



**UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”
Faculdade de Engenharia e Ciências de Guaratinguetá**

PEDRO NUNES LOPES NETO

**Desenvolvimento de um Sistema de Classificação e Diagnóstico Automático de Células
em Redes de Telefonia Móvel de Quarta Geração**

Guaratinguetá - SP

2024

Pedro Nunes Lopes Neto

**Desenvolvimento de um Sistema de Classificação e Diagnóstico Automático de Células
em Redes de Telefonia Móvel de Quarta Geração**

Dissertação apresentada à Faculdade de Engenharia e Ciências do Campus de Guaratinguetá, Universidade Estadual Paulista, para obtenção do título de Mestre em Engenharia em Produção.

Orientador: Prof. Dr. Celso Eduardo Tuna
Coorientador: Prof. Dr. José Celso Freire Junior

Guaratinguetá - SP
2024

L864d	<p>Lopes Neto, Pedro Nunes</p> <p>Desenvolvimento de um sistema de classificação e diagnóstico automático de células em redes de telefonia móvel de quarta geração / Pedro Nunes Lopes Neto – Guaratinguetá, 2024.</p> <p>62 : il.</p> <p>Bibliografia: f. 58-62</p> <p>Dissertação – Universidade Estadual Paulista, Faculdade de Engenharia e Ciências de Guaratinguetá, 2024.</p> <p>Orientador: Prof. Dr. Celso Eduardo Tuna Coorientador: Prof. Dr. José Celso Freire Junior</p> <p>1. Processo decisório por critério múltiplo. 2. Aprendizado do computador. 3. Engenharia - Processamento de dados. 4. Inteligência artificial. I. Título.</p> <p style="text-align: right;">CDU 65.012.4(043)</p>
-------	--

Luciana Máximo
Bibliotecária CRB-8/3595

IMPACTO POTENCIAL DESTA PESQUISA

O trabalho inovador em gerenciamento de redes de celular 4G, com métodos de decisão multicritério e de machine learning, tem amplo impacto na sociedade, preenchendo lacunas acadêmicas e estimulando avanços científicos. Publicações internacionais fortalecem parcerias globais, enquanto a colaboração academia-indústria impulsiona empregos e desenvolvimento econômico.

POTENTIAL IMPACT OF THIS RESEARCH


The innovative work in 4G cellular network management, employing multi-criteria decision-making and machine learning methods, has a broad impact on society, filling academic gaps and driving scientific advancements. International publications strengthen global partnerships, while academia-industry collaboration boosts job creation and economic development.

Pedro Nunes Lopes Neto

**ESTA DISSERTAÇÃO FOI JULGADA ADEQUADA PARA A OBTENÇÃO DO TÍTULO DE
"MESTRE EM ENGENHARIA"**


**PROGRAMA: ENGENHARIA
CURSO: MESTRADO**

APROVADA EM SUA FORMA FINAL PELO PROGRAMA DE PÓS-GRADUAÇÃO


 Documento assinado digitalmente
MANOEL CLEBER DE SAMPAIO ALVES
Data: 16/02/2024 09:07:57-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Manoel Cléber de Sampaio Alves
Coordenador


BANCA EXAMINADORA:

 Documento assinado digitalmente
CELSO EDUARDO TUNA
Data: 29/01/2024 12:22:15-0300
Verifique em <https://validar.iti.gov.br>

Prof Dr Celso Eduardo Tuna
Orientador / UNESP/FEG
participou por videoconferência

 Documento assinado digitalmente
FABRICIO MACIEL GOMES
Data: 29/01/2024 15:56:11-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Fabrício Maciel Gomes
USP
participou por videoconferência

 Documento assinado digitalmente
PALOMA MARIA SILVA ROCHA RIZOL
Data: 02/02/2024 18:31:32-0300
Verifique em <https://validar.iti.gov.br>

Profa Dra ,Paloma Maria Silva Rocha Rizol
Unesp/FEG
participou por videoconferência

Janeiro de 2024

DADOS CURRICULARES

PEDRO NUNES LOPES NETO

NASCIMENTO	14.05.1983 – Guaratinguetá / SP
FILIAÇÃO	Maria de Fátima Ferreira Lopes José Nunes Lopes
1998/2000	Curso Técnico em Informática Industrial CTIG/Unesp – Guaratinguetá / SP, Brasil
2002/2007	Curso de Graduação - Bacharel em Engenharia Elétrica Unesp – Guaratinguetá / SP, Brasil
2005/2006	Especialização em Gerenciamento e Produção em Engenharia Elétrica INPG – Grenoble, França
2014/2015	Curso de Pós-Graduação <i>Lato Sensu</i> MBA em Gerenciamento de Projetos FGV – São José dos Campos / SP, Brasil
2020/2022	Curso de Pós-Graduação <i>Lato Sensu</i> MBA em Data Science e Analytics ESALQ/USP – Piracicaba / SP, Brasil

AGRADECIMENTOS

Agradeço à minha esposa, Josikeli, pela incansável dedicação, apoio e compreensão ao longo deste desafiador período de pesquisa. Sua generosidade em abdicar de preciosas horas de descanso, para que eu pudesse concluir minha tese de mestrado, foi essencial. Sem a sua presença constante e apoio incondicional, seria impossível conciliar minhas múltiplas responsabilidades como engenheiro, estudante e pesquisador.

Quero também estender meus agradecimentos aos estimados professores José Celso Freire Junior e Celso Eduardo Tuna. Agradeço por abrirem novamente as portas do Campus da Unesp em Guaratinguetá, um lugar que considero o alicerce de toda a minha formação. É esse ambiente inspirador que moldou e continua a moldar o profissional que sou hoje. Sua orientação e inspiração foram fundamentais para o meu crescimento acadêmico e profissional.

RESUMO

O aumento expressivo da demanda por serviços de qualidade nas redes de telefonia móvel, impulsionado pela disseminação generalizada de dispositivos móveis e pela vasta quantidade de aparelhos ativos globalmente, tem incentivado avanços constantes nas tecnologias de telecomunicações. O desenvolvimento contínuo das redes de quarta geração e a implementação da tecnologia de quinta geração são respostas a essa demanda crescente. A adoção dessas tecnologias trouxe consigo a geração de uma enorme quantidade de dados estatísticos relacionados ao desempenho das células das estações rádio-base, os quais podem ser analisados para aumentar a eficiência do sistema. Nesse contexto, este trabalho apresenta um processo inovador para lidar com dados estatísticos referentes ao desempenho das células em redes de telefonia móvel de quarta geração. O objetivo é automatizar a classificação das células de uma rede, com a identificação e categorização dos problemas dessas células, visando a redução de custos operacionais e o aumento da eficiência na correção de falhas. Para alcançar esse propósito, foi desenvolvido um processo computacional baseado em métodos de decisão multicritério e algoritmos de aprendizado de máquina. O processo proposto classifica as células com base em seu desempenho, identificando de forma eficaz as falhas existentes por meio de técnicas avançadas de inteligência artificial. Especificamente, a análise massiva de dados é utilizada para o reconhecimento automático de padrões estatísticos e operacionais das células, substituindo a análise manual custosa e demorada. Esse enfoque inovador promove uma abordagem mais ágil e eficiente na gestão do desempenho da rede, contribuindo para a otimização operacional e aprimoramento contínuo dos serviços de telefonia móvel.

PALAVRAS-CHAVE: Redes de Acesso por Rádio 4G (LTE); Métodos de Decisão Multicritério; Aprendizado de máquina; Gerenciamento de desempenho.

ABSTRACT

The significant increase in demand for quality services in mobile networks, driven by the widespread proliferation of mobile devices and the vast number of active devices globally, has spurred continuous advancements in telecommunications technologies. The ongoing development of fourth-generation networks and the implementation of fifth-generation technology are responses to this growing demand. However, adopting these technologies generate an enormous amount of statistical data related to the performance of base station cells, necessitating a more efficient analysis. In this context, this dissertation introduces an innovative process for handling statistical data concerning the performance of cells in fourth-generation mobile networks. The goal is to automate the classification of cells in a network, identifying and categorizing the cells' issues to reduce operational costs and enhance the efficiency of fault correction. A computational model based on multicriteria decision methods and machine learning algorithms was developed to achieve this purpose. The proposed model classifies cells based on their performance, more effectively identifying existing faults through advanced artificial intelligence techniques. Specifically, massive data analysis automatically recognizes statistical and operational patterns in cells, replacing the costly and time-consuming manual analysis. This innovative approach promotes a more agile and efficient approach to network performance management, contributing to operational optimization and the continuous improvement of mobile services.

KEYWORDS: 4G Radio Access Networks (LTE); Multi-criteria Decision Making (MCDM); Machine learning; Performance management.

LISTA DE FIGURAS

Figura 1 - Inscrições de usuários de celulares por tecnologia (em bilhões)	15
Figura 2 - Tráfego global de dados gerado por celulares por trimestre (T) (EB por mês)	16
Figura 3 - Publicações por ano com os temas MCDM e RAN.	19
Figura 4 - Publicações por ano com os temas ML e RAN.	19
Figura 5 – Arquitetura básica de uma Rede de Acesso por Rádio.....	25
Figura 6 – Parte de monitoramento da função de autocorreção	27
Figura 7 – Classificação amplas dos métodos MCDM	31
Figura 8 - Esquema geral do processo proposto.....	35
Figura 9 – Estrutura da tabela cells_kpis.....	39
Figura 10 – Representação do banco de dados MySQL e seleção dos dados coletados	40
Figura 11 – Proposta de uma nova classificação dos métodos MCDM	41
Figura 12 – Representação da hierarquia dos níveis de decisão AHP	42
Figura 13 – Representação do ranqueamento do modelo MAUT	46
Figura 14 – Representação da variação do tamanho da árvore em relação a seu erro relativo	50

LISTA DE QUADROS

Quadro 1 - Escala Fundamental.....	43
Quadro 2 - Exemplo de classificação das análises	48

LISTA DE TABELAS

Tabela 1 - Exemplo dos dados coletados	39
Tabela 2 – KPIs selecionados	43
Tabela 3 – Correlação par-a-par entre KPIs	44
Tabela 4 – Categorias de classificação das células com problemas de desempenho	48
Tabela 5 - Valores do Custo de Complexidade gerados pela função printcp.....	49
Tabela 6 – Indicadores da célula 3083.....	52
Tabela 7 – Resultados da Função Utilidade (U) em células de uma rede LTE real.....	53
Tabela 8 – Resultados iniciais da acurácia	54
Tabela 9 – Resultados ajustados da acurácia	55

LISTA DE ABREVIATURAS E SIGLAS

1G	Tecnologia de rede de primeira geração
2G	Tecnologia de rede de segunda geração
3G	Tecnologia de rede de terceira geração
3GPP	Third-Generation Partnership Project Standard Organization
4G	Tecnologia de rede de quarta geração
5G	Tecnologia de rede de quinta geração
AHP	Analytic Hierarchy Process
ANR	<i>Automatic Neighbor Relation</i>
BI	<i>Business Intelligence</i>
BBU	<i>Baseband Unit</i>
CI	<i>Consistency Index</i>
CP	<i>Complexity Cost</i>
CR	<i>Consistency Ratio</i>
DL	<i>Downlink</i>
EB	Exabytes = 10^{18} bytes
ELECTRE	<i>Elimination and Choice Expressing Reality</i>
E-RAB	<i>Evolved UTRAN Radio Access Bearer</i>
ERB	Estação Rádio-Base
GRA	<i>Grey Relational Analysis</i>
GSM	<i>Global System for Mobiles</i>
HWN	<i>Heterogeneous Wireless Networks</i>
HO	<i>Handover</i>
IA	Inteligência Artificial
IEEE	Institute of Electrical and Electronics Engineers
IP	<i>Internet Protocol</i>
IoT	<i>Internet of Things</i>
ITU	International Telecommunication Union
KPI	<i>Key Performance Indicator</i>
LTE	<i>Long-Term Evolution</i>
M2M	<i>Machine-to-Machine</i>
MADM	<i>Multi-Attribute Decision Methods</i>

MAUT	<i>Multi-Attribute Utility Theory</i>
MCDM	<i>Multicriteria Decision Making</i>
ML	<i>Machine Learning</i>
MODM	<i>Multi-Objective Decision Methods</i>
MPP	Modelo de Produto Ponderado
NGMN	Next Generation Mobile Networks
PAS	Ponderação Aditiva Simples
PI	<i>Performance Indicator</i>
PM	<i>Performance Manager</i>
QoS	<i>Quality of Service</i>
RAT	<i>Radio Access Technology</i>
RF	Radio-Frequência
RI	<i>Random Index</i>
RRC	<i>Radio Resource Control</i>
SON	<i>Self-Organizing Networks</i>
SRVCC	<i>Single Radio Voice Call Continuity</i>
TCoSH	<i>Trigger Condition of Self-Healing</i>
TOPSIS	<i>Technique for Order Preference by Similarity to Ideal Solution</i>
UMTS	<i>Universal Mobile Telecommunications Service</i>
UTRAN	<i>UMTS Terrestrial Radio Access Network</i>
VIKOR	Otimização Multicritério e Solução de Compromisso
VoLTE	<i>Voice over LTE</i>
WCDMA	<i>Widespread Code-Division Multiple-Access</i>

SUMÁRIO

1	INTRODUÇÃO	15
1.1	CONTEXTUALIZAÇÃO	15
1.2	OBJETIVOS.....	18
1.3	ESTADO ATUAL DA ÁREA	18
1.4	MATERIAIS E MÉTODOS	20
1.5	JUSTIFICATIVA.....	21
2	FUNDAMENTAÇÃO TEÓRICA.....	24
2.1	CONCEITO DE REDES DE ACESSO POR RÁDIO.....	24
2.2	CONCEITOS DE REDES AUTO-ORGANIZÁVEIS.....	25
2.3	CONCEITOS DE AUTORRECUPERAÇÃO	26
2.4	O SISTEMA DE GERENCIAMENTO DE REDES DE TELEFONIA MÓVEL	27
2.5	DETECÇÃO DE FALHAS EM CÉLULAS	28
2.6	INDICADORES-CHAVE DE DESEMPENHO	29
2.7	MÉTODOS DE DECISÃO MULTICRITÉRIO	30
2.8	APRENDIZADO DE MÁQUINA SUPERVISIONADO.....	32
3	O PROCESSO PROPOSTO	35
3.1	ESQUEMA GERAL DO PROCESSO PROPOSTO	35
3.2	SELEÇÃO DOS INDICADORES DE DESEMPENHO.....	36
3.2.1	KPIs de Acesso	36
3.2.2	KPIs de Retenção.....	37
3.2.3	KPIs de Mobilidade.....	38
3.3	COLETA DOS DADOS	39
3.4	DESENVOLVIMENTO DO PROCESSO DE CLASSIFICAÇÃO DE CÉLULAS	40
3.4.1	Definição dos Pesos utilizando o método AHP.....	41
3.4.2	Geração da função utilidade utilizando o método MAUT.....	45
3.5	DEFINIÇÃO DAS CATEGORIAS DE PROBLEMAS DE DESEMPENHO	47
3.6	DESENVOLVIMENTO DO PROCESSO DE DIAGNÓSTICO DAS CÉLULAS	48
3.6.1	Uso do Algoritmo de Árvore de Decisão.....	49


3.6.2	Uso do Algoritmo <i>Random Forest</i>	50
3.6.3	Uso do Algoritmo <i>Extreme Gradient Boosting</i>	50
4	RESULTADOS E DISCUSSÃO	51
4.1	CLASSIFICAÇÃO DAS CÉLULAS.....	51
4.2	DIAGNÓSTICO DAS CÉLULAS.....	53
4.2.1	Resultados Iniciais.....	53
4.2.2	Inclusão do KPI de Integridade	54
4.2.3	Resultados Otimizados.....	54
5	CONCLUSÃO	56
	REFERÊNCIAS	58

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

O número de usuários de celulares aumentou 4% no mundo em 2022, chegando a 8,3 bilhões, conforme dados apresentados na Figura 1. Esse crescimento foi liderado pela China, seguida por Bangladesh e Nigéria. Desse total, cerca de 75% dos usuários utilizam a tecnologia de quarta geração (4G) *Long-Term Evolution* (LTE), que ainda continua crescendo em todas as regiões, embora a tecnologia de quinta geração (5G) já tenha chegado a 1 bilhão de usuários.

Figura 1 - Inscrições de usuários de celulares por tecnologia (em bilhões).




Fonte: Ericsson (2023).

Esse contínuo aumento de usuários de celulares desde 2017 (Figura 1), aliado a um expressivo aumento do número de celulares inteligentes (*Smartphones*), maior velocidade de conexões e maior disponibilidade de conteúdos de vídeos (por meio de aplicativos como Youtube e Instagram), têm gerado um forte incremento do tráfego de dados por celulares no mundo; entre 2021 e 2022 o tráfego de dados quase duplicou, conforme dados apresentados na Figura 2. Isso acarreta, por sua vez, um volume cada vez maior de dados estatísticos de desempenho, que se torna extremamente difícil de ser manipulado e armazenado. A expectativa do mercado é de que o tráfego de dados cresça 3,5 vezes até 2028 (ERICSSON, 2023), influenciado pela disseminação da tecnologia de redes 5G, o que gerará maiores desafios à

otimização do desempenho da rede em um ambiente muito mais complexo, com centenas de variáveis a serem analisadas pelos engenheiros de telecomunicações, para tomada de decisões e para controle de seus indicadores.

Figura 2 - Tráfego global de dados gerado por celulares por trimestre (T) (EB por mês).



Fonte: Ericsson (2023).

Essa combinação de bilhões de usuários de celulares conectados e petabytes de dados computacionais está levando à criação de sistemas de telecomunicações em uma escala de complexidade que está além da habilidade humana de entendê-los e de controlá-los completamente. O gerenciamento e a operação desses sistemas requerem um alto grau de automação inteligente. Segundo um estudo da Ericsson (2018) a área de Inteligência de Máquina, que engloba os campos de Inteligência Artificial (IA) e de Aprendizado de Máquina, oferece a melhor possibilidade para manipulação desses dados.

Desde que os computadores foram inventados, indagou-se se eles poderiam aprender, e diversos algoritmos desenvolvidos mostraram-se efetivos para certos tipos de tarefa de aprendizado (MITCHELL, 1997). Porém a capacidade computacional era um fator restritivo, assim como a limitada capacidade de armazenamento de dados, freando um maior

desenvolvimento nessa área; entretanto, nos últimos anos, a capacidade computacional deixou de ser um fator limitante, juntamente com a possibilidade de armazenagem de dados em nuvem, que permitiu a manipulação de um volume de dados nunca imaginada. Esses avanços tecnológicos facilitaram a retomada dos estudos em Inteligência de Máquina e sua relevância em uma ampla variedade de setores da indústria, como Tecnologia da Informação e Comunicação, Produção e Transportes (ERICSSON, 2018).

No contexto geral de aplicações de Inteligência Artificial, aquelas voltadas à otimização do desempenho do usuário no acesso à rede de telefonia móvel apresentam um enorme desafio, pois requerem uma mudança das regras clássicas de otimização de redes de telefonia móvel, que incluem análise de estatísticas de rede por meio da geração de gráficos e de tabelas e a classificação manual das células que geram maiores problemas na rede. Essas análises são realizadas por grandes equipes de engenheiros e de operadores de sistema.

Requerimentos adicionais incluem fluxos de dados flexíveis e programáveis para coleta e armazenamento de dados, modelos para criação, execução e atualização dos algoritmos e adoção de unidades de processamento para treinamento. O pré-requisito principal para aplicar a IA com sucesso nesse contexto é conhecer profundamente a natureza e o papel de diferentes classes de parâmetros que afetam o desempenho da rede, bem como a complexidade e o potencial de melhora em cada classe (ERICSSON, 2019).

O monitoramento e controle do desempenho da rede é tradicionalmente realizado por um time de engenheiros suportados por sistemas especializados, com o objetivo de otimizar áreas particulares (tipicamente um agrupamento de células). Logo, o desempenho da rede é geralmente otimizado utilizando instruções manuais e automáticas, combinadas com valores mínimos de aceitação para cada métrica de desempenho. Essas métricas e instruções são, atualmente, completamente baseadas na experiência e nas observações humanas (ERICSSON, 2019).

Uma das mais importantes métricas de desempenho em uma rede de telefonia móvel é a taxa de queda de chamada de voz. Esse indicador é definido na especificação 3GPP TS 32.450 (2019), e indica a porcentagem do número de chamadas estabelecidas com sucesso que foram desconectadas (caíram). Sendo um indicador crucial sobre a qualidade da rede, tem efeitos claros na experiência do usuário; portanto uma das principais metas de um operador é reduzir o valor da taxa de queda de chamada de voz (3GPP, 2020).

Com base no exposto, o trabalho de pesquisa proposto busca automatizar a classificação de células da rede com base no desempenho de seus principais indicadores de desempenho, medidos em redes de telefonia móvel de tecnologia 4G, tais como a taxa de queda de chamadas

de voz, e identificar seus problemas utilizando técnicas de Inteligência Artificial, Aprendizado de Máquina e métodos de decisão multicritério, para reduzir o tempo de resposta a ações corretivas e para reduzir custos operacionais no gerenciamento das redes.

1.2 OBJETIVOS

O objetivo geral deste trabalho é desenvolver um processo capaz de classificar as células de uma rede de telefonia móvel 4G com base em seu desempenho, e automatizar a identificação e categorização de problemas nas referidas células. O processo é baseado na análise dos principais indicadores de desempenho definidos por organizações internacionais, utilizando-se de técnicas de Aprendizado de Máquina (*machine learning* – ML) e Métodos de Decisão Multicritério.


Para atingir esse objetivo geral, foram estabelecidos os seguintes objetivos específicos:

- Identificar os métodos de decisão multicritério mais utilizados e mais adequados para o problema em questão;
- Identificar os últimos avanços em *machine learning* para utilização na área de telecomunicações de redes de telefonia móvel;
- Identificar os principais problemas de desempenho encontrados em células em redes de telefonia móvel de quarta geração;
- Coletar os principais indicadores de desempenho de células instaladas em redes de telefonia móvel no Brasil;
- Selecionar, dentre os principais indicadores de desempenho, os mais relevantes para o presente trabalho;

1.3 ESTADO ATUAL DA ÁREA

Na análise de publicações correlatas ao trabalho em tela, com dados obtidos na base de dados Scopus, foi constatada a escassez de pesquisas acadêmicas sobre a aplicação de métodos de decisão multicritério para a resolução de problemas de desempenho nas redes de telefonia móvel de acesso por rádio (*Radio Access Networks* – RAN). Verifica-se um número extremamente baixo de publicações, com seu aumento somente a partir dos últimos dez anos. Destaca-se o crescente interesse no tema entre 2021 e 2022, com 31 publicações (conforme apresentado na Figura 3), evidenciando a novidade da aplicação dessa teoria em redes RAN (conceito descrito na sessão 2.1), facilitada pelas novidades tecnológicas antes inexistentes, conforme mencionado nos parágrafos anteriores.


Figura 3 - Publicações por ano com os temas MCDM e RAN.



Fonte: Scopus (2023).

Ressaltando as publicações com aplicação de ML para a resolução de problemas de desempenho em redes RAN, revela-se uma tendência notável de crescimento exponencial nos últimos 5 anos (Figura 4), mostrando um aumento substancial no interesse e na pesquisa relacionados a esses temas combinados. Conforme mencionado no presente trabalho, os avanços tecnológicos dos últimos anos propiciam a maior utilização de algoritmos de ML para a análise de desempenho das redes RAN, incentivada também pelo aumento significativo de usuários e de *smartphones* conectados, e do aumento exponencial de tráfego de dados gerados por celulares (Figura 2).

Figura 4 - Publicações por ano com os temas ML e RAN.



Fonte: Scopus (2023).

Em 2015, foi publicado pela fabricante de equipamentos de rede Ericsson Telefonaktiebolaget LM um artigo no IEEE em que se utilizava um método tradicional de aprendizado de máquina para previsão de quedas de conexões de dados utilizando-se coleta de mensagens entre celulares e a rede (DAROCZY; VADERNA; BENCZUR, 2015). Entre 2016 e

2018, foram publicados alguns artigos, a partir de pesquisas realizadas sobretudo na Europa, voltados mais à utilização de aprendizados de máquina para detecção de problemas específicos na rede, como falhas físicas e falta de capacidade em equipamentos.

A partir de 2019, a quantidade e variedade de artigos aumentaram significativamente, com trabalhos muito mais complexos de utilização de ML para resolução de problemas ligados às redes RAN 4G e 5G. Observa-se também uma modificação nas origens das publicações, centradas na China e nos Estados Unidos. Destaca-se um artigo, publicado no Canadá, que utiliza também algoritmos de ML, porém com objetivos muito mais abrangentes, para detecção de inúmeras falhas de desempenho em células e a realização de diagnósticos de correções automáticas (MANZANILLA-SALAZAR; MALANDRA; SANSÒ, 2019), o que o aproxima muito da pesquisa proposta no presente trabalho. Não obstante, sua proposta era focada na análise de comunicações *Machine-to-Machine* (M2M).

Ainda em 2019, outro trabalho, realizado em Taiwan, também apresentou resultado da utilização de algoritmos sofisticados de ML para diagnósticos automáticos de problemas de desempenho em redes 4G, podendo classificar também falhas multicausais (CHEN et al., 2019). Embora esse trabalho utilize mais medições de sinal de usuários do que contadores estatísticos, os resultados obtidos aproximam-se muito dos resultados pretendidos no presente trabalho, servindo de apoio ao desenvolvimento do processo planejado.

As publicações citadas mostram a relevância e a atualidade da pesquisa desenvolvida, tanto pelos trabalhos correlatos publicados, como pelo movimento iniciado pelos fabricantes de equipamentos, que também passaram a incluir soluções de aprendizado de máquina em seus portfólios.

1.4 MATERIAIS E MÉTODOS

Toda avaliação do comportamento de uma rede de telefonia móvel requer dados de desempenho coletados e gravados pelos elementos de rede, e armazenados e gerenciados por um sistema de gerenciamento centralizado. Esse ambiente de gerenciamento da rede é denominado de sistema de Gerenciamento de Desempenho (*Performance Management* – PM), presente em diversos fabricantes de equipamentos de redes RAN. O propósito de qualquer PM é coletar dados, que poderão ser utilizados para verificar a configuração lógica, física e virtual da rede de telefonia móvel e para identificar potenciais problemas na rede. A análise desses dados pode indicar os níveis de tráfego, a configuração, a utilização de recursos, a qualidade de serviço e a disponibilidade de recursos da rede. Eles são armazenados na forma de contadores de desempenho (PM *counters*), que por sua vez são agregados em equações que calculam

indicadores de desempenho (3GPP, 2018).

Na presente pesquisa, foram coletados os principais contadores de uma rede de telefonia móvel 4G real instalada no Distrito Federal do Brasil, Brasília, obtidos de uma operadora de telefonia móvel que fornece cobertura 4G na região. Coletaram-se os contadores de 4925 células, por um período de uma semana, em julho de 2021, por meio de arquivos estatísticos salvos pelo PM do fabricante dessa rede. Eles informam, entre outros dados, a taxa de queda de chamadas de voz e de conexões de dados, conforme descrito nas normas 3GPP (3GPP, 2019). Uma lista dos indicadores de desempenho da rede de telefonia móvel selecionados foi gerada como parte da pesquisa.

Na sequência, foi criada uma base de dados em um sistema de gerenciamento de banco de dados MySQL, disponível de forma gratuita no mercado. Foram elencados os principais problemas de desempenho percebidos pelo usuário, procedendo-se à sua classificação por meio de estudo de casos e da própria experiência do autor na otimização de desempenho das redes de telefonia móvel de acesso por rádio.

Obtidas as informações teóricas sobre métodos de decisão multicritério e algoritmos de aprendizado de máquina, coletadas as estatísticas e os contadores selecionados durante a pesquisa, procedeu-se desenvolvimento de um processo para classificação e diagnóstico automáticos de todas as células que apresentem problemas de desempenho nessa rede de telefonia móvel de tecnologia 4G. Para tal, foram utilizadas as linguagens de programação R e Python, mais propícias para aplicação de ML e para manipulação de dados estatísticos por meio do acesso à base de dados criada. Essa etapa foi a mais complexa e demorada do projeto, pois foi necessária extensa validação dos resultados obtidos, comparando-os às análises que engenheiros realizam dos problemas e seus diagnósticos.

Como resultado da pesquisa, foi calculada a acuracidade das classificações de problemas existentes nas células por meio do processo de ML desenvolvido, analisando-se a evolução e seus indicadores de desempenho. Assim, a pesquisa foi concluída, após o término de todos os testes e validação dos processos, com a visualização dos resultados por meio da ferramenta de *Business Intelligence* (BI) Power BI. Uma etapa associada à publicação dos resultados obtidos e à redação da dissertação de mestrado encerrou este trabalho de pesquisa.

1.5 JUSTIFICATIVA

A Inteligência Artificial experimentou um renascimento extraordinário nos últimos anos. A abundância de dados e a capacidade computacional disponíveis atualmente tornaram possível

a aplicação de métodos criados há décadas, como o aprendizado de máquina. Investimentos substanciais dos setores privados e públicos propiciaram o crescimento de um ecossistema composto de bibliotecas, plataformas e publicações que impulsionaram a área e facilitaram o acesso a técnicas de IA para desenvolvedores em diversas áreas.

Apesar dos avanços teóricos da disciplina de IA ocorrerem geralmente nos domínios de processamento de imagem e jogos, as vantagens exibidas por esses sistemas têm atraído atenção de diversas indústrias, pois demonstram grande potencial para melhorar o desempenho, reduzir custos e acelerar o tempo de introdução de produtos e serviços finais no mercado (ERICSSON, 2019). Em todo o mundo, operadores também estão prontos para instalar a quinta geração da tecnologia de redes de telefonia móvel pois, comparada com a infraestrutura de rede atual, a tecnologia 5G irá trazer maiores velocidade de conexão, menor latência, sinalização mais eficiente, suporte para maiores espectros de frequência, maior flexibilidade e outras técnicas avançadas para maximizar seu uso e otimizar custos.

Espera-se que o número de equipamentos conectados cresça rapidamente como resultado desse desempenho otimizado: sensores irão se beneficiar de uma melhor largura de banda para a internet, dispositivos que demandam alto tráfego de dados, como câmeras de vídeo, poderão enviar mais dados e carros e *drones* terão conexões mais confiáveis. Esses novos aparelhos serão a catálise de uma nova onda de inovação para todas as indústrias envolvidas (ERICSSON, 2018).

Na atualidade, com a predominância da tecnologia 4G, as equipes de otimização das redes de telefonia móvel conseguem, no tratamento dos problemas, analisar entre 20 e 50 células por dia (cada Estação Rádio-Base – ERB, pode possuir entre 3 e 12 células). A disseminação da tecnologia 5G levará ao aumento significativo de dados trafegados, conforme a adição de novos usuários relatada, e eventualmente dos problemas reportados, o que tornará a manipulação e análise manual de dados um desafio cada vez maior para engenheiros e operadores de redes, dificultando a identificação de falhas e tornando mais demorado o processo de correção de problemas nas células da rede.

Com IA e Aprendizado de Máquina, poder-se-á classificar células de uma região inteira em segundos. Utilizando-se o fluxo diário de dados, será possível a classificação não somente reativa, mas também proativa, prevendo futuros problemas a partir da análise dos principais indicadores de desempenho de cada célula, facilitando a instalação futura do 5G e propiciando novas bases para o gerenciamento de desempenho da nova tecnologia.

O trabalho também se propõe a aumentar a confiabilidade da classificação de problemas, quando comparado ao trabalho manual realizado atualmente por engenheiros, tornando a

ferramenta automática mais eficaz na manutenção do desempenho ótimo da rede, prevenindo futuras falhas e degradações de desempenho. O processo proveniente desse trabalho poderá ser utilizado por operadores de rede de telefonia móvel e prestadores de serviço, bem como por empresas fornecedoras de equipamentos de redes, gerando redução de custos e melhores desempenhos aos usuários.

A análise da pesquisa bibliográfica realizada sobre o tema permite também afirmar que são escassas as pesquisas sobre o tema no Brasil. A execução do trabalho proposto poderá contribuir com a produção de artigos nessa área no país e poderá incentivar empresas nacionais e outras universidades a atuarem na área, desenvolvendo, por exemplo, novos processos que apliquem ML para solução de problemas de desempenho em redes de telefonia móvel. Nas empresas, a metodologia proposta pode facilitar a redução de custos e a melhoria da eficiência em projetos de otimização de desempenho de redes de telefonia móvel 4G e 5G, propiciar um melhor planejamento para a introdução da tecnologia 5G e a transformação para a Indústria 4.0.

Pelo exposto, pode-se observar a relevância e interesse da proposta de pesquisa, o que se acredita, justifique plenamente seu desenvolvimento, enfatizando que o processo proposto para a tecnologia 4G pode ser adaptado futuramente para a tecnologia 5G.

2 FUNDAMENTAÇÃO TEÓRICA

Esta seção contextualiza os conceitos e teorias utilizados neste trabalho. Os Conceitos de Redes de Acesso por Rádio – RAN, e de redes auto-organizáveis são descritos, com atenção especial para a autorrecuperação (*Self-Healing*). A detecção de falhas em células e os indicadores de desempenho da rede também são discutidos. Na sequência, são discutidos os métodos de decisão multicritério e os algoritmos de aprendizado de máquina supervisionados, aplicados ao problema em questão.

2.1 CONCEITO DE REDES DE ACESSO POR RÁDIO

Uma Rede RAN é o principal componente de um sistema de telecomunicações sem fio, que conecta dispositivos individuais a outras partes da rede através de um *link* de rádio. Esse *link* conecta os equipamentos do usuário, tais como smartphones e computadores, ao núcleo da rede (*core network*), que gerencia, entre outros dados, sua localização e informações dos usuários das operadoras.

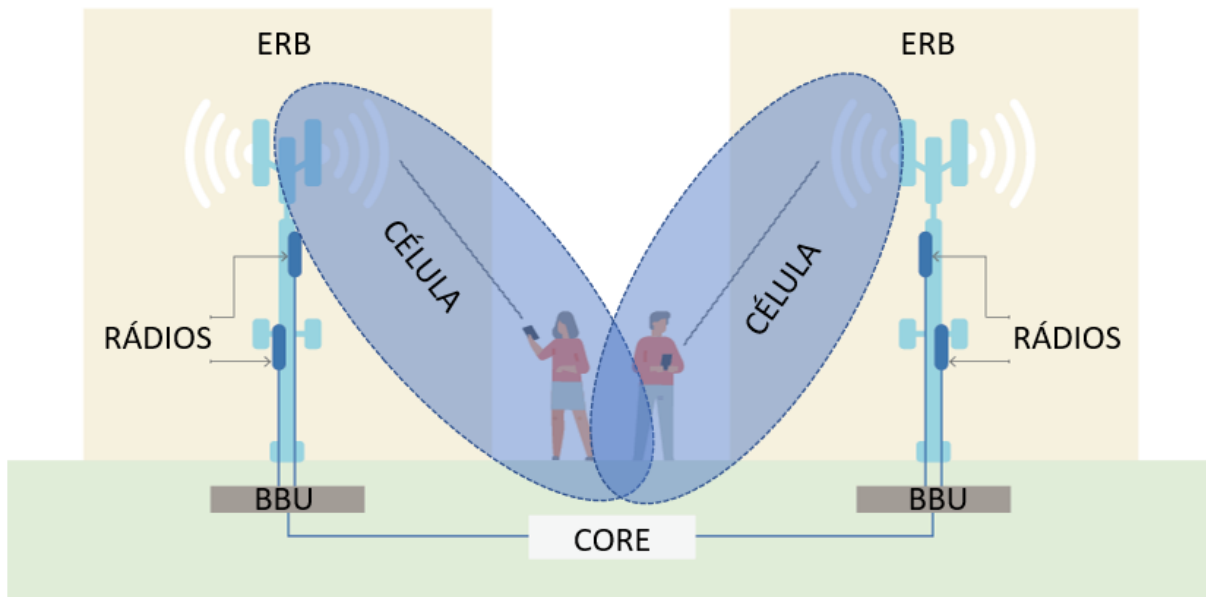
Como o próprio nome indica, a rede RAN é o elemento de rádio da rede de telefonia móvel. Além desse elemento, uma rede de telefonia móvel é composta de áreas de coberturas chamadas células. Uma célula é servida por ao menos um transmissor de rádio, e o padrão tipicamente é de três células para cada Estação Rádio-Base. A ERB é constituída por três elementos essenciais (Figura 5):

- Antenas: Convertem sinais elétricos em ondas de rádio;
- Rádios: Transformam informação digital em sinais que podem ser enviados pelo ar e asseguram que as transmissões estejam na banda de frequência correta com os níveis de potência adequados;
- Unidade de Banda Base (*Baseband Unit* – BBU): Provê funções de processamento de sinal que tornam a comunicação sem fio possível. As BBUs detectam erros, asseguram o sinal e a utilização eficiente dos recursos.

As redes RAN evoluíram da primeira geração à quinta geração de tecnologia celular. Com o desenvolvimento da quarta geração de redes de telefonia móvel nos anos 2000, a organização para padronização de telecomunicações móveis 3rd Generation Partnership Project (3GPP) introduziu a rede RAN 4G LTE, e a rede de acesso por rádio e o *core* mudaram significativamente. Com o 4G, a conectividade do sistema foi baseada pela primeira vez em IP (*Internet Protocol*), substituindo as redes anteriores, baseadas em circuito (TECHTARGET

NETWORKING, 2022), utilizadas principalmente para serviços de voz. Para tanto, foi desenvolvido o serviço de Voz sobre LTE (*Voice over LTE - VoLTE*), que utiliza a rede IP LTE para chamada de voz, integrando-se totalmente à experiência existente dos usuários, ao mesmo tempo que fornece maior qualidade de voz (GSM ASSOCIATION, 2014).

Figura 5 – Arquitetura básica de uma Rede de Acesso por Rádio.



Fonte: Adaptada de Techtargt Networking (2022).

Desde que as primeiras redes de telefonia móvel foram introduzidas, as capacidades da rede RAN expandiram para incluir chamadas de voz, mensagem de texto, e transmissão de áudio e vídeo. Os tipos de dispositivos utilizados nessas redes também aumentaram drasticamente, incluindo todos os tipos de veículos, *drones* e internet das coisas (*Internet of Things – IoT*) (TECHTARGET NETWORKING, 2022).

2.2 CONCEITOS DE REDES AUTO-ORGANIZÁVEIS

Em 2008, a Aliança Next Generation Mobile Network (NGMN), um fórum aberto fundado por grandes operadoras de redes de telefonia móvel, definiu os requisitos e recomendações para a implementação de redes auto-organizáveis (NGMN ALLIANCE, 2008), as quais permitiam a automação de alguns processos de planejamento, configuração e otimização de rede por meio de funcionalidades da rede auto-organizável (*Self-Organizing Network – SON*) (3GPP, 2020). As funcionalidades indicadas pela NGMN eram autoconfiguração, auto-otimização, gerenciamento de falhas e correção de falhas (posteriormente renomeado como autorrecuperação). Mais tarde, o 3GPP, que fornece relatórios

e especificações para tecnologias de telecomunicações celulares, introduziu o SON em seus padrões como um elemento fundamental para a implantação do LTE e definiu as principais funcionalidades SON com base nos requisitos da NGMN (3GPP, 2020). As principais funcionalidades SON, mencionadas acima, são resumidas por Barco, Lazaro e Muñoz (2012) como sendo:

- Autoconfiguração: inclui funções para implantação da rede e configuração de seus parâmetros. Graças à autoconfiguração, os elementos da rede podem iniciar autonomamente, executar rotinas de configuração e configurar parâmetros iniciais.
- Auto-otimização: responsável pelo ajuste automático dos parâmetros, que devem ser recalculados dinamicamente quando as condições de tráfego e rede mudam. A auto-otimização inclui ajuste de parâmetros relacionados à lista de células vizinhas, equilíbrio de tráfego, mobilidade e cobertura.
- Autorrecuperação: inclui funções para lidar com degradações ou interrupções de serviço, incluindo detecção e diagnóstico de falhas e mecanismos para compensação de interrupções.

As primeiras duas funcionalidades estão bem documentadas, e algumas funções, como a Relação Automática de Vizinhas (*Automatic neighbor relation – ANR*) e a auto-conectividade de nós, foram até mesmo utilizadas nas primeiras implantações do LTE. A autoconfiguração reduz custos e acelera a implantação de células na rede, enquanto a auto-otimização fornece economias de custo operacional através da otimização de economia de energia ou balanceamento de carga.

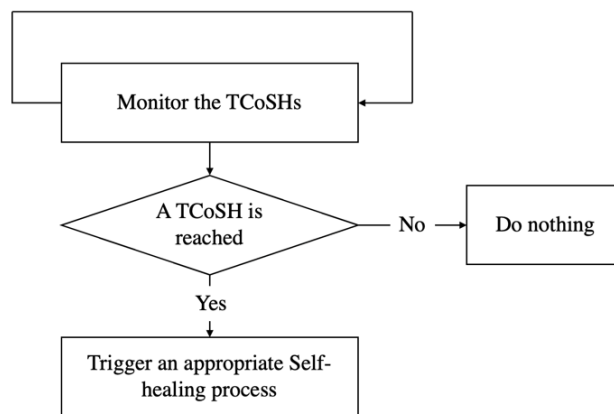
Por outro lado, estudos sobre autorrecuperação são escassos, pois é o mais complexo dos três domínios devido à variedade de fornecedores, versões de software e tipos de hardware que coexistem em uma única rede (SZILAGYI; NOVACZKI, 2012). Os estudos existentes sobre autorrecuperação são incompletos, lidando apenas com certos aspectos de autorrecuperação em cenários específicos, como a detecção de desligamentos completos de células (BARCO; LAZARO; MUNOZ, P., 2012). No entanto, novos estudos sobre detecção e diagnóstico automático de falhas também poderiam reduzir o custo de gerenciamento de redes.

2.3 CONCEITOS DE AUTORRECUPERAÇÃO

Conforme descrito pelo 3GPP, a autorrecuperação tem como objetivo resolver ou mitigar as falhas automaticamente, acionando ações de recuperação apropriadas. A função de

autorrecuperação consiste em duas partes: a parte de monitoramento e a parte do processo de recuperação (3GPP, 2020). Na primeira parte (mostrada na Figura 6), a condição de acionamento da autorrecuperação (*Trigger Condition of Self-Healing – TCoSH*), que pode ser um alarme ou um indicador de desempenho, é monitorada; quando a TCoSH é alcançada, uma ação particular é acionada para prevenir ou mitigar a falha específica. O processo proposto no presente trabalho foca na detecção de uma falha de célula durante a fase de monitoramento do processo de autorrecuperação.

Figura 6 – Parte de monitoramento da função de autocorreção.



Fonte: Adaptada de 3GPP (2020).

Detectar e solucionar falhas de células é uma das principais preocupações dos operadores e fornecedores de rede. O autorreparo é necessário quando uma célula se degrada, impactando o restante da rede. Esse tipo de célula é chamado de célula problemática e cada operador e fornecedor usa um indicador diferente para identificar os sintomas de falha da célula. Um sintoma é uma medida cujo valor observado ajuda a identificar uma falha. Os sintomas incluem indicadores de desempenho, alarmes, medidas *online* e testes de condução. (BARCO; LAZARO; MUNOZ, 2012).

2.4 O SISTEMA DE GERENCIAMENTO DE REDES DE TELEFONIA MÓVEL

O 3GPP define como objetivos básicos de um sistema de gerenciamento de redes de telefonia móvel a capacidade de gerenciar equipamentos fornecidos por diferentes fabricantes, prover comunicação entre os diferentes elementos da rede e prover o gerenciamento de sua configuração, desempenho e falhas. Para tal, o sistema utiliza um processo de coleta e de processamento de dados, interagindo com todos os elementos da rede para coletar eventos e indicadores de desempenho para distribuição a outros processos. O processo de coleta de dados

também inclui processá-los por meio de filtragem, agregação, formatação e correlação das informações coletadas (3GPP, 2022). O gerenciamento das informações coletadas é dividido em:

- Gerenciamento de Desempenho: coleta medições de desempenho da rede por meio de contadores e eventos;
- Gerenciamento de Roaming: coleta informações de usuários que estão fora da área de sua operadora;
- Gerenciamento de Fraude: coleta informações de controle de usuários;
- Gerenciamento de Falhas: coleta alarmes gerados pelos elementos de rede;
- Gerenciamento de Segurança: coleta informações de acesso de usuários à rede;
- Gerenciamento de Configuração: coleta informações de configuração dos elementos da rede.

2.5 DETECÇÃO DE FALHAS EM CÉLULAS

Em geral, os alarmes só conseguem identificar uma falha de célula em casos críticos, ou seja, falhas de *software* e *hardware*, problemas de transmissão ou períodos de inatividade. Uma única falha pode gerar vários alarmes, e várias falhas diferentes podem disparar um único alarme. Além disso, as mensagens de alarme às vezes não podem ser transmitidas quando uma célula perde conectividade ou para de enviar informações. Também em muitas ocasiões, uma falha de célula não gera nenhum alarme. Isso pode ocorrer em função de condições de rádio ruins, ou seja, cobertura inadequada, sombreamento ou interferência externa (BARCO; LAZARO; MUNOZ, 2012). Também pode ser causada por configuração incorreta. Portanto os indicadores de desempenho são as principais entradas usadas pelos especialistas em redes RAN para detectar uma falha de célula e são usados como critério para o processo de tomada de decisão proposto neste trabalho.

Barco, Lazaro e Muñoz (2012) propõem um modelo de referência de autorreparo, que é a base para o processo de detecção de falhas de célula utilizado neste trabalho. De acordo com eles, a detecção de falhas é responsável por identificar as células problemáticas a serem reparadas, incluindo células com interrupção de serviço (detecção de interrupção de célula) e células com degradação de serviço (detecção de degradação de célula). Um possível método

simples de detecção de falha de célula consiste em definir limites para alguns indicadores de desempenho. No entanto, as degradações graduais não podem ser detectadas simplesmente por um limite, especialmente se a detecção proativa for realizada. Os autores afirmam, portanto, que um modelo deve ser desenvolvido considerando todos os indicadores de desempenho relevantes, utilizando uma lógica de decisão apropriada para determinar se ocorreu uma interrupção ou degradação.

2.6 INDICADORES-CHAVE DE DESEMPENHO

Com o objetivo de facilitar o gerenciamento e avaliar o desempenho de uma rede, além de realizar comparações entre diferentes áreas ou períodos, é necessário que um operador meça os indicadores estatísticos de desempenho dessa rede. A amostragem de dados estatísticos pode ser realizada regularmente, ou seja, diariamente, semanalmente ou mensalmente (3GPP, 2015). Os dados estatísticos de desempenho são coletados e registrados pelos elementos da rede, seguindo um cronograma estabelecido pelo operador. Esses dados são usados para avaliar o desempenho da rede em cinco áreas: tráfego de rede, configuração, acesso a recursos, disponibilidade de recursos e qualidade de serviço (3GPP, 2018). Os indicadores de Qualidade de Serviço (*Quality of Service – QoS*), que medem o desempenho da rede que o usuário final deve experimentar, são as medições consideradas neste trabalho.

Os indicadores de desempenho são definidos por cada fornecedor de equipamentos, com base em padronizações definidas por organismos como o 3GPP. Isso permite uma ação rápida para controlar, quando necessário, o desempenho e os recursos da rede e dos serviços. Uma rede RAN pode ter centenas de indicadores de desempenho (*Performance Indicators – PIs*). Muitas vezes, as medições são realizadas simplesmente porque estão disponíveis, não porque são significativas. Deve-se observar que a gama completa de informações de estado da rede e PIs não é necessária para gerenciar a rede. Um dos desafios de gerenciar redes é entender quais dados são críticos para apoiar objetivos específicos (ITU, 2006). PIs que representam as medições essenciais de desempenho de rede podem ser chamados de indicadores-chave de desempenho (*Key Performance Indicators – KPIs*).

Para uma rede RAN LTE, o 3GPP define seis categorias de KPIs (3GPP, 2019). Todas, exceto a última, podem ser usadas para medir o QoS. As categorias são as seguintes:

- 1) KPIs de acessibilidade: usados para medir a disponibilidade do serviço dentro de tolerâncias especificadas e outras condições estabelecidas quando solicitado pelo usuário (ITU, 2008);
- 2) KPIs de retenção: usados para medir interrupções anormais do serviço (ITU, 2008);


- 3) KPIs de mobilidade: usados para medir como a funcionalidade de mobilidade LTE está operando;
- 4) KPIs de integridade: usados para medir a integridade dos dados, garantindo que os dados não foram alterados de maneira não autorizada (ITU, 2008);
- 5) KPIs de disponibilidade: usados para medir a porcentagem de vezes em que a célula é considerada disponível;
- 6) KPIs de eficiência energética: usados para medir a eficiência energética de dados nos elementos da rede LTE.

2.7 MÉTODOS DE DECISÃO MULTICRITÉRIO

Métodos de Decisão Multicritério (*Multi-criteria decision-making* – MCDM) têm uma história relativamente curta como disciplina. Suas bases foram estabelecidas entre 1950 e 1960, e se tornaram o paradigma dominante na análise de decisões e no suporte à decisão na presença de múltiplas dimensões de avaliação (ZAVADSKAS et al., 2014). Métodos MCDM têm sido uma das áreas de problema de crescimento mais rápido em muitas disciplinas, onde um conjunto de alternativas precisa ser avaliado em termos de vários critérios (TRIANTAPHYLLOU, 2010). No entanto não existe uma única metodologia bem definida que se possa seguir do início ao fim de um processo de tomada de decisão. Ao manipular objetos que só podem ser descritos e comparados usando múltiplas características, agregá-las é um problema significativo. A agregação tem como objetivo sintetizar as características (geralmente contraditórias) dos objetos para alcançar um objetivo, como escolher entre os objetos, classificá-los por ordem de prioridade, ordená-los em categorias, e assim por diante (BOYSSOU et al., 2006).

Métodos MCDM usam uma ampla variedade de abordagens para resolver os problemas mencionados. Eles podem ser amplamente classificados em duas categorias (Figura 7): Métodos de decisão multi-atributo (*Multi-attribute Decision-Making* – MADM) discretos, e Métodos de decisão multiobjetivos (*Multi-Objective Decision-Making* – MODM) contínuos. Métodos MODM estão associados a problemas em que as alternativas não são predefinidas. O objetivo é projetar a melhor escolha/opção considerando um conjunto de restrições de projeto bem definidas e um conjunto de objetivos quantificáveis. Assim, os métodos MODM tratam com o processo de *design* e o número de alternativas é infinito (contínuo). Por outro lado, métodos MADM tratam com opções discretas e predefinidas, descritas por conjuntos de critérios determinados e discretos (ZAVADSKAS et al., 2014).

Figura 7 – Classificação ampla dos métodos MCDM.



Fonte: Adaptada de Zavadskas et al. (2014).

Verifica-se a utilização de Métodos MCDM em redes RAN principalmente para abordar problemas discretos de seleção de rede em redes sem fio heterogêneas, e nota-se que os problemas de tomada de decisão tornaram-se mais complexos desde o surgimento da tecnologia de acesso por rádio (*Radio Access Technology – RAT*) de terceira geração (3G) WCDMA (Wideband Code Division Multiple Access), especificado no Release 99 pelo 3GPP em 1999 (3GPP 2000), que permitiu taxas de dados mais altas e facilitou o aumento significativo do número de dispositivos móveis. Além disso, dispositivos móveis com capacidades avançadas viram uma grande proliferação com a evolução para o 4G e a tecnologia LTE, especificada no Release 8 pela 3GPP em 2008 (3GPP, 2009). A implantação do 5G introduziu uma nova RAT, que coexistirá com as RATs atuais. Portanto, a seleção da melhor rede essencialmente se torna um processo MCDM (Paul; Falowo, 2017).

Obayiuwana e Falowo (2017) revisam e classificam os métodos MCDM mais significativos usados para resolver os problemas de tomada de decisão de Redes Sem Fio Heterogêneas (HWNs). Por outro lado, Yeryomin e Seitz (2016) avaliaram diferentes métodos utilizados no problema de seleção de rede de múltiplos critérios. Algumas outras aplicações críticas dos métodos MCDM nesses problemas podem ser encontradas em Pervaiz (2010), Sasirekha e Ilanzkumaran (2013) e Nguyen-Vuong et al. (2013). Ao mesmo tempo, Alhabo e Zhang (2018) preveem que a introdução do 5G e a crescente demanda por dados móveis levarão a um esquema de seleção que considera diferentes usuários com diferentes prioridades e preferências.

A evolução do LTE e o aumento do tráfego de dados também introduziram novos problemas de tomada de decisão, que os métodos MCDM poderiam resolver. Embora a seleção de rede possa ser considerada uma transferência vertical, o LTE foi projetado para suportar a mobilidade do usuário, mesmo em alta velocidade, movendo-se de uma célula para outra durante as sessões de serviço ativas (NATHANIEL et al., 2014), o que é considerado uma transferência horizontal. A transferência horizontal também pode contribuir para um balanceamento de carga eficaz para o uso ideal dos recursos da rede. Reconhecendo isso,

Nathaniel, Ariffin, Farzamnia e Adegboyega (2014) usaram uma nova abordagem MCDM para criar um quadro com um modelo de decisão para resolver o problema de balanceamento de carga no LTE. Além disso, Dudnikova, Dini, Giupponi e Panno (2015) introduziram outra abordagem inovadora para MCDM ao considerar o problema gerado por redes heterogêneas densamente implantadas, onde há um aumento significativo no consumo de energia da rede. Para lidar com essa situação, eles propuseram o uso da análise de relação de cinza e do processo de hierarquia analítica (ferramentas MCDM) para encontrar o número de ERBs a serem desligadas para maximizar a economia de energia.

Portanto, diferentes métodos MCDM têm sido amplamente aplicados em redes RAN, principalmente para o problema de seleção de rede. No entanto a crescente complexidade gerada por novas tecnologias, o colossal tráfego de dados, o crescente número de assinaturas móveis e o número acumulado de células instaladas na rede ao longo dos anos tornam esse cenário um terreno fértil para novas aplicações dos métodos MCDM para resolver novos problemas de decisão. O presente trabalho propõe uma nova aplicação dos métodos de decisão multicritério MAUT (Multi-Attribute Utility Theory) e AHP (Analytic Hierarchy Process) para resolver o problema de decisão sobre que células LTE com problemas de desempenho precisam ser detectadas e classificadas em um sistema de autocorreção em uma rede em que as alternativas não são pré-determinadas e o número de opções é vasto.

2.8 APRENDIZADO DE MÁQUINA SUPERVISIONADO

Um dos objetivos deste trabalho é prever o valor de uma variável resposta, qual seja a classificação do problema de desempenho de uma determinada célula de uma rede RAN, a partir de variáveis preditoras, quais sejam os KPIs da rede selecionados neste trabalho; portanto o problema em questão pode ser resolvido por um modelo estatístico acoplado a um algoritmo computacional, denominado Aprendizado de Máquina supervisionado.

Aprendizado de máquina é a ciência de programação de computadores para que eles aprendam a partir de dados obtidos, e acredita-se que o artigo de Turim (1950) seja o primeiro a tratar do tema, seguido por outros artigos na década de 1950, embora a maioria dos conceitos estatísticos utilizados em aprendizado de máquina fossem desenvolvidos nos séculos 18 e 19, com contribuições de Gauss, Laplace, entre outros. Os avanços nos aprendizados de máquina estão diretamente relacionados a melhorias na área computacional a partir da década de 1960. Já a partir de 1980, com o surgimento dos computadores pessoais e linguagens de programação como a R, pacotes para análises estatísticas passam a ser obtidos livremente (MORETTIN, 2020).

Em 1990, surgiram as primeiras aplicações de aprendizado de máquina de ampla importância, como reconhecimento de voz, detecção de uso fraudulento de cartão de crédito, dentre outros. Em 2006, Geoffrey Hinton et al. Publicaram um artigo mostrando como treinar uma rede neural capaz de reconhecer dígitos escritos a mão com grande precisão, denominando a técnica de *Deep Learning*. Esse artigo foi um marco para a comunidade científica, demonstrando a eficácia do aprendizado de máquina para solucionar problemas complexos, e sua aplicação estendeu-se para diversas áreas. Atualmente, o aprendizado de máquina conquistou a indústria, sendo a peça central de diversas tecnologias avançadas (GÉRON, 2019).

Os algoritmos de aprendizado de máquina utilizados atualmente podem ser classificados como supervisionado ou não supervisionado. No aprendizado não supervisionado, há apenas um conjunto de variáveis preditoras, e o objetivo é descrever associações e padrões entre essas variáveis. No aprendizado supervisionado, o objetivo é prever o valor de uma variável resposta a partir de variáveis preditoras. Os modelos supervisionados caracterizam-se por serem alimentados pela variável resposta desejada, de forma a servir como treino para o algoritmo. A variável resposta pode ser quantitativa ou qualitativa, sendo o modelo de regressão um dos mais utilizados para o primeiro caso. Para variáveis qualitativas (também denominadas de categóricas ou discretas), podem ser utilizados modelos de classificação tais como máquinas de suporte vetorial, árvores de decisão, método do k-ésimo vizinho, etc. (MORETTIN, 2020). Como a variável resposta do presente trabalho é do tipo qualitativa, o modelo utilizado foi do tipo supervisionado de classificação.

Dentre os modelos estatísticos de aprendizado de máquina supervisionado, encontram-se os modelos de árvores de decisão, que foram desenvolvidos na década de 1980 por Leo Breiman e associados, tanto para regressão quanto para classificação, e seu modelo de classificação foi selecionado para o presente trabalho por sua fácil interpretação e aplicação, bem como por serem conceitual e computacionalmente simples, apesar de menos precisos que modelos mais complexos (MORETTIN, 2020).

Também foram testadas variações dos modelos originais, tais como *Random Forests* e *Extreme Gradient Boosting*. As *Random Forests* utilizam uma agregação *bootstrap*, ou *bagging*, definida como um método para gerar múltiplas versões aleatórias das árvores, formando uma “floresta” aleatória, e aumentando, assim, a acurácia do modelo. Já o *Extreme Gradient Boosting* utiliza o método *boosting*, cujo objetivo é reduzir o viés e a variância do aprendizado, considerando uma sequência de previsores fracos para obter um previsor forte no final, utilizando árvores de decisão (MORETTIN, 2020). O algoritmo sequencialmente adiciona preditores a um conjunto, tentando ajustar o novo preditor aos erros residuais gerados pelo

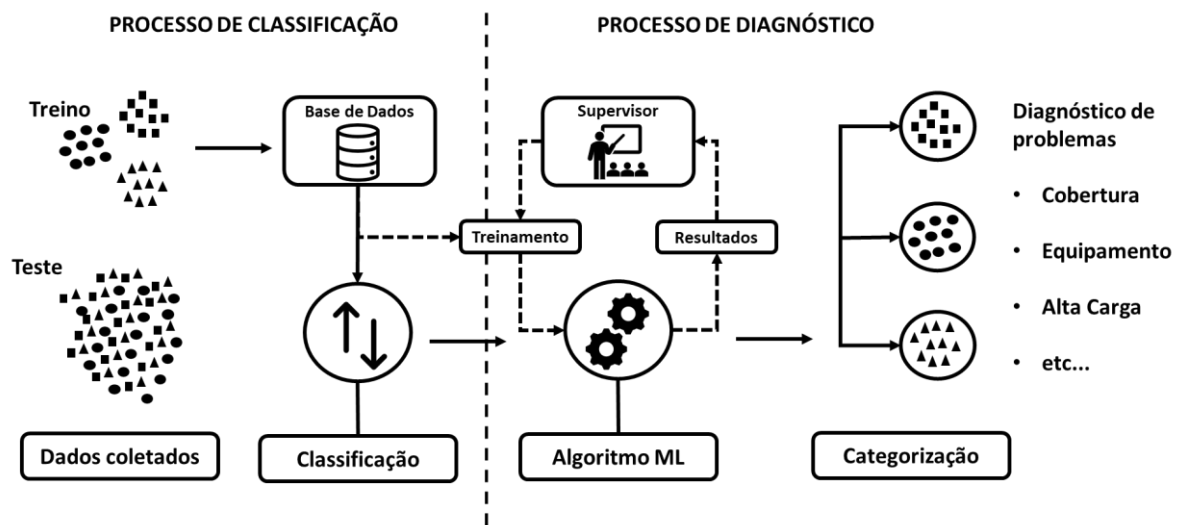
preditor predecessor. O algoritmo *Extreme Gradient Boosting* foi desenvolvido por Tianqi Chen e tornou-se muito popular após vencer diversas competições de algoritmos de aprendizados de máquina (GÉRON, 2019).

3 O PROCESSO PROPOSTO

3.1 ESQUEMA GERAL DO PROCESSO PROPOSTO

A Figura 8 apresenta o esquema geral do processo proposto pelo presente trabalho. Ele se divide em dois subprocessos: O processo de Classificação das células e o processo de Diagnóstico de problemas das Células; o primeiro processo é baseado na utilização de métodos de decisão multicritério para agregação dos diversos índices de performance das células e criação de uma única função, que retorna valores únicos para cada célula, permitindo sua ordenação do menor para o maior valor. O segundo processo é solucionado por meio de algoritmos de Machine Learning supervisionados, que são treinados com centenas de análises realizadas por engenheiros de RF, e tem como resultado um possível diagnóstico de problema para cada célula.

Figura 8 - Esquema geral do processo proposto.



Fonte: Elaborada pelo autor (2023).

Na construção do processo proposto, o primeiro passo dado foi selecionar os KPIs com maiores impactos na experiência final do usuário, considerando os indicadores de desempenho de chamadas de voz e de conexões de dados. As principais fontes de dados de desempenho do trabalho encontram-se nas coletas de indicadores de desempenho realizadas pelos sistemas de gerenciamento da rede RAN 4G de Brasília. As células são então classificadas do menor para o maior desempenho, para facilitar o gerenciamento de falhas e processos de autorrecuperação, reduzindo o número de células gerenciadas e recuperadas.

Após a coleta das variáveis de entrada, ajuste da variável de saída por meio das classificações por categorias e seleção dos algoritmos de aprendizado de máquinas, a última etapa do trabalho foi a elaboração e execução do processo em linguagem R para geração da classificação de problemas de desempenho em células de redes RAN 4G. Para tal, a base coletada foi dividida em base treino e base teste, seguindo uma divisão de 70% de cada classificação para a base treino e 30% de cada classificação para a base teste. As etapas do processo são descritas nas sessões seguintes.

3.2 SELEÇÃO DOS INDICADORES DE DESEMPENHO

A seleção dos indicadores de desempenho foi baseada em dois fatores: a motivação para melhorar a experiência do usuário (3GPP, 2020) e a dificuldade de expressá-la objetiva e matematicamente. Finalmente, das seis categorias de KPIs definidos em 3GPP TS 32.450 (3GPP, 2019) e classificados como KPIs de Qualidade de Serviço, primeiramente foram selecionados oito KPIs individuais das três categorias com o maior impacto na experiência do usuário: acesso, retenção e mobilidade.

As principais características desses KPIs são a similaridade de suas equações e sua facilidade de normalização, pois todos são calculados como a média de dois ou mais contadores de desempenho e variam de 0 a 1, diferentemente do que ocorre com os KPIs de Integridade. A divisão entre KPIs de voz e de dados segue o que foi afirmado em *Telemanagement Forum Wireless Services Measurement Handbook GB923* (THE OPEN GROUP, 2004): redes de voz e dados têm sido provisionadas separadamente e os KPIs são considerados independentemente para cada serviço. Os KPIs selecionados e suas equações são descritos a seguir.

3.2.1 KPIs de Acesso

Acesso E-RAB (*Evolved UTRAN Radio Access Bearer*) é uma medida que mostra a probabilidade de um usuário ser provido com uma E-RAB após sua requisição. Esse tipo de KPI é percebido pelo usuário em serviço de dados como um atraso de conexão e tem forte impacto no serviço de voz, pois é percebido como uma indisponibilidade no serviço. Dois KPIs foram selecionados:

- 1) Acesso de dados E-RAB: KPI que mostra a probabilidade de sucesso para estabelecimento da E-RAB de dados (equação 1).

$$\begin{aligned} & ACC_ERAB_DATA \\ & = \frac{\text{Número de estabelecimento de ERAB de dados com sucesso}}{\text{Número de tentativas de estabelecimento de ERAB de dados}} \end{aligned} \quad (1)$$

- 2) Acesso VoLTE E-RAB: KPI que mostra a probabilidade de sucesso para estabelecimento da VoLTE E-RAB (equação 2).

$$\begin{aligned} & ACC_ERAB_VoLTE \\ & = \frac{\text{Número de estabelecimento de ERAB VoLte com sucesso}}{\text{Número de tentativas de estabelecimento de ERAB de dados}} \end{aligned} \quad (2)$$

3.2.2 KPIs de Retenção

Retenção da E-RAB é uma média que mostra a frequência com que o usuário perde uma E-RAB de uma forma anormal quando essa é utilizada. Esse tipo de KPI também é percebido pelo usuário final em um serviço de dados como um atraso de conexão, pois o serviço precisa ser restabelecido. Também afeta seriamente o serviço de voz, pois interrompe uma chamada de voz. O 3GPP define retenção como desconexões anormais de E-RAB por tempo de sessão em segundos; entretanto, neste trabalho, ele será medido como a taxa de desconexões anormais de E-RAB pelo total de desconexões E-RAB (normais e anormais), métrica amplamente utilizada pelas principais operadoras de rede RAN. Dois KPIs foram selecionados:

- 1) Retenção de Dados E-RAB: KPI que mostra a porcentagem do número de desconexões anormais de E-RAB com dados no *buffer* (equação 3).

$$\begin{aligned} & RET_ERAB_DATA \\ & = \frac{\text{Número de desconexões anormais de ERABs de dados}}{\text{Número total de desconexões de ERABs de dados}} \end{aligned} \quad (3)$$

- 2) Retenção de VoLTE E-RAB: KPI que mostra a porcentagem do número de desconexões anormais de VoLTE E-RABs com dados no *buffer* (equação 4).

$$RET_ERAB_VoLTE = \frac{\text{Número de desconexões anormais de ERABs VoLTE}}{\text{Número total de desconexões de ERABs VoLTE}}. \quad (4)$$

Uma desconexão de E-RAB é somente considerada anormal se a E-RAB assume que havia dados esperando para serem transferidos no *buffer* (ITU, 2006).

3.2.3 KPIs de Mobilidade

Mobilidade é um procedimento em que o usuário muda de célula servidora em modo conectado, definido pelo 3GPP com o nome de *Handover* (HO) (3GPP, 2023). O 3GPP inclui a mobilidade agregada entre mesmas frequências e entre frequências diferentes. Entretanto, nesse trabalho, consideramos como KPIs separados, pois eles afetam os serviços de dados e VoLTE de forma diferente. Falhas de mobilidade podem causar atrasos nas transferências de dados e degradação na chamada de voz, afetando a percepção do usuário. Dois KPIs foram selecionados:

- 1) Mobilidade Intra-frequência: KPI que mostra como a mobilidade está funcionando na mesma frequência LTE (equação 5)

$$INTRA_HO_DATA = \frac{\text{Número de HO intrafrequency realizados com sucesso}}{\text{Número de tentativas de HO intrafrequency}} \quad (5)$$

- 2) Mobilidade Inter-Frequência: KPI que mostra como a mobilidade está funcionando entre frequências LTE diferentes (equação 6).

$$INTER_HO_DATA = \frac{\text{Número de HO interfrequency realizados com sucesso}}{\text{Número de tentativas de HO interfrequency}} \quad (6)$$

Outro processo considerado ao avaliar problemas relacionados à mobilidade é a Continuidade Única de Chamadas de Voz por rádio (*Single Radio Voice Call Continuity* – SRVCC), que é a continuidade entre chamadas de voz no VoLTE e acesso comutado por circuito (WCDMA ou GSM RATs) (3GPP, 2020). O procedimento SRVCC pode ser considerado um caso particular de transferência de chamada, iniciando quando a cobertura ou qualidade da chamada VoLTE está ruim. A sessão é transferida para uma RAT diferente para manter a chamada ativa.

O procedimento SRVCC consiste em duas etapas: preparação SRVCC e execução SRVCC. A preparação SRVCC não impacta diretamente o usuário final, mas pode indicar um cenário de falha. A execução SRVCC afeta fortemente o usuário final, gerando interrupções na chamada de voz. Portanto, ambos KPIs relacionados ao SRVCC são selecionados:

- 3) Preparação SRVCC: KPI que mostra a taxa de sucesso da primeira etapa do SRVCC, preparando a transferência SRVCC, começando quando o dispositivo do usuário recebe o comando de transferência (QUALCOMM, 2012) (equação 7).

$$SRVCC_PREP = \frac{\text{Número de Preparações SRVCC realizadas com sucesso}}{\text{Número de tentativas de Preparação SRVCC}} \tag{7}$$

4) Execução SRVCC: KPI que mostra a taxa de sucesso da segunda etapa, que ocorre quando o dispositivo do usuário executa a transferência após o sucesso na etapa anterior (QUALCOMM, 2012) (equação 8).

$$SRVCC_EXE = \frac{\text{Número de Execuções SRVCC realizadas com sucesso}}{\text{Número de tentativas de Preparação SRVCC}} \tag{8}$$

3.3 COLETA DOS DADOS

Foram coletados os indicadores QoS que formam os KPIs selecionados na sessão 3.1, no período mencionado na sessão 1.4. Após a coleta dos dados, foi criada uma base de dados em MySQL para armazenar os dados coletados. Foi criada a tabela “cells_kpis” com os campos correspondentes aos KPIs, armazenados por célula, conforme indicados nas Figuras 9 e 10.

A Tabela 1 mostra um exemplo da base de dados gerada após a coleta dos indicadores e cálculo dos KPIs selecionados.

Tabela 1 - Exemplo dos dados coletados.

Cell	ACC_RRC_DATA	ACC_ERAB_DATA	ACC_ERAB_VOLTE	RET_ERAB_DATA	RET_ERAB_VOLTE	INTRA_HO_DATA	INTER_HO_DATA
Cell 1	6.78106	98.64728	98.53387	95.28871	92.20036	85.89750	99.71671
Cell 2	17.41726	99.57477	99.46333	98.80641	98.48901	96.32791	98.50746
Cell 3	28.20513	100.00000	100.00000	87.55556	0.00000	90.90909	100.00000
Cell 4	99.94583	100.00000	100.00000	99.77990	0.00000	98.14815	100.00000
Cell 5	62.64452	99.50839	99.21756	98.95559	95.20898	95.35956	99.55556

Fonte: Elaborada pelo autor com base no software MySQL Workbench (2023).

Figura 9 – Estrutura da tabela cells_kpis.

The screenshot shows the MySQL Workbench interface for the 'cells_kpis' table. The table name is 'cells_kpis', schema is 'ttc', charset is 'utf8mb4', and engine is 'InnoDB'. The table structure is as follows:

Column Name	Datatype	PK	NN	UQ	B	UN	ZF	AI	G	Default/Expression
Cell	TEXT	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	NULL
ACC_RRC_DATA	DOUBLE	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	NULL
ACC_ERAB_DATA	DOUBLE	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	NULL
ACC_ERAB_VOLTE	DOUBLE	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	NULL
RET_ERAB_DATA	DOUBLE	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	NULL
RET_ERAB_VOLTE	DOUBLE	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	NULL
Intra_HO_Data	DOUBLE	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	NULL
Inter_HO_Data	DOUBLE	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	NULL

Fonte: Elaborada pelo autor com base no software MySQL Workbench (2023).

Figura 10 – Representação do banco de dados MySQL e seleção dos dados coletados.

Cell	ACC_RRC_DATA	ACC_ERAB_DATA	ACC_ERAB_VOLTE	RET_ERAB_DATA	RET_ERAB_VOLTE	Intra_HO_Data	Inter_HO_Data
Cell_1	6.781060495	98.64727615	98.5338726	95.28871014	92.20035778	85.89749938	99.71671388
Cell_2	17.41725601	99.57476575	99.46332737	98.80641199	98.48901099	96.32790966	98.50746269
Cell_3	28.20512821	100	100	87.55555556	0	90.90909091	100
Cell_4	99.94982882	100	100	99.77989729	0	98.14814815	100
Cell_5	62.64491836	99.50839058	99.2175614	98.95559321	95.20899493	95.38955594	99.55555556
Cell_6	99.06103286	100	100	98.81422925	50	100	92.59259259
Cell_7	73.62010105	99.49282616	99.59016393	99.45844793	98.21673525	97.72771792	99.58246347
Cell_8	85.26439311	70.79046335	99.51612903	97.33187619	98.17880795	97.76941536	99.32424242
Cell_9	69.13400915	98.95132593	98.83907841	89.75171257	89.83739837	92.64489405	97.82608696
Cell_10	94.85403266	76.25205011	100	98.60997547	71.42857143	82.85714286	100
Cell_11	99.91480951	80.16040507	99.18397626	96.3735591	93.27309237	98.51656167	75.46235472
Cell_12	98.67982606	82.89164232	99.12109375	99.73655999	99.90892532	99.13385124	99.10596512
Cell_13	99.52830189	96.19047619	0	80.24193548	0	0	100
Cell_14	80.60088257	97.37288865	98.49094567	94.2217283	96.2254902	91.23372097	99.45788157
Cell_15	82.29679328	98.7650856	97.43589744	96.91812903	90	77.31341284	100
Cell_16	85.06761214	99.54818305	99.61685824	99.30842125	95.93405935	98.46308894	99.8729352
Cell_17	94.64357121	85.58218679	99.4486692	98.11677265	99.2799347	97.50106077	100
Cell_18	87.43570504	87.77583628	98.59528227	90.12944867	92.8359317	87.31694633	100
Cell_19	89.57117483	86.31989258	99.15844457	94.7347564	93.61702128	93.33564509	99.75490196
Cell_20	99.72669453	88.18256671	99.21534438	97.32709836	87.95539033	97.36754044	83.73549884
Cell_21	90.33623255	99.3089514	96.33699634	98.08497946	77.44665217	93.24527169	100
Cell_22	86.68128905	97.77848168	98.4375	93.81224836	86.90824079	90.76539816	99.70149254
Cell_23	87.78562281	90.49704899	99.3622449	94.91461983	95.75144169	89.75340979	97.97979798
Cell_24	89.82459275	89.04252706	98.62985685	93.38265516	96.00416956	89.73352034	99.86338798
Cell_25	91.98356838	89.54627519	98.58089311	95.60082511	95.62043796	95.18499914	100
Cell_26	97.37984754	94.28180713	93.65589112	96.83969562	77.36351531	93.80722906	100
Cell_27	97.30094467	96.73807066	96.15384615	97.02162383	74.13354839	87.85046729	100
Cell_28	93.08518458	89.91245278	99.2540097	93.8770346	95.6088401	89.87583961	100


Fonte: Elaborada pelo autor com base no software MySQL Workbench (2023).

3.4 DESENVOLVIMENTO DO PROCESSO DE CLASSIFICAÇÃO DE CÉLULAS

As principais dificuldades em classificar todas as células em uma rede são o grande número de objetivos quantificáveis e o grande número de alternativas não predefinidas (centenas de KPIs e milhares de células LTE). Além disso, esse problema poderia ser associado a métodos contínuos de MCDM. Porém o número de células, ainda que vasto, pode ser delimitado por um conjunto formado pela área ou cidade a ser monitorada, e os KPIs podem ser selecionados e quantificados de acordo com a importância e situação específica definida pelos operadores de rede, o que poderia, em oposição, ser associado a métodos discretos.

Como solução apresentada, adotou-se o uso de métodos discretos de MCDM para resolver esse problema, em que, embora as alternativas sejam numerosas e não predefinidas (células com falhas), há um conjunto de objetivos quantificáveis (KPIs selecionados). Portanto, com base na ampla classificação de métodos MCDM apresentada por Zavadskas et al. (2014), o presente problema poderia ser associado a uma nova categoria de problemas ainda não considerada, situada na interseção entre problemas discretos e problemas contínuos, denominada problemas amplos (*Broad Problems*) (Figura 11). Essa classificação teria como características um amplo número de alternativas associado a um conjunto de objetivos quantificáveis.

Figura 11 – Proposta de uma nova classificação dos métodos MCDM.



Fonte: Adaptada de ZAVADSKAS et al (2014).

Para realizar o processo de classificação, foi adotada a função utilidade, que possibilita medir a desejabilidade de preferir diferentes objetos, chamados de alternativas. O índice de utilidade é o grau de bem-estar que cada uma dessas alternativas fornece ao tomador de decisão. A função utilidade compreende vários critérios que avaliam a utilidade global de uma alternativa. Para cada critério, o tomador de decisão atribui um índice de utilidade marginal. Uma vantagem de definir funções utilidade é que as opções do problema de decisão recebem uma pontuação global. Os índices de utilidade marginal dos critérios são agregados para produzir a pontuação de utilidade global. Essa pontuação torna possível comparar todas as opções e classificá-las da melhor para a pior, com classificações iguais permitidas. Uma pontuação ruim em um critério pode ser compensada por uma boa pontuação em outro (ISHIZAKA; NEMERY, 2013). Essa abordagem é chamada de abordagem de agregação completa.

Ishizaka e Nemery (2013) afirmam que, se a função utilidade para cada critério (uma representação da utilidade percebida em relação ao desempenho da opção em um critério específico) for conhecida, então a teoria da utilidade multi-atributo é recomendada. É o caso do presente problema, onde os critérios são os KPIs selecionados, cada um com uma função definida. Como todos os KPIs selecionados são uma proporção, eles variam do intervalo de 0 a 1. Portanto o método MAUT pode ser utilizado para construir a função utilidade.

O método proposto envolve duas etapas principais, que são descritas nos itens subsequentes.

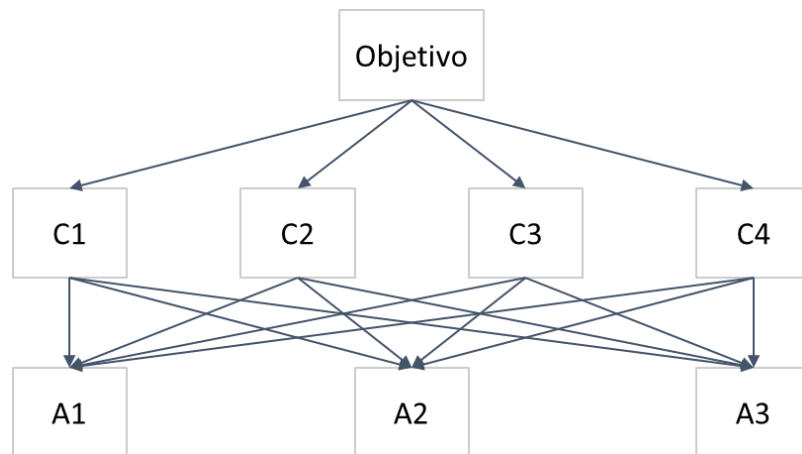
3.4.1 Definição dos Pesos utilizando o método AHP

Para construir a função utilidade, deve-se definir os pesos para cada um dos KPIs selecionados. O método AHP foi escolhido para este fim, pois se baseia em estruturas hierárquicas simples para representar problemas de decisão (SAATY, 2013). Os pesos são encontrados calculando-se pontuações (ou prioridades, como são chamadas no AHP) com base nas comparações em pares fornecidas pelo usuário (ISHIZAKA; NEMERY, 2013). O método,

introduzido por Saaty (1980), é um processo de tomada de decisão baseado na habilidade inata do ser humano de usar informações e experiências para estimar magnitudes relativas por meio de comparações em pares. Essas comparações são usadas para construir escalas de razão de várias dimensões, organizadas em uma estrutura hierárquica que permite um procedimento sistemático para organizar o raciocínio básico e a intuição, dividindo um problema em partes menores. Assim, o AHP leva de julgamentos superficiais de comparação em pares às prioridades na hierarquia (SAATY, 2013).

O problema, considerado pelo método, é estruturado de acordo com uma hierarquia, onde o elemento mais alto é o objetivo da decisão. O segundo nível da hierarquia representa os critérios (Cn), e o nível mais baixo representa as alternativas (An). Em hierarquias mais complexas, mais níveis podem ser adicionados para representar subcritérios. Não obstante, há um mínimo de três níveis na hierarquia, conforme representação da Figura 12.

Figura 12 – Representação da hierarquia dos níveis de decisão AHP.



Fonte: Adaptada de Ishizaka e Nemery (2013).

Para definir os pesos dos KPIs selecionados, o AHP é implementado em três etapas, seguindo o procedimento descrito por Dudnikova et al. (2015).

- 1) O problema é decomposto em suas partes constituintes, ou critérios, que são os KPIs descritos na subseção anterior (resumidos na Tabela 2).

Tabela 2 – KPIs selecionados.

Categoria	Serviço	KPI
Acesso	Dados	ACC_ERAB_DATA
	Voz	ACC_ERAB_VoLTE
Retenção	Dados	RET_ERAB_DATA
	Voz	RET_ERAB_VoLTE
Mobilidade	Dados	INTRA_HO_DATA
	Dados	INTER_HO_DATA
	Voz	SRVCC_PREP
	Voz	SRVCC_EXE

Fonte: Elaborada pelo autor (2023).

- 2) É atribuído um valor de importância relativa a cada critério por meio de comparação em pares. A escala fundamental, ou escala Saaty, apresentada no Quadro 1 (SAATY, 2013), é utilizada para classificar o julgamento introduzido na Tabela 2. Nas redes LTE, a voz é um serviço de dados (VoLTE), e segue os critérios de qualidade mais rigorosos, já que a voz é suscetível a atraso, *jitter* e perda (THE OPEN GROUP, 2004); portanto o método proposto neste trabalho atribui maior importância aos KPIs de voz do que aos outros KPIs.

Quadro 1 - Escala Fundamental.

Importância	Definição	Explicação
1	Importância Igual	Dois fatores contribuem igualmente ao objetivo.
3	Importância Moderada	Experiência e julgamento favorecem levemente um fator ao outro.
5	Importância Forte	Experiência e julgamento favorecem fortemente um fator sobre o outro.
7	Importância Muito Forte	Um favor é favorecido muito fortemente sobre o outro; sua dominância é demonstrada em prática.
9	Importância Extrema	A evidência favorecendo um fator sobre o outro é a ordem de afirmação mais alta possível.
2,4,6,8	Valores intermediários sobre os julgamentos adjacentes.	

Fonte: Adaptado de SAATY (2013).

Os julgamentos quantificados sobre pares de critérios são representados pela seguinte matriz $j \times j$ A (equação 9):

$$A = \begin{bmatrix} 1 & a_{12} & \cdots & a_{1j} \\ 1/a_{12} & 1 & \cdots & a_{2j} \\ \vdots & \vdots & \ddots & \vdots \\ 1/a_{j1} & 1/a_{2j} & \cdots & 1 \end{bmatrix} \quad (9)$$

- 3) O autovetor w da matriz A é calculado usando o método da média geométrica (PERVAIZ; BIGHAM, 2009) (equação 10), e os pesos relativos dos fatores (ω_j) são derivados dos componentes do autovetor normalizado (DUDNIKOVA et al., 2015) (equação 11):

$$w_j = (\prod a_{jj})^{1/q} \quad (10)$$

$$\omega_j = \frac{w_j}{\sum_{j=1}^q w_j} \quad (11)$$

A matriz A , o autovetor e os pesos relativos calculados a partir das equações apresentadas são mostrados na Tabela 3.

Tabela 3 – Correlação par-a-par entre KPIs.

	RET_ ERAB_ VoLTE	ACC_ ERAB_ VoLTE	RET_ ERAB_ DATA	ACC_ ERAB_ DATA	INTER_ HO_ DATA	INTRA_ HO_ DATA	SRVCC _PREP	SRVCC _EXE	w	ω
RET_ ERAB_ VoLTE	1	3	6	5	9	9	9	9	5.2650	0.4276
ACC_ ERAB_ VoLTE	1/3	1	3	7	5	4	6	5	2.8373	0.2304
RET_ ERAB_ DATA	1/6	1/5	1	3	6	5	2	2	1.3643	0.1108
ACC_ ERAB_ DATA	1/5	1/7	1/3	1	3	3	2	2	0.8748	0.0710
INTER_ HO_ DATA	1/9	1/5	1/6	1/3	1	5	2	2	0.6296	0.0511
INTRA_ HO_ DATA	1/9	1/4	1/5	1/3	1/5	1	2	2	0.4429	0.0360
SRVCC_ PREP	1/9	1/6	1/2	1/2	1/2	1/2	1	9	0.5652	0.0459
SRVCC_ EXE	1/9	1/5	1/2	1/2	1/2	1/2	1/9	1	0.3339	0.0271

Fonte: Elaborada pelo autor (2023).

Como esperado, os KPIs de voz têm os pesos relativos mais altos, e a capacidade de retenção de chamadas VoLTE (RET_ERAB_VoLTE) possui o peso mais significativo.

Como as comparações realizadas no AHP são subjetivas, os erros de julgamento são inevitáveis e devem ser detectados pela verificação da taxa de consistência (CR) de A antes de selecionar os valores dos pesos. O CR é calculado conforme equação 12:

$$CR = \frac{CI}{RI}; CI = \frac{\lambda_{max} - q}{q - 1} \quad (12)$$

Onde CI é um índice de consistência, e representa o desvio do autovalor máximo da matriz A (λ_{max}) do número de critérios usados no processo de comparação (q). RI é um índice aleatório, sendo o CI médio de uma matriz recíproca gerada aleatoriamente. Todos os valores de RI para diferentes dimensões de matriz são fornecidos por Saaty (2013). Se CR for igual a zero, a matriz é perfeitamente consistente. Se $CR \leq 0,1$, os valores de peso avaliados são aceitáveis (DUDNIKOVA et al., 2015). O λ_{max} é calculado conforme equação 13:

$$\lambda_{max} = \left[\sum_{j=1}^q a_{j1} \quad \cdots \quad \sum_{j=1}^q a_{jq} \right] \cdot \begin{bmatrix} \omega_1 \\ \cdots \\ \omega_j \end{bmatrix} \quad (13)$$

No presente problema, $\lambda_{max} = 8.9276$, $CI = 0.1325$, $RI = 1.41$, e $CR = 0.0940$; portanto $CR \leq 0.1$, e os pesos relativos obtidos são consistentes.


3.4.2 Geração da função utilidade utilizando o método MAUT

Uma das abordagens mais facilmente compreensíveis para a análise de decisão é a teoria de utilidade multi-atributo (MAUT), de Keeney e Raiffa (1993). A MAUT é baseada na hipótese de que todo tomador de decisão tenta otimizar, consciente ou implicitamente, uma função que agrega todos os seus pontos de vista. Isso significa que as preferências do tomador de decisão podem ser representadas pela função utilidade U. Cada alternativa do conjunto A é avaliada com base na função U, e recebe uma pontuação de utilidade U(a) (um exemplo é mostrado na Figura 13). Essa pontuação de utilidade permite que todas as alternativas sejam classificadas da melhor para a pior (ISHIZAKA; NEMERY, 2013). As relações de preferência e indiferença entre as outras opções de A são definidas conforme equações 14 e 15:

$$\forall a, b \in A: a P b \Leftrightarrow U(a) > U(b): a \text{ é preferido a } b; \quad (14)$$

$$\forall a, b \in A: a P b \Leftrightarrow U(a) = U(b): a \text{ e } b \text{ são indiferentes.} \quad (15)$$

Figura 13 – Representação do ranqueamento do modelo MAUT.



Fonte: Adaptada de Ishizaka e Nemery (2013).

A função utilidade é definida utilizando o modelo aditivo, que é o modelo mais popular e amplamente utilizado. Nesse modelo, a soma ponderada simples é um caso particular em que U_j são todas funções lineares (ISHIZAKA; NEMERY, 2013). O índice de utilidade corresponde à equação 16:

$$\forall a_i \in A: U(a_i) = U(f_1(a_i), \dots, f_q(a_i)) = \sum_{j=1}^q U_j(f_j(a_i)) \cdot \omega_j \quad (16)$$

Onde q é o número de critérios, ω_j é o peso do critério f_j , e $U_j(f_j) \geq 0$. Eles geralmente satisfazem a restrição de normalização, conforme equação 17 (ISHIZAKA; NEMERY, 2013):

$$\sum_{j=1}^q \omega_j = 1 \quad (17)$$

A função utilidade marginal é tal que a melhor alternativa em um critério específico tem uma pontuação de utilidade marginal de 1, e a pior opção tem uma pontuação de 0 no mesmo critério.

O método proposto usa a soma ponderada simples para construir a função utilidade para cada célula LTE, considerando os oito KPIs selecionados como critérios (a_i), os pesos relativos obtidos pelo método AHP, e o número de falhas para cada KPI. O número de falhas é necessário para evitar a atribuição de uma pontuação alta a uma célula com KPIs degradados, mas com um número baixo de falhas devido ao baixo tráfego.

A função é então normalizada, dividindo-se a soma ponderada pela soma dos pesos multiplicada pelas falhas de cada KPI, conforme apresentado na equação 18:

$$\forall a_i \in A: U(a_i) = \frac{\sum_{j=1}^q U_j(f_j(a_i)) \cdot \omega_j \cdot Fails_j}{\sum_{j=1}^q \omega_j \cdot Fails_j} \quad (18)$$

O número de falhas de cada KPI é calculado como a diferença entre o número de tentativas e o número de sucessos de cada indicador, conforme equação 19:

$$Fails_j = Number\ of\ attempts_j - Number\ of\ successes_j \quad (19)$$

3.5 DEFINIÇÃO DAS CATEGORIAS DE PROBLEMAS DE DESEMPENHO

Conforme mencionado na sessão 1.4, foram utilizados os dados de uma rede de telefonia móvel real por conterem as análises dos problemas de cada célula 4G, realizadas pelos engenheiros de RF responsáveis pelo monitoramento e otimização da região (O Quadro 2 mostra um exemplo de análises e classificações coletadas) . Esses dados são de suma importância para o treinamento dos algoritmos de aprendizado de máquina, servindo como variável de saída das variáveis de entrada (os KPIs de desempenho). Impôs-se um desafio no tratamento desses dados, pois as análises não foram realizadas de forma estruturada, contendo textos e classificações distintas utilizadas por cada engenheiro.

Sendo assim, a primeira etapa de classificação foi estruturar e reduzir a variável de saída em categorias sucintas que pudessem ser classificadas pelos algoritmos de aprendizado de máquina. Foram consideradas mais de 80 diferentes análises, as quais foram classificadas finalmente em nove categorias distintas, conforme Tabela 4. As classificações dos problemas seguiram uma ordem de importância, sendo a categoria “Disponibilidade” a mais importante, e a categoria “Baixo Tráfego” a menos importante. Todas as análises com problemas sem identificação foram classificadas na categoria “Otimização”. Por fim, todas as células consideradas sem degradação (KPIs com níveis maiores que 99%) foram classificadas como “OK”.

Quadro 2 - Exemplo de classificação das análises.

Análise	Classificação
<i>Histerese A3 offset</i>	<i>Mobilidade</i>
<i>Problema de acesso da célula não identificado</i>	<i>Otimização</i>
<i>Configuração do tilt da antena</i>	<i>Cobertura</i>
<i>Interferência no canal PUCCH</i>	<i>Interferência</i>
<i>Problemas de inter-freq HO com muita antecedência</i>	<i>Mobilidade</i>
<i>Problemas de inter-freq HO com muito atraso</i>	<i>Mobilidade</i>
<i>Problema bidirecional</i>	<i>Cobertura</i>
<i>Sobreposição de cobertura</i>	<i>Cobertura</i>
<i>Problema de disponibilidade na célula</i>	<i>Disponibilidade</i>
<i>Cell individual offset</i>	<i>Configuração</i>
<i>Célula isolada</i>	<i>Cobertura</i>
<i>Cobertura estendida da célula</i>	<i>Cobertura</i>
<i>Capacidade limitada</i>	<i>Alta Carga</i>
<i>Potência configurada errada</i>	<i>Cobertura</i>
<i>CQI impactado</i>	<i>Mobilidade</i>
<i>CRSGain baixo</i>	<i>Cobertura</i>
<i>Cobertura indoor</i>	<i>Cobertura</i>
<i>Degradação não identificada</i>	<i>Otimização</i>
<i>Falha de Core</i>	<i>Equipamento</i>

Fonte: Elaborado pelo autor (2023).

Tabela 4 – Categorias de classificação das células com problemas de desempenho.

Categoria	Importância	Células	Percentual
Disponibilidade	1	150	9%
Equipamento	2	735	42%
Interferência	3	47	3%
Cobertura	4	216	12%
Alta Carga	5	33	2%
Mobilidade	6	28	2%
Otimização	7	181	10%
Baixo Tráfego	8	35	2%
OK	9	317	18%
TOTAL		1742	

Fonte: Elaborada pelo autor (2023).

3.6 DESENVOLVIMENTO DO PROCESSO DE DIAGNÓSTICO DAS CÉLULAS

Para geração dos resultados dos testes, foram desenvolvidos 3 processos alternativos: o primeiro utilizando o algoritmo de *Árvore de Decisão*, o segundo utilizando o algoritmo de *Random Forest*, e o terceiro utilizando o algoritmo *Extreme Gradient Boosting*. Eles são abordados a seguir.

3.6.1 Uso do Algoritmo de Árvore de Decisão


Esse processo utilizou a função *rpart* da biblioteca *rpart* para execução do algoritmo de Árvore de Decisão, utilizando a função *printcp* para definição dos valores do hiper parâmetro Custo de Complexidade (CP – *Complexity Parameter*) da árvore. A Tabela 5 apresenta os resultados obtidos para diversos valores de CP, sendo: *nsplit* o número de divisões (*splits*) da árvore (seu valor indica o tamanho da árvore), *rel error* o Erro Relativo do Algoritmo, que provê a medida de quão bem o algoritmo generaliza (um valor menor indica melhor generalização), *xerror* o Erro do Algoritmo, que estima o quão bem ele irá desempenhar para dados novos, e *xstd* o Desvio Padrão do Algoritmo, que fornece uma ideia da variabilidade de seu desempenho (um valor menor sugere um desempenho mais estável e consistente). Para otimização dos resultados da árvore, foi utilizado o método *Grid Search manual*, com variação do CP para avaliar o melhor resultado do algoritmo e definir o melhor tamanho da árvore, conforme representação do resultado na Figura 14.

Tabela 5 - Valores do Custo de Complexidade gerados pela função *printcp*.

CP	nsplit	rel error	xerror	xstd
0.063402889	0	1	1	0.02796589
0.024077047	2	0.87319422	0.8876404	0.0278622
0.020866774	4	0.82504013	0.8651685	0.02779659
0.015248796	5	0.80417335	0.8330658	0.02767656
0.011235955	7	0.77367576	0.8250401	0.02764168
0.008025682	9	0.75120385	0.812199	0.02758177
0.006420546	10	0.74317817	0.8330658	0.02767656
0.0058855	11	0.73675762	0.8443018	0.02772211
0.004815409	14	0.71910112	0.8507223	0.02774643
0.004494382	16	0.7094703	0.8507223	0.02774643
0.003745318	31	0.62760835	0.8603531	0.02778057
0.0035313	34	0.61637239	0.8619583	0.02778599
0.003210273	39	0.59871589	0.882825	0.02784941
0.002889246	76	0.47030498	0.8956661	0.02788198
0.002407705	86	0.43980738	0.9438202	0.02796058
0.002140182	90	0.43017657	0.9614767	0.02797226
0.001926164	117	0.35955056	0.9630819	0.02797287
0.001605136	122	0.34991974	1.0288925	0.02793243
0.001337614	291	0.06902087	1.035313	0.02792165
0.001284109	304	0.05136437	1.0433387	0.02790646
0.001203852	310	0.04333868	1.0433387	0.02790646
0.001146526	314	0.03852327	1.0513644	0.02788936
0.001070091	321	0.03049759	1.0513644	0.02788936
0.000802568	333	0.0176565	1.0513644	0.02788936
0	355	0	1.0577849	0.0278743

Fonte: Elaborada pelo autor com base nos resultados da biblioteca *rpart* (2023).

Figura 14 – Representação da variação do tamanho da árvore em relação a seu erro relativo.



Fonte: Elaborada pelo autor com base no resultado da linguagem “R” (2023).

3.6.2 Uso do Algoritmo *Random Forest*

Esse processo utilizou duas funções distintas para executar o algoritmo *Random Forest*, a função *randomForest*, da biblioteca *randomForest*, para execução do processo inicial, e a função *train* da biblioteca *caret* para otimização dos resultados da *Random Forest*. Configurou-se seu método como *rf* e sua métrica como *Accuracy*, para que a função fosse executada para resolução de problemas de classificação. Para configuração dos hiper-parâmetros da última função por meio da metodologia *grid search*, utilizou-se a função *traincontrol* da biblioteca *caret*, com a função de problemas de múltiplas categorias (*summaryFunction = multiClassSummary*). Nessa última função, foi utilizada a técnica de *cross-validation* denominada *k-fold*, com 8 *folds* e 4 repetições.

3.6.3 Uso do Algoritmo *Extreme Gradient Boosting*

Assim como o algoritmo da *Random Forest*, o terceiro processo utilizou também a função *train*, da biblioteca *caret*, para otimização dos resultados, porém configurando seu método como *xgbTree*. Para configuração dos hiper-parâmetros por meio da metodologia *grid search*, utilizou-se a função *traincontrol*, da biblioteca *caret*, com a função de problemas de múltiplas categorias (*summaryFunction = multiClassSummary*). Nessa última função, foi utilizada a técnica de *cross-validation k-fold*, com 10 *folds*, por meio do método *cv* da função.

4 RESULTADOS E DISCUSSÃO

4.1 CLASSIFICAÇÃO DAS CÉLULAS

Primeiramente, foi realizada a amostragem estatística dos dados dos oito KPIs selecionados, agregando os contadores em uma base de 24 horas, sendo a função de utilidade U (equação 18) aplicada às células. Em seguida, as funções utilidade das células foram classificadas em ordem inversa, da pior para a melhor, para identificar rapidamente as células mais degradadas. Os resultados são apresentados em um painel (conforme exemplo da Tabela 7), com as células rotuladas, começando com a Célula 0 até a Célula 4925.

Os valores dos KPIs no painel são classificados em três faixas, para facilitar o monitoramento visual:

- 1) Crítico: De 0 to 0,50, indicando os valores mais críticos;
- 2) Alarmante: De 0,50 to 0,99, indicando valores intermediários;
- 3) OK: de 0,99 a 1, indicando os valores mais altos.

Os valores de utilidade seguem a mesma classificação, variando de 0 a 1, com valores críticos entre 0 e 0,50. Como exemplo dos resultados obtidos, a Tabela 7 reproduz o resultado para um dia específico, mostrando as dez primeiras células. A função utilidade permite que os oito KPIs das células sejam agregados em um único indicador, facilitando sua classificação. Além disso, apenas 0,20% das células apresentam valores abaixo de 0,50, reduzindo significativamente o número de células críticas do universo selecionado que precisam ser gerenciadas e sanadas, e destacando as piores células em termos de QoS, que são os principais objetivos do processo proposto.

No dia da análise, a célula 3083 foi classificada como a pior célula, pois a preparação do SRVCC teve um desempenho muito ruim, seguida pela execução do SRVCC e KPIs de mobilidade. No entanto, a célula não tinha alarmes ativos ou outros problemas operacionais e não foi identificada pelo gerenciamento de falhas tradicional. Fundamentalmente, embora a célula 3083 não tenha sido a célula com mais falhas, seu impacto na rede foi enorme, pois as falhas estavam concentradas na mobilidade VoLTE, que o usuário final teria percebido como degradação da qualidade de voz. A Tabela 6 mostra todas as medições da Célula 3083 usadas para calcular sua Função Utilidade, conforme detalhado na equação (20).

$$U(3083) = \frac{\sum_{j=1}^q U_j(f_j(3083)) \cdot \omega_j \cdot Fails_j}{\sum_{j=1}^q \omega_j \cdot Fails_j} \quad (20)$$

onde

$$\sum_{j=1}^q U_j(f_j(3083)) \cdot \omega_j \cdot Fails_j = 0.9923 \cdot 0.4276 \cdot 1 + 1 \cdot 0.2304 \cdot 0 + 0.9996 \cdot 0.1108 \cdot 10 + 0.9998 \cdot 0.0710 \cdot 3 + 0.9870 \cdot 0.0511 \cdot 76 + 0.9852 \cdot 0.0360 \cdot 119 + 0.0026 \cdot 0.0459 \cdot 2267 + 0.8333 \cdot 0.0271 \cdot 1$$

e

$$\sum_{j=1}^q \omega_j \cdot Fails_j = 0.4276 \cdot 1 + 0.2304 \cdot 0 + 0.1108 \cdot 10 + 0.0710 \cdot 3 + 0.0511 \cdot 76 + 0.0360 \cdot 119 + 0.0459 \cdot 2267 + 0.0271 \cdot 1$$

Tabela 6 – Indicadores da célula 3083.

KPI	Sucesso	Tentativas	Falhas	Valor	Peso
VoLTE_RET	129	130	1	0.9923	0.4276
VoLTE_ACC	130	130	0	1.0000	0.2304
RET_ERAB	25776	25786	10	0.9996	0.1108
ACC_ERAB	19505	19508	3	0.9998	0.0710
HO_INTRA	7912	8031	76	0.9870	0.0511
HO_INTER	5762	5838	119	0.9852	0.0360
SRVCC_PREP	6	2273	2267	0.0026	0.0459
SRVCC_EXE	5	6	1	0.8333	0.0271

Fonte: Elaborada pelo autor (2023).

Outro resultado significativo da aplicação do processo proposto é mostrado pela análise das células 0574 e 0573. São células vizinhas e apresentam valor zero nos KPIs VoLTE. No entanto, eles não tiveram falhas de VoLTE, o que indica que não há tráfego nesse serviço, mesmo que os KPIs que afetam sua função de utilidade sejam de conexão de dados. No entanto, a falta de tráfego VoLTE também pode indicar uma falha de configuração e deve ser investigada pelos gestores de desempenho das células.

Uma análise geral dos resultados das piores células da rede pode fornecer aos engenheiros informações valiosas sobre sua integridade, pois agrega os KPIs de rádio LTE mais relevantes. Por exemplo, os valores dos KPIs das piores células da Tabela 7 mostram que os problemas de rede estão concentrados nos indicadores de mobilidade e SRVCC, o que significa que a mobilidade é a questão chave a ser abordada.

Tabela 7 – Resultados da Função Utilidade (U) em células de uma rede LTE real.

Cell	U	Fails	RET_ ERAB_ VoLTE	ACC_ ERAB_ VoLTE	RET_ ERAB_ DATA	ACC_ ERAB_ DATA	INTER_ HO_ DATA	INTRA_ HO_ DATA	SRVCC _PREP	SRVC C EXE
Cell 3083	0.088	2477	0.9923	1.0000	0.9996	0.9998	0.9870	0.9852	0.0026	0.8333
Cell 2806	0.119	3056	0.9967	0.9882	0.9995	0.9972	0.9876	0.9815	0.0029	1.0000
Cell 1411	0.246	7761	0.9957	1.0000	0.9979	0.9963	0.1931	0.9863	1.0000	1.0000
Cell 1802	0.305	1490 5	0.9883	0.9881	0.9991	0.9993	0.2823	0.9426	1.0000	1.0000
Cell 2217	0.307	1482 2	0.9952	1.0000	0.9994	0.9993	0.9860	0.2809	0.0000	0.0000
Cell 1834	0.316	1735	0.9985	0.9977	0.9996	0.9985	0.9793	0.9895	0.0061	1.0000
Cell 0574	39.788	506	0.0000	0.0000	0.9993	0.9997	0.5068	0.3742	0.0000	0.0000
Cell 0862	40.363	124	0.9969	0.9973	0.9986	0.9997	0.9971	0.9311	0.0829	0.9810
Cell 0573	41.888	204	0.0000	0.0000	0.9987	0.9992	0.7213	0.3468	0.0000	0.0000
Cell 1417	42.469	420	1.0000	0.9939	0.9994	0.9986	0.3808	0.9668	1.0000	1.0000

Fonte: Elaborada pelo autor (2023).

4.2 DIAGNÓSTICO DAS CÉLULAS

4.2.1 Resultados Iniciais

Foi utilizada a métrica da Acurácia (razão entre os resultados obtidos com os resultados reais) como medição do nível de exatidão dos resultados obtidos pelos algoritmos de aprendizado de máquina na classificação dos problemas de desempenho de células 4G, utilizando-se as categorias definidas no trabalho. Utilizando-se os 8 KPIs selecionados inicialmente como variáveis de entrada, os resultados dos algoritmos foram considerados médios, em torno de 60% na base de teste. O resultado otimizado do algoritmo da Árvore de Decisão foi superior para a base de teste, com CP de 0.011235955 e tamanho da árvore de 7. A Tabela 8 mostra os resultados iniciais da acurácia obtida com os diferentes algoritmos.

Tabela 8 – Resultados iniciais da acurácia.

Algoritmo	Acurácia	
	Treino	Teste
Árvore de Decisão	59%	64%
Random Forest	100%	59%
Extreme Gradient Boosting	68%	60%

Fonte: Elaborada pelo autor (2023).

4.2.2 Inclusão do KPI de Integridade

No processo inicialmente proposto, optou-se por não utilizar KPIs de integridade, pois esses possuem diferentes variações de valores e maior dificuldade de comparação em relação aos demais tipos de KPIs; entretanto esses KPIs mostram como a rede impacta a qualidade do serviço provido ao usuário final (3GPP, 2019), sendo vinculados diretamente à sua experiência. Por isso, o KPI de DL Throughput foi incluído no processo ajustado para verificar sua importância.

O KPI de DL Throughput (equação 21) mede o volume em kbit trafegado na camada IP por segundo. Um baixo valor indica que a rede 4G está congestionada, com pouco recurso disponível ou que o usuário está em uma situação de baixa cobertura ou qualidade. A inclusão desse KPI teve por objetivo verificar se há aumento da acurácia do processo.

$$DL_Throughput_Data \text{ (kbit/s)} = \frac{\text{Volume trafegado em Downlink (kbit)}}{\text{Tempo em segundos (s)}} \quad (21)$$

4.2.3 Resultados Otimizados

Utilizando-se os 8 KPIs selecionados inicialmente mais o KPI de integridade DL Throughput como variáveis de entrada, os resultados de todos os algoritmos foram superiores, embora ainda considerados médios, em torno de 63% na base de teste. A inclusão desse KPI de integridade mostra a possibilidade de expansão do processo para inclusão de KPIs que representem a utilização dos recursos disponíveis da rede RAN, além dos KPIs de desempenho já incluídos, pois a disponibilidade de recursos torna-se cada vez mais escassa com o aumento de usuários e do tráfego na rede.

O resultado otimizado do algoritmo da Árvore de Decisão foi superior para a base de teste, obtido também com CP de 0.011235955 e tamanho da árvore de 7. A Tabela 9 mostra os resultados ajustados da acurácia para os algoritmos utilizados, após a inclusão do KPI de DL Throughput.

Tabela 9 – Resultados ajustados da acurácia.

Algoritmo	Acurácia	
	Treino	Teste
Árvore de Decisão	60%	65%
Random Forest	100%	63%
Extreme Gradient Boosting	87%	63%

Fonte: Elaborada pelo autor (2023).

5 CONCLUSÃO

O trabalho de pesquisa apresentado neste manuscrito propôs o uso de uma aplicação inovadora de métodos MCDM para análise de desempenho de redes RAN 4G e gerenciamento de falhas em suas células, classificando as células LTE de pior desempenho. Acredita-se que essa seja a primeira tentativa de utilizar métodos MCDM discretos para resolver problemas com objetivos quantificáveis onde as alternativas são numerosas e não predeterminadas.

Conforme mostrado no Capítulo anterior, conseguiu-se identificar células com desempenho muito baixo, sem alarmes operacionais ativos, que não poderiam ser identificadas por meio do gerenciamento tradicional de falhas. Ao classificar as células com base em uma função utilidade U que agrega os principais KPIs de QoS de rádio, o método proposto indica automaticamente as piores células a serem reparadas, auxiliando na melhoria da qualidade da rede de forma mais eficiente. Além disso, a função utilidade U pode filtrar células com base em objetivos de desempenho a serem analisados e reparados pelos engenheiros de rede. Essa abordagem pode reduzir o tempo consumido na identificação de células defeituosas que afetam o desempenho do usuário final, melhorando o desempenho percebido da rede LTE.

A classificação, o diagnóstico e o reparo rápido e eficiente das células com problemas de desempenho mais críticas podem ajudar as operadoras e os provedores de serviços de otimização de redes RAN 4G no gerenciamento de seu desempenho, satisfazendo mais rapidamente os requisitos de qualidade estabelecidos pelo governo ou por outras agências de fiscalização, por exemplo. Os pesos definidos pelo método AHP também podem ser adaptados às necessidades das operadoras – por exemplo, alterando as prioridades de voz para dados ou mobilidade – tornando o processo personalizável.

Os resultados obtidos do modelo de aprendizado de máquina para o diagnóstico dos problemas tiveram uma acurácia máxima de 65%, ainda considerada média, mas próxima do limiar de 70%, considerada uma acurácia alta. Sendo assim, os indicadores-chaves de desempenho selecionados conseguiram descrever bem os problemas de desempenho apresentados, sem a necessidade de coletas de alarmes de falhas em equipamentos, contadores de servidores ou outras coletas de difícil obtenção e volume dispendioso de dados. A coleta dos dados de análise e sua divisão em categorias foi de suma importância para o processo, pois serviu de treino para os algoritmos de aprendizado de máquina.

O resultado obtido pelo algoritmo *Random Forest* deve ser considerado com ressalvas, pois o resultado da acurácia em 100% para a base de treino indica uma possível existência de *overfitting* do processo. Já o algoritmo *Extreme Gradient Boosting* apresentou o melhor

resultado para a base de treino, indicando resultados mais robustos e melhor treino para o modelo, sendo finalmente o algoritmo mais indicado

O processo proposto também pode ser utilizado para classificar um grupo de células (por exemplo, clusters ou cidades), agregando os KPIs selecionados e calculando a função utilidade para cada grupo definido, ajudando a identificar variações de desempenho nesse grupo. Além disso, o processo pode ser adaptado para classificar células de outras tecnologias de acesso por rádio, como o 5G NR (*New Radio*), selecionando os KPIs mais importantes para cada tecnologia e aplicando os pesos e a função utilidade. Portanto o método descrito neste trabalho possui uma estrutura que pode ser adaptada a diferentes sistemas de gestão de desempenho.

A utilização do processo também pode reduzir significativamente o tempo para detectar uma célula com falha, além de identificar células com falha não detectadas na rede por meio de alarmes ou outros sistemas de gerenciamento de falhas. Ainda, os pesos e a priorização de KPIs podem ser alterados de acordo com as prioridades do cliente, sendo uma estrutura flexível que se adapta à gestão da rede. Algumas desvantagens do método também foram percebidas durante os testes, como células “adormecidas”, células com recursos suspensos e células de baixo tráfego, que não puderam ser bem detectadas. As células desligadas também se tornam inacessíveis e indetectáveis pelo processo, que não substitui os sistemas tradicionais de detecção de células defeituosas.

A abordagem proposta pode contribuir significativamente para o gerenciamento do desempenho de células em redes RAN. Apresentou-se um novo método de agregação de KPI para classificar as células LTE de pior desempenho com base em métodos MCDM, e diagnóstico automático por meio de algoritmos de aprendizado de máquina. Este trabalho também contribui para a literatura MCDM, apresentando seus métodos às funcionalidades do SON e aplicando-os a um grande conjunto de opções não predeterminadas.

REFERÊNCIAS

3GPP - 3RD GENERATION PARTNERSHIP PROJECT. Technical specification group services and system aspects. **TS 21.101**: technical specifications and technical reports for a utran-based 3GPP system. Version 3. Release 99. 2000.

3GPP - 3RD GENERATION PARTNERSHIP PROJECT. Technical Specification Group Services and System Aspects. **TS 21.101**: technical specifications and technical reports for a UTRAN-based 3GPP system. Version 8. Release 8. 2009.

3GPP - 3RD GENERATION PARTNERSHIP PROJECT. Technical specification group services and system aspects. **TS 23.216**: single radio voice call continuity (SRVCC); Stage 2. Release 16. 2020.

3GPP - 3RD GENERATION PARTNERSHIP PROJECT. Technical specification group services and system aspects. **TS 28.404**: Quality of Experience (QoE) Measurement Collection; Concepts, Use Cases and Requirements. Release 16. 2020.

3GPP - 3RD GENERATION PARTNERSHIP PROJECT. Technical specification group services and system aspects. **TS 32.401**: Performance Management (PM); Concept and Requirements. Release 15. 2018.

3GPP - 3RD GENERATION PARTNERSHIP PROJECT. Technical specification group services and system aspects. **TS 32.421**: Subscriber and Equipment Trace; Trace Concepts and Requirements. Release 11. 2015.

3GPP - 3RD GENERATION PARTNERSHIP PROJECT. Technical specification group services and system aspects. **TS 32.450**: Key performance indicators (KPI) for evolved universal terrestrial radio access network (E-UTRAN): Definitions. Release 15. 2019.

3GPP - 3RD GENERATION PARTNERSHIP PROJECT. Technical specification group services and system aspects. **TS 32.451**: key performance indicators (KPI) for evolved universal terrestrial radio access network (E-UTRAN): Requirements. Release 16. 2019.

3GPP - 3RD GENERATION PARTNERSHIP PROJECT. technical specification group services and system aspects. **TS 32.500**: Self-Organizing Networks (SON); Concepts and requirements. Release 16. 2020.

3GPP - 3RD GENERATION PARTNERSHIP PROJECT. Technical specification group services and system aspects. **TS 32.541**: Self-organizing networks (SON); Self-healing concepts and requirements. Release 16. 2020.

3GPP - 3RD GENERATION PARTNERSHIP PROJECT. Technical specification group services and system aspects. **TS 32.101**: 3GPP Telecommunication management; Principles and high level requirements. Release 17. 2022.

3GPP - 3RD GENERATION PARTNERSHIP PROJECT. Technical specification group radio access networks. **TS 36.300**: Evolved Universal Terrestrial Radio Access (E-UTRA) and Evolved Universal Terrestrial Radio Access Network (E-UTRAN); Overall description; Stage 2. Release 17. 2023.

ALHABO, M.; ZHANG, L. Multi-criteria handover using modified weighted TOPSIS methods for heterogeneous networks. **IEEE Access**, v. 6, p. 40547–40558, 2018.

BARCO, R.; LAZARO, P.; MUNOZ, P. A unified framework for self-healing in wireless networks. **IEEE Commun. Mag.**, v. 50, n. 12, pp. 134–142, 2012.

BOYSSOU, D. *et al.* **Evaluation and decision models with multiple criteria: stepping stones for the analyst.** New York: Springer, 2006.

DUDNIKOVA, A. *et al.* Multi-criteria decision for small cell switch off in ultra-dense LTE networks. *In: INTERNATIONAL CONFERENCE ON TELECOMMUNICATIONS (CONTEL)*, 13., Graz, Austria. **Proceedings [...]**. Graz, p. 1–8, 2015.

CHEN, K. *et al.* Machine learning based automatic diagnosis in mobile communication networks. **IEEE Transactions on Vehicular Technology**, v. 68, n. 10, p. 10081-10093, oct. 2019.

GÉRON, A. **Hands-on machine learning with scikit-learn, Keras & TensorFlow: concepts, tools, and techniques to Build Intelligent Systems.** California: O’Reilly Media, 2019.

DAROCZY, B.; VADERNA, P.; BENCZUR, A. machine learning based session drop prediction in LTE Networks and Its SON Aspects. **IEEE 81st Vehicular Technology Conference (VTC Spring)**, Glasgow, p. 1-5, 2015.

ERICSSON- Telefonaktiebolaget LM. **Ericsson Mobility Report**, 2019. Disponível em: <https://www.ericsson.com/en/mobility-report>. Acesso em: 29 abr. 2020.

ERICSSON- Telefonaktiebolaget LM. **Ericsson Mobility Report**, 2021. Disponível em: <https://www.ericsson.com/en/mobility-report>. Acesso em: 20 abr. 2022.

ERICSSON- Telefonaktiebolaget LM. **Ericsson Mobility Report**, 2023. Disponível em: <https://www.ericsson.com/en/mobility-report>. Acesso em: 23 Ago. 2023.

ERICSSON- Telefonaktiebolaget LM. Nova solução da Ericsson utiliza inteligência artificial para simplificar serviços. **Ericsson Press Release**, 2019. Disponível em: <https://www.ericsson.com/pt/press-releases/2019/1/nova-solucao-da-ericsson-utiliza-inteligencia-artificial-para-simplificar-servicos>. Acesso em 29 abr. 2020.

ERICSSON- Telefonaktiebolaget LM. **Ericsson Technology Review**, 2019. Disponível em: <https://www.ericsson.com/en/reports-and-papers/ericsson-technology-review/articles/enhancing-ran-desempenho-with-ai>. Acesso em: 29 abr. 2020.

ERICSSON- Telefonaktiebolaget LM. **Ericsson White Paper**, 2018. Artificial intelligence and machine learning in next-generation systems. Disponível em: <https://www.ericsson.com/en/reports-and-papers/white-papers/machine-intelligence>. Acesso em: 29 abr. 2020.

GSM ASSOCIATION. **VoLTE Service Description and Implementation Guidelines**. FCM.01. 2014.

HU, H. *et al.* Self-configuration and self-optimization for LTE networks. **IEEE Commun. Mag.**, v. 48, n. 2, pp. 94–100, 2010.

ITU - INTERNATIONAL TELECOMMUNICATION UNION. **ITU-T Recommendation E.419**: business oriented key performance indicators for management of networks and services. 2006.

ITU - INTERNATIONAL TELECOMMUNICATION UNION. **ITU-T Recommendation E.800**: Definitions of terms related to quality of service. 2008.

ISHIZAKA, A.; NEMERY, P. **Multi-criteria decision analysis**: methods and software. New York: John Wiley & Sons, 2013.

KEENEY, R. L.; RAIFFA, H. **Decisions with multiple objectives**: preferences and value trade-offs. Cambridge, Reino Unido: Cambridge University Press, 1993.

MITCHELL, M. T. **Machine learning**. Ed. McGraw-Hill, 1997.

NATHANIEL S. *et al.* Multi-criteria load balancing decision algorithm for LTE network. **4th International Conference on Engineering Technology and Technopreneuship (ICE2T)**, pp. 57–62, Kuala Lumpur, Malaysia, 2014.

NGMN ALLIANCE. **Mobile networks recommendation on SON and O&M requirements**. Release, 2008.

NGUYEN-VUONG, Q. *et al.* Multicriteria optimization of access selection to improve the quality of experience in heterogeneous wireless access networks. **IEEE Transactions on Vehicular Technology**, v. 62, n. 4, p. 1785–1800, 2013.

NORY, R. New WID on N.R. dynamic spectrum sharing (DSS). **3GPP TSG RAN Meeting**, #86, Tdoc RP-193260, 2019.

MANZANILLA-SALAZAR, O.; MALANDRA, F.; SANSÒ, B. ENodeB failure detection from aggregated performance kpis in smart-city lte infrastructures. *In*: INTERNATIONAL CONFERENCE ON THE DESIGN OF RELIABLE COMMUNICATION NETWORKS (DRCN), 15., 2019, Coimbra. **Proceedings** [...]. Coimbra, Portugal, p. 51-58, 2019.

MORETTIN, A. P.; SINGER, M. J. **Introdução à ciência de dados**: fundamentos e aplicações. São Paulo: Departamento de Estatística, Universidade de São Paulo, 2020.

OBAYIUWANA, E.; FALOWO, O.E. Network selection in heterogeneous wireless networks using multicriteria decision-making algorithms: a review. **Wireless Networks**, v. 23, n. 8, p. 2617–2649, 2017.

PAUL, U.; FALOWO, O. E. Efficient RAT-selection for group calls using intuitionistic fuzzy TOPSIS in heterogeneous wireless networks. *In*: IEEE AFRICON, 2017., 2017, Cidade do Cabo. **Proceedings** [...]. Cidade do Cabo, África do Sul, p. 365–370, 2017.

PERVAIZ, H. A multi-criteria decision making (MCDM) network selection model providing enhanced QoS differentiation to customers. **MCIT'2010: International Conference on Multimedia Computing and Information Technology**, art. no. 5444854, 2010, p. 49–52, 2010.

PERVAIZ, H.; BIGHAM, J. Game theoretical formulation of network selection in competing wireless networks: an analytic hierarchy process model. **Third International Conference on Next Generation Mobile Applications, Services and Technologies**, p. 292–297, Cardiff, Reino Unido, 2009.

QUALCOMM TECHNOLOGIES. **Qualcomm White Paper**. VoLTE with SRVCC: The second phase of voice evolution for mobile LTE devices, 2012. Disponível em: <https://www.qualcomm.com/media/documents/files/srvcc-white-paper.pdf>. Acesso em: 29 abr. 2020.

RUPPRECHT F. *et al.* An approach for evaluating collaborative software environments based on integration of house of quality with multi-attribute utility theory. *In: INTERNATIONAL CONGRESS ON ULTRA MODERN TELECOMMUNICATIONS AND CONTROL SYSTEMS AND WORKSHOPS (ICUMT)*, 9., 2017, Munique. **Proceedings [...]**, Munique, Alemanha, p. 45–54, 2017.

SAATY, T. L. **Fundamentals of decision making and priority theory with the analytic hierarchy process**. Pittsburgh, PA, Estados Unidos: RWS Publications, 2013.

SAATY, T. L. **The analytic hierarchy process: planning, priority setting, resource allocation**. 2nd ed. Pittsburgh: RWS Publications, 1990.

SALLENTO, O. *et al.* A roadmap from UMTS optimization to LTE self-optimization. **IEEE Commun. Mag.**, v. 49, n. 6, p. 172–82, 2011.

SASIREKHA, V.; ILANZKUMARAN, M. Heterogeneous wireless network selection using FAHP integrated with TOPSIS and VIKOR. *In: INTERNATIONAL CONFERENCE ON PATTERN RECOGNITION, INFORMATICS AND MOBILE ENGINEERING*, 2013., 2013, Salem. **Proceedings [...]**. Salem, India, p. 399–407, 2013.

SCOPUS. **Base de dados Elsevier**. Disponível em: <https://www.scopus.com/home.uri>. Acesso em: 4 dez. 2023.

SZILAGYI, P.; NOVACZKI, S. An automatic detection and diagnosis framework for mobile communication systems. **IEEE Transactions on Network and Service Management**, v. 9, n. 2, p. 184–197, 2012.

TECHTARGET NETWORKING. **Radio access network definition**. Disponível em: <https://www.techtarget.com/searchnetworking/definition/radio-access-network-RAN>. Acesso em: 18 abr. 2022.

THE OPEN GROUP. **SLA Management Handbook.**, Berkshire, Reino Unido, 2004. v. 4.

TRIANANTAPHYLLOU, E. **Multi-criteria decision making methods: a comparative study**. Nova York:: Springer, 2010.

VASER, M.; FORCONI, S. QoS KPI and QoE KQI relationship for LTE video streaming and VoLTE services. *In: INTERNATIONAL CONFERENCE ON NEXT GENERATION MOBILE APPLICATIONS, SERVICES AND TECHNOLOGIES*, 9., 2015, Cambridge. **Proceedings** [...]. Cambridge, Reino Unido, p. 318–323, 2015.

YERYOMIN, Y.; SEITZ, J. Enhanced multi-criteria-based path selection algorithm for heterogeneous networks. *In: INTERNATIONAL CONFERENCE ON UBIQUITOUS AND FUTURE NETWORKS (ICUFN)*, 8., 2016, Vienna. **Proceedings** [...]. Vienna, Austria, p. 804–809, 2016.

ZAVADSKAS, E. K. *et al.* State of art surveys of overviews on MCDM/MADM methods. **Technological and Economic Development of Economy**, v. 20, n. 1, p. 165–179,