

Handover Baseado em Aprendizado de Máquina para Redes LTE com Falhas de Cobertura

Ycaro Ravel Dantas, Tarciana C. de Brito Guerra, Vicente A. de Sousa Jr.

Resumo—A disponibilidade de informações de desempenho da rede LTE e a evolução na capacidade de processamento em tempo real de grandes volumes de dados têm proporcionado o surgimento de abordagens baseadas em aprendizado de máquina para o aprimoramento de funcionalidades clássicas, tal como o *handover*. Este trabalho propõe e analisa o desempenho de estratégias de *handover* baseadas em aprendizado de máquina que privilegiem a Qualidade de Serviço (QoS) dos usuários em um cenário de redes LTE em que eNBs específicas sofrem com falhas de cobertura, situação comum ao paradigma de estrutura celular hierárquica ou à chamada *Overlay Network Architecture*, no jargão de redes 5G. As soluções propostas trazem ganhos de QoS e são menos complexas que soluções existentes na literatura.

Palavras-Chave—*handover*, LTE, falhas de cobertura, aprendizado de máquina.

Abstract—The availability of information regarding the network's performance and the evolution of the capacity of big data's real time processing have enabled new approaches based on machine learning techniques to enhance classical features of mobile networks, like *handover*. This paper proposes and analyse the performance of *handover* strategies based on machine learning that privileges user's Quality of Service (QoS) in LTE networks where specific eNBs witness coverage holes, a common situation in hierarchical cell structures or the so called *Overlay Network Architecture*, regarding the 5G nomenclature. Our proposed solutions perform better than existing ones with reduced computational complexity.

Keywords—*handover*, LTE, coverage holes, machine learning.

I. INTRODUÇÃO

Diante da necessidade de atender à crescente demanda por largura de banda e cobertura universal para um grande número de dispositivos, novos paradigmas têm guiado o planejamento das redes de comunicações móveis atuais. Um deles é o *dense deployment*, que baseia-se na implementação maciça e contínua de estações base, separadas por distâncias muito inferiores às que costumavam ser usadas anteriormente. Outro é o *Hierarchical Cell Structure* (HCS), também denominado *Overlay Network Architecture* no jargão das redes 5G [1], que consiste na utilização de estações base com capacidades e tamanhos diversos (macro, micro, pico e femtocélulas), cujas áreas de cobertura se sobrepõem para melhor servir a uma demanda heterogênea de usuários em determinada área.

O surgimento de arquiteturas baseadas em tais paradigmas também traz novos desafios. Enquanto o planejamento de redes

O autor Ycaro Ravel Dantas está vinculado ao Sidia Instituto de Ciência e Tecnologia, Manaus, Brasil. E-mail: ycaro.d@samsung.com

Os autores Tarciana C. de Brito Guerra, Vicente A. de Sousa Jr. estão vinculados ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação (PPGEEC) da Universidade Federal do Rio Grande do Norte, Natal-RN, Brasil. E-mails: {tarcianabrito,vicente.sousa}@ufrn.edu.br.

As simulações de prova de conceito deste artigo foram realizadas graças ao Núcleo de Processamento de Alto Desempenho (NPAD/UFRN). Este trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

móveis tradicionais envolvia apenas o uso de macrocélulas e estações base localizadas acima do teto de casas e prédios, as redes atuais dependem cada vez mais de estações de menor alcance, posicionadas abaixo do topo das construções, muitas vezes implantadas pelos próprios usuários e que, portanto, estão mais sujeitas à atenuação por obstáculos [2]. Por conseguinte, são maiores as chances de que algumas das células sofram com falhas de cobertura em uma arquitetura HCS. Isso significa que um usuário pode estar conectado a uma célula em um momento e, no instante seguinte, adentrar em uma área de falha de cobertura, experimentando, conseqüentemente, uma queda brusca em sua Qualidade de Serviço (QoS, de *Quality of Service*).

Desta maneira, o cenário descrito habilita o *handover* como uma funcionalidade chave para a garantia de manutenção de alta QoS, fundamental em cenários como os de *Ultra Reliable Low Latency Communications* (URLLC) e *enhanced Mobile Broadband* (eMBB) das redes 5G. A razão para tal é que, se a técnica utilizada para esta funcionalidade levar em conta as células que fornecerão melhor QoS ao usuário no longo prazo, pode-se mitigar o problema previamente descrito fazendo com que se evite estações base que experimentam falhas de cobertura em um padrão de mobilidade conhecido. Todavia, em redes LTE os algoritmos tradicionais se baseiam apenas no nível de sinais de referência no momento do *handover*, descartando uma análise da QoS percebida após o processo. Diante do exposto e considerando o volume de dados coletados pelas redes LTE atuais, técnicas baseadas em aprendizado de máquina se apresentam como alternativas viáveis à abordagem tradicional de gerenciamento de mobilidade.

Para a implementação e posterior estudo de um cenário que reproduz o problema de falhas de cobertura anteriormente descrito, este artigo utiliza o *LTE-EPC Network Simulator* (LENA), módulo dedicado à simulação de redes LTE no ns-3 [3]. A partir do cenário proposto em [2], foi realizada uma coleta de dados para o treinamento e avaliação de novas estratégias de *handover* baseadas em aprendizado de máquina.

A. Trabalhos Relacionados

A implementação no ns-3 dos algoritmos de *handover* para redes LTE foi apresentada em [4], sendo todos eles baseados em regras estabelecidas nas especificações do sistema. Em [5], os desempenhos desses algoritmos clássicos em cenários HCS são comparados.

O aperfeiçoamento do processo de *handover* para melhoria do desempenho da rede é comumente delegado à concepção de novos algoritmos baseados nas regras pré-existentes, como apresentado em [6], ou ao ajuste dos parâmetros desses algoritmos, como em [7], que apresenta uma estratégia de otimização, ou em [8] e [9], que utilizam lógica fuzzy para encontrar a melhor configuração para os algoritmos.

Os trabalhos [10] e [11] avaliam a utilização de aprendizado de máquina nas redes 5G, apontando seu uso como algo estratégico, mas que deve ser feito com cautela. Já [12] apresenta uma perspectiva sobre a utilização de redes neurais artificiais para o melhoramento de diversas funcionalidades das redes de comunicação móvel. Em redes LTE, técnicas baseadas em aprendizado de máquina foram propostas para a otimização do escalonamento em [13] e do gerenciamento de *cache* em *small cells* em [14].

O *handover* é abordado, juntamente com o problema do balanceamento de carga, nas estratégias baseadas em aprendizado de máquina propostas em [15] e [16]. Por sua vez, os autores de [17] propõem a utilização de redes neurais para auxiliar o processo de *handover* vertical em redes heterogêneas, mas o *handover* entre células da mesma hierarquia não é analisado.

Em [2], propõe-se um cenário para a simulação de redes LTE com falhas de cobertura no ns-3. Foi implementado um algoritmo que permite a coleta de dados para avaliação offline de estratégias de *handover* baseadas em aprendizado de máquina. Já [18] utiliza o cenário proposto em [2] e sugere uma estratégia de *handover* baseada em aprendizado de máquina que apresenta resultados promissores. Todavia, a avaliação de desempenho contempla apenas uma estratégia com redes neurais e somente perda de propagação na modelagem do canal.

Utilizando o cenário proposto em [2], este trabalho implementa novas estratégias de *handover* baseadas em aprendizado de máquina, as testa sob condições de propagação mais hostis e realiza uma análise de desempenho abrangendo um algoritmo de *handover* clássico do LTE.

Este artigo está organizado como a seguir. A Seção II apresenta as estratégias clássicas de *handover* em redes LTE. A seção III detalha o funcionamento das estratégias de *handover* baseadas em aprendizado de máquina, incluindo as propostas neste artigo. Por sua vez, a seção IV descreve a modelagem do sistema, enquanto a V apresenta a análise dos resultados obtidos. A seção VI relata as considerações finais.

II. ESTRATÉGIAS DE HANDOVER EM REDES LTE

As estratégias de *handover* classicamente utilizadas em redes LTE são baseadas em eventos, que consistem no registro de uma ocorrência pré-definida, de acordo com o comportamento de um dado sinal de referência. O *Reference Signal Received Power* (RSRP), uma medida de potência do sinal, e o *Reference Signal Reference Quality* (RSRQ), uma medida de qualidade, são utilizados como sinais de referência para guiar o processo de *handover*. Para o *Release 8* do LTE, 5 eventos foram definidos para o *handover* entre células da mesma *Radio Access Technology* (RAT) [19]. Um algoritmo de *handover* pode utilizar um ou mais eventos e a configuração do algoritmo, estabelecida pela *Evolved Node B* (eNB), define o sinal de referência a ser empregado. O *User Equipment* (UE) irá monitorar os sinais de referência e reportar à eNB a ocorrência de eventos que gerem *handover*.

Os eventos utilizados nas simulações aqui retratadas são os seguintes: A2, que ocorre quando a célula atual se torna pior do que um limiar (*threshold*) pré-estabelecido; e o A4, que acontece quando o nível do sinal de referência de uma célula vizinha ultrapassa um limiar pré-configurado. Tanto o A2 como o A4 são usados pelo algoritmo

A2A4RsrpHandoverAlgorithm, que apresenta uma estratégia de *handover* clássica baseada exclusivamente em eventos. Tal algoritmo foi inicialmente proposto e implementado pelo trabalho [2], e, como sugerido pela nomenclatura, é configurado para usar o sinal RSRP. Ele se distingue dos demais algoritmos de *handover* presentes no ns-3 por poder ser usado de maneira determinística, razão pela qual é essencial para este trabalho.

Ao configurar o limiar do evento A4 como 1 (na escala definida por [19]), possibilitando que qualquer célula vizinha o atenda, e ao atribuir um identificador de célula ao atributo *targetCell*, escolhe-se, previamente à simulação, a célula à qual o UE irá se conectar durante o processo de *handover*. Caso o valor do *targetCell* seja definido como -1, o algoritmo decidirá pela célula vizinha com maior RSRP. Esta abordagem possibilita a análise *offline* de técnicas de *handover* baseadas em aprendizado de máquina, já que permite o armazenamento das métricas de QoS resultantes de todas as opções de conexão possíveis, desde que sejam simuladas controlando-se o *targetCell*, viabilizando que tais máquinas aprendam com os resultados de suas próprias escolhas. Cabe ressaltar que, apesar de a célula alvo poder ser pré-definida, a decisão sobre o momento do *handover* continua delegada ao evento A2.

III. ESTRATÉGIAS DE *handover* BASEADAS EM APRENDIZADO DE MÁQUINA

O objetivo das estratégias de *handover* baseadas em aprendizado de máquina aqui abordadas é determinar a célula vizinha que forneça melhor QoS ao usuário. A utilização dessas estratégias é relevante em cenários para os quais a magnitude dos sinais de referência no momento do *handover* não fornece um bom indicativo da célula que proverá a melhor QoS a longo prazo, como nos casos em que há falhas de cobertura.

Para analisar a eficácia de tais estratégias, considerou-se um cenário no qual o usuário realiza download de um arquivo de tamanho fixo enquanto se move e demanda a execução do *handover*. Tal cenário foi implementado em [2], utilizado em [18] e melhor descrito na Seção IV. Três métricas de QoS são utilizadas: percentual de downloads completos, tempo de download e número de bytes recebidos. As métricas permitem estabelecer um conjunto de regras para a definição da melhor célula *target*:

- Regra 1: a melhor *target* é aquela para qual o download é completado;
- Regra 2A: se mais de uma *target* completa o download, a melhor é aquela para qual o tempo de download é menor;
- Regra 2B: se nenhuma das *targets* completa o download, a melhor é aquela para qual o número de bytes recebidos é maior (oferece melhor vazão).

As duas primeiras regras são baseadas em [18]. A terceira regra é proposta aqui para a avaliação de cenários com condições de propagação mais hostis.

Três estratégias de *handover* baseadas em técnicas de aprendizado de máquina serão abordadas neste trabalho. A primeira delas, cuja estrutura encontra-se na Fig. 1, consiste na modificação do que foi proposto em [18] para a inserção do nível 2B, de modo a implementar a terceira métrica de QoS. Em cada nível, uma rede neural é dedicada a prever o resultado da métrica de QoS correspondente em cada célula *target*. Os resultados das redes são comparados para determinar a célula

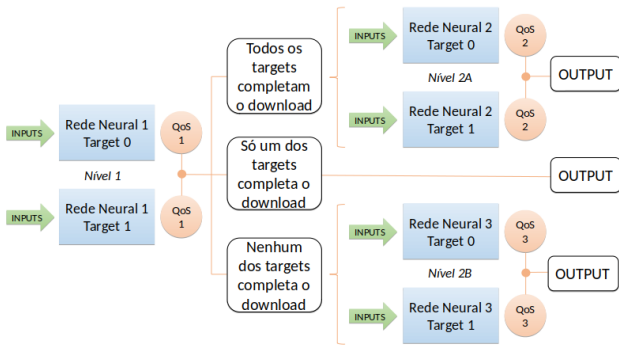


Fig. 1. Estrutura das máquinas de aprendizado usadas nas Estratégias 1 e 2. mais adequada, seguindo os critérios estabelecidos pelas regras homônimas de cada nível.

No primeiro nível, uma rede neural é utilizada para prever se o download é finalizado em cada uma das possíveis eNBs *targets*. Caso a previsão indique que a transferência será concluída em apenas uma delas, a máquina de aprendizado escolherá a eNB que proporcione esse resultado. Caso a conclusão do download seja esperada em todas as eNBs, o nível 2A definirá como *target* a eNB cujo tempo de download previsto é menor. Caso nenhuma das candidatas a *target* indique que completará o download, o nível 2B, que tem como saída a terceira métrica de QoS, escolherá a eNB para qual a previsão do número de bytes recebidos é maior. São utilizados como *inputs* o RSRP e RSRQ do usuário em relação a todas as células do cenário, incluindo a célula de origem, no momento do *handover* e no *report* anterior ao mesmo.

Enquanto a primeira estratégia utiliza como *inputs* os sinais de referência de todas as eNBs do cenário, a segunda utiliza apenas os sinais de referência correspondentes à eNB *target* que está sendo avaliada. Isto é, para o treinamento de uma rede referente à *target* 0, por exemplo, apenas os sinais de referência do UE em relação a essa eNB *target* são considerados, assim como a métrica de QoS do nível correspondente.

Além de refletir uma etapa comum à construção de máquinas de aprendizado, a de seleção de características, a segunda estratégia possui uma vantagem prática: se o treinamento de cada rede neural depender apenas dos sinais de referência da eNB a que se refere, a introdução de novas eNBs em um cenário (comum em um ambiente de *dense deployment*) não invalida os dados coletados anteriormente, sendo esta estratégia, portanto, mais facilmente escalável. Na primeira estratégia, a introdução de novas eNBs demanda a alteração do número de *inputs* nas redes já existentes, consequentemente exigindo o seu retreinamento, e a inserção de novos ramos na estrutura. Na segunda, apenas a introdução de novos ramos é suficiente quando novas eNBs aparecem.

A terceira estratégia, mostrada na Fig. 2, consiste na utilização de apenas uma rede neural. Nela, novamente são utilizados como *inputs* os sinais de referência para todas as eNBs do cenário. A rede neural retorna diretamente a melhor eNB *target* prevista. Assim, seu treinamento exige que se rotule os exemplos de entrada com a eNB *target* mais adequada de acordo com as regras definidas no início desta seção. Apesar de ser menos escalável que as demais, já que a inserção de novas *targets* exigiria não só a modificação do número de *inputs* como do número de *outputs*, ela possui a vantagem de ser mais simples e demandar menos esforço computacional pelo fato de usar apenas uma rede neural.



Fig. 2. Estrutura das máquinas de aprendizado usadas na Estratégia 3.

As redes das três estratégias são treinadas a partir dos dados (*inputs*) de RSRP e RSRQ medidos pelo UE no momento em que o *handover* é requisitado e na medição imediatamente anterior. Para viabilizar o treinamento, os dados são rotulados de acordo com a métrica de QoS que se deseja estimar ou com a *target* eNB a ser escolhida (*outputs*), para o caso da Estratégia 3. Esses dados representam o conhecimento da rede sobre sua experiência passada.

As estratégias avaliadas não determinam quando o *handover* será realizado, já que se baseiam em sinais de referência coletados no momento da ativação de um evento (neste caso, do evento A2), mas permitem otimizar a escolha da eNB *target*. Por essa razão, são adequadas à utilização em conjunto com *A2A4RsrpHandoverAlgorithm*.

IV. MODELAGEM DO SISTEMA E CONFIGURAÇÃO DAS MÁQUINAS DE APRENDIZADO

As simulações foram conduzidas na versão 3.22 do ns-3, a partir do código fornecido em [2]. Dois cenários foram avaliados. No primeiro, apenas a perda de propagação é considerada como desvanecimento de larga escala. Ela é implementada pelo modelo *OkumuraHataPropagationLossModel* do ns-3. No segundo, além da perda de propagação, também se considera o efeito do sombreamento e se utiliza a função *OhBuildingsPropagationLossModel* e o parâmetro *ShadowSigmaOutdoor* do ns-3.

A configuração dos cenários envolve três eNBs, três UEs e um obstáculo próximo à eNB 2, como detalhado na Fig. 3. Cada UE é posicionado ao lado de uma eNB no início da simulação. Os UEs 2 e 3 não possuem mobilidade. O UE 1 irá se mover a uma velocidade de 60 km/h em linha reta, com um ângulo sorteado entre -60° e 30° . Cada nova simulação sorteará um novo ângulo, e o movimento fará com que o UE 1 se afaste da eNB 1 e entre na área de cobertura das eNBs 2 e 3, realizando *handover*.

Os ângulos sorteados compõem três regiões. A região superior é coberta pela eNB 3 e não sofre com falhas de cobertura. A região inferior é coberta pela eNB 2 e também não sofre com falhas de cobertura. A região central, todavia, será a mais afetada, pois, mesmo estando mais próxima da

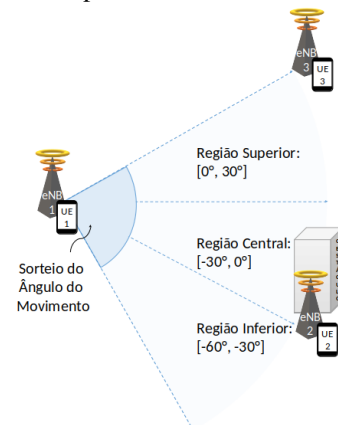


Fig. 3. Configuração do cenário de teste da rede LTE.

eNB 2, tem o sinal dessa eNB obstruído pelo obstáculo. Enquanto o UE que adentra tal região tende a experimentar melhores níveis de RSRP e RSRQ da eNB 2 em relação à eNB 3 no momento do *handover*, ele poderá encontrar a área de falha de cobertura da eNB 2 logo em seguida.

Ao considerar somente perda de percurso como manifestação do canal, percebe-se que as regiões superior e inferior possuem eNBs *targets* preferenciais, de fácil decisão no momento do *handover*, enquanto a região central demanda um conhecimento da QoS percebida a longo prazo para que se defina a célula mais promissora. Assim, o cenário reproduz o problema exposto na Seção I. Um cenário mais desafiador é encontrado ao modelar o canal incluindo o sombreamento, cuja característica aleatória pode ter forte impacto nos sinais de referência que assistem o processo de *handover*. Seu efeito não é considerado nos cenários utilizados em [2] e [18]. A validação nesse cenário, assim como a proposição das estratégias 2 e 3 apresentadas acima, materializam algumas das contribuições deste artigo.

Os parâmetros das campanhas de simulação estão detalhados na Tabela I. Um total de 1232 sementes do gerador de números aleatórios foi utilizado em cada um dos cenários. Para cada semente, um novo ângulo para o trajeto do UE 1 é sorteado. Em cada cenário, foram realizadas duas campanhas de simulações para estimar o resultado de *A2A4RsrpHandoverAlgorithm* com as eNBs 2 ou 3 como *targetCell*. Os resultados foram usados para o treinamento e teste das estratégias de *handover* baseadas em aprendizado de máquina já apresentadas. Com os resultados em mãos, também pode-se avaliar o comportamento natural de *A2A4RsrpHandoverAlgorithm*, que, em condições não determinísticas, decidiria pela célula com melhor RSRP no momento do *handover*.

Para a construção das máquinas de aprendizado utilizou-se a versão 0.18.1 da biblioteca *Scikit-Learn* para Python 3.6. Ela permitiu a implementação de redes perceptron de múltiplas camadas (MLP, de *Multi-layer Perceptron*) por meio das funções *MLPClassifier* e *MLPRegressor*. A biblioteca também forneceu os métodos de pré-processamento dos dados e de seleção de modelos.

A arquitetura das redes neurais utilizadas neste trabalho, que foi determinada de forma empírica, possui 3 camadas, sendo 24, 12 e 4, respectivamente, o número de neurônios em cada uma delas. A função de ativação selecionada foi a tangente hiperbólica ($f(x) = \tanh(x)$). Já o *solver*, que se refere à

TABELA I

PARÂMETROS DE SIMULAÇÃO BASEADOS EM [2].

Parâmetro	Valor
Largura de banda do sistema	5 MHz
Distância entre eNBs	500 m
Modelo de erro e Adaptação de Enlace	MiErrorModel
Área simulada	2000x2000m ²
Número de macro eNBs	3
Potência de transmissão das eNBs	46 dBm
Número de UEs	3
Velocidade do UE 1	60 km/h
Modelo de perda de propagação	Okumura-Hata
Sombreamento	Cenário 1: Sem sombreamento Cenário 2: Lognormal 8 dB
Altura das eNBs	30 m
Altura do obstáculo	35 m
Tráfego oferecido	Bulk File Transfer (FTP)
Tamanho do arquivo	15 MB
Tempo de simulação	100 seg

função de ajuste dos pesos, foi configurado como *lbfgs*, que remete ao algoritmo Broyden–Fletcher–Goldfarb–Shannon. O parâmetro *alpha*, termo de regularização usado para evitar o *overfitting*, foi configurado como 0,0005, e o número máximo de iterações foi fixado em 1000. Para os demais parâmetros, foram mantidos os valores padrão das funções.

Os dados das simulações foram divididos pela função *train_test_split*, sendo 80% destinados ao conjunto de treinamento das redes e 20% ao de testes. Além disso, todas as *features* tiveram suas escalas padronizadas pela função *StandardScaler* (distribuição centrada em 0 e desvio padrão igual a 1). Já os valores dos parâmetros de configuração dos algoritmos clássicos de *handover* foram mantidos como o padrão, conforme apresentado em [2] e [4].

V. ANÁLISE DE RESULTADOS

A correlação entre os *inputs* e a melhor célula *target* é mostrada para os Cenários 1 e 2 nas Figs. 4 e 5, respectivamente. Percebe-se que a inserção do sombreamento, além de configurar um cenário distinto pelas condições de propagação, caracteriza um novo desafio ao treinamento das redes, tendo em vista o baixo nível de correlação entre as variáveis utilizadas, quando comparado ao do Cenário 1.

Para ganhar confiança estatística nos resultados, apesar da aleatoriedade presente nas funções *MLPClassifier* e *MLPRegressor* (inicialização aleatória dos pesos das redes neurais) e no método *train_test_split* (diferentes divisões das simulações entre os conjuntos de treino e testes), foram realizadas 1000 execuções de todas as estratégias, cada uma utilizando uma semente de aleatoriedade do (*random_state*) diferente.

Os quesitos avaliados são: o percentual de acertos em relação à melhor escolha, o percentual de downloads completos, a vazão e o tempo médio de downloads para cada conjunto de testes, sendo este último contabilizado apenas para os casos em que a transferência do arquivo foi completada.

Os resultados dos cenários 1 e 2 estão expostos na Tabela II. No Cenário 1, pode-se perceber que as novas estratégias tiveram desempenho superior ao do algoritmo clássico, demonstrando sua capacidade de prever a QoS do usuário devido à análise de experiências anteriores. A utilização de qualquer uma das três no lugar de *A2A4RsrpHandoverAlgorithm* permite um aumento superior a 10% no percentual de downloads completos e na vazão média.




Fig. 4. Mapa de correlação entre as *features* e a melhor célula *target* para o cenário sem sombreamento.




Fig. 5. Mapa de correlação entre as *features* e a melhor célula *target* para o cenário com sombreamento.

TABELA II
RESULTADOS.

	Cenário 1 (sem sombreamento)				Cenário 2 (com sombreamento)			
	A2A4 RSRP	Est. 1	Est. 2	Est. 3	A2A4 RSRP	Est. 1	Est. 2	Est. 3
Acertos (%)	75,71	99,50	99,56	99,67	57,73	78,53	76,45	86,45
Downloads completos (%)	88,39	99,86	99,86	99,81	47,90	61,64	61,72	60,32
Vazão média (Mbps)	2,84	3,16	3,16	3,16	1,93	2,31	2,31	2,29
T. de download médio (s)	41,53	39,90	39,89	39,88	39,42	38,92	39,07	38,61

Além disso, o aumento da vazão gera uma queda no tempo médio de download.

Já o Cenário 2, cujos resultados também podem ser vistos na Tabela II, o sombreamento modela o aspecto aleatório da propagação, gerando um ambiente mais hostil, no qual as três métricas de QoS são prejudicadas. Nessas condições, em todas as estratégias, pode-se perceber que o percentual de acertos é inferior ao de downloads completos, o que permite inferir que, em muitos casos, nenhuma eNB *target* é capaz de finalizar o download.

Entretanto, mesmo em condições adversas, há uma clara vantagem, assim como no caso anterior, das estratégias baseadas em aprendizado de máquina sobre o algoritmo clássico, que não atinge sequer o patamar de 50% de downloads completos. Não obstante, é possível perceber que as máquinas têm mais dificuldade em realizar previsões concretas devido ao efeito randômico do sombreamento, de forma que apenas a Estratégia 3 consegue um nível médio de acertos acima de 80%.

VI. CONCLUSÕES

Este trabalho propõe e avalia o desempenho de estratégias de *handover* baseadas em aprendizado de máquina frente a estratégias convencionais utilizadas em redes LTE. A configuração escolhida para os cenários, em que uma das células experimenta falha de cobertura, consiste em um caso relevante, cada vez mais presente nas redes modernas e no qual os algoritmos tradicionais podem ter um desempenho abaixo do esperado. Observou-se que as estratégias baseadas em aprendizado de máquina melhoraram a QoS do usuário. As abordagens propostas (Estratégias 2 e 3) se mostraram boas concorrentes para as utilizadas no mesmo cenário por [18], mantendo desempenho similar ou superior e com redução de complexidade e aumento da escalabilidade. Também foi

possível observar os desafios impostos às técnicas escolhidas ao se considerar o efeito do sombreamento. Os indicadores de QoS utilizados aqui permitiram validar as estratégias apresentadas e podem ser substituídos de acordo com o propósito do cenário e o que se deseja otimizar. Assim, as técnicas atendem ao requisito de customização para cenários específicos das redes 5G. Mantendo a estrutura das máquinas, pode-se utilizar, por exemplo, a latência como uma métrica em cenários URLLC ou a vazão em cenários eMBB. A continuação deste trabalho envolve tanto a concepção de novas estratégias baseadas em outras técnicas de aprendizado de máquina, como a utilização das estratégias propostas em cenários mais complexos.

REFERÊNCIAS

- [1] ITU-R, "Report ITU-R m.2376-0 - technical feasibility of IMT in bands above 6 GHz," ITU, Tech. Rep., 2015.
- [2] Z. Ali, N. Baldo, J. Mangues-Bafalluy, and L. Giupponio, "Simulating LTE mobility management in presence of coverage holes with ns-3," *Simulation Tools and Techniques (SIMUTOOLS)*, 2015.
- [3] ns-3. (2018) ns-3 website (<http://code.nsnam.org/>). [Online]. Available: <http://code.nsnam.org/>
- [4] B. Herman, N. Baldo, M. Miozzo, M. Requena, and J. Ferragut, "Extensions to LTE mobility functions for ns-3," *Proceedings of the 2014 Workshop on ns-3*, 2014.
- [5] T. C. B. Guerra, Y. R. Dantas, and V. A. Sousa, "Performance analysis of handover strategies in the 3gpp small cell scenario," *The 2017 International Conference On Computational Science And Computational Intelligence (CSCI-ISMCI)*, 2017.
- [6] M. Thakkar, L. Agrawal, A. Rangiseti, and B. Tamma, "Reducing ping-pong handovers in LTE by using ai-based measurements," *Twenty-third National Conference on Communications (NCC)*, 2017.
- [7] H. Ferng and Y. Huang, "Handover scheme with enode-b pre-selection and parameter self-optimization for LTE-A heterogeneous networks," *International Conference on Machine Learning and Cybernetics*, 2016.
- [8] E. Cardoso, K. Silva, and R. Francés, "Intelligent handover procedure for heterogeneous LTE networks using fuzzy logic," *13th International Wireless Communications and Mobile Computing Conference*, 2017.
- [9] M. Saeed, M. El-Ghoneimy, and H. Kamal, "An enhanced fuzzy logic optimization technique based on user mobility for LTE handover," *34th National Radio Science Conference (NRSC)*, 2017.
- [10] T. Buda, H. Assem, L. Xu, D. Raz, U. Margolin, E. Rosensweig, D. Lopez, M. Corici, M. Smirnov, R. Mullins, and O. Uryupina, "Can machine learning aid in delivering new use cases and scenarios in 5G?" *1st International Workshop on Management of 5G Networks (5GMan)*, 2016.
- [11] C. Jiang, H. Zhang, Y. Ren, Z. Han, K. Chen, and L. Hanzo, "Machine learning paradigms for next-generation wireless networks," *IEEE Wireless Communications*, 2017, 24(2), pp.98-105.
- [12] M. Chen, U. Challita, W. Saad, C. Yin, and M. Debbah, "Machine learning for wireless networks with artificial intelligence: A tutorial on neural networks," 2017, arXiv:1710.02913.
- [13] J. Sue, R. Hasholzner, J. Brendel, M. Kleinstueber, and J. Teich, "A binary time series model of LTE scheduling for machine learning prediction," *1st International Workshops on Foundations and Applications of Self* Systems*, 2016.
- [14] G. Shen, L. Pei, P. Zhiwen, L. Nan, and Y. Xiaohu, "Machine learning based small cell cache strategy for ultra dense networks," in *2017 9th International Conference on Wireless Communications and Signal Processing (WCSP)*, Oct 2017, pp. 1–6.
- [15] S. S. Mwanje, L. C. Schmelz, and A. Mitschele-Thiel, "Cognitive cellular networks: A q-learning framework for self-organizing networks," *IEEE Transactions on Network and Service Management*, 2016.
- [16] P. Semov, P. Koleva, K. Tonchev, V. Poulkov, and A. Mihovska, "Autonomous learning model for achieving multi cell load balancing capabilities in hetnet," *International Black Sea Conference on Communications and Networking (BlackSeaCom)*, 2016.
- [17] N. M. Alotaibi and S. S. Alwakeel, "A neural network based handover management strategy for heterogeneous networks," *14th International Conference on Machine Learning and Applications (ICMLA)*, 2015.
- [18] Z. Ali, N. Baldo, J. Mangues-Bafalluy, and L. Giupponio, "Machine learning based handover management for improved qoe in LTE," *Network Operations and Management Symposium (NOMS)*, 2016.
- [19] 3GPP, *3GPP TS 36.133: Evolved Universal Terrestrial Radio Access (E-UTRA); Requirements for support of radio resource management*, The 3rd Generation Partnership Project Std., 2009.