

Algoritmo Híbrido de Handover com LSTM para Redes Open RAN com mobilidade Urbana

Luiz Quirino Rezende da Costa Filho, Lucas Lino do Carmo Freitas, Álvaro Augusto Machado de Medeiros, Edelberto Franco Silva, Sérgio Roberto Barros e Francisco Hugo Costa Neto

Resumo—A densificação das redes móveis e a arquitetura Open RAN impõem desafios ao gerenciamento de mobilidade, especialmente pelo aumento de *handovers ping-pong* e trocas desnecessárias que degradam a experiência do usuário. Este artigo propõe um algoritmo híbrido de *handover* que combina métodos convencionais e inteligência artificial para mitigar esses problemas. A abordagem utiliza o evento A2A4 para o disparo inicial e uma rede neural Long Short-Term Memory (LSTM), em versões multicelular e unicelular, para validar preditivamente se a célula alvo manterá qualidade superior à servidora nos próximos 10 passos temporais. A solução foi avaliada em simulações integradas ns-3/SUMO, utilizando o mapa de Juiz de Fora para representar um cenário urbano realista. Os resultados mostram redução de *handovers ping-pong* e trocas desnecessárias, evidenciando o potencial da proposta para uso como xApp em ambientes Open RAN.

Palavras-Chave—Open RAN, Handover, LSTM, Ping-Pong, SUMO.

Abstract—The densification of mobile networks and the Open RAN architecture impose challenges on mobility management, particularly due to the increase in ping-pong handovers and unnecessary handovers that degrade the user experience. This paper proposes a hybrid handover algorithm that combines conventional methods and artificial intelligence to mitigate these issues. The approach employs the A2A4 event for the initial trigger and a Long Short-Term Memory (LSTM) neural network, in both multicellular and unicellular versions, to predictively validate whether the target cell will maintain superior quality compared to the serving cell over the next 10 time steps. The solution was evaluated through integrated ns-3/SUMO simulations using the map of Juiz de Fora to represent a realistic urban scenario. The results show a reduction in ping-pong handovers and unnecessary handovers, highlighting the potential of the proposed solution for use as an xApp in Open RAN environments.

Sérgio Roberto Barros e Francisco Hugo Costa Neto (emails: {sbarros, fhugo}@cpqd.com.br) são do Centro de Pesquisa e Desenvolvimento em Telecomunicações (CPQD). Eles recebem apoio do CPQD e do MCTI - Ministério da Ciência, Tecnologia e Inovação, com recursos financeiros da FUNTTEL e administrados pela FINEP, especificamente no âmbito dos projetos AERF - Ações Estratégicas para Redes Futuras, Contrato 01.22.0471.01, Referência 1508/22; Luiz Quirino Rezende da Costa Filho e Álvaro Augusto Machado de Medeiros (e-mails: luiz.quirino@estudante.ufjf.br e alvaro.medeiros@ufjf.br), Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Juiz de Fora, Juiz de Fora-MG; Lucas Lino do Carmo Freitas e Edelberto Franco Silva (e-mails: lucas.freitas@estudante.ufjf.br e edelberto.franco@ufjf.br), Programa de Pós-Graduação em Ciência da Computação, Universidade Federal de Juiz de Fora, Juiz de Fora-MG. Este trabalho foi apoiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) - código de financiamento 001. Este trabalho foi parcialmente financiado pelo projeto SGHaul apoiado pelo Centro de Excelência em Redes Abertas EMBRAPII/CPQD, com recursos financeiros do PPI IoT/Manufatura 4.0/PPI HardwareBR do edital MCTI número 51/2023, firmado com a EMBRAPII. Este trabalho foi desenvolvido no âmbito do Projeto Brasil 6G - Fase III, com apoio do Ministério da Ciência, Tecnologia e Inovação (MCTI), sob o número de processo 01245.020548/2021-07.

Keywords—Open RAN, Handover, LSTM, Ping-Pong, SUMO.

I. INTRODUÇÃO

As redes móveis têm passado por um grande crescimento, acompanhado pelo aumento do tráfego de dados e pela necessidade de maior flexibilidade e eficiência. Nesse contexto, técnicas de aprendizado de máquina vêm sendo investigadas para otimizar processos da RAN (*Radio Access Network*), como o *handover*, tradicionalmente baseados em heurísticas definidas pelo 3GPP (*3rd Generation Partnership Project*). Além disso, o Open RAN introduziu avanços importantes ao promover maior desagregação e interoperabilidade entre os componentes da RAN, destacando-se o RIC (*RAN Intelligent Controller*), responsável por permitir a criação de xApps para controle inteligente da rede [1].

Contudo, a densificação das células torna mais frequentes problemas de mobilidade, como o *handover ping-pong*, trocas desnecessárias de célula e, em alguns casos, falhas de enlace RLF (*Radio Link Failures*), comprometendo a eficiência da comunicação e a experiência do usuário [2]. Embora algoritmos tradicionais, como o A2A4, utilizem métricas de RSRP (*Reference Signal Received Power*) e RSRQ (*Reference Signal Received Quality*) para decisões de *handover*, tais abordagens possuem caráter reativo e não consideram a evolução futura das condições do canal [3].

Neste trabalho, propomos uma abordagem híbrida para mitigação de *handovers ping-pong* e transferências desnecessárias em redes móveis, combinando o algoritmo tradicional A2A4 com um modelo preditivo baseado em LSTM. O modelo atua como um validador inteligente do processo de *handover*, utilizando informações temporais da qualidade do sinal para estimar o comportamento futuro das células envolvidas e refinar a decisão de mobilidade. A avaliação foi realizada no simulador ns-3 (*Network Simulator*) integrado ao SUMO (*Simulation of Urban Mobility*), utilizando mobilidade veicular baseada em um mapa urbano real da cidade de Juiz de Fora, permitindo analisar o desempenho da solução em um cenário mais representativo de redes móveis urbanas. Além da redução de *handovers* indesejados, também foi analisado o impacto da estratégia proposta sobre a ocorrência de RLFs, permitindo discutir os benefícios e limitações decorrentes da utilização do modelo preditivo. Os resultados demonstram que a abordagem proposta reduz a ocorrência de *handovers ping-pong* e transferências desnecessárias em relação ao algoritmo de referência.

O restante deste trabalho está organizado da seguinte forma. A Seção II explora os trabalhos da literatura sobre *handover ping-pong* desnecessários. A Seção III descreve o ambiente experimental e a metodologia utilizada para treinamento e avaliação do modelo híbrido. Na Seção IV, são discutidos os resultados, as limitações observadas e o impacto da proposta. Por fim, na Seção V são apresentadas as conclusões e oportunidades para trabalhos futuros.

II. TRABALHOS RELACIONADOS

Nesta seção são analisados trabalhos que propuseram modelos de *handover* inteligentes no contexto geral de redes móveis, com foco na redução de *ping-pongs*. São discutidas soluções que abordaram a predição como estratégia para prevenir possíveis situações de flutuação de sinais.

Naeem et al. [4] abordaram o efeito *ping-pong* em redes heterogêneas por meio de um sistema baseado em lógica fuzzy, utilizando parâmetros como intensidade do sinal, velocidade do usuário e histórico de trajetórias para melhorar as decisões de *handover*. Os resultados demonstraram melhorias na taxa de sucesso de *handover* em relação aos métodos tradicionais baseados em potência do sinal e temporizadores, reduzindo chamadas perdidas e atenuando o efeito *ping-pong*. Os autores destacam o potencial da abordagem para aplicações futuras com IA preditiva.

Bastidas et al. [5] propuseram um método baseado em predição de SINR com RLS para ajustar dinamicamente o TTT e reduzir falhas de *handover* e eventos *ping-pong*. Os resultados mostraram reduções de 27,5% nas falhas de *handover* e 37,2% nos casos de *ping-pong*, embora o método também provoque atrasos em *handovers* legítimos.

Em [6], os autores propuseram um modelo preditivo de *handover* baseado em LSTM e SVM para reduzir a latência e melhorar a precisão das decisões. O LSTM prediz parâmetros como RSRP e RSRQ, enquanto o SVM seleciona a rede alvo e permite a pré-alocação de recursos. Os testes, realizados com *datasets* de mobilidade e sinais 5G, alcançaram acurácia de até 99,99%, além de reduzir significativamente o tempo médio de *handover* em comparação aos métodos não preditivos.

III. PROPOSTA

Este trabalho propõe um mecanismo de decisão de *handover* baseado em predição para reduzir *handovers ping-pong* e desnecessários em redes móveis. A abordagem combina simulação no ns-3 [7] com um modelo LSTM capaz de prever o comportamento futuro do canal, utilizando métricas de qualidade de sinal como critério adicional às técnicas tradicionais baseadas em limiares.

Inicialmente, o ns-3 foi utilizado para gerar dados sob diferentes condições de mobilidade e propagação. As simulações, executadas sem algoritmos de *handover*, integraram SUMO e ns-3 com o mapa da região central de Juiz de Fora, permitindo coletar métricas de RSRP e RSRQ da célula servidora e vizinhas ao longo das trajetórias veiculares. Foram realizadas 15 simulações com diferentes *seeds* e padrões de mobilidade urbana.

Durante a coleta, observou-se irregularidade no intervalo das métricas, variando entre 100 ms e 1 s. Para tratar essa variação, foi introduzida a variável Δt , representando a diferença de tempo entre coletas consecutivas e servindo como contexto temporal para a rede neural.

A. Arquitetura do Modelo Preditivo e Estratégias de Entrada

Os dados foram processados em janelas deslizantes para o treinamento do modelo, utilizando 15 amostras de entrada para prever 10 passos futuros. Esse horizonte foi definido com base nas simulações do algoritmo A2A4, nas quais se observou que, em média, esse intervalo abrangia o período entre o disparo de um *handover* e uma eventual ocorrência de *handover ping-pong*. Valores menores reduziram a detecção de transferências desnecessárias, enquanto valores maiores diminuíram a precisão das previsões.

Para avaliar a estratégia proposta, os *handovers* registrados durante as simulações foram classificados segundo critérios temporais. Um *handover* foi considerado como *ping-pong* quando o UE (*User Equipment*) retornou à célula de origem em um intervalo inferior a 15 segundos. Já um *handover* foi classificado como desnecessário quando a permanência na célula de destino foi inferior a 30 segundos antes de uma nova transferência. Assim, todo *handover ping-pong* também é considerado desnecessário.

A proposta para reduzir *handovers* desnecessários utiliza um modelo de regressão baseado em LSTM, desenvolvido com TensorFlow [8] e Keras [9]. A arquitetura possui duas camadas LSTM, com 64 e 32 unidades, seguidas por uma camada densa de saída para regressão. Além disso, foram avaliadas duas estratégias distintas de seleção de atributos de entrada para analisar seu impacto na precisão da predição.

A primeira estratégia, uma abordagem multicélula, considera um conjunto de células para avaliação. O vetor de entrada, com dimensão (15,7), é composto pelas métricas RSRQ e RSRP da célula servidora, e das duas células vizinhas com melhor sinal no instante da coleta, além do Δt . A camada de saída é configurada para prever simultaneamente 20 valores, 10 passos futuros do RSRQ da servidora e 10 passos da melhor vizinha candidata. Esta abordagem busca capturar a correlação entre a queda de sinal de uma torre e o aumento de sinal de outra.

A segunda estratégia adota uma abordagem unicelular, prevendo o comportamento de uma única célula a partir de RSRQ e Δt . Sua aplicação requer duas predições paralelas: uma para a célula servidora e outra para a candidata. O objetivo é reduzir a dimensionalidade da rede e facilitar a convergência do treinamento. Em ambas as estratégias, os dados foram divididos em 80% para treinamento e 20% para teste, utilizando o otimizador Adam, 30 épocas e taxa de aprendizagem de 0.001. A arquitetura utilizada é apresentada na Figura 1.

A diferença conceitual entre os algoritmos avaliados é ilustrada no diagrama de decisão apresentado na Figura 2. Enquanto o algoritmo A2A4 executa o *handover* imediatamente após o disparo do gatilho, as abordagens baseadas em LSTM adicionam uma etapa de validação preditiva. No caso do




Fig. 1. Representação da arquitetura LSTM

modelo unicelular, a decisão é baseada em previsões independentes da célula servidora e da candidata, enquanto o modelo multicelular realiza uma previsão conjunta considerando a célula servidora e as células vizinhas. Como consequência, os algoritmos podem apresentar comportamentos distintos diante de um mesmo cenário de mobilidade.




Fig. 2. Diagrama dos algoritmos propostos

B. Integração e Validação de Handover no ns-3

A implementação no simulador ns-3 foi realizada para utilizar a estrutura existente de forma eficiente e minimamente intrusiva, com o objetivo de realizar a validação do algoritmo proposto. O algoritmo de *handover* padrão baseada A2A4 foi modificado para interagir com o modelo preditivo. A ideia é implementar a lógica de *handover* em um código Python, aproveitando os benefícios e facilidades de suas bibliotecas, e utilizar o código adaptado do ns-3 para se comunicar por meio de um *socket*, enviando métricas e recebendo tomadas de decisões. Na arquitetura proposta, o modelo A2A4 continua responsável pelo monitoramento contínuo das métricas e pelo disparo inicial dos gatilhos de mobilidade, respeitando os parâmetros de *histerese* e *Time-to-Trigger*.

No entanto, ao invés de executar o *handover* após o disparo do gatilho, o sistema chama o módulo LSTM. O modelo preditivo utiliza um pequeno histórico contendo as 15 amostras mais recentes armazenadas do UE e projeta o comportamento futuro das células envolvidas. O algoritmo então analisa as tendências. O *handover* só é realizado se a previsão indicar

que a célula candidata manterá uma qualidade superior à servidora durante o horizonte de 10 passos futuros. Caso a previsão aponte uma queda rápida na qualidade da célula alvo ou uma recuperação da célula servidora dentro deste intervalo, o *handover* é bloqueado, classificando o gatilho inicial como um potencial *ping-pong* ou *handover* desnecessário. Desta forma, o LSTM atua como um validador inteligente, refinando as decisões do algoritmo clássico e aumentando a robustez do gerenciamento de mobilidade.

IV. RESULTADOS

Para analisar os resultados, foi realizada uma sequência de testes, objetivando comparar os modelos propostos com o modelo padrão A2A4. Foram executadas 5 rodadas de simulação para cada algoritmo, onde em cada execução, foi alterado a semente (*seed*) para aleatoriedade do ns-3 e gerado rotas diferentes no SUMO, assegurando que os modelos sejam submetidos a diferentes variações de desvanecimento de canal, interferência e movimentação. Os resultados apresentados a seguir representam portanto, a média dessas execuções.

Os critérios utilizados para classificação dos *handovers* *ping-pong* e dos *handovers* desnecessários foram definidos conforme descrito na Seção III. No treinamento, os modelos multicelular e unicelular apresentaram, respectivamente, RMSE de 1.078 e 1.012, MAE de 0.772 e 0.744, e R^2 de 0.832 e 0.740.

A. Ambiente de simulação

O ambiente de simulação foi configurado para replicar um cenário de rede heterogênea 4G/LTE, que inclui tanto macrocélulas quanto microcélulas. Esta configuração visa criar regiões de cobertura sobreposta e cenários de mobilidade que introduzem a ocorrência de *handovers* *ping-pong* e desnecessários com certa frequência, permitindo a avaliação dos algoritmos propostos.

O ambiente de simulação é composto por 13 células, sendo 9 macrocélulas e 4 microcélulas. As macrocélulas foram distribuídas sobre o mapa de Juiz de Fora conforme a figura 4, enquanto as microcélulas foram posicionadas na região central do cenário, cobrindo o centro da cidade de Juiz de Fora. As macrocélulas utilizam potência de transmissão de 46 dBm e as microcélulas de 24 dBm, ambas operando com largura de banda de 20 MHz e frequência central em torno de 2.1 GHz. O cenário considera a presença de 5 UEs móveis. A mobilidade dos usuários foi gerada com o simulador SUMO, utilizando um cenário baseado na região central da cidade como mostra a Figura 3.

B. Análise de handover

Os resultados obtidos das cinco execuções para cada algoritmo demonstram uma melhoria consistente proporcionada pelas abordagens baseadas em LSTM na mitigação de *handovers* indesejáveis.

Em relação aos *handovers* *ping-pong*, observa-se uma redução significativa promovida pelos modelos preditivos, conforme Figura 5. O algoritmo A2A4 padrão registrou uma

média de 151.8 eventos com um desvio padrão de 21.72. O modelo LSTM multicelular, que processa informações de múltiplas células simultaneamente, apresentou o melhor desempenho, com uma média de 112.4 eventos e um desvio padrão de 17.2. Isto representa uma redução média de 26.1% em comparação ao A2A4. A abordagem LSTM unicelular, que requer duas inferências por decisão, também superou o padrão, com uma média de 123.2 eventos e desvio padrão de 18.9, representando uma redução média de 18.9%. A menor variabilidade (desvio padrão) observada nas abordagens com LSTM sugere que o algoritmo preditivo apresenta comportamento consistente e menos susceptível às flutuações, nas diferentes condições avaliadas.

A análise dos *handovers* desnecessários (que incluem os eventos *ping-pong*) revela um padrão de melhoria similar, porém com um impacto mais acentuado devido ao maior volume de eventos, conforme Figura 6. O algoritmo A2A4 produziu uma média de 343 *handovers* desnecessários (com desvio padrão de 39.15). Novamente, a arquitetura LSTM multicelular obteve o melhor resultado, reduzindo a média para 234 eventos (com desvio padrão de 16.4), o que representa uma redução de 31.8%. O modelo unicelular alcançou uma média de 282.4 eventos, e desvio padrão de 36.6, uma redução de 17.7%. Estes resultados confirmam que a validação preditiva implementada pelo LSTM é eficaz não apenas para evitar oscilações rápidas, mas também para evitar transferências precoces ou que não sejam vantajosas ou que não resultaria em uma melhoria para o UE. É importante notar que a diferença percentual de redução entre os dois tipos de *handover* é maior para os desnecessários, embora o modelo tenha sido projetado para predição de 10 passos futuros, objetivando redução de *ping-pongs*. Ainda assim, os resultados indicam que o modelo LSTM foi eficiente em evitar *handovers* que, apesar de não configurarem *ping-pong* imediato, ainda são prematuros.

Para complementar os resultados foi realizado uma análise da potência média do sinal (RSRP) coletada em todas as simulações, conforme Figura 7. As médias de RSRP para os usuários ao longo de todas as execuções foram equivalentes entre os três algoritmos, com variações irrelevantes. Esses resultados sugerem que a redução dos *handovers* não decorre de uma deterioração da qualidade média do sinal recebido, mas de uma estratégia mais seletiva para execução das transferências.



Fig. 3. Mapa da cidade de Juiz de Fora no SUMO

C. Análise de RLFs

Embora os modelos baseados em LSTM tenham reduzido significativamente os *handovers* desnecessários e do tipo *ping-pong*, observou-se um aumento na ocorrência de RLFs em comparação ao algoritmo A2A4. Enquanto o A2A4 apresentou média de 23 RLFs por execução (desvio padrão de 3,2), as abordagens LSTM registraram médias de 66 RLFs na configuração unicelular (desvio padrão de 8,4) e 123 RLFs na multicelular (desvio padrão de 14,2).

Esse comportamento pode ser explicado pela estratégia de validação adotada pelos modelos preditivos. Ao adiar ou cancelar *handovers* que seriam executados pelo A2A4, os usuários permanecem conectados à célula servidora por mais tempo, inclusive em regiões de cobertura degradada. Embora




Fig. 4. Posicionamento das eNBs




Fig. 5. Handover Ping-pong por algoritmo




Fig. 6. Handover desnecessários por algoritmo

essa abordagem reduza oscilações e *handovers* prematuros, ela também aumenta a probabilidade de permanência em condições de sinal inadequadas, favorecendo a ocorrência de RLFs. Esse efeito é mais evidente na abordagem multicelular, que apresenta simultaneamente a maior redução de *handovers* e a maior taxa de falhas de enlace.

Para complementar essa análise, a Figura 8 apresenta conjuntamente o número de *handovers* realizados e de RLFs observados em cada algoritmo. Embora estes eventos possuam naturezas distintas (onde RLFs podem incluir interrupções de serviço e procedimentos adicionais de recuperação da conexão), a análise conjunta não tem como objetivo atribuir o mesmo peso a ambos os eventos, mas oferecer uma visão complementar do número total de intervenções relacionadas à mobilidade produzidas por cada estratégia, adotando o RLF como uma transferência não planejada. Deste ponto de vista, é possível observar que os algoritmos baseados em LSTM ainda apresentam um número total de eventos de mobilidade inferior ao do A2A4. Em média, o A2A4 resultou em aproximadamente 720.6 *handovers* e 23 RLFs por execução, totalizando cerca de 743.6 eventos. Da mesma forma, o algoritmo LSTM multicelular apresentou cerca de 323 *handovers* e 123 RLFs, totalizando cerca de 446 eventos, enquanto o LSTM unicelular resultou em cerca de 540 *handovers* e 66 RLFs, com total de 606 eventos. Esses resultados indicam que, mesmo com o aumento de RLFs, os modelos propostos reduzem o número total de eventos de mobilidade em relação ao método padrão.

A maior ocorrência de RLFs não invalida a proposta, mas aponta uma direção para trabalhos futuros, onde o modelo preditivo deve buscar não apenas a precisão na previsão da qualidade entre células, mas também a detecção antecipada

de condições que levam a RLFs.

V. CONCLUSÃO E TRABALHOS FUTUROS

Este trabalho apresentou uma abordagem para redução de *handovers ping-pong* e *handovers* desnecessários em redes móveis, baseado na predição da qualidade de sinal futuro por meio de redes neurais LSTM. A proposta foi avaliada em um ambiente de simulação com ns-3, no qual métricas de qualidade de sinal, como RSRP e RSRQ, foram coletadas e utilizadas para treinar modelos preditivos capazes de validar decisões de *handover* disparadas pelo algoritmo padrão A2A4. Duas estratégias distintas foram investigadas, uma abordagem multicelular, que considera simultaneamente informações da célula servidora e das principais células vizinhas, e uma abordagem unicelular, baseada na predição individual do comportamento de cada célula candidata. Os resultados obtidos demonstram que ambas as variações do método proposto foram eficazes na redução do número de *handovers ping-pong* e desnecessários quando comparadas ao A2A4. Em particular, a abordagem multicelular apresentou os maiores ganhos, alcançando reduções superiores a 20% nos eventos de *ping-pong* e próximas a 30% nos *handovers* desnecessários, além de apresentar menor variabilidade entre execuções.

Como trabalhos futuros, pretende-se incorporar novas métricas de qualidade e desempenho, como SINR, latência e carga das células, visando aumentar a robustez do *handover* e reduzir RLFs. Também será investigado o uso de *Federated Learning* para o treinamento distribuído dos modelos LSTM, evitando o compartilhamento centralizado de dados.

Por fim, a implementação da estratégia como um *xApp* em ambientes *Open RAN*, incluindo aspectos relacionados à integração com o RIC, latência de inferência e custo computacional, constitui uma etapa futura para avaliar sua viabilidade prática.

REFERÊNCIAS

- [1] C. Fianadrino, L. Bonati, S. D'Oro, M. Polese, T. Melodia, and J. Widmer, "Explora: Ai/ml explainability for the open ran," *Proceedings of the ACM on Networking*, vol. 1, no. CoNEXT3, pp. 1–26, 2023.
- [2] S. Alraih, R. Nordin, I. Shaya, N. F. Abdullah, and A. Alhammadi, "Ping-pong handover effect reduction in 5g and beyond networks," in *2021 IEEE Microwave Theory and Techniques in Wireless Communications (MTTW)*. IEEE, 2021, pp. 97–101.
- [3] K. Sun *et al.*, "Proactive handover type prediction and parameter optimization based on machine learning," *IEEE Transactions on Wireless Communications*, 2025.
- [4] B. Naeem, R. Ngah, and S. Z. M. Hashim, "Reduction in ping-pong effect in heterogeneous networks using fuzzy logic," *Soft Computing*, vol. 23, no. 1, pp. 269–283, 2019.
- [5] E. R. Bastidas-Puga *et al.*, "Handover based on a predictive approach of signal-to-interference-plus-noise ratio for heterogeneous cellular networks," *IET Communications*, vol. 13, no. 6, pp. 672–678, 2019.
- [6] G. Kaur, R. K. Goyal, and R. Mehta, "An efficient handover mechanism for 5g networks using hybridization of lstm and svm," *Multimedia Tools and Applications*, vol. 81, no. 26, pp. 37 057–37 085, 2022.
- [7] G. F. Riley and T. R. Henderson, "The ns-3 network simulator," in *Modeling and tools for network simulation*. Springer, 2010, pp. 15–34.
- [8] M. Abadi *et al.*, "{TensorFlow}: a system for {Large-Scale} machine learning," in *12th USENIX symposium on operating systems design and implementation (OSDI 16)*, 2016, pp. 265–283.
- [9] F. Chollet *et al.*, "Keras," 2015. [Online]. Available: <https://github.com/fchollet/keras>




Fig. 7. Média de RSRP por Algoritmo




Fig. 8. Número de Handovers e RLFs por algoritmo