE 19th Annual Consumer Communications Networking Conference (CCNC), 2022, pp. 1-6, doi: 10.1109/CCNC49033.2022.9700507.
- [19] Ho, T. K. "Random decision forests". In *Proceedings of 3rd international conference on document analysis and recognition (Vol. 1, pp. 278–282)*, 1995.