



GT IQoS: III Workshop Open RAN Brasil

Agenda



- Equipe
- Introdução
- Apresentação da Proposta
- Detalhamento da xAPP: Classificador-Gerenciador de Slice
- Visão Geral da Implementação no Testbed
- Metodologia de Treinamento e Avaliação
- Testes e Resultados Obtidos
- Conclusão



Equipe



**Coordenador do GT
UFPA**
Professor André
Riker



**Bolsista
PPGCC-UFPA**
Victor Leite



**Bolsista
PPGCC-UFPA**
Matheus Gomes



**Pesquisador Associado
PPGCC-UFPA | RNP**
Murilo Silva



**Bolsista
PPGCC-UFPA**
Glauber Santiago



**Bolsista
UFPA**
Felipe Alves



Pesquisador Associado
João Batista



Introdução



- Open RAN
 - Uso de Fatiamento de Rede (Network Slicing) no 5G;
 - Criar fatias distintas para diferentes aplicações:
 - eMBB (Enhanced Mobile Broadband);
 - mMTC (Massive Machine-Type Communications);
 - URLLC (Ultra-Reliable Low Latency Communications).

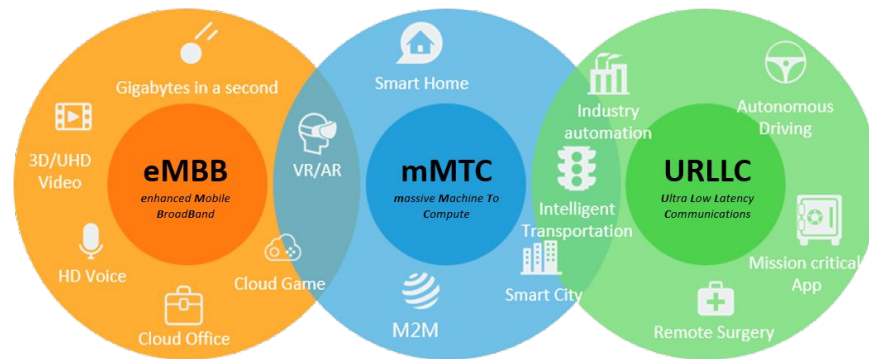


Figura 2: Os 3 tipos de serviços redes móveis 5G. (Fonte: The Westcott Space Cluster)



- Resumo do Problema:
 - Identificação do tipo de serviço consumido pela UE não é feita de forma dinâmica;
 - A alocação da UE à fatia mais adequada é um desafio em ambientes reais;
 - Soluções manuais aumentam custos e reduzem a eficiência operacional.
 - Possibilidade:
 - Utilizar modelos de Aprendizado de Máquina (AM) para:
 - Classificar o tráfego do usuário;
 - Alocar UEs em slices compatíveis com o tipo de serviço.
- Tomada de decisão
- Basear em KPMs (Medidas-chave de Desempenho) fornecidas pelos Nós E2.

Apresentação da Proposta



- Alocar UEs dinamicamente às fatias 5G no Open RAN.
- Utilizar aprendizado de máquina para analisar KPMs (Key Performance Metrics) do Nó E2.
- Arquitetura da Solução:
 - Implementado como microsserviço cloud-native;
 - Integrado ao Near-RT RIC por meio de uma xApp.
- Realizar a alocação no Core 5G, atualizando o Slice-service type (SST) da UE.

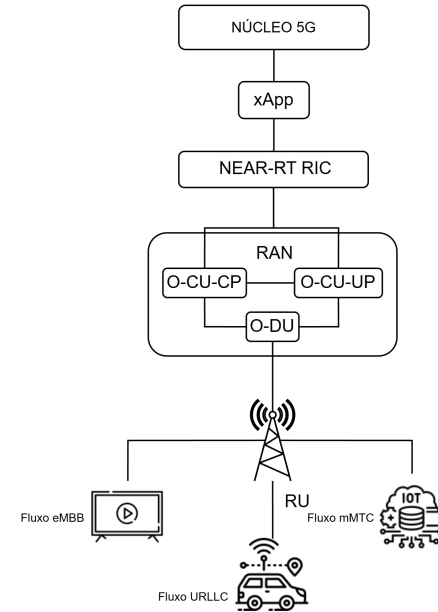


Figura 3: Visão geral da proposta. (Fonte: Autor)

Apresentação da Proposta



- Módulos principais implementados:
 - Coleta de métricas do desempenho da rede;
 - Codificação e decodificação de mensagens entre xApp e controlador;
 - Classificação da UE e tomada de decisão para alocação na fatia correta;

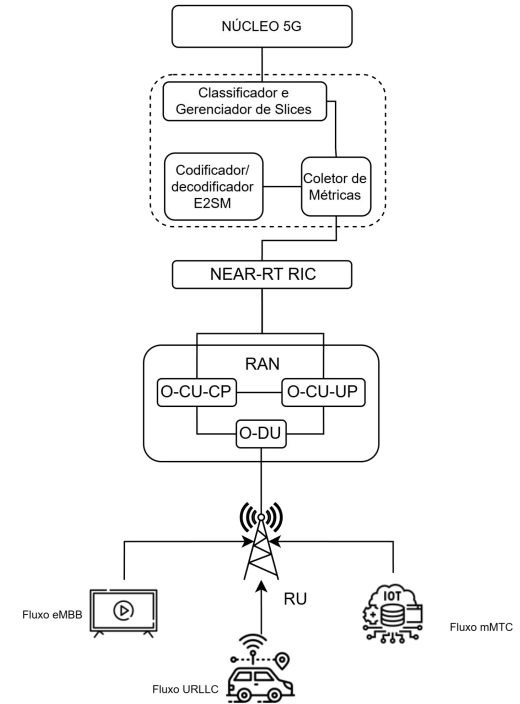


Figura 4: Visão geral com os módulos. (Fonte: Autor)

Apresentação da Proposta



- Módulos principais implementados:
 - Coleta de métricas do desempenho da rede;
 - Codificação e decodificação de mensagens entre xApp e controlador;
 - Classificação da UE e tomada de decisão para alocação na fatia correta;

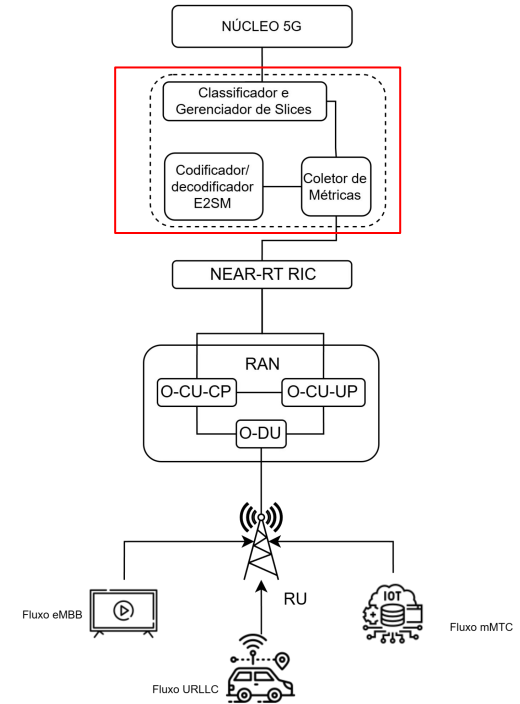
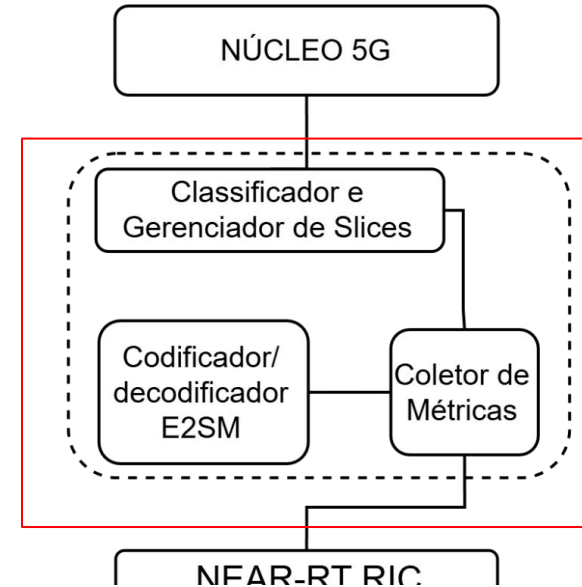


Figura 4: Visão geral com os módulos. (Fonte: Autor)

Apresentação da Proposta



- Módulos principais implementados:
 - Coleta de métricas do desempenho da rede;
 - Codificação e decodificação de mensagens entre xApp e controlador;
 - Classificação da UE e tomada de decisão para alocação na fatia correta;

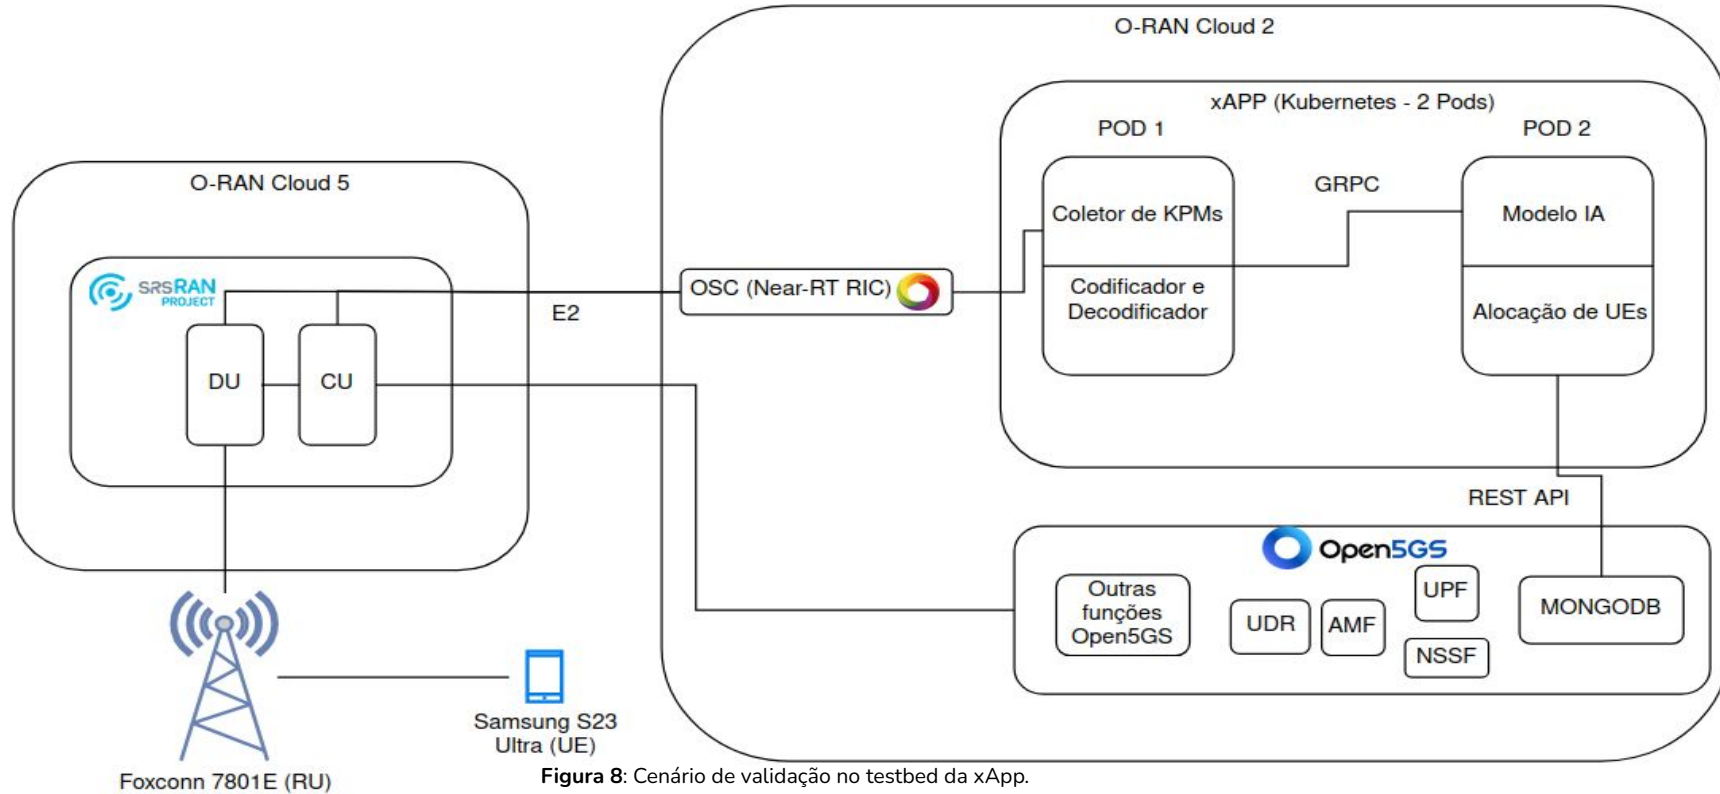


xApp - Classificador/Gerenciador de Slices



- Módulo central da solução atuando com os módulos de coleta e codificação/decodificação;
- Responsável pelo tratamento das mensagens da xApp;
- Processamento das Mensagens:
 - Seleção de métricas de entrada para classificação;
 - Normalização e padronização dos dados;
 - Cruzamento do ID da UE com as métricas recebidas;
- Classificação e Identificação da Fatia:
 - A saída do classificador contém o ID da fatia de destino;
 - O ID corresponde ao SST no qual a UE será alocada no 5G Core;
 - Verificação junto ao 5G Core para validar se a fatia classificada é diferente da atual:
 - Se for diferente: Atualiza a sessão do usuário (PDU) para alterar o SST;
 - Se for igual: Mantém o SST atual.

Visão Geral da Implementação no Testbed



Metodologia de Treinamento e Avaliação



- Modelo
 - Features: taxa de transferência (uplink e downlink) e quantidade de PRBs
 - Target: (default = 0, eMBB = 1, URLLC = 2, mIoT = 3)
 - Arquitetura: LSTM + Camada Densa
 - Números de amostra por entrada (Blocos de Tempo)
 - “Colosseum O-RAN COMMAG Dataset”
- Metodologia de treino e ajuste de Hiperparâmetros :
 - HyperOpt (Python)
 - Grid de Hiperparâmetros
 - Validação Cruzada (K-Fold)
 - Early Stopping
 - Dropout

Hiperparâmetro	Valores
Unidades LSTM	32, 48, 64, 80, 96, 112, 128
Função de Ativação	relu, tanh
Taxa de Aprendizado	0.01, 0.001, 0.0001

Tabela 1: Tabela de hiperparâmetros do modelo.

Testes e Resultados Obtidos



- Resultados:
 - O modelo apresentou uma performance alta na tarefa de classificar as UEs nos seus respectivos slices.
 - Os melhores resultados foram obtidos considerando 5 registros por entrada .

TABLE I
TRAFFIC CLASSES TYPES

Slice ID	Traffic classes	Behavior
1	eMBB	Constant bitrate traffic (1 Mbps per UE)
2	URLLC	Poisson traffic (10 pkt/s of 125 bytes per UE)
3	mMTC	Poisson traffic (30 pkt/s of 125 bytes per UE)

Classe de Serviço/Slice	Precisão	Recall	F1 Score
0 - default	100%	98%	99%
1 - eMBB	100%	99%	99%
2 - URLLC	98%	96%	97%
3 - mIoT	97%	99%	98%
Acurácia	98%		

Tabela 2: Tabela de resultados do modelo.

Conclusão



- O GT IQoS atingiu com sucesso o seu objetivo.
 - Longo percurso até chegar na versão final apresentada (SRS RAN + OSC+ Open 5GS)
 - Diversos RICs e pilhas RAN foram testadas
 - Diversos modelos de aprendizado foram testados (DT, RNN, LSTM, DNN)
 - Formação de recursos humanos
 - Concluídos: 1 TCC + 1 Mestrado
 - Previsão para 2025: 1 TCC + 2 Mestrados
- Previsão promissora de avanços na solução apresentada



GT IQoS
Obrigado!