



# APLICAÇÃO DE UMA REDE NEURAL TEMPORAL PARA A PREDIÇÃO DO COMPORTAMENTO DE CANAL EM REDES 5G

Patrick Luiz de Araújo\*<sup>1</sup> e Éderson Rosa da Silva†<sup>1</sup>

<sup>1</sup>FEELT - Universidade Federal de Uberlândia

**Resumo** - Um parâmetro que passa a ser particularmente importante no dimensionamento das novas redes móveis é o estado do canal de comunicação, principalmente ao se considerar as frequências propostas para as redes 5G, o número crescente de dispositivos conectados e a necessidade de alocar recursos de forma eficiente. Para dimensionar os efeitos do canal, a *Base Station (BS)* recebe do *User Equipment (UE)* uma medição da qualidade do canal, chamada *Channel Quality Information/Indicator (CQI)*, a partir da qual faz o escalonamento dos recursos para melhor atender os usuários. O estudo aqui desenvolvido visa gerar uma base de dados confiável de um fluxo de *CQI* ao longo de uma transmissão em uma rede móvel *LTE-A* com alguns parâmetros da *Release 15* das *Technical Specification (TS)* do 3GPP para o 5G. Após isso, propõe-se a modelagem do problema por meio do *Machine Learning* para prever o *CQI* ao longo de uma transmissão. Por fim, avalia-se a confiabilidade da proposta, comparando os valores preditos pelo sistema e os reais.

**Palavras-Chave**- 5G. 3GPP. CQI. Machine Learning. Redes móveis.

## CHANNEL BEHAVIOR STUDY IN 5G NETWORKS: A PREDICTIVE ANALYTICS

**Abstract** - A parameter that becomes particularly important in the design of new mobile networks is the state of the communication channel, especially considering the proposed frequencies for 5G networks, the increasing number of connected devices and the need to allocate resources efficiently. To scale channel effects, Base Station (BS) receives from User Equipment (UE) a channel quality measurement, called Channel Quality Information / Indicator (CQI), from which it scales resources to best meet users. The study developed here aims to generate a reliable database of a CQI stream over a transmission over an LTE-A mobile network with some 3GPP Technical Specification (TS) Release 15 parameters for 5G. After that, it is proposed to model the problem using Machine Learning to predict CQI over a transmission. Finally, the reliability of the proposal is evaluated by comparing the predicted

values by the system and the real ones.

**Keywords** -5G. 3GPP. CQI. Machine Learning. Mobile Network.

### NOMENCLATURA

*ACR* Average Difference Ratio.

*BS* Base Station.

*CFI* Control Format Indicator.

*CQI* Channel Quality Information/Indicator.

*LSTM* Long Short-Term Memory.

*LTE - A* Long Term Evolution Advanced.

*MCS* Modulation and Coding Scheme.

*ML* Machine Learning.

*OCEAN* Online CSI prEdiction scheme for 5G wireless communicationNs.

*RB* Resource Block.

*RNN* Recurrent Neural Network.

*SINR* Signal-to-interference-plus-noise ratio.

*TBS* Transport Block Size.

*TS* Technical Specification.

*UE* User Equipment.

## I. INTRODUÇÃO

Conforme visto na *TS 38.104* a nova geração de redes 5G vai operar em frequências que vão de 450 MHz a 52,6 GHz, apresentando, em canais com frequências de ordem superior, uma grande dependência da qualidade do canal e da magnitude dos sinais interferentes [1]. Para canais na faixa de 38 GHz mesmo janelas de vidro e muros são obstáculos que podem dificultar ou impossibilitar a comunicação [2].

Estes desafios são só parte dos problemas que serão enfrentados na implantação de redes móveis de última geração.

\*patrick@ufu.br

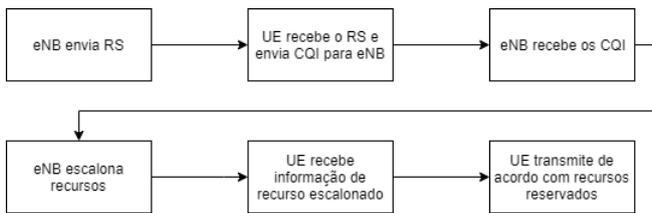
†ersilva@ufu.br

Conforme registrado em [3] no quarto trimestre de 2018 haviam 5,9 bilhões de dispositivos conectados, com 43 milhões de novos dispositivos conectados em rede no período. Neste contexto, espera-se um crescimento ainda maior do número de dispositivos, que irão demandar uma banda de frequência cada vez maior. Assim, a rede 5G deve ser pensada desde o início como uma infraestrutura robusta e que consiga atender dezenas de bilhões de dispositivos conectados.

Para administrar os recursos de rede no 5G, o escalonador está em execução na (BS). Este agente capta uma série de parâmetros da rede como qualidade do canal, banda requerida (por usuário e por aplicação), justiça, entre outros, e busca alocar a banda disponível da melhor forma possível.

A medida da qualidade do canal é um parâmetro importante que pode ser usado no escalonamento de recursos pela BS. O conceito da BS ter a sensibilidade e a percepção da qualidade do enlace entre ela e todos os UEs é chamada de *channel sensitivity* (sensitividade de canal), onde a ideia básica é saber o quão boa são as condições enfrentadas por cada nó da rede. Esta medição, similar a feita no 4G [4] é chamada de *Link Monitoring* (monitoramento de enlace) e considera outros parâmetros do canal, chamados de *Channel State Information* (CSI). O esquema de medição da qualidade do canal pode ser visto na figura 1.

Figura 1: Diagrama do escalonamento de recursos.



Neste contexto, dado que grande parte das interferências de canal são de ordem pseudo-aleatória e com um curto intervalo de tempo, os CSI usados no escalonamento podem estar desatualizados, podendo haver perda de desempenho do escalonador.

Para superar esta barreira, a *Signal-to-interference-plus-noise ratio* (SINR) (que interfere diretamente nos CSI) deve ser analisada ao longo de uma comunicação a partir do CQI reportado. Esta medição é feita comparando o *Reference Signal* (RS), um sinal enviado pelo eNB (e que é conhecido pelos 2 lados do enlace), com o sinal de fato recebido pelo UE.

Com uma base de dados suficientemente grande (com o registro do CQI ao longo do tempo), pode-se avaliar a implementação de um algoritmo preditivo para estimar a qualidade do canal em momentos futuros ao envio do CQI, podendo ser utilizado para um escalonamento mais eficiente.

Para usar esta periodicidade dos eventos como vantagem, redes de *Machine Learning* (ML) são grandes aliadas e já são usadas em diversas áreas de análise de dados com implementações de sucesso em áreas como previsão de demanda de tráfego em redes móveis [5], [6].

Em [7] está documentado o uso de ML para otimizar o processo de roteamento nas redes. Outro caso de sucesso documentado similar ao explorado aqui está descrito em [5], onde a

qualidade do canal é prevista por uma rede neural e testada de forma prática. Com estas hipóteses comprovadas, propõe-se o treinamento de uma *Recurrent Neural Network* (RNN) com células *Long Short-Term Memory* (LSTM) para avaliar o CQI temporalmente, na tentativa de desenvolver um modelo preditivo para a variável.

A célula LSTM possui aplicações que vão desde reconhecimento de imagem e padrões até tradução de textos, sendo aplicáveis ao desafio proposto também, devido a sua capacidade de lidar com séries temporais de dados.

Para realizar a implementação do modelo, foi escolhida a linguagem Python e a biblioteca TensorFlow, visto que são um sistema bastante popular e com uma boa documentação para consulta.

## II. CORPO

### A. Simulação do parâmetro de CQI na rede LTE-A

Todo a modelagem foi configurada de forma a aproximar a simulação da rede *Long Term Evolution Advanced* (LTE-A) ao máximo de uma transmissão de alta taxa (tal qual o 5G), sendo os principais valores apresentados na tabela 1.

Tabela 1: Parâmetros de simulação usados.

Parâmetro	Valor atribuído
SNR	6 dB
RMC	R.3
CFI	2
Número de antenas receptoras	4
Delay	Modelo EPA
Frequência de Doppler	5 Hz
Correlação de antenas	High
Modelo de desvanecimento	GMEDS
Estimador de canal	Modelo imperfeito
Delay do CQI	8 subframes

Após toda a configuração inicial, a simulação é iniciada. O CQI reportado possui as seguintes características:

1. O CQI é reportado a cada 2 subframes;
2. O CQI reportado está com um atraso de 8ms (ou 8 subframes, já que o frame é de 1ms).

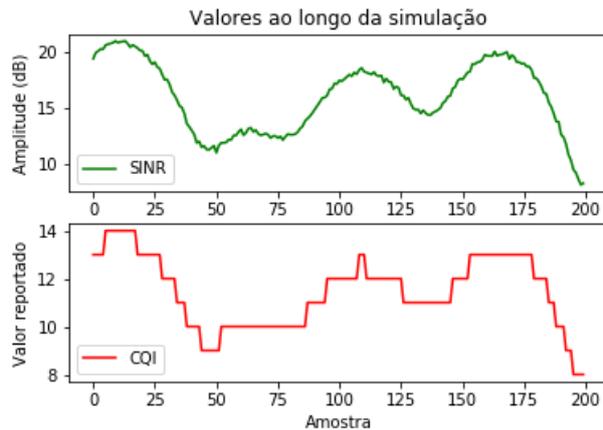
Num segundo momento é calculado o valor médio do CQI e o processamento do mesmo é feito da seguinte forma:

1. O CQI lido é enviado ao buffer (quando recebido) e uma média é calculada (no subframe em que não é recebido);
2. O mesmo CQI recebido é usado para o cálculo do *Modulation and Coding Scheme* (MCS) da transmissão;
3. O MCS é reportado com a finalidade de calcular o *Transport Block Size* (TBS) e os *Resource Block* (RB)s são calculados;
4. Com os TBs a forma de onda do *Transport Block* (TB) é calculada;
5. A forma de onda do TB recebe um ruído AWGN;
6. O sinal a ser enviado é transmitido pelo UE e o processo se reinicia.

Um outro parâmetro que foi variado foram os *seeds* da simulação. Foram usados os *seeds* 7, 8, 9 e 10 para gerar uma variabilidade maior nos valores reportados pela simulação.

De forma geral gera-se 12500 amostras com o resultado do valor do *CQI* e do *SINR* (para cada *seed*), entretanto, para facilitar a visualização, apresenta-se os valores do *CQI* e do *SINR* em um intervalo de tempo selecionado conforme visto na Figura 2.

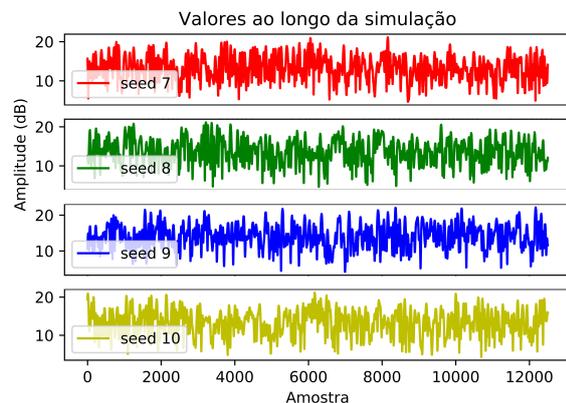
Figura 2: *SINR* e *CQI* obtidos ao longo de um intervalo de tempo selecionado.



Como pode ser visto, o *CQI* acompanha o comportamento da *SINR* do canal, já que é um reflexo direto desta ao longo do tempo. Enquanto a *SINR* varia entre 5dB e 20dB, o *CQI* varia entre aproximadamente 6 e 15.

Após realizar as simulações da geração da base de dados no Matlab variando os *seeds*, os resultados para o *SINR* podem ser vistos na figura 3.

Figura 3: *SINR* para diferentes *seeds*.



De uma forma geral, o comportamento dos resultados variando os *seeds* de simulação apresentam pequenas variações nos valores. As curvas ainda apresentam uma tendência senoidal, com certa periodicidade nas variações.

Para uma melhor avaliação do montante total dos resultados, uma análise estatística pode ser vista na Tabela 2.

Tabela 2: Análise estatística dos resultados para diferentes *seeds*.

Seed	Métrica	Média	Desvio	Mínimo	25%	50%	75%	Máximo
7	CQI	10,401	1,4271	6,0	9,0	10,0	11,0	14,0
	SINR	13,353	2,9282	4,6396	11,351	13,381	15,527	21,1
8	CQI	10,401	1,4271	6,0	9,0	10,0	11,0	14,0
	SINR	13,751	2,9426	4,6377	11,744	13,78	15,94	21,114
9	CQI	10,617	1,4968	6,0	10,0	11,0	12,0	14,0
	SINR	14,222	3,0829	4,1707	12,130	14,240	16,451	22,13
10	CQI	10,267	1,4834	6,0	9,0	10,0	11,0	14,0
	SINR	13,474	3,0798	4,3084	11,309	13,719	15,725	21,214

Conforme visto, os *seeds* 7 e 8 apresentam parâmetros similares, enquanto os demais apresentam alguma variação entre si. Outro fato a se destacar é que os primeiro, segundo e terceiro quartis foram os mesmos para o *CQI* com os *seeds* 7, 8 e 10.

Os valores de média ficaram em torno de 10 para o *CQI* em todos os *seeds*, enquanto a *SINR* teve um valor médio em torno de 13, exceto para o *seed*=9.

### B. Construção da rede neural

Após a obtenção de uma base de dados confiável, é possível iniciar o treinamento da rede para a construção e teste da rede neural usada. Todas as execuções foram feitas no ambiente Google Colaboratory, uma ferramenta disponibilizada pela Google para a execução de redes neurais usando o Python, com ênfase na biblioteca TensorFlow. As vantagens do ambiente são a grande velocidade das máquinas alocadas e a gratuidade do serviço.

Os seguintes passos são tomados na construção da rede:

1. As bibliotecas que serão usadas são importadas;
2. Os dados em CSV são lidos e adaptados para serem usados na execução;
3. Os dados de *CQI* são divididos em uma base de treinamento da rede e outra de teste;
4. Os parâmetros da rede são configurados;
5. A base de treinamento é passada pela rede e a mesma é treinada;
6. Após treinada, a base de teste é processada pela rede e os valores preditos são gerados.

Os principais parâmetros da rede podem ser vistos na Tabela 3:

Tabela 3: Critérios usados na rede neural.

Parâmetro	Valor atribuído
Modelo de rede	Rede RNN com um único parâmetro temporal
Neuron	LSTM
Número de neurons	100
Ritmo de aprendizado	0,001
Número de iterações totais	8000
Tamanho do batch	100 valores
Condição de parada	A partir de 4000 iterações e erro quadrático médio abaixo de 0,0006

A arquitetura *RNN* foi usada por ser um sistema usado para a resolução de problemas com variáveis temporais. Os neurons *LSTM* foram testados para a obtenção dos melhores resultados, sendo usados em uma rede com 100 neurons.

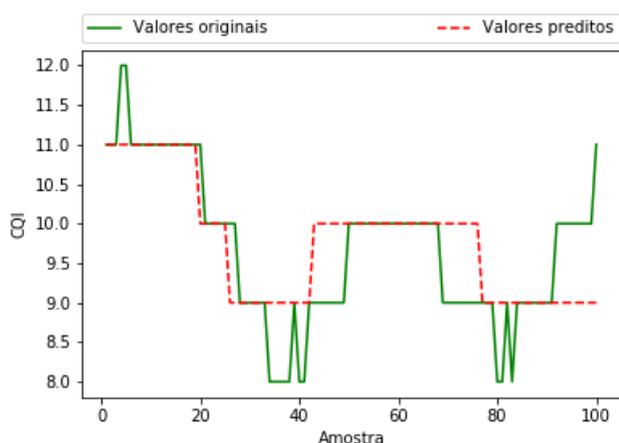
O ritmo de aprendizado ideal foi de 0,001, baseado em uma série de testes variando o ritmo de aprendizado e o número de iterações. Esta segunda variável, por sua vez, foi setada em 8000 para uma boa previsão e um *batch* (número de amostras processadas por vez) de 100 foi usado. Já a condição de parada da rede foi pensada para evitar o *overfitting* e o treinamento insuficiente da rede.

### C. Treinamento e avaliação das previsões

Após a divisão da base de dados gerada entre base de treinamento e base de teste (tendo sido usadas as últimas 200 amostras de cada *seed*) o processo de treinamento da rede pode ser feito diversas vezes, variando de forma sutil os parâmetros de velocidade de aprendizado e número de iterações para obter melhores resultados. Em último caso, recomenda-se, como foi feito, uma condição de parada dinâmica nas iterações.

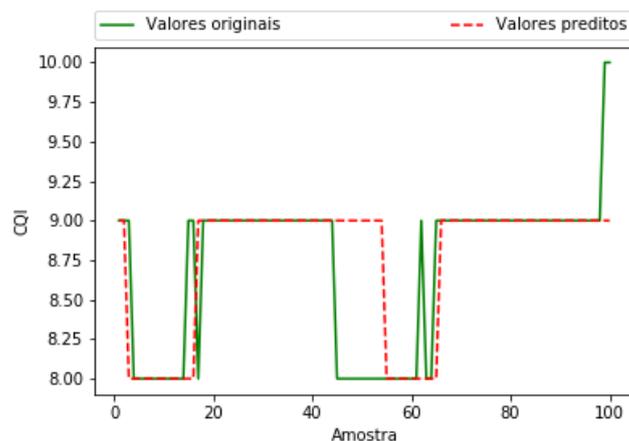
Para o *seed=7* uma rede com 61% de acerto foi obtida. A rede convergiu para um erro quadrático médio inferior a 0,0006 em torno de 5000 iterações. Os resultados finais de previsão podem ser vistos na figura 4

Figura 4: Teste de previsão para o *seed=7*.



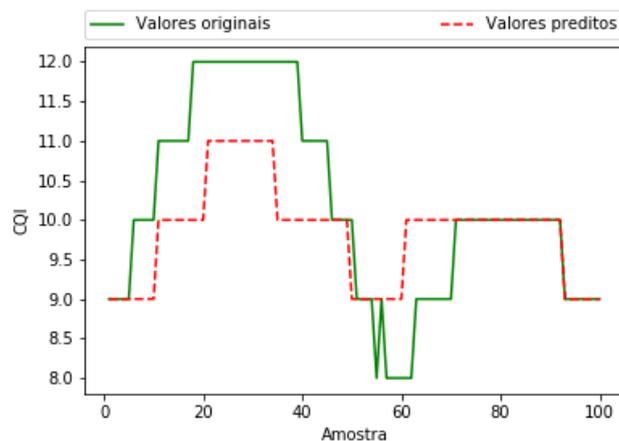
Para o *seed=8* uma rede com 82% de acerto foi obtida. A rede não convergiu para um erro quadrático médio inferior a 0,0006 e 8000 iterações foram processadas. Os resultados finais de previsão podem ser vistos na figura 5.

Figura 5: Teste de previsão para o *seed=8*.



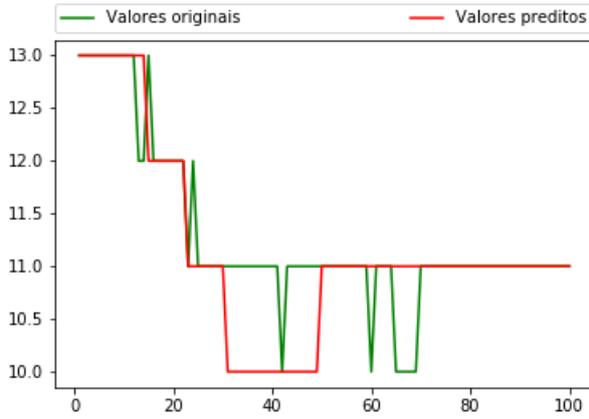
Para o *seed=9* uma rede com 44% de acerto foi obtida. A rede não convergiu para um erro quadrático médio inferior a 0,0006 e 8000 iterações foram processadas. Os resultados finais de previsão podem ser vistos na figura 6.

Figura 6: Teste de previsão para o *seed=9*.



Para o *seed=10* houve um índice de acerto de 76%, um valor bastante satisfatório para provar o conceito de previsão da qualidade do canal. Na Imagem 7 pode-se ver os resultados previstos e os valores originais, mostrando o bom desempenho geral da rede neural desenvolvida.

Figura 7: Valores reais e valores preditos para o  $seed=10$ .



#### D. Avaliação preliminar dos resultados

O desempenho do algoritmo proposto é sintetizado a partir da Tabela 4, em que a porcentagem de acerto é tabelada em função do  $seed$ .

Tabela 4: Resumo dos resultados obtidos.

Seed	Porcentagem de acerto do algoritmo
7	61
8	82
9	44
10	76
<b>Média</b>	<b>65,75</b>

Para uma comparação com [5] será avaliado o *Average Difference Ratio (ACR)*, dado pela Equação 1.

$$ACR = \frac{1}{T} \sum_{i=1}^T \frac{ValorPredito - ValorReal}{ValorReal} \quad (1)$$

Este parâmetro é particularmente importante na avaliação da predição pois, mesmo que o valor predito do  $CQI$  não seja numericamente igual ao valor real, eles podem estar próximos. Pode-se verificar a avaliação dos resultados em função do  $ACR$  na Tabela 5 a seguir.

Tabela 5: Valor dos  $ACR$  para os  $seeds$  simulados.

Seed	ACR
7	4,3560
8	2,1306
9	6,2957
10	4,4931

O algoritmo *Online CSI prEdiction scheme for 5G wireless communicAtions (OCEAN)* proposto em [5] apresentou um  $ACR$  médio entre 2,730% e 3,457%. Entretanto, a rede desenvolvida é muito mais complexa, levando em consideração uma série de parâmetros extras e com dois sistemas adicionais de *Convolutional Neural Networks*, mostrando que a aplicação inicial aqui proposta é promissora..

### III. CONCLUSÃO

A grande ideia explorada neste trabalho é a da viabilidade do uso de redes neurais em sistemas de redes móveis, dado que:

1. Alguns eventos em uma rede móvel são previsíveis (movimentação, variação do meio, etc);
2. A cada dia mais e mais aparelhos estarão na rede enviando uma quantidade cada vez maior de informações para a estação base, havendo uma base de dados gigante em potencial para ser explorada;
3. As redes de quinta geração serão totalmente virtualizadas, havendo a abertura para o desenvolvimento de uma série de subsistemas não previstos nas *releases* atualmente vistas;
4. O aumento do poder computacional dos nós na rede permite a implementação de algoritmos cada vez mais complexos.

Como foi abordado, ainda há uma série de desafios a serem vencidos nas redes de quinta geração, principalmente por causa da grande quantidade de usuários na rede e do aumento da demanda de tráfego. Muitos destes desafios poderão ser superados com a exploração de canais com frequência cada vez maiores e com o uso de técnicas como a densificação celular. Aliado a futura virtualização de infraestrutura, a idealização do uso de redes neurais nas redes 5G já é um objeto de estudo em várias frentes para solucionar os desafios da nova geração de redes celulares.

Conforme visto, a rede com os neurons *LSTM* apresentou um desempenho promissor para a previsão da qualidade do canal de comunicação. Apesar de um resultado médio de 65,75% de acerto obtido com a rede construída ser mediano, a análise a partir do  $ACR$  mostrou que a rede está com ótimos resultados, mesmo quando comparada a redes mais complexas como o algoritmo *OCEAN* [5].

Há a proposta de três novas linhas para o aprimoramento da ideia, sendo uma focada no melhoramento do modelo preditivo, uma visando a implementação prática e outra na implementação de redes de aprendizado por reforço.

A primeira ideia é a respeito do aprimoramento da rede, tanto no sentido de aprimorar a sua estrutura quanto a inclusão de novas variáveis para a análise. Conforme visto em [5], outras variáveis podem ser usadas para prever a qualidade do canal, como a frequência, temperatura, umidade do ar, horário do dia, etc.

A segunda ideia é a respeito da integração da técnica proposta com mecanismos de escalonamento de recursos que utilizam o  $CQI$  para tomada de decisões.

Extrapolando esta linha, pode-se pensar inclusive na implementação de redes de *Reinforcement Learning*, onde a rede é moldada em tempo real. Assim, com o passar do tempo, o sistema estaria continuamente sendo aprimorado e pronto para as mais diversas situações de mobilidade e qualidade do canal.

Comprovada a eficiência da caracterização e predição da qualidade do canal com redes neurais, um outro sistema poderia ser modelado na estação-base, no qual o  $CQI$  de diversos

dispositivos estaria sendo recebido em tempo real e, em função da localização relativa dos aparelhos em rede, a qualidade do canal poderia ser prevista para cada dispositivo.

## REFERÊNCIAS

- [1] 3RD GENERATION PARTNESHIP PROJECT. "Base Station (BS) radio transmission and reception. [S.l.]", 2018. Release 15. Disponível em: <<https://portal.3gpp.org/desktopmodules/Specifications/SpecificationDetails.aspx?specificationId=2412>>.
- [2] RAPPAPORT, T. S. et al. "Overview of millimeter wave communications for fifth-generation (5g) wireless networks-with a focus on propagation models". IEEE Transactions on Antennas and Propagation, IEEE, p. 97–111, 2017.
- [3] ERICSSON. "The Ericsson Mobility Report". [S.l.], 2019. Disponível em: <<https://www.ericsson.com/assets/local/mobility-report/documens/2019/emr-q4-update-2018.pdf>>.
- [4] HELIX, E. "5G physical layer specifications". 2017. Acessado pela última vez em 3 de abril de 2019. Disponível em: <<https://medium.com/5g-nr/5g-physical-layer-specifications-e025f8654981>>.
- [5] LUO, C. et al. "Channel state information prediction for 5g wireless communications: A deep learning approach". IEEE Tansactions on Network Science and Engineering, 2018.
- [6] SCIANCALEPORE, V. et al. "Mobile traffic forecasting for maximizing 5g network slicing resource utilization". IEEE Conference on Computer Communications, 2017.
- [7] KATO, N.; et al. "The deep learning vision for heterogeneous network traffic control: Proposal, challenges, and future perspective". IEEE Wireless Communications, 2017.

## DADOS BIOGRÁFICOS

**Patrick Luiz de Araújo**, nascido em 11/12/1996 em Uberlândia-MG, é graduando em engenharia de telecomunicações pela Universidade Federal de Uberlândia. Suas áreas de interesse são: Redes de Computadores, Redes Móveis e Machine Learning.

**Éderson Rosa da Silva**, possui graduação em Engenharia Elétrica pela Universidade Federal de Uberlândia (2007) e doutorado em Engenharia Elétrica pela Universidade Federal de Uberlândia (2010). Atualmente é professor adjunto da Universidade Federal de Uberlândia. Tem experiência na área de Engenharia Elétrica e Telecomunicações, com ênfase em redes de computadores, atuando principalmente nos seguintes temas: redes móveis sem fio, simulação e qualidade de serviço.