

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**ORQUESTRAÇÃO DE RECURSOS MULTICAMADAS PARA ARQUITETURAS DE
PRÓXIMA GERAÇÃO**

ERMÍNIO AUGUSTO RAMOS DA PAIXÃO

TD: 22/2024

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém - Pará - Brasil
2024

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ERMÍNIO AUGUSTO RAMOS DA PAIXÃO

**ORQUESTRAÇÃO DE RECURSOS MULTICAMADAS PARA ARQUITETURAS DE
PRÓXIMA GERAÇÃO**

Tese apresentada à Banca Examinadora do Programa de Pós-graduação em Engenharia Elétrica da UFPA para a obtenção do Grau de Doutor em Engenharia Elétrica na área de Computação Aplicada, elaborada sob a orientação do Prof. Dr. Diego Lisboa Cardoso.

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém - Pará - Brasil
2024

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)**

R175o Ramos da Paixão, Ermínio Augusto.
ORQUESTRAÇÃO DE RECURSOS MULTICAMADAS
PARA ARQUITETURAS DE PRÓXIMA GERAÇÃO / Ermínio
Augusto Ramos da Paixão. — 2024.
77 f. : il. color.

Orientador(a): Prof. Dr. Diego Lisboa Cardoso
Tese (Doutorado) - Universidade Federal do Pará, Instituto de
Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica,
Belém, 2024.

1. H-CRAN. 2. Orquestração de Recursos. 3.
Balanceamento de Carga. 4. Tidal effect. I. Título.

CDD 621.3845

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
**ORQUESTRAÇÃO DE RECURSOS MULTICAMADAS PARA ARQUITETURAS DE
PRÓXIMA GERAÇÃO**

AUTOR: ERMÍNIO AUGUSTO RAMOS DA PAIXÃO

TESE SUBMETIDA À AVALIAÇÃO DA BANCA EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA DA UNIVERSIDADE FEDERAL DO PARÁ E JULGADA ADEQUADA PARA OBTENÇÃO DO GRAU DE DOUTOR EM ENGENHARIA ELÉTRICA NA ÁREA DE COMPUTAÇÃO APLICADA. APROVADA EM __ / __ / ____.

BANCA EXAMINADORA:

Prof. Dr. Diego Lisboa Cardoso
Orientador - PPGEE/ITEC/UFPA

Prof. Dr. Eduardo Coelho Cerqueira
Membro Interno - PPGEE/ITEC/UFPA

Prof. Dr. Fabrício José Brito Barros
Membro Interno - PPGEE/ITEC/UFPA

Prof. Dr. Ugo Silva Dias
Membro Externo à Instituição - ENE/UNB

Prof.^o Dr. Harold Dias De Mello Junior
Membro Externo à Instituição - ELE/PUC-RIO

Visto:

Prof. Dr. Diego Lisboa Cardoso
Coordenador do PPGEE/ITEC/UFPA

AGRADECIMENTOS

Agradeço, primeiramente a Deus, por sempre me guiar nos momentos difíceis.

À minha mãe, Francinelma Ramos e ao meu pai Antônio Paixão, por todos os conselhos e apoio incondicional.

Ao meu avó, Raimundo Zacarias, por me incentivar nessa jornada.

Ao meu irmão, Antônio Hermes, que sempre me guia para o caminho correto, bem como o apoio de sua família.

À minha noiva, Cláudia Nogueira, que compartilha e me incentiva a alcançar meus objetivos.

A toda minha família que, direta ou indiretamente, ajudou-me a alcançar mais um passo na minha formação acadêmica.

Aos meus amigos que sempre me desejam o melhor e me acompanham em mais esse passo.

Aos meus amigos do Laboratório de Pesquisa Operacional (LPO), que sempre estiveram prontos para ajudar em qualquer circunstância.

Ao meu orientador, Diego Lisboa Cardoso que sempre se dedicou e me incentivou para que o meu trabalho pudesse chegar até aqui.

Agradeço ao CNPq pelo apoio financeiro em forma de bolsa para a realização desta pesquisa.

À Universidade Federal do Pará (UFPA), pela oportunidade a mim ofertada para a realização desta qualificação de tese.

RESUMO

Devido ao aumento significativo no tráfego de dados e ao grande número de dispositivos com *Internet Protocol* (IP), operadoras e pesquisadores estão buscando soluções para atender a maior demanda. Uma das mais atrativas delas é a *Heterogeneous Cloud Radio Access Networks* (H-CRAN), que tem a capacidade de solucionar problemas da geração atual e agregar diversas melhorias, como processamento centralizado e maior eficiência energética. O problema central reside na complexidade de gerenciar e otimizar esses recursos de forma eficiente, principalmente em cenários de alta demanda e densidade de dispositivos. No entanto, a orquestração de recursos como rádio, mapeamento entre rádio e *BaseBand Unit* (BBU) e balanceamento de carga no pool de BBU ainda são de extrema importância. Esta tese apresenta um *framework* que visa reconfigurar a rede móvel em áreas que sofrem com a variabilidade de tráfego *tidal effect*, de modo a obter alta disponibilidade, economia de energia e maior eficiência no processamento dados. Os resultados obtidos foram comparados com outras abordagens da literatura e mostraram que o *Framework* proposto consegue otimizar os recursos da *Peak Remote Radio Head* (PRRH) e da BBU sem afetar o QoS mínimo do usuário, os mesmos evidenciam uma redução de até 9% no número de antenas ativas durante um período de 24h, vale ressaltar que a solução proposta consome até 14% menos que a principal referência dessa tese.

Palavras-chaves: H-CRAN, Orquestração de Recursos, Balanceamento de Carga, Tidal effect.

ABSTRACT

Due to the significant increase in data traffic and the large number of devices using Internet Protocol (IP), operators and researchers are seeking solutions to meet the growing demand. One of the most attractive solutions is Heterogeneous Cloud Radio Access Networks (H-CRAN), which has the capability to address current generation problems and bring various improvements, such as centralized processing and greater energy efficiency. The central challenge lies in the complexity of managing and optimizing these resources efficiently, especially in high-demand scenarios with dense device populations. However, the orchestration of resources such as radio, mapping between radio and BaseBand Unit (BBU), and load balancing in the BBU pool remains critically important. This thesis presents a framework aimed at reconfiguring the mobile network in areas affected by the variability of tidal effect traffic, ensuring high availability, energy savings, and improved data processing efficiency. The results obtained were compared with other approaches in the literature and demonstrated that the proposed framework optimizes the resources of the Peak Remote Radio Head (PRRH) and the BBU without compromising the user's minimum QoS. The findings highlight a reduction of up to 9% in the number of active antennas over a 24-hour period and emphasize that the proposed solution consumes up to 14% less energy than the primary reference in this thesis.

Keywords: H-CRAN, Resource Orchestration, Load Balance, Tidal effect.

LISTA DE ILUSTRAÇÕES

Figura 1 – Evolução das Redes Móveis.	16
Figura 2 – Arquitetura de Rede Celular Geral 5G, rodovias inteligentes, <i>smart home</i> e carros inteligentes.	19
Figura 3 – Arquitetura C-RAN, rede centralizada, <i>fronthaul</i> e BBU <i>pool</i>	21
Figura 4 – Ilustração SDN, plano de dados, plano de controle e plano de aplicação. . .	22
Figura 5 – Fluxograma PSO.	25
Figura 6 – Fluxograma SA.	27
Figura 7 – <i>framework</i> de Reorquestração, tráfego inicial dos usuário, desligamento com metaheurística, conversão do tráfego em usuários bloqueados e balanceamento	33
Figura 8 – Processo de Mapeamento e Balanceamento da BBU, transmissão de decisão, verificação de configuração de dados e verificação global dos dados de balanceamento.	33
Figura 9 – Processo ilustrativo de Orquestração de Recursos utilizando o SA.	34
Figura 10 – Variação da Carga de Tráfego em um Dia.	39
Figura 11 – Arquitetura alterada do NS-3	41
Figura 12 – Delay (ms) médio em 24 horas	44
Figura 13 – <i>jitter</i> (ms) Médio em 24 Horas.	45
Figura 14 – Média de pacotes perdidos (%) em 24h.	45
Figura 15 – Média de PRRHs ligadas em 24h.	46
Figura 16 – <i>Throughput</i> Médio em 24h	47
Figura 17 – Consumo de energia total	48

LISTA DE TABELAS

Tabela 1 – Parâmetros da Simulação.	39
Tabela 2 – Parâmetros do Simulated Annealing (SIGWELE; HU; SUSANTO, 2020). .	43
Tabela 3 – Parâmetros do FA (SILVA GONÇALVES et al., 2023).	43

LISTA DE ABREVIATURAS E SIGLAS

1G	Primeira Geração de Telefonia Móvel
2G	Segunda Geração de Telefonia Móvel
3G	Terceira Geração de Telefonia Móvel
4G	Quarta Geração de Telefonia Móvel
ADC	<i>Application Delivery Controller</i>
APIs	<i>Application Programming Interface</i>
BSs	<i>Base Stations</i>
CAPEX	<i>CAPital EXpenditure</i>
CF	<i>Carrier Frequency</i>
C-RAN	<i>Centralized Radio Access Network</i>
D-RAN	<i>Distributed Radio Access Network</i>
GMS	<i>Global System for Mobile</i>
GSM	<i>Global System for Mobile Communication</i>
HC	<i>Hard Capacity</i>
HDTV	<i>High-Definition Television</i>
HetNets	<i>Heterogeneous Networks</i>
IC	inteligência computacional
IA	inteligência artificial
IoT	<i>Internet of Things</i>
IVC	<i>Inter-Vehicle Communication</i>
KHz	<i>kiloHertz</i>
Kbps	<i>kilobit for second</i>
KPI	<i>Key Performance Indicator</i>

MHz	<i>Megahertz</i>
MRRH	<i>Macro Remote Radio Head</i>
multi-RAT	<i>Multiple Radio Access Technology</i>
PSO	<i>particle swarm optimization</i>
QoS	<i>Quality of Service</i>
RAN	<i>Radio Access Network</i>
RF	<i>Radio Frequência</i>
RRH	<i>Remote Radio Head</i>
SA	<i>Simulated Annealing</i>
SINR	<i>Signal-to-Interference-plus-Noise Ratio</i>
SMS	<i>Short Message Service</i>
SON	<i>Self organizing network</i>
SUI	<i>Stanford University Interim</i>
TLS	<i>Transport Layer Security</i>
UMTS	<i>Universal Mobile Telecommunication System</i>
UE	<i>User Equipament</i>
UHD	<i>Ultra High Definition</i>
VBs	<i>Virtual Boxes</i>
vBBU	<i>Virtual BaseBand Unit</i>

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Definição do Problema	14
1.2	Objetivo Geral	14
1.3	Objetivos Específicos	14
1.4	Organização do Tese	15
2	FUNDAMENTAÇÃO TEÓRICA	16
2.1	Considerações Iniciais	16
2.2	Evolução das Redes Móveis	16
2.2.1	Primeira Geração de Redes Móveis (1G)	16
2.2.2	Segunda Geração de Redes Móveis (2G)	17
2.2.3	Terceira Geração de Redes Móveis (3G)	17
2.2.4	Quarta Geração de Redes Móveis (4G)	17
2.2.5	Quinta Geração de Redes Móveis (5G)	18
2.2.6	Sexta Geração de Redes Móveis (6G)	18
2.3	C-RAN	19
2.4	SDN	21
2.4.1	Inteligência Computacional (IC)	23
2.4.1.1	Metaheurística	23
2.4.1.2	Inspiradas ou não na natureza	24
2.4.2	Baseadas em população ou baseadas em busca de pontos simples	24
2.4.2.1	Particle Swarm Optimization (PSO)	24

2.4.2.2	<i>Simulated Annealing (SA)</i>	26
2.5	Considerações Finais	27
3	TRABALHOS CORRELATOS	28
3.1	Considerações Iniciais	28
3.1.1	Framework	28
3.1.2	Otimização de Balanceamento	28
3.1.3	Eficiência Energética	29
3.2	Considerações Finais	30
4	PROPOSTA DE TESE	31
4.1	Considerações Iniciais	31
4.2	Proposta de Tese	31
4.3	Algoritmos Metaheurísticos	32
4.3.1	Algoritmo SA	32
4.3.2	Algoritmo FA	35
4.4	Implementação do cenário	37
4.4.1	Parâmetros de Rede	37
4.4.2	Ambiente de simulação	40
4.5	Considerações Finais	42
5	RESULTADOS	43
5.1	Considerações Iniciais	43
5.2	Resultados	43
5.3	Considerações Finais	47
6	CONCLUSÃO	49
6.1	Considerações Iniciais	49

6.2	Conclusão	49
6.3	Contribuições	49
6.3.1	Publicações	50
6.4	Trabalhos Futuros	51
6.5	Dificuldades Encontradas	52
	REFERÊNCIAS	53
7	ANEXO	57
7.1	Considerações Iniciais	57

1 INTRODUÇÃO

De acordo com os projetos da Cisco (CISCO SYSTEMS, 2023), até o final de 2028, espera-se que haja 9,2 bilhões de dispositivos móveis com um consumo de 46 GB por mês e 26% Crescimento no tráfego de dados móveis. Ao mesmo tempo, Ericsson (ERICSSON, 2022) prevê que cinco bilhões de assinaturas 5G (55% do total) serão ativadas, garantindo uma extensa cobertura de 85%. Além disso, estima-se que as redes 5G serão responsáveis por 70% do tráfego móvel, atendendo ao crescimento exponencial projetado. Essas previsões da Cisco e da Ericsson destacam um cenário promissor para a evolução da tecnologia móvel até 2028, impulsionando avanços significativos na conectividade global.

Com o surgimento de cada vez mais dispositivos e aplicações voltadas à rede, surge a necessidade de reestruturar sua arquitetura, pois a atual *Distributed Radio Access Network* (D-RAN) não consegue se adequar às novas necessidades, visto que tem um alto custo de despesas de capital e elevadas taxas de processamento operacional com incremento de *Base Stations* (BSs) (WANG et al., 2019). Considerando os novos desafios do atual cenário das redes móveis, emerge como possível solução a *Centralized Radio Access Network* (C-RAN), que visa centralizar o processamento dos *User Equipment* (UE), melhorando a eficiência energética e com capacidade de reorganizar os dados da rede (ERICSSON, 2020). Aliado a ela, outra tecnologia promissora é o *Software Defined Network* (SDN) que insere novos recursos e aplicabilidades, tais como, programação autoajustável, gerenciamento centralizado e baixo custo de implantação (MAROTTA et al., 2015).

O SDN é capaz de separar o plano controle (decisões) do plano de dados (encaminhamento de pacotes). A vantagem dessa separação é que ela permite o controlador SDN ter uma visão global e atualizada não só de toda a rede, mas também de todos os fluxos de dados, o que pode aumentar a flexibilidade e escalabilidade do sistema, tornando as redes programáveis, adaptáveis e com custo-benefício (MAROTTA et al., 2015; CHEN; RONG; ZHANG et al., 2017). Essas características permitem, por exemplo, a integração de soluções inovadoras com base em técnicas de Inteligência Artificial (IA).

A C-RAN surgiu como uma arquitetura de rede celular capaz de (a) atender à demanda por dados de alto tráfego do UE final; (b) otimizar o uso de recursos físicos e (c) reduzir custos (YAN et al., 2018a). Entretanto, a arquitetura C-RAN tem requisitos robustos, como baixa latência, baixo *jitter* e alto custo na implantação da infraestrutura, métricas difíceis de serem alcançadas (CHEN; RONG; ZHANG et al., 2017). Levando em conta todos esses obstáculos, foi desenvolvida a *Heterogeneous Cloud Radio Access Networks* (H-CRAN), que possibilita integrar as arquiteturas *Heterogeneous Networks* (HetNets) descentralizada e C-RAN, permitindo assim, realizar aplicações de processamento de sinal, centralização de carga de trabalho e eficiência energética (CHEN; RONG; ZHANG et al., 2017).

1.1 Definição do Problema

Um dos pontos de grande discussão no contexto dessas novas arquiteturas é a implantação, uma vez que o planejamento da capacidade total de uma rede móvel e o número de *Peak Remote Radio Head* (PRRH) são geralmente projetadas para atender a capacidade máxima de tráfego. Todas as PRRHs continuam ligadas independentemente do fluxo de dados que esteja sendo transmitido, causando assim, alto custo energético e a subutilização de equipamentos. Esse comportamento variado é intitulado de "*tidal effect*" (CHEN; RONG; ZHANG et al., 2017).

Outro fator que chama atenção é que a taxa de processamento em cada *BaseBand Unit* (BBU) é estipulada por um número total de UEs ativos simultaneamente nos setores das BBUs (YAN et al., 2018a). Contudo, há uma limitação de *hardware* ou *software*, que delimita a quantidade de UE ativos na BBU, essa denominado de *Hard Capacity* (HC), a qual, se não for cumprida, pode acarretar na perda de dados ou de desempenho. Assim, as redes precisam ter suporte a *Self-organizing network* (SON) e com isso lidar com essa problemática através do mapeamento eficiente dos recursos.

Há problemas como o *tidal effect*, o qual é causado pela operação contínua das PRRHs, independentemente do tráfego e, a limitação da capacidade das BBUs para atender ao número de UEs ativos, destacam-se como desafios críticos para o desempenho e a eficiência energética das redes móveis modernas. A subutilização de recursos e o consumo excessivo de energia indicam uma necessidade de adaptação dinâmica da rede em resposta às variações do tráfego, enquanto a HC nas BBUs demanda uma gestão cuidadosa dos usuários ativos para evitar perda de dados e manter a qualidade do serviço. Dado o impacto direto dessas questões no custo operacional e na experiência do usuário, encontrar soluções eficientes para esses desafios se torna essencial, ressaltando a importância de redes que sejam autogerenciáveis e capazes de otimizar recursos por meio de tecnologias como as redes auto-organizáveis.

1.2 Objetivo Geral

Diante disso, essa proposta de tese tem como objetivo principal propor um *framework* capaz de integrar o monitoramento da rede, aprimorar a otimização e a eficiente orquestração de recursos em uma rede H-CRAN/SDN, mesmo em diferentes condições de tráfegos, visando maximizar a experiência da UE, bem como reduzir o número de recursos operacionais, considerando aspectos de eficiência energética, custos financeiros, operacionais, carga, entre outros.

1.3 Objetivos Específicos

Os objetivos específicos representam pontos direcionados às ações e delineiam as etapas cruciais para a realização da tese, conforme visto em:

- Estudar e implementar mecanismos de desligamento inteligente de PRRHs em redes Quinta Geração de Telefonia Móvel 5G;
- Estudar métodos de mapeamento e reorquestração de recursos entre RRH-BBU;
- Proposição de novos indicadores e/ou uso de indicadores de performance híbridos;
- Estudar diferentes meta-heurísticas buscando otimizar a orquestração de recursos e minimizar o tempo de processamento;
- Criar cenários de simulação o mais próximo possível da realidade e com maior número de dispositivos conectados em relação à literatura, a fim de estudar o impacto em redes de alta carga.

1.4 Organização do Tese

Esta tese segue a seguinte estrutura de organização:

- Capítulo 2: O capítulo expõe de forma objetiva os principais temas em relação a este trabalho, as principais características das novas arquiteturas e os principais algoritmos utilizados na literatura para otimização de rede.
- Capítulo 3: Este capítulo expõe os artigos que serão utilizados como base para a produção desta tese.
- Capítulo 4: O capítulo exhibe o cenário e a proposta inicial de mapeamento e reorquestração de recursos, usando uma técnica de desligamento inteligente e *Key Performance Indicator* (KPIs) para minimizar o número de chamadas bloqueadas.
- Capítulo 5: Neste capítulo, são expostas algumas características dos cenários utilizados e os resultados preliminares.
- Capítulo 6: O capítulo apresenta possíveis contribuições, trabalhos futuros e o cronograma de execução da tese.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Considerações Iniciais

Neste capítulo, estará exposta uma visão geral dos principais conceitos relacionados ao desenvolvimento desta proposta de tese, em que se evidenciam as técnicas e tecnologias embarcadas neles, como: balanceamento de carga, SDN, eficiência energética, simuladores e algoritmos bioinspirados.

2.2 Evolução das Redes Móveis

O desenvolvimento da comunicação móvel tem sido visto como uma sequência de gerações que, nos últimos 40 anos, testemunhou o avanço de quatro importantes gerações. Os avanços iniciaram com a telefonia móvel na década 80 e foram evoluindo seus serviços oferecidos juntamente com a tecnologia de comunicação. Segundo (CISCO, 2020), projeções da Cisco e Ericsson indicam um grande aumento no número de dispositivos móveis e no consumo de dados até 2028, com um crescimento de 26% no tráfego de dados móveis. As redes 5G serão responsáveis por 70% desse tráfego, cobrindo 85% da população global e impulsionando a conectividade, conforme ilustrado pela Figura 1.

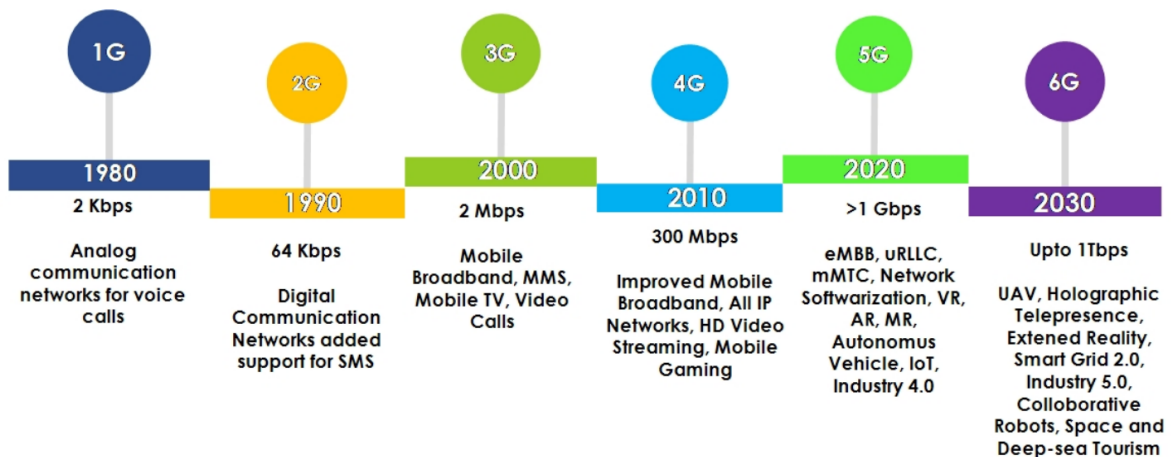


Figura 1 – Evolução das Redes Móveis.

Fonte: Evolution of Mobile Networks (RATHOD et al., 2022).

Os avanços na área da comunicação móvel é um tema que trata sobre as necessidades de comunicação para os seres humanos e dispositivos.

2.2.1 Primeira Geração de Redes Móveis (1G)

A partir de 1980, devido à constante necessidade da comunicação móvel, surge a Primeira Geração de Telefonia Móvel (1G), essa rede móvel trouxe a possibilidade de dividir as

frequências em vários canais e cada canal transportar um sinal de dados para a comunicação sem fio, o nome dado para essa técnica foi *Frequency Division Multiple Access* **FDMA** (BABA et al., 2018).

2.2.2 Segunda Geração de Redes Móveis (2G)

No início dos anos 90, surge uma nova geração: a Segunda Geração de Telefonia Móvel (2G), que passou a utilizar a técnica *Global System for Mobile Communication* (GSM), a qual permite usar criptografia digital, o que torna a comunicação mais segura. Essa geração trouxe grandes inovações, como a utilização de textos, imagens, *Short Message Service* (SMS) e *e-mails*. Para tal, foi projetada em maior largura de banda de 30 a 200 *kiloHertz* (KHz), com taxa de dados de 64 *kilobits for second* (Kbps). Mesmo com grandes avanços nessa geração, o sucesso das novas aplicações resultaram na chegada da nova geração, a Terceira Geração de Telefonia Móvel (3G).

2.2.3 Terceira Geração de Redes Móveis (3G)

No início dos anos 2000, chega a 3G com o intuito de elevar a velocidade da rede e, para isso, foi criado o *Global System for Mobile* (GMS) que é três vezes mais rápido que o GMS convencional. Também foi adicionado um protocolo intitulado *Universal Mobile Telecommunication System* (UMTS) que realiza a comutação dos pacotes da rede sem fio e da banda larga, o que ampliou o acesso e tornou a comunicação mais transparente. Para ter uma *internet* de alta velocidade, essa rede usou faixas de frequência de 2100 *MegaHertz* (MHz) e largura de banda de 15-20 MHz. Entretanto, a 3G tinha um alto consumo energético em relação às antigas versões, já que os aparelhos que suportavam essa tecnologia eram menos acessíveis e exigiam maior largura de banda, tais adversidades levaram à criação da rede Quarta Geração de Telefonia Móvel (4G).

2.2.4 Quarta Geração de Redes Móveis (4G)

A 4G teve seu lançamento no ano de 2012 e um dos grandes avanços da nova rede foi a velocidade de download que chegava até 100 **Mbps** *megabit* por Segundo, assim como outras melhorias foram implementadas às redes, tais como: *Multi-Media Jornal*, *streaming* em tempo real, *High-Definition Television* (HDTV), serviços baseados em localização, digital vídeo, chamadas de vídeo e serviços multimídia expandidos. Já na parte operacional, a duração da bateria foi melhorado e teve seu custo reduzido. O 4G se mostrou superior à antiga geração em vários aspectos, um deles foi a possibilidade de usar o *Quality of Service* (QoS) e uma latência baixa, sendo capaz de baixar arquivos robustos.

Segundo (VORA, 2015), com a implantação da rede 4G, constatou-se um aumento na área de cobertura, velocidade e melhoria no QoS, mas devido ao surgimento de diversas aplicações e dispositivos, a comunidade científica e as empresas uniram esforços para a criação de

uma rede móvel que pudesse suportar essas novas necessidades. Em consideração a isso, a rede 5G foi projetada e já está em processo de implementação.

2.2.5 Quinta Geração de Redes Móveis (5G)

Com o aumento dos número de usuários conectados à rede e a explosão de dispositivos móveis, a implantação da rede 5G se tornou cada vez mais necessária, pois, além do crescimento em demanda, as novas aplicações requerem requisitos mais arrojados. Devido a isso, diversas pesquisas foram realizadas com o propósito de identificar as principais prioridades desta nova rede, o grupo Metis na Europa, 5G fórum, Coreia do Sul, e IMT-2020 *Promotion Group (PG!)*, na China, foram responsáveis por investigar as demandas dos usuários, cenários de aplicações, soluções em potencial e novas técnicas.

Inovações, como *Internet of Things (IoT)* e *smartphones*, aceleraram a necessidade de uma nova arquitetura, pois eles exigem processamento elevado e maior taxa de dados. Algumas tecnologias presentes nessas inovações são: realidade virtual, *Ultra High Definition (UHD)*, *Cloud Computing* e *Inter-Vehicle Communication (IVC)*, a Figura 2 representa uma rede 5G. Além da alta conectividade e velocidade elevada, a nova rede conta com latência de ponta a ponta, previsão de distribuição de usuários, densidade de conexão e KPIs integrados às soluções da rede (HASSAN; YAU; WU, 2019).

Esse crescimento contínuo em aplicativos de acesso móvel e centrados em máquinas tem causado demandas que excedem os recursos das tecnologias móveis atuais. Esses aplicativos de última geração para dispositivos móveis e IoT exigirão acesso à Internet onipresente, com QoS garantida, alta capacidade e contínua (AKPAKWU et al., 2017). Como solução para esta problemática de oferta e demanda, o desenvolvimento da tecnologia móvel da 5G está em processo de implantação, visando a sanar as necessidade dos usuários e equipamentos (SHAFIQUE et al., 2020).

Como resultado, a evolução das redes de acesso de rádio precisa ser complementada pela evolução das redes de transporte, a fim de realizar os *benchmarks* de 5G. Em particular, para suportar comunicação de baixa latência, alta capacidade, custo efetivo e mais ecológico, toda a rede de ponta a ponta deve ser revisada. Para lidar com a demanda de tráfego em crescimento exponencial que se prevê que aumente oito vezes nos próximos anos (HASSAN; YAU; WU, 2019), o primeiro passo foi propor e expor o conceito de controle centralizado de sinais de rádio para ser introduzido na rede 5G, que é conhecida como a arquitetura C-RAN

2.2.6 Sexta Geração de Redes Móveis (6G)

A sexta geração de redes móveis ou simplesmente 6G, representa a evolução das tecnologias de comunicação sem fio dos últimos anos, sucedendo o atual padrão 5G. Essa nova geração promete revolucionar a conectividade ao oferecer velocidades de conexão extraordinárias e capacidades ainda mais avançadas. O 6G está sendo desenvolvido para proporcionar uma



Figura 2 – Arquitetura de Rede Celular Geral 5G, rodovias inteligentes, *smart home* e carros inteligentes.

Fonte: 5G EXPLAINED - HOW 5G WORKS 2020.

experiência de comunicação ainda mais rápida, eficiente e abrangente, superando as expectativas estabelecidas pelo 5G.

No contexto da nova geração, a rede 6G destaca-se o emprego de extensos conjuntos de antenas, uma característica distintiva nos sistemas 5G (DE FIGUEIREDO et al., 2018). Prevê-se que essa tecnologia continuará em direção aos sistemas 6G, mas com aumento no número de elementos dos arranjos em uma ordem de magnitude, dando origem ao MIMO ultra-massivo (SHLEZINGER et al., 2021).

2.3 C-RAN

Foi introduzida pela primeira vez pela China *Mobile*, em 2009, para acomodar o grande crescimento das redes móveis (MOBILE, 2011). É uma nova arquitetura móvel que tem o potencial de lidar com inúmeras estações-base e capaz de virtualizar a rede, se for preciso.

No C-RAN, o processamento de banda e canal é virtualizado e compartilhado entre os operadores em um *pool* de banda de base centralizado. Essa centralização e compartilhamento permitem um tratamento de tráfego mais dinâmico e uma melhor utilização de recursos, incluindo implantação de estações base.

Essa arquitetura teria o potencial de diminuir o custo das despesas, pois as estações de base são virtualizadas e não implantadas fisicamente em diferentes áreas. Além disso, reduz o consumo de energia em comparação com as redes tradicionais, devido ao fato de as estações base estarem localizadas no mesmo dispositivo físico.

Segundo (CHIH-LIN et al., 2014), a C-RAN se destaca por inúmeras vantagens como:

- Adaptável ao *Multiple Radio Access Technology* (multi-RAT): pois ela consegue conjuntamente gerenciar e executar diversos tipos de bandas de sinais, o que aumenta a adaptabilidade da rede.
- Economia de energia e custo-benefício: a centralização e virtualização das BBU *pools* conduzem à otimização da utilização de energia, ativando e desativando a *Remote Radio Head* (RRH) e a BBU *pools* em relação a condições de tráfego.
- Aumento da taxa de transferência e diminuição do atraso da rede: levando em conta à centralização de recursos e a possibilidade de redução do tempo inativo da BBU *pool*.
- Implantação rápida e arquitetura flexível: a *Radio Access Network* (RAN) tradicional requer uma grande área para implantação de RRH. A arquitetura C-RAN supera esse problema dividindo a seção de Radio Frequência (RF) RRH da BBU *pool*. Essa arquitetura reduz o processo de instalação.

No modelo apresentado na Figura 3, é exposta a arquitetura de uma C-RAN, em que as RRHs são conectadas à BBU *pool* através de um protocolo de interconexão, como o *Common Public Radio Interface (CPRI)* (ERICSSON, 2020). As BBUs na BBU *pool* estão interligadas e conectadas a um servidor intitulado "*Host Manager*", que verifica a carga em cada BBU e é encarregado de selecionar a configuração adequada de BBU-RRH. Cada BBU pode trabalhar com "*N*" setores, os quais se configuram pelo número total de usuários que aquela BBU pode suportar, dependendo de sua capacidade. Cada setor contém múltiplas RRHs conectadas a ele. As RRHs pertencem unicamente a um setor em um intervalo de tempo (HASSAN; YAU; WU, 2019).

A arquitetura C-RAN consiste em três principais aspectos presentes nela, ou seja, a RRH, *link fronthaul/backhaul* e a BBU (HASSAN; YAU; WU, 2019). As principais características dessas unidades são explicadas abaixo:

- RRH: A RRH possui circuitos de RF, como conversores de sinal para cima / baixo, circuito *Application Delivery Controller* (ADC) e uma interface óptica para tratar os sinais da camada física. Os UEs estão interligados à unidade de antena do RRH através de um *link fronthaul* ou microondas. Usar a RRH torna maior a cobertura e reduz o *CAPital EXpenditure* (CAPEX) do C-RAN.
- *Fronthaul e backhaul link*: A conexão entre a RRH e a BBU é designado como *fronthaul*. Um *fronthaul* pode ser com ou sem fio. A fibra óptica é mais apta para a rede *fronthaul*, visto que possui mais disponibilidade de largura de banda e custo baixo. Já o *backhaul*, no CRAN, liga a BBU e a rede principal para controle de dados e aplicações. A utilização de recursos avançados como SDN e *Network Functions Virtualization (NFV)* no *backhaul* adiciona mais capacidade e eficiência ao QoS do C-RAN.

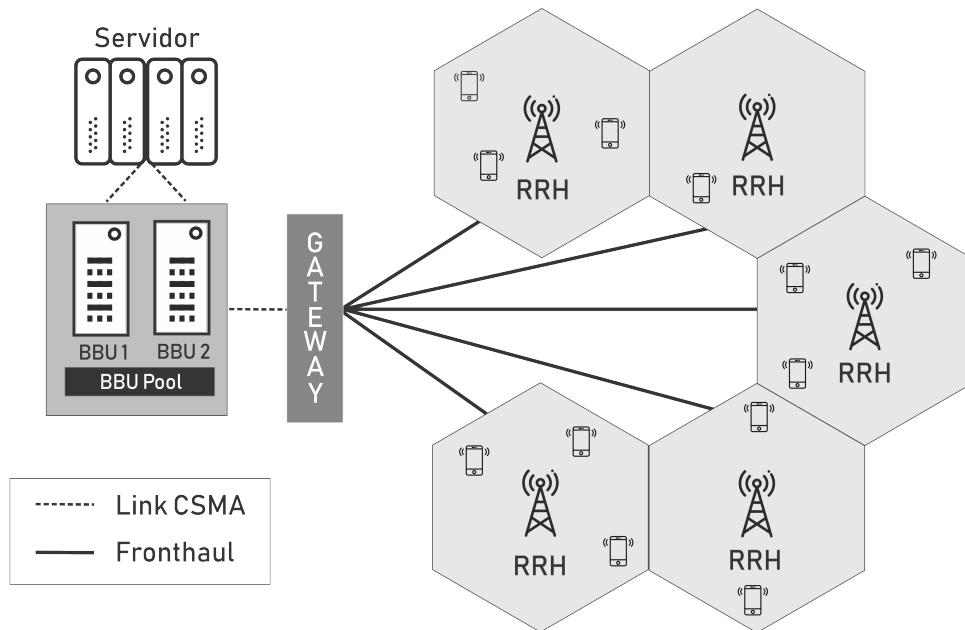


Figura 3 – Arquitetura C-RAN, rede centralizada, *fronthaul* e BBU *pool*.

Fonte: Autoria Própria.

- BBU: A BBU é uma unidade centralizada de gerenciamento e processamento residindo em uma BBU *pool*. A BBU usa tecnologia de *cloud computer* e virtualização para obter compartilhamento ajustável de recursos físicos e controle do espectro. Cada BBU representa, em um grupo de *Virtual Boxes* (VBs), um classificador de pacotes e um *hypervisor*. O processamento da BBU é realizado em um VB. O *hypervisor* gerencia todas as execuções de VBs criadas na BBU (PENG et al., 2014).
- Segundo (CHEN; RONG; MOUAKI et al., 2015), a taxa de processamento em cada BBU é estipulada por um número total de usuários ativos simultaneamente nos setores das BBUs. Contudo, há uma restrição de *hardware* ou *software*, que limita o número de usuários ativos em cada setor, que é chamada de HC, que pode ocasionar perda de dados ou de desempenho, quando mal gerenciada. Dessa forma, foi adotada uma técnica que visa a adequar o mapeamento e alocação de recursos na rede, que é a SON, após sua execução a rede deve apresentar mais eficiência e uma distribuição mais justa do uso da capacidade de cada BBU.

2.4 SDN

A SDN é um modelo de redes baseada na proposta de separar o plano de controle de uma rede do plano de dados que encaminha o tráfego de rede. O objetivo dessa desagregação é criar uma rede que seja gerenciada centralmente e programável. A tecnologia é usada principalmente em data centers corporativos para clientes que exigem uma rede que possa se adaptar mais facilmente às necessidades do negócio em comparação com as arquiteturas de rede tradicionais

(RAY; KUMAR, 2021).

Em SDNs, os dispositivos de rede tornam-se simples dispositivos de encaminhamento de pacotes (plano de dados), enquanto o "cérebro" ou controle lógico é implementado no controlador (plano de controle). Essa mudança de paradigma traz vários benefícios em comparação aos métodos usados até então. Primeiro, é muito mais fácil introduzir novas ideias na rede através de um programa de *software*, dado que esse é mais fácil de alterar e manipular do que usar um conjunto fixo de comandos em dispositivos de rede. Segundo, a SDN apresenta os benefícios de uma abordagem centralizada à configuração de rede, em oposição ao gerenciamento distribuído: os operadores não precisam configurar todos os dispositivos de rede individualmente para fazer mudanças no comportamento da rede, mas sim tomar decisões de encaminhamento de tráfego em toda a rede em um local logicamente único, o controlador, com conhecimento global do estado da rede (RAY; KUMAR, 2021).

A Figura 4 ilustra o funcionamento da rede SDN e explica suas principais características.

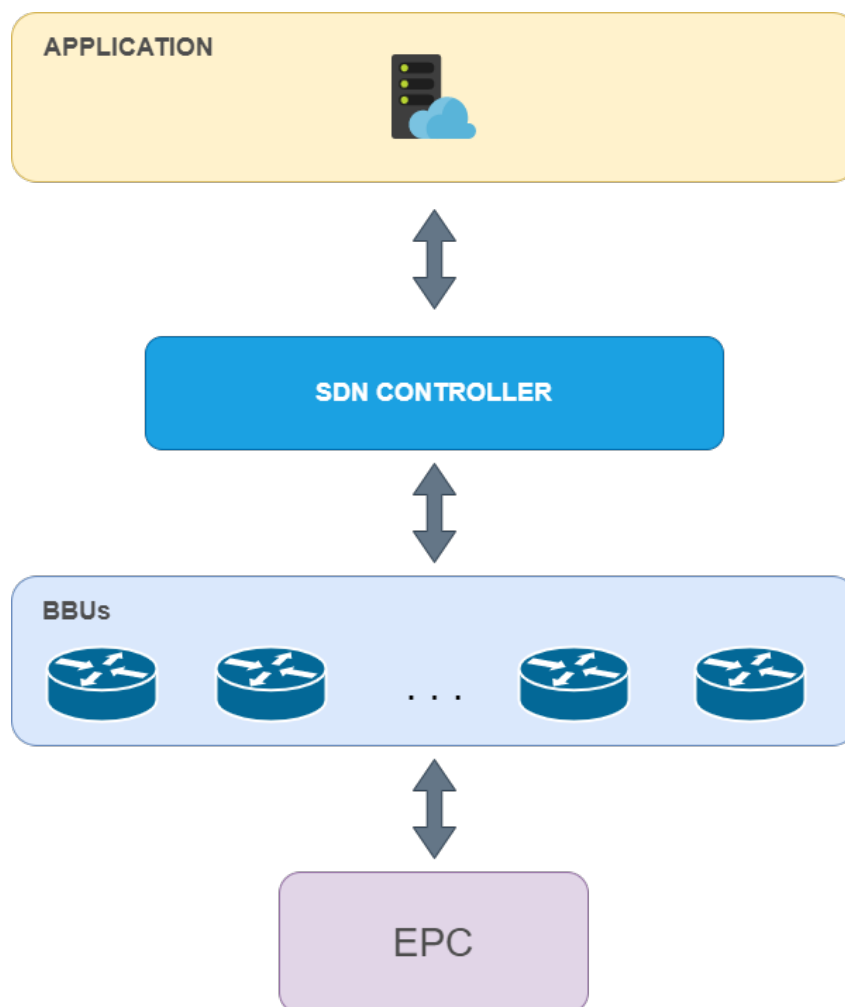


Figura 4 – Ilustração SDN, plano de dados, plano de controle e plano de aplicação.

Fonte:(MEDEIROS et al., 2020).

Plano de dados: O plano de dados é encarregado de executar todas tarefas de dados, ou seja, encaminhar os dados na rede, fragmentação e remontagem. Ele atua em dispositivos de redes, como pontos de acesso, roteadores e comutadores virtuais disponíveis para acesso e gerenciáveis por controladores SDN. Os dispositivos de rede e os controladores se comunicam por meio de conexões seguras em portas lógicas, exemplo a conexão *Transport Layer Security* (TLS). Um dos protocolos mais utilizado para prover essa comunicação entre os dispositivos e os controladores é o *OpenFlow* (ALAM et al., 2020).

Plano controle: É responsável por interpretar o conjunto de controladores da SDN que realizam as funcionalidades de controle e supervisão do encaminhamento dos fluxos de dados. Ele é o principal elemento encarregado de criar tabelas de *flux*, políticas de manipulação de dados, coletar informações e desconsiderar a complexidade da rede (BONFIM; DIAS; FERNANDES, 2019). O controlador utiliza uma interface chamada *Application Programming Interface* (APIs) que possibilita a comunicação entre todos os elementos da SDN, ela se divide em três, onde a primeira API *Eastbound* possibilita a comunicação entre os controladores e o plano controle; no *Southbound*, é feita a comunicação entre controladores e dispositivos de rede, já no *Northbound*, estabelece-se a comunicação entre os controladores e aplicações (BONFIM; DIAS; FERNANDES, 2019).

Plano de aplicação: É a representação de uma ou mais aplicações que se comunicam com o controlador para extrair uma visão genérica da rede em um processo de tomada de decisão. Ela é incumbida de definir regras e oferecer diferentes serviços, como controle de acesso, sistemas de detecção de intrusão, *firewall*, QoS, serviços de proxy e balanceamento de carga. O API *Northbound* é executor dessa abstração (BONFIM; DIAS; FERNANDES, 2019).

2.4.1 Inteligência Computacional (IC)

A Inteligência Computacional refere-se a um sistema que desempenha suas funções de maneira inteligente, inspira-se em processos naturais e exibe características humanas como raciocínio, aprendizado, evolução e capacidade de adaptação. Dentre as técnicas utilizadas em IC, destacam-se redes neurais, computação evolucionária, lógica *fuzzy* e sistemas especialistas (DE BRUYN et al., 2020).

Um dos principais focos da IC é solucionar problemas que eram considerados sem solução e otimizar gastos e recursos. Isso dá-se devido ao uso de várias técnicas capazes de identificar tendências e adaptar-se ao problema estudado (DE BRUYN et al., 2020).

2.4.1.1 Metaheurística

Segundo [Glover, Kochenberger,2003], uma metaheurística é uma estratégia de busca, não específica para um determinado problema, que tenta explorar eficientemente o espaço das soluções viáveis desse problema. São algoritmos aproximados que incorporam mecanismos para evitar confinamento em mínimos ou máximos locais. Conhecimentos específicos do pro-

blema podem ser utilizados na forma de heurística para auxiliar no processo de busca (por exemplo, na busca de um possível bom vizinho de um determinado ponto). Resumindo, podemos dizer que metaheurísticas são mecanismos de alto nível para explorar espaços de busca, cada uma usando um determinado tipo de estratégia. De grande importância na aplicabilidade de uma meta-heurística é o balanço dinâmico entre diversificação e intensificação, fazendo uma distinção entre os termos ingleses *exploration* e *exploitation*. O primeiro pode-se traduzir por diversificação, exploração diversificada, busca em largura ou simplesmente exploração; o segundo por exploração focada, busca em profundidade ou intensificação. Um dos desafios na aplicação de uma meta-heurística é encontrar o equilíbrio ideal entre diversificação e intensificação. Há diferentes modos de se classificar e descrever uma meta-heurística. A seguir são apresentados alguns aspectos que podem ser levados em consideração.

2.4.1.2 Inspiradas ou não na natureza

Talvez o modo mais intuitivo de se classificar meta-heurísticas seja com base nas origens do algoritmo. Nesse sentido, podemos diferenciar os algoritmos inspirados na natureza, como os Algoritmos Genéticos [HOLLAND, 1975] e os Algoritmos das Formigas [Bonabeu et al, 1999], daqueles não-inspirados na natureza, como a metaheurística *Iterated Local Search* [RAYWARD-SMITH et al, 1996]. Essa classificação pode não ser muito significativa, visando mais a oferecer uma abordagem didática. Por exemplo, o uso de memória na Busca Tabu [GLOVER, 1989] é ou não inspirada em um processo natural? Dizemos que uma meta-heurística é bio-inspirada quando suas regras de busca tentam simular alguns aspectos do comportamento de seres vivos como, por exemplo, o Algoritmo das Formigas, o algoritmo dos Pássaros [EBERHART E SHI, 2001] ou o algoritmo das Abelhas [ABBASS, 2001].

2.4.2 Baseadas em população ou baseadas em busca de pontos simples

No método construtivo ou de trajetória, parte-se de um conjunto solução vazio e segue-se acrescentando elementos a esse conjunto até obter uma solução viável para o problema. Métodos populacionais partem de um conjunto de soluções iniciais (a população inicial) e tentam encontrar uma solução melhor alterando-se elementos dessa população. Um exemplo de modelo construtivo é o Algoritmo das Formigas, pois descreve uma trajetória no espaço de busca durante a sua execução. Metaheurísticas baseadas em população, ao contrário, executam um processo de busca modificando a população inicial, como os Algoritmos Genéticos e o *Simulated Annealing*.

2.4.2.1 Particle Swarm Optimization (PSO)

O *Particle Swarm Optimization* (PSO) foi projetado em 1995 por James Kennedy e Russel Eberhart, e está no campo da computação evolucionária, visto que ele é inspirado no princípio do darwinismo sobre evolução das espécies e consegue tratar problemas de otimiza-

ção (EBERHART, R.; KENNEDY, J., 1995). A ideia principal do PSO está intimamente ligada às pesquisas, cujo foco é o algoritmo evolutivo que juntamente com o PSO dão ênfase ao modo de enxame que tem capacidade de cobertura de uma região maior e função objetiva e otimizada. Além de estudar os sistemas artificiais com características de vida (EBERHART, R.; KENNEDY, J., 1995).

O processo de execução do PSO é exibido na Figura 5, no qual o fluxograma inicia com a criação de um enxame de partículas em que cada partícula corresponde a uma solução candidata. Em seguida, as partículas exploram a área da solução aleatoriamente com velocidades distintas, e após passar pela *fitness* do algoritmo, as partículas são direcionadas aos seus melhores valores de aptidão. A velocidade de uma partícula individual é alterada de modo estocástico em cada iteração e sua atualização decorre da experiência da melhor posição histórica da respectiva partícula e a melhor experiência de posição de partículas vizinhas, isto é, a melhor posição global (EBERHART, R.; KENNEDY, J., 1995).

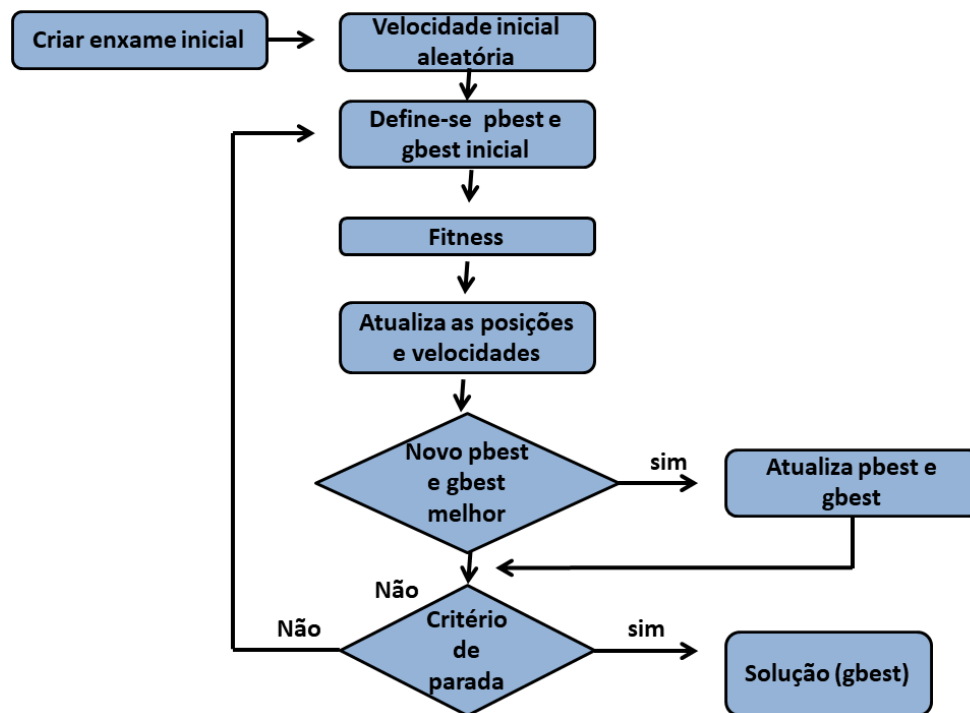


Figura 5 – Fluxograma PSO.

Fonte: Adaptado de (EBERHART, R.; KENNEDY, J., 1995).

Segundo (EBERHART, R.; KENNEDY, J., 1995) a posição de cada partícula é determinada pelo vetor e seu movimento pela velocidade da partícula, que pode ser calculada de acordo com a fórmula a seguir:

$$\vec{x}_i(t) = \vec{x}_i(t-1) + \vec{v}_i(t) \quad (1)$$

Vale evidenciar que quanto maior a distância, maior o valor dessa velocidade. Cada indivíduo guarda os resultados obtidos até o momento, (e o êxito em cada decisão) e o co-

nhecimento do desempenho dos indivíduos em sua vizinhança. Geralmente é colocado pesos aleatoriamente a cada parte e, portanto, a velocidade é formulada e determinada por:

$$\vec{v}_i(t) = \vec{v}_i(t-1) + \varphi_1 \cdot rand_1 \cdot (\vec{p}_i - \vec{x}_i(t-1)) + \varphi_2 \cdot rand_2 \cdot (\vec{p}_g - \vec{x}_i(t-1)) \quad (2)$$

na qual 1 e 2 são dois números positivos e aleatórios com distribuição uniforme, na faixa de [0,0, 1,0]. Em (2), há três componentes principais para a atualização da velocidade:

- Por vezes referido como “inércia” e/ou “*Momentum*”, modela a tendência da partícula de continuar na direção que tem viajado;
- O *pbest* (melhor local) de cada partícula indica o quão próximo que os dados já chegaram ao destino;
- E o *gbest* (melhor global), que só muda quando o valor do *pbest* de qualquer partícula se aproxima da meta, que é o *gbest*. A cada iteração do algoritmo, o *gbest* se aproxima do alvo, até que uma das partículas atinja o objetivo final.

2.4.2.2 Simulated Annealing (SA)

O *Simulated Annealing* (SA) é um algoritmo metaheurístico baseado na termodinâmica, essa técnica utiliza uma busca local probabilística para realizar a otimização. A metaheurística usada é uma metáfora de um processo térmico, dito *annealing*, utilizado em metalurgia para obtenção de estados de baixa energia num sólido. O processo térmico *annealing* é bastante utilizado no aprimoramento de aços, onde o material é aquecido até altas temperaturas, fazendo com que os átomos se movimentem livremente e depois é resfriado gradativamente para que as moléculas se encaixem em uma melhor posição (VAN LAARHOVEN; AARTS, 1987).

O processo do SA, como mostrado pela Figura 6, consiste, em primeiro, em aquecer o metal para que os átomos se movam, em seguida essa temperatura é reduzida em etapas até que o metal "esfrie" e não ocorram mais alterações. A cada temperatura, a simulação deve prosseguir por tempo suficiente para que o sistema atinja um estado estacionário. A temperatura encontrada é checada e, se ela for melhor, ela é selecionada, se não, ela pode ser selecionada conforme a probabilidade estabelecida. Conforme a temperatura diminui, o algoritmo se torna menos propenso a aceitar soluções piores. Após esfriar totalmente o metal, só restaram soluções ótimas (VAN LAARHOVEN; AARTS, 1987).

O mecanismo de arrefecimento é, provavelmente, o componente mais importante e decisiva para um bom desempenho do algoritmo SA. O arrefecimento efetivo da temperatura pode ser feito por vários mecanismos (OSMAN; KELLY, 1997) (COHN; FIELDING, 1999). O mais comum utiliza uma variação geométrica:

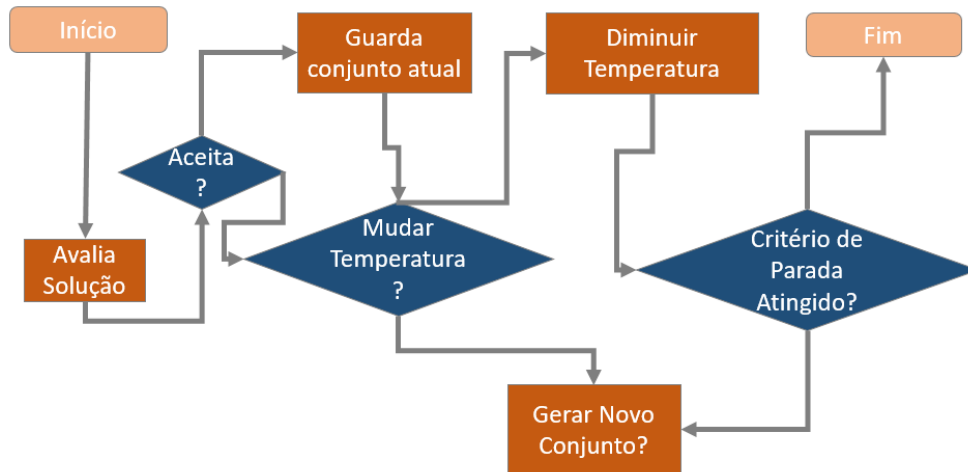


Figura 6 – Fluxograma SA.

Fonte: Autoria Própria.

$$T_{i+1} = sT_i \quad (3)$$

em que o fator s varia tipicamente entre 0,8 e 0,99. Outro esquema possível é a função dos limites superior T_0 e inferior T_f da temperatura e do número de iterações N :

$$T_{i+1} = T_i \left(\frac{T_0}{T_f} \right)^Y \quad (4)$$

O sistema torna-se estável quando a temperatura atinge valores próximos de zero. Nesse caso, a probabilidade da condição de *Boltzman* ser satisfeita é diminuída drasticamente, ou seja, são diminuídas as chances de uma solução sub-ótima (solução com um valor da função objetivo maior que a melhor solução atual) ser aceita. A solução obtida, quando o sistema encontra-se nesta situação, evidencia a localização de um mínimo local. O procedimento pode ser finalizado de acordo com a condição de parada estabelecida. Essa condição pode ser em relação ao valor da temperatura, a quantidade de iterações do algoritmo ou ao valor da função objetivo.

2.5 Considerações Finais

O aumento de dispositivos móveis e novas aplicações é um dos dos principais motivos para a criação e pesquisa nesse âmbito. Tais aspectos pressionam a comunidade científica e as empresas de telecomunicações a desenvolverem soluções adequadas e capazes de suportar as novas métricas dessa nova geração. Em vista disso, esse capítulo frisou os principais conceitos e soluções emergentes que visam a mitigar as principais problemáticas atuais.

3 TRABALHOS CORRELATOS

3.1 Considerações Iniciais

O uso de *HetNets* é largamente apontado como solução viável para atender os requisitos da rede 5G CRAN e H-CRAN, entretanto, a implantação desordenada de PRRHs e a má orquestração de recursos de rede geram uma diversidade de problemas, desde gerenciamento de interferência até financeiros, como custo de implantação elevado ou um aumento significativo no consumo de energia, problemas que podem inviabilizar o uso desta tecnologia. Assim, diversos trabalhos na literatura propuseram metodologias inteligentes para implantação.

3.1.1 Framework

Em (SIGWELE; HU; SUSANTO, 2020), é discutido o problema de otimização de eficiência energética em dois níveis em uma rede H-CRAN. Na primeira etapa, é executado um algoritmo de desligamento dinâmico para PRRH, baseado em uma função de utilidade e mantendo o QoS dos usuários, em que apenas as PRRHs são desligadas e as *Macro Remote Radio Access* (MRRHs) são mantidas para garantir a cobertura mínima. Já na segunda etapa, dois algoritmos são utilizados para reduzir o número de servidores BBUs, consequentemente, economizando energia, isso se dá pela consolidação de *Virtual BandBase Unit* (vBBU) baseada em nuvem. Ambas as soluções propostas apresentam bons resultados, garantindo assim economia de energia sem perder a qualidade do QoS.

Em (SOTIRIOS; SPANTIDEAS, 2022), é proposta uma solução para otimização de redes C-RAN, com foco na seleção de setores RRH e no balanceamento de carga, utilizando processos de decisão de *Markov* (MDP) e mapeamento dinâmico entre setores RRH e unidades BBU. Ele introduz uma estrutura para a seleção de pares RRH-Sector, usando o Processo de Decisão de Markov (MDP) para lidar com condições dinâmicas da rede e apresenta uma estratégia de mapeamento dinâmico entre RRH-Sector e BBU, promovendo assim, uma rede auto-organizável. Além disso, foi desenvolvido um mecanismo de balanceamento de carga para otimizar a capacidade da rede. As simulações mostram melhorias em desempenho e eficiência energética, e o modelo integra as necessidades de usuários e operadores.

3.1.2 Otimização de Balanceamento

Os autores de (PAIXÃO et al., 2018) destacam a arquitetura C-RAN como uma alternativa promissora, devido ao seu poder de processamento e à capacidade de reconfigurar e mapear os usuários de maneira inteligente. Foi explorado um método para otimizar o QoS dessa arquitetura, utilizando um KPI para minimizar o número de UEs bloqueados. Com esse objetivo, o algoritmo PSO foi aplicado para realizar o emparelhamento entre os usuários e o KPI,

otimizando o QoS. Os resultados obtidos foram satisfatórios, demonstrando um desempenho potencialmente superior ao de outras abordagens apresentadas na literatura.

O estudo apresentado em (YANG, 2009) enfatiza a eficiência dos algoritmos inspirados pela natureza no campo da otimização. Nesse contexto, é introduzida uma técnica inovadora, detalhadamente desenvolvida e bem descrita, conhecida como o FA. Os autores avaliam o desempenho do FA em comparação com abordagens metaheurísticas já estabelecidas, como o PSO. O novo algoritmo foi empregado para resolver uma variedade de problemas de otimização aplicados a diferentes funções. Os resultados obtidos mostram que o FA se destacou em relação aos algoritmos comparados, evidenciando maior eficiência na solução desses problemas e maior potencial para enfrentar desafios futuros.

Com o intuito de otimizar o mapeamento entre as BBUs e as RRHs, os autores de (ADIRAJU; RAO, 2022) implementaram o algoritmo do PSO, uma técnica pertencente ao campo da Inteligência de Enxame, visando a uma gestão inteligente dos recursos na arquitetura C-RAN. O estudo tem como objetivo principal reduzir os custos da rede por meio de uma alocação dinâmica de recursos, ao mesmo tempo que procura minimizar o consumo de energia dos componentes da C-RAN, impactando diretamente na distribuição das RRHs. Os resultados demonstraram uma diminuição significativa no consumo de energia, aliada à manutenção da eficiência energética, orientando a pesquisa para redes de comunicação mais sustentáveis e economicamente viáveis.

As arquiteturas propostas em (YANG; ZHANG et al., 2016) e (YANG; YAO et al., 2022) demonstram eficácia na otimização integrada de recursos de radiofrequência, espectro óptico e processamento das BBUs, com o objetivo de maximizar a cobertura de rádio e atender aos requisitos de QoS. Os estudos apresentam resultados promissores nesses aspectos essenciais. No entanto, vale ressaltar que eles não aprofundam a questão da orquestração de recursos nos *pools* de BBUs. Em particular, não consideram plenamente os impactos do fenômeno de maré, o que pode levar ao bloqueio de usuários devido a uma alocação inadequada de recursos. Essa lacuna na análise pode comprometer a eficiência operacional em cenários dinâmicos, na qual a demanda de tráfego é variável.

3.1.3 Eficiência Energética

Foi proposto no (MA, Xiaoyan 2023) explorar as características da tecnologia 5G, enfatizando sua elevada largura de banda, baixa latência e o conseqüente aumento no consumo de energia, em virtude do crescimento previsto no número de dispositivos conectados. O texto ressalta o papel das redes celulares heterogêneas densas (HCNs) na redução da sobrecarga das estações-base macro (MBSs), por meio da implementação de pequenas estações-base (SBSs), o que contribui para a ampliação da capacidade e da cobertura da rede. Os autores apontam a necessidade de desenvolver estratégias eficazes de eficiência energética para as estações-base, que representam aproximadamente 70% do consumo de energia das comunicações, a fim de

mitigar os crescentes custos com eletricidade e atender às preocupações ambientais.

O estudo em (SRIVASTAVA; GUPTA; KAUR, 2020) aborda a eficiência energética do sistema por meio da alocação de recursos e controle de potência. Os autores propuseram uma redução no consumo de energia ao ativar ou desativar as RRHs com base na distribuição atual dos usuários. O problema foi modelado com o objetivo de maximizar a eficiência energética (EE), sujeita à restrição de garantir o uso total da frequência entre as RRHs. A solução foi estruturada em várias etapas para simplificar a complexidade do problema. Primeiramente, as RRHs a serem ativadas ou desativadas são selecionadas; em seguida, com base nas RRHs em operação, a alocação de usuários e a potência de transmissão das RRHs são otimizadas. Por fim, os usuários não atendidos são alocados à estação base macro. A análise de desempenho indica que a solução proposta melhora significativamente a EE do sistema e reduz o consumo de energia, superando outras abordagens na literatura, com um aumento superior a 57% na EE.

3.2 Considerações Finais

Com base na análise dos trabalhos aqui apontados, fica claro que, embora os problemas de alocação de recursos de PRRHs e de BBU's tenham sido abordados amplamente, em separado ou em conjunto, nenhum dos estudos mencionados lidou efetivamente com o problema do mapeamento e balanceamento de carga de rede levando em consideração a tomada de decisão baseada multi-nível, fator determinante para uma orquestração de recursos eficiente. Portanto, pode-se afirmar que este trabalho faz duas contribuições principais: a) implementação de um novo algoritmo para desligamento de antenas baseado em SA; b) Algoritmo de balanceamento de carga otimizado baseado no FA para redefinição de mapeamento BBU-RRH baseado na etapa anterior.

4 PROPOSTA DE TESE

4.1 Considerações Iniciais

Este capítulo propõe um *framework* de reorquestração de recursos em redes móveis, que visam otimizá-la, com foco na distribuição igualitária do tráfego e eficiência energética. Embora existam várias técnicas disponíveis para otimizar o posicionamento de estações base voadoras em redes móveis, há uma falta de soluções específicas para cenários urbanos onde o *tidal effect* e espacial afetam a qualidade da rede. Para lidar com isso, é necessário investir em infraestrutura e tecnologia, como o 5G, H-CRAN e SDN, que oferecem maior capacidade e gestão inteligente de recursos. A utilização de infraestruturas temporárias também é crucial para adaptar dinamicamente a rede às variações de tráfego, reduzindo o consumo de energia. Assim, o desenvolvimento deste *framework* é essencial para garantir a sustentabilidade e eficácia das redes móveis a longo prazo (ADIRAJU; RAO, 2022).

4.2 Proposta de Tese

O *framework* proposto e o diagrama de sequência que exibem as etapas de funcionamento do SDN controller no âmbito dessa proposta estão descritos nas Figuras 7 e 8. Primeiramente, os dados de posicionamento geográfico das PRRHs disponíveis, em uma dada região, bem como o posicionamento dos UEs, por hora, são dados como entrada no sistema. O Simulated Annealing (SA) é acionado e irá determinar a melhor combinação de PRRHs, por período, buscando otimizar o QoS dos UEs e minimizando a interferência, desligando as PRRHs desnecessárias. O segundo passo é vinculado à carga gerada pelas PRRHs ao cloud BBU. Nesta etapa, um algoritmo metaheurístico *firefly algorithm* (FA) é acionado, que visa a realizar o mapeamento e balanceamento da carga das PRRHs entre as BBUs, respeitando a capacidade máxima de cada setor da BBU. Abaixo, são listados os itens existentes neste *framework*:

- **Área de Cobertura:** As PRRHs são posicionadas em formato de grade, ou seja, com distâncias iguais entre elas. Há somente uma MMRH posicionada no centro do cenário. Além disso, os UE tem perfis de tráfego iguais, ou seja, possuem o mesmo serviço que demanda uma determinada taxa de dados.
- **SDN controller:** O SDN controller é o gerenciador de todos os processos desse diagrama, conforme será descrito abaixo.
- **Perfil de Tráfego:** Em cada hora a quantidade e a posição dos UEs é alterada. Os UEs se conectam à RRH mais próxima. Isso faz com que haja diferentes perfis de tráfego nas RRH em cada período analisado. Portanto, a informação gerada por essa etapa consiste no número de UEs conectados em cada RRH e a taxa de dados de cada UE.

- SA: A partir dessas informações, o algoritmo de otimização SA é acionado para determinar quais PRRH podem ser desligadas sem que a taxa de dados dos UEs diminua a ponto de gerar uma probabilidade de bloqueio elevada. Desde essa etapa é definido o estado de cada PRRH (ligada ou desligada) e a quais RRHs os UEs estão conectados. Este algoritmo é explicado em detalhes na seção 4.3.1.
- Converte o tráfego dos UEs em usuários bloqueados: Os dados dos UE são convertidos em usuários bloqueados e enviados para a BBU *pool*.
- Mapeamento dos Usuários: Mapeia usuários bloqueados e identifica onde estão alocadas.
- Alocação dos UE-PRRH-BBU inicial: Inicia a alocação dos UE nas PRRHs e das PRRHs nas BBUs.
- Balanceamento de carga ativado BBUs: Executa o balanceamento dos recursos entre as BBUs, que tem capacidade determinada pelo KPI de usuários bloqueados.
- Balanceamento de carga ativado em setores das BBUs: Executa o balanceamento dos recursos entre os setores das BBUs.
- O FA realiza o balanceamento de cargas nos setores das BBUs, alocando cada PRRH em um setor para minimizar o consumo de energia. Os KPIs utilizados incluem a capacidade de cada setor e antena, além do consumo energético. Foi necessário modificar o EPC do Ns-3.41 para inserir um controlador SDN, conforme detalhado na seção 4.3.2.
- Recursos reorquestrados: Após passar por todas as etapas de balanceamento, são expostos os recursos reorquestrados em suas respectivas BBUs e setores. Com isso, é obtida uma configuração de rede otimizada para o perfil de tráfego de um determinado período.

4.3 Algoritmos Metaheurísticos

Nesta subseção, serão discutidos os algoritmos escolhidos, suas principais características e sua adaptação ao problema abordado. Algoritmos bioinspirados melhoraram significativamente a resolução de problemas complicados, particularmente aqueles relacionados à otimização. Segundo (YANG, 2009), esses algoritmos são considerados entre os mais eficazes para resolver problemas de otimização, principalmente aqueles classificados como NP-problema não-deterministicamente polinomial.

4.3.1 Algoritmo SA

O SA é uma técnica de otimização inspirada no processo de recozimento térmico de metais. Esse processo físico envolve aquecer um material a uma temperatura elevada e, em seguida, resfriá-lo gradualmente para que atinja um estado de mínima energia. Analogamente,

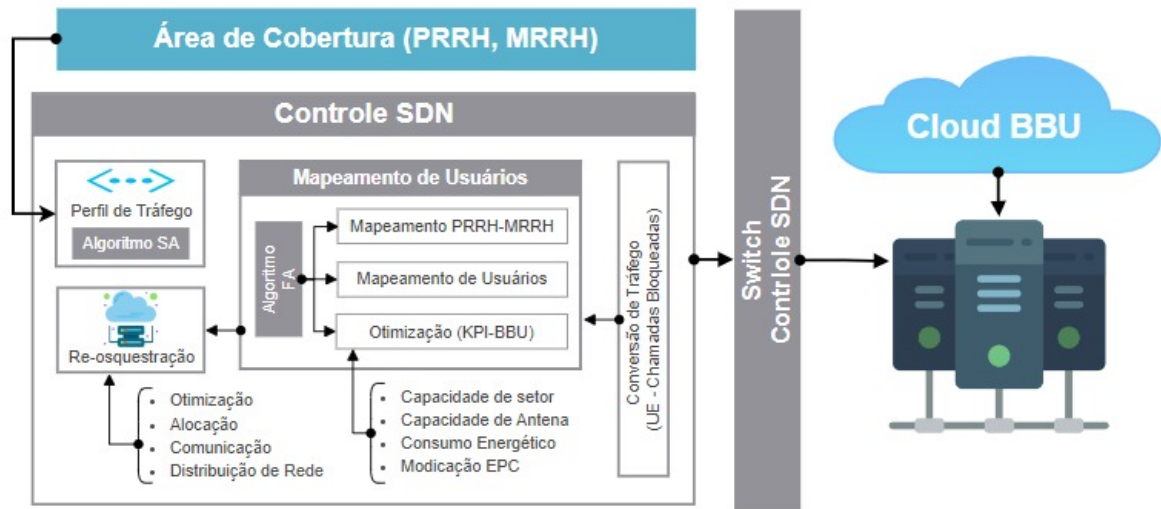


Figura 7 – *framework* de Reorquestração, tráfego inicial dos usuário, desligamento com metaheurística, conversão do trafego em usuários bloqueados e balanceamento

Fonte: Autoria Própria.

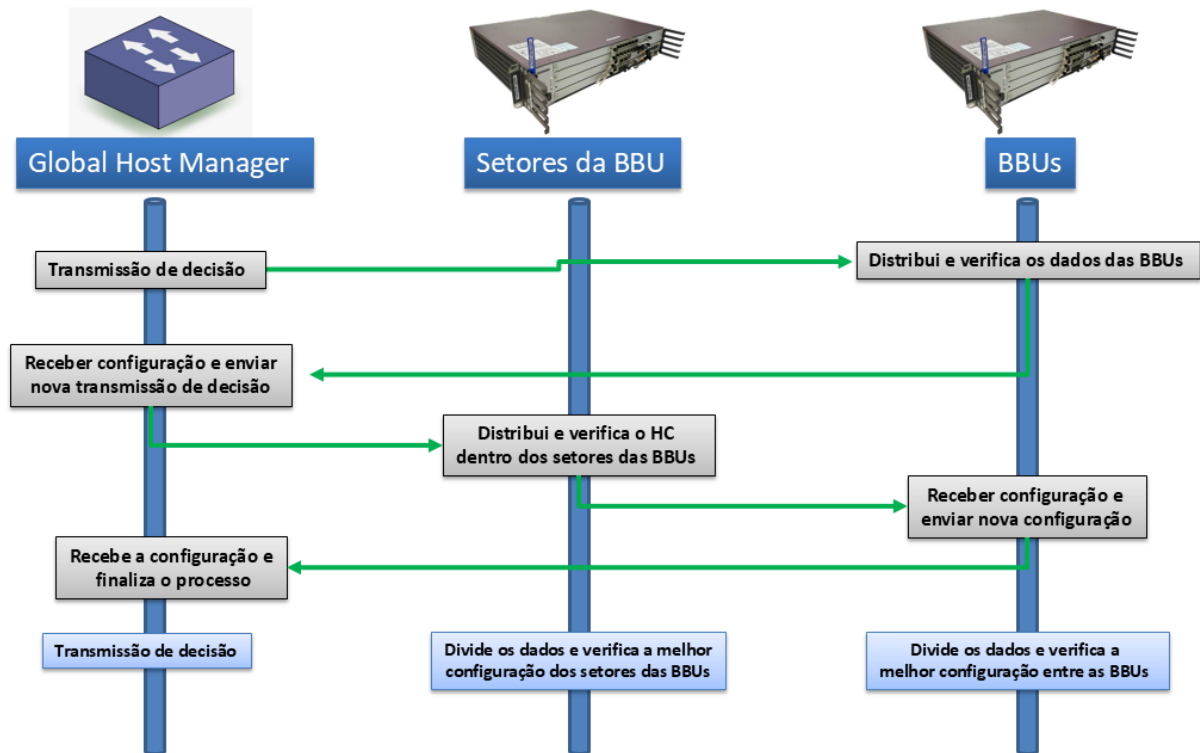


Figura 8 – Processo de Mapeamento e Balanceamento da BBU, transmissão de decisão, verificação de configuração de dados e verificação global dos dados de balanceamento.

Fonte: Adaptado de (KIRKPATRICK; GELATT JR; VECCHI, 1983).

o SA busca encontrar a solução ótima de um problema explorando o espaço de soluções de forma controlada.(KIRKPATRICK; GELATT JR; VECCHI, 1983).

O pseudocódigo do SA detalha o passo a passo do seu funcionamento. Após a ativação do algoritmo, os UE são alocados em suas respectivas PRRHs, e aquelas que estiverem subutilizadas, serão desligadas ou mantidas ativas com base nas equações apresentadas a seguir, que servem como principais métricas para essa decisão. A Figura 8 ilustra o funcionamento do SA.




Figura 9 – Processo ilustrativo de Orquestração de Recursos utilizando o SA.

Fonte: Adaptado de (KIRKPATRICK; GELATT JR; VECCHI, 1983).

O número total de UE conectado aos PRRHs é dado pela equação 5, em que $(Ants(i))$ é o total número de UE conectados a PRRHs na hora i :

$$Ants(i) = \sum_{j=0}^N x(j) \quad (5)$$

, em que $x(j)$ é o número de UEs conectado ao PRRH(j) e N é o número de PRRHs ativos. Esse número pode variar de zero (quando apenas o MRRH é ativado) até número máximo de PRRHs presentes na rede. O valor de N é determinado pelo algoritmo SA que seleciona o conjunto de PRRHs que proporcionem o menor custo. Para verificar o custo T_s , a Equação 6 é usada:

$$T_s = TA(i) - Ants(i) \quad (6)$$

$$TA(i) = 3600 \cdot D(i) \quad (7)$$

$$D = (0.90, 0.69, 0.56 \dots 0.81, 0.96, 1) \quad (8)$$

, na qual $TA(i)$ é o número de UEs na rede na hora i ; D é a distribuição dos UEs em 24 períodos do dia. Essa distribuição está em consonância com o fluxo das UEs no distrito de Manhattan, em Nova York (CHEN; RONG; ZHANG et al., 2017).

Uma vez determinado qual conjunto PRRH tem o menor custo, calcula-se a probabilidade de bloqueio da solução encontrada. O algoritmo terminará somente se essa probabilidade for menor que 0,1%, caso contrário o valor de N é incrementado e uma nova seleção é feita pelo algoritmo de recozimento, agora com mais um PRRH ativo.

A saída do algoritmo é dada por uma matriz $S(i, j)$ que, corresponde ao número de UEs conectados a cada PRRH j na hora i .

Algoritmo 1: Pseudocódigo do SA

```

1 Função objetivo equação 1
2 Gera a população inicial  $x_i (i = 1, 2, \dots, n)$ 
3 Determina a temperatura inicial  $I_i$  em  $x_i$  usando  $f(x_i)$ 
4 início
5    $\sigma(S) = 0$ 
6   enquanto  $t < MaxGerações$  faça
7     para  $i = 1$  até  $n$  faça
8       para  $j = 1$  até  $n$  faça
9         se  $I_j > I_i$  então
10          | verifica a probabilidade for menor ou igual a 0,1%
11          fim
12          avalia a solução
13        fim
14      fim
15      Apresenta a solução
16    fim
17 fim

```

O posicionamento dos UEs é dado com entrada para o SA, que buscará encontrar o melhor mapeamento entre UEs e PRRHs (conforme equações 6, 7 e 8), desligando assim aquelas que serão subutilizadas conforme pode ser observado na Figura 9.

4.3.2 Algoritmo FA

O segundo é FA, que imita o hábito social de animais, como os insetos, peixes e pássaros. Eles exploram uma região, determinado pela função objetivo (ou *fitness*), a fim de encontrar

a solução ótima para o problema. A posição da melhor partícula da população será a melhor posição individual (EBERHART, Russell; KENNEDY, James, 1995).

O procedimento de execução do algoritmo FA é detalhadamente apresentado no pseudocódigo a seguir. O algoritmo adota um indicador de desempenho inspirado no proposto por (SILVA GONÇALVES et al., 2023), com o objetivo de otimizar o processo de mapeamento e balanceamento, além de avaliar seu comportamento em uma rede com variações no fluxo de tráfego.

Então, procurou-se equilibrar a carga dos BBUs, minimizando o número de UE por setor, a fim de evitar usuários bloqueados e sobrecarga em um determinado setor, melhorando assim a rede. A função objetiva foi alterada, para distribuir igualmente a quantidade de UE pelo número de setores disponíveis no BBU *pool*. Para isso, inicialmente, é criado um vetor de UE por setor, como modelado na Equação 9.

$$U_s = \sum_{j=1}^N C_j R_s^{i+1}, S = 1, 2, \dots, K \quad (9)$$

, na qual:

- U_s é o número UE por setor;
- N é o total PRRHs;
- K é o total setor;
- C é a quantidade de UE conectados na PRRH j ;
- R é uma variável binária onde assume o valor 1 se a PRRH;
- j está alocada no setor s .

, o vetor U_s é usado na função objetivo, que irá variar de acordo com o número de UE na rede de forma a garantir que os setores estarão balanceados e, portanto, suas respectivas BBUs também. Todos os possíveis U_s para todos os K (setores) serão testados para obter o menor valor possível de (KPI_{min}). Esse processo envolve reduzir o número de usuários bloqueados e consequentemente maximizar o QoS, como demonstrado na Equação 10.

$$\{0, if(U_s - HC) < 0\} or \{(U_s - HC)if(U_s - HC) \geq 0\} \quad (10)$$

, a saída do modelo é dada pelo vetor:

$S_j^{i+1} = \{S_1^{i+1}, S_2^{i+1}, \dots, S_N^{i+1}\}$, que representa os setores das BBUs S_j^{i+1} e PRRHs que foram alocados a esses setores.

Algoritmo 2: Firefly Algorithm pseudocode.

Data: Objective Function $f(x)$, $x = (x_1, \dots, x_d)^T$; Generate initial firefly population x_i ($i = 1, 2, \dots, n$); Sets light intensity I_i in x_i using $f(x_i)$; Sets absorption coefficient γ

Result: Best solution found

```

1  $\sigma(S) = 0$ ;
2 while  $t < MaxGeneration$  do
3   for  $i = 1$  to  $n$  do
4     for  $j = 1$  to  $n$  do
5       if  $I_j > I_i$  then
6         | Move the firefly  $i$  towards the firefly  $j$ ;
7       end
8         Calculate  $\beta(r) = \beta_0 e^{-\gamma r^2}$ ;
9         Evaluate new solutions and update light intensities;
10      end
11    end
12    Rank the fireflies and find the best one;
13 end

```

4.4 Implementação do cenário

Aqui serão detalhados o cenário implementado e as alterações que foram realizadas no núcleo do simulador para que fosse possível rodar um cenário H-CRAN e os algoritmos bioinspirados.

4.4.1 Parâmetros de Rede

A cobertura celular pode ser definida com base na cobertura, potência, métodos de codificação e perdas de propagação (POPOOLA et al., 2018). Efetivamente, o *path loss* pode ser medida a partir do modelo Hata e sua extensão COST231 para *Carrier Frequency* (CF) abaixo de 2 GHz e do modelo *Stanford University Interim* (SUI) para CF acima de 2 GHz (CASTRO et al., 2010). A relação *Signal-to-Interference-plus-Noise Ratio* (SINR) do *downlink* para uma determinada subportadora N é atribuída a UE k no PRRH ao qual está conectado. Isso pode ser expresso como a Equação 11:

$$SINR_k = \frac{P_{k,b(k)}}{\sigma^2 + I_k} \quad (11)$$

, na qual $P_{k,b(k)}$ é a potência recebida (em *watts*) na subportadora N atribuída a UE k pelo PRRH $b(k)$ que o serve, σ^2 é a potência de ruído térmico e I_k é a interferência intercelular de PRRHs vizinhos. Supõe-se que todos os PRRHs estejam transmitindo na potência máxima P . A potência recebida no UE k de $b(k)$ pode ser calculada usando a Equação 12, que expressa a potência recebida de um UE k com base na potência transmitida e no desvanecimento do sinal. O modelo de propagação SUI (ERCEG, 2001) foi usado para calcular o sinal de desvanecimento.

$$P_{k,b(k)} = \frac{10^{\frac{TP+G(k)-L_{SUI}}{10}}}{1000} \quad (12)$$

, na qual TP é a potência do sinal de entrada de interesse, G é o Ganho e L_{SUI} é o valor em dB do sinal de desvanecimento que é calculado pelo modelo de propagação SUI, e expresso pelas seguintes equações:

$$L_{SUI} = A + 10\gamma \log \frac{d}{d_o} + S, d > d_o, \quad (13)$$

$$A = 20 \log \frac{4\pi d_o}{\lambda}, \quad (14)$$

$$\gamma = a - bh_b + \frac{C}{h_b} \quad (15)$$

, em que d é a distância do PRRH ao ponto medido em metros, d_o é igual a 1 metro de acordo com (CHECKO et al., 2014); λ é o comprimento de onda em metros; γ é o expoente da perda de percurso; h_b é a altura do PRRH, que pode estar entre 10 e 80 metros; A , B e C são as constantes que dependem do tipo de terreno do cenário; nesse caso, utilizou-se C ($A = 3,6$, $B = 0,005$ e $C = 20$); S é o efeito de sombreamento, que pode estar entre 8,2 e 10,6 dB.

Assumiu-se que cada UE atinge o limite estabelecido pelo teorema da capacidade de Shannon, ou seja, a taxa de dados para k é expressa como (CHECKO et al., 2014), onde B é a largura de banda do sistema Equação 16.

$$C_k = B * \log_2(1 + SINR_k) \quad (16)$$

O cenário implementado, foi uma rede móvel H-CRAN, onde o fluxo da rede foi retirado do perfil de UE de distritos da cidade de *New York*, na qual, a área é de 4km de extensão (CHEN; RONG; ZHANG et al., 2017). Uma vez que possibilitará investigar uma grande fração de informações que desempenham um papel vital na engenharia de tráfego, design de rede, balanceamento de carga e preços, tal comportamento pode ser observado na figura 10. Onde 100 PRRHs foram randomicamente posicionadas, uma MRRH, Uma BBU *pool* com cinco BBUs residentes e 3600 UE com características homogêneas, para que, deste modo, todos os UE possuam os mesmos requisitos. As dimensões do cenário foram normalizadas conforme os limites territoriais da região de *New York* (CHEN; RONG; ZHANG et al., 2017). O restante dos parâmetros pode ser encontrado na tabela 1.

A problemática discutida nesse trabalho é dividida em duas etapas. A primeira, visa minimizar o número de PRRHs subutilizadas durante seu funcionamento diário, esse processo é




Figura 10 – Variação da Carga de Tráfego em um Dia.

Fonte: Adaptado de (YAN et al., 2018b).

Tabela 1 – Parâmetros da Simulação.

Parâmetros	Valor
Largura de Banda B	180kHz
Perda de Propagação ($MRRH$)	COST231
Perda de Propagação ($PRRH$)	SUI-TYPE A
Potência de Transmissão ($MRRH$)	43 dBm
Potência de Transmissão ($PRRH$)	23 dBm
Área Total do Cenário	4km ²
Altura da PRRH	16m
Área de Cobertura (PRRH)	150m
Área de Cobertura (MRRH)	4km
Intervalo de Confiança	95%
Número de experimentos	31

explicado na seção 4.1. Já na segunda, após a obtenção dos resultados da primeira etapa, é realizado um balanceamento entre as BBUs ativas e entre seus respectivos setores, essa metodologia é exposta na seção 4.2.

Além disso, foi considerada a eficiência energética do sistema. A eficiência energética é definida como a relação entre a taxa de dados transmitida e a energia consumida. Para um cenário com $k = 1, 2, \dots, K$ usuários, a eficiência energética do k -ésimo usuário é descrita pela Equação 17

$$EE_k = \frac{R_k}{p_k + P_c} \quad (17)$$

, na qual:

- R_k representa a taxa de transmissão do usuário k ;

- p_k é a potência consumida pelo usuário k ;
- P_c é o consumo fixo de energia necessário para operar o ponto de acesso (Access Point), mesmo sem transmissão de rádio frequência (RF).

consequentemente, a eficiência energética total do sistema é expressa pela Equação 18

$$EE = \sum_{k=1}^K EE_k \quad (18)$$

4.4.2 Ambiente de simulação

Para testar o comportamento das heurísticas, foi desenvolvida uma simulação no NS-3.41. No momento em que este trabalho foi desenvolvido, o simulador não possuía suporte nativo para recursos de SDN. A Figura 11 apresenta a arquitetura final após as alterações realizadas. A seção "Application" representa os serviços e aplicações que utilizam a rede, como chamadas de voz ou VOIP (Voice Over IP). Ela simboliza o tráfego gerado pelos usuários, que é processado e roteado pela infraestrutura da rede.

O "SDN Controller" (Controlador SDN) é responsável pelo gerenciamento e controle da rede. Ele inclui algoritmos para alocação e mapeamento de usuários, como o algoritmo SA e o FA, além de realizar a Mapeamento de Usuários (User Mapping). O controlador SDN define políticas e coordena a infraestrutura para otimizar os KPIs, fazer alocação e reorquestração de recursos, além do mapeamento entre PRRH e MRRH.

As BBUs são unidades que foram adicionadas no simulador e que são responsáveis pelo processamento de sinais de rádio e geralmente ficam localizadas no núcleo da rede. O EPC é a parte central do núcleo da rede, encarregado de gerenciar a comunicação de dados entre os dispositivos móveis e a internet. Seus componentes são:

- PCEF (Policy and Charging Enforcement Function): Funciona como um módulo que aplica políticas de qualidade de serviço (QoS) e monitora o uso de dados dos usuários para cobrança.
- PGW (Packet Data Network Gateway): O gateway para redes externas de dados, responsável por rotear os dados entre a rede móvel e redes externas, como a internet.
- SGW (Serving Gateway): Um gateway que roteia dados entre a rede de acesso e o EPC, gerenciando a mobilidade dos usuários ao longo da rede.
- MME (Mobility Management Entity): Gerencia a mobilidade e autenticação dos usuários, além de coordenar a conexão dos dispositivos móveis com a rede.

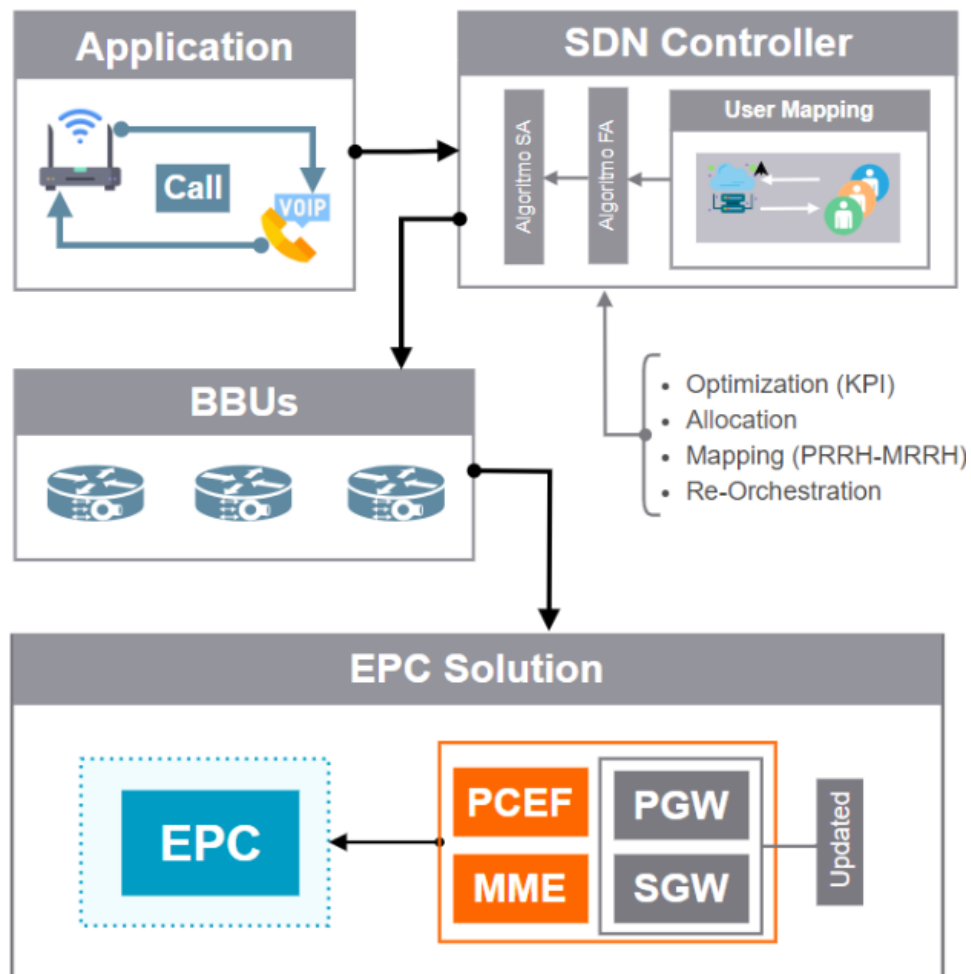


Figura 11 – Arquitetura alterada do NS-3

Fonte: Autoria Própria.

Os componentes PGW e SGW foram aprimorados e reconfigurados para incorporar um gerenciamento dinâmico e otimizado da rede. A adaptação da arquitetura envolveu, em particular, a integração de controladores e switches pertencentes ao paradigma SDN, utilizando a biblioteca OFSwitch13. Essa abordagem permitiu aprimorar a flexibilidade e a eficiência na administração dos recursos de rede, criando os fundamentos necessários para a implementação de uma rede verdadeiramente 5G, com suporte a alta capacidade, baixa latência e escalabilidade dinâmica.

O conjunto de BBU foi inserido entre o *Evolved Packet Core* (EPC) e a camada de serviços, com cada RRH sendo conectada uma BBU. Cada switch poderia lidar com até 300 usuários, de acordo com o HC estabelecido para as BBU.

Para implementar essa modificação, várias mudanças foram feitas no código fonte do Ns-3.41. Uma variável chamada *m-mymap* foi criada para mapear o *International Mobile Subscriber Identity* (IMSI) do usuário ao seu endereço IPv4. Uma função chamada *RecvMymap()* também foi adicionada no módulo EPC (especificamente nos arquivos *epc-sgw-pgw-application.cc*

e *point-to-point-epc-helper.cc*) para obter esse mapeamento após a conexão dos UEs.

No arquivo principal da simulação, uma função chamada *CallMap()* foi criada. Essa função é ativada no tempo de simulação de 0,5 segundos, ou seja, após os UEs estabelecerem a conexão com RRHs, usando o EPC-helper do Ns-3.41 para chamar a função *RecvMymap()* e obter o mapeamento entre os IMSIs dos usuários e seus respectivos endereços IPv4. Esse mapeamento é armazenado na variável *m-mymap*. A função de *callback NotifyConnectionEstablishedUe()* do Ns-3.41 foi usada para criar uma segunda variável chamada *my-map2*, que mapeia o IMSI do usuário ao *CELL-ID* da RRH ao qual ele estava conectado.

Em seguida, foi criada uma função chamada *SendToController()*, que é ativada no tempo de simulação de 1,5 segundos e recebe o controlador SDN como parâmetro. O controlador da biblioteca *OFswitch13* possui a função *Allocation()* que determina o fluxo nos switches. Essa função recebe como parâmetro as variáveis *m-mymap* e *my-map2*. Como o protocolo *OpenFlow* é baseado no endereço IP dos elementos, é criada uma terceira variável chamada *my-map3*, que mapeia o endereço IP do usuário ao switch (ou BBU) ao qual ele será alocado. No início, a alocação é feita aleatoriamente.

4.5 Considerações Finais

Este capítulo apresentou o desenvolvimento e a organização do *framework* de reorquestração de recursos. Foram detalhadas todas as etapas da metodologia proposta, desde a obtenção dos dados até as estratégias de balanceamento do número necessário de PRRHs, o balanceamento de carga entre setores da BBU e a modelagem do *framework*. O objetivo foi desenvolver um *framework* capaz de resolver problemas em redes móveis de próximas gerações, incluindo o desligamento inteligente das PRRHs, o balanceamento entre as BBUs e seus respectivos setores, e a melhoria da eficiência energética da rede.

5 RESULTADOS

5.1 Considerações Iniciais

Neste capítulo serão apresentadas as características e configurações utilizadas nas simulações do sistema, bem como os resultados numéricos dos experimentos. Todas as simulações foram realizadas no software Ns-3.41 e utilizando como base dados do distrito de Manhattan (Nova York, Estados Unidos), já citado na sessão anterior. As simulações foram executadas em uma máquina com processador Intel(R) Core(TM) i5-3317u com clock de 1.7 GigaHertz (GHz) e memória RAM de 8GB DDR3. O objetivo das simulações é testar o *FrameWork* proposto e verificar sua acurácia, além de aferir e avaliar o desligamento inteligente, balanceamento de carga entre as BBUs e eficiência energética. Ao final do processo, tem-se a previsão das regiões futuramente afetadas por congestionamento/sobrecarga na rede, quantidade de PRRHs que podem ser desligadas, BBU pool com sua carga devidamente balanceada e menor consumo de energia, sem afetar o desempenho da rede. A seguir, serão apresentados os resultados para cada parte do *FrameWork*, bem como a discussão dos resultados.

5.2 Resultados

Nesta seção, serão apresentados os resultados obtidos com o *FrameWork* de Reorquestração proposto, comparando-o com outras abordagens relevantes da literatura, incluindo Long Term Evolution Advanced (LTE-A) e Heuristic Dynamic Switch Off (HDSO) (SIGWELE; HU; SUSANTO, 2020). A Tabela 2 apresenta os parâmetros utilizados no SA e a Tabela 3 apresenta os parâmetros utilizados no algoritmo FA.

Tabela 2 – Parâmetros do Simulated Annealing (SIGWELE; HU; SUSANTO, 2020).

Parâmetros	Valores
Tamanho da população	100
Taxa de hibridização	0,8
Taxa de mutação	0,01
Número de iterações	100
Temperatura inicial	1000
Temperatura final	0,01

Tabela 3 – Parâmetros do FA (SILVA GONÇALVES et al., 2023).

Parâmentos	Valores
Fator de aceleração local(Pbest)	1,8
Fator de aceleração global (Gbest)	1,8
Tamanho total	220
Limíte do número de interações	100

Essas abordagens foram escolhidas por sua relevância no campo e pelo potencial de demonstrar as vantagens e limitações do *FrameWork* proposto em relação a métodos estabelecidos. Na Figura 12, são exibidas as médias do *delay* (em ms) da rede, durante um período de 24 horas. Observa-se que o algoritmo HDSO teve uma média de 28.9% de delay e o modelo proposto obteve 22.9%, a diferença de delay entre os algoritmos foi de 6.03% evidenciando a robustez do algoritmo utilizando nessa tese. Um delay mais baixo reduz o tempo de resposta para o usuário final, resultando em uma experiência mais fluida e responsiva, essencial para aplicações como stream de vídeo, jogos online e videoconferências.




Figura 12 – Delay (ms) médio em 24 horas

Pode-se observar na figura 13, que o modelo proposto obteve um *jitter* 7.75% menor em relação ao algoritmo comparado, o que destaca uma melhoria na estabilidade e transmissão de dados e também no refinamento da qualidade geral da experiência do usuário, pois um *jitter* mais baixo significa menor variação no atraso de pacotes. Além disso, um *jitter* reduzido auxilia na melhor alocação e utilização dos recursos da rede, pois há menos necessidade de correção de erros e retransmissões.

Tal afirmação pode ser balizada através do número de pacotes perdidos, apresentado na figura 14. O modelo proposto teve, no geral, 26.6% a menos de pacotes perdidos em relação ao HDSO, constatando-se assim, a eficácia da orquestração de recursos proposta nessa de tese. O modelo proposto apresenta uma variação menor de pacotes perdidos em momentos de pico de tráfego. Nota-se que há um trade-off entre a diminuição de RRHs ativas e a taxa de pacotes perdidos. Ou seja, quanto maior for o número de RRHs desligadas, maior é a probabilidade de obter-se um valor alto de pacotes perdidos.




Figura 13 – jitter (ms) Médio em 24 Horas.




Figura 14 – Média de pacotes perdidos (%) em 24h.

Na Figura 15, são apresentadas as médias das PRRHs ativas ao longo de um período de 24 horas, demonstrando a eficácia do modelo proposto. Ele conseguiu manter, em média, 89% das suas antenas ativas, uma redução de 9% em comparação com o HDSO. Em momentos de menor tráfego de dados, o modelo proposto apresentou sua capacidade de otimização ao desativar 44% das PRRHs subutilizadas, superando o HDSO em 20%. Esses resultados ressaltam a habilidade do algoritmo em lidar com a dinâmica do tráfego em regiões urbanas densamente povoadas.

A capacidade de desligar mais RRHs e ainda assim obter melhores métricas de delay, *jitter* e pacotes perdidos decorre do fato de que o modelo proposto utiliza uma técnica de algoritmos bio-inspirados enquanto o HDSO utiliza apenas uma função que ranqueia as PRRHs para determinar quais deve ser desligadas.

A capacidade de desligar mais PRRHs na rede traz vários benefícios importantes, incluindo uma economia significativa de energia, que contribui para a redução dos custos operacionais e para uma maior sustentabilidade da rede. Além disso, reduzir o número de antenas ativas durante períodos de tráfego baixo pode minimizar a interferência, melhorando o desempenho geral da rede e a qualidade do serviço (QoS) para os usuários. Essa abordagem também prolonga a vida útil dos equipamentos da rede ao reduzir o desgaste, levando a menores necessidades de manutenção e maior confiabilidade a longo prazo. Esses benefícios destacam o potencial do algoritmo proposto para otimizar os recursos da rede de forma eficaz, adaptando-se às demandas flutuantes de tráfego.




Figura 15 – Média de PRRHs ligadas em 24h.

Na figura 16, é analisado o throughput médio dos UEs da rede. Nota-se que ambas as

abordagens conseguem manter o throughput mínimo, entretanto o modelo proposto consegue manter mais usuários conectados e com um throughput médio 23% maior do que o HDSO, tal fato é atribuído à escolha eficiente das PRRHs a serem mantidas ativas e, conseqüentemente, em uma melhor distribuição dos recursos entre todos os UEs.




Figura 16 – *Throughput* Médio em 24h

O consumo total da rede é avaliado na Figura 17 considerando os cenários em que são alterados apenas os algoritmos utilizados. Destaca-se a robustez da solução implementada, visto que o modelo proposto, que compõe o *FrameWork*, consome 14% a menos que o HDSO e 44% menos que o LTE-A. Mostrando-se assim, capaz de aumentar o processamento da rede e aperfeiçoar o consumo de energia.

5.3 Considerações Finais

Neste capítulo, foram apresentados os resultados obtidos após a execução do *FrameWork* de Reorquestração que foi desenvolvido nessa tese. No qual foi abordado a reorquestração de recursos em multiníveis em uma rede H-CRAN. O modelo apresentado executa dois algoritmos bioinspirados para otimizar as soluções estudadas, após essa etapa o mesmo é comparado com outras propostas da literatura.

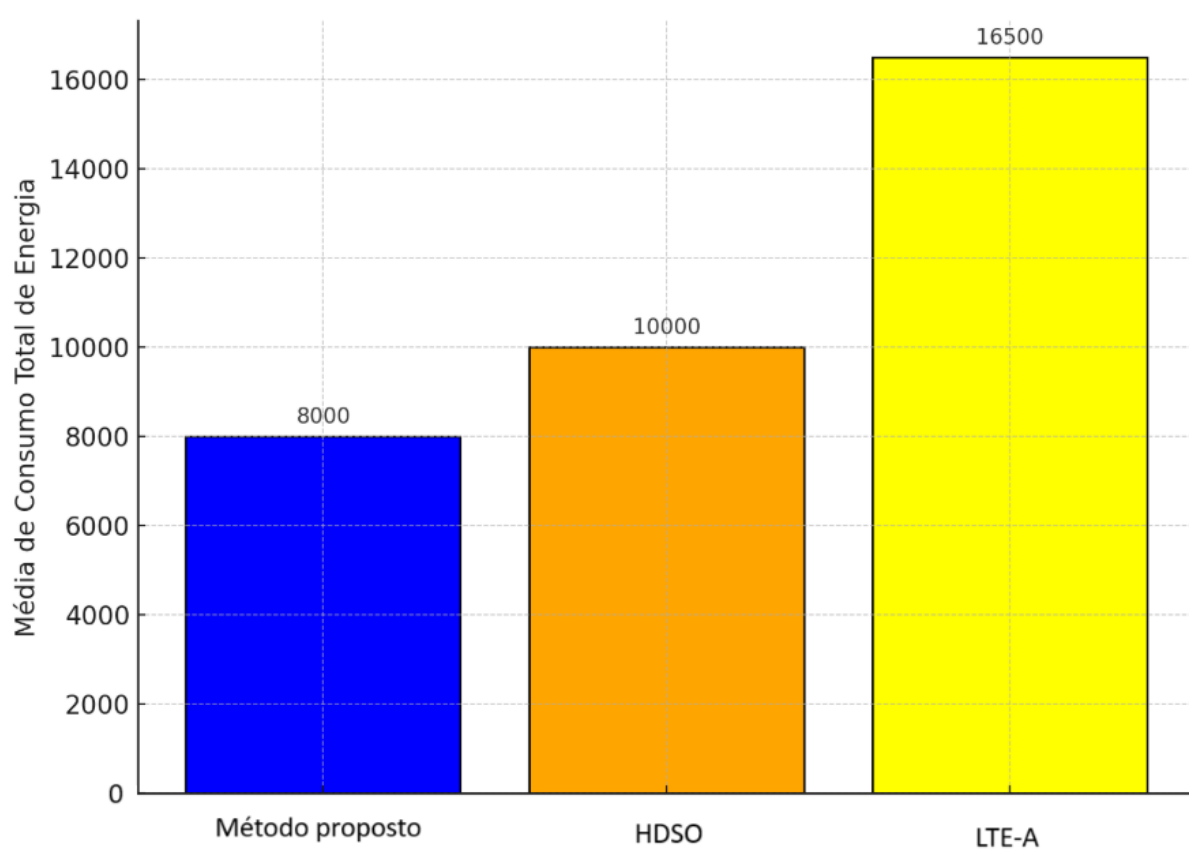


Figura 17 – Consumo de energia total

6 CONCLUSÃO

6.1 Considerações Iniciais

Este capítulo finaliza a presente tese, no qual são expostas as considerações acerca da mesma, publicações, trabalhos futuros e o dificuldades encontradas.

6.2 Conclusão

Nesta tese, propôs-se um *framework* para a orquestração eficiente de recursos em redes H-CRAN/SDN, integrando técnicas de desligamento inteligente de PRRHs e balanceamento de carga com algoritmos metaheurísticos. Os resultados demonstraram que o modelo desenvolvido é capaz de superar significativamente as abordagens existentes em várias métricas essenciais.

O modelo proposto apresentou uma redução de 6,03% no *delay* em relação ao HDSO, com um atraso médio de 22,9 ms, enquanto o *jitter* foi 7,75% menor, destacando uma maior estabilidade na transmissão de dados. Além disso, obteve uma redução de 26,6% nos pacotes perdidos, evidenciando maior eficiência no transporte de informações.

No âmbito da eficiência energética, o *framework* foi capaz de desligar até 44% das PRRHs subutilizadas, superando o HDSO em 20%, o que resultou em uma economia de energia de 14% comparado ao HDSO e 44% em relação ao LTE-A. Essa melhoria não comprometeu a qualidade do serviço, com o *throughput* médio sendo 23% maior do que o do HDSO devido à ativação eficiente das PRRHs necessárias.

Esses resultados reforçam a relevância do modelo na promoção de soluções para redes móveis de próxima geração, contribuindo para a sustentabilidade e maior eficiência das redes de telecomunicação. Além de avanços significativos na experiência do usuário, o *framework* reduz custos operacionais e otimiza recursos de forma adaptativa. Assim, ele se destaca como uma alternativa robusta e viável para os desafios crescentes em cenários de alta demanda e variabilidade de tráfego.

6.3 Contribuições

As principais contribuições desta tese são:

- Desenvolvimento de um *framework* para: Integrar monitoramento de rede, otimização e orquestração de recursos em ambientes H-CRAN/SDN. Aprimorar a experiência do usuário, minimizando recursos e custos operacionais. Aborda aspectos críticos como eficiência energética e gerenciamento de carga.

- Desenvolvimento de uma estrutura de orquestração de recursos: Criação de uma estrutura que integra monitoramento de rede, otimização e orquestração de recursos em ambientes H-CRAN/SDN. Aperfeiçoar a experiência do usuário, minimizando recursos e custos operacionais. Abordar aspectos críticos como eficiência energética e gerenciamento de carga.
- Otimização da alocação de recursos: Abordagem para otimizar o mapeamento entre Peak Remote Radio Heads (PRRH) e BaseBand Units (BBU). Atingir alta disponibilidade e economia de energia em arquiteturas de rede modernas.
- Análise comparativa com soluções existentes: Comparação completa do modelo proposto com algoritmos existentes, como o Heuristic Dynamic Switch Off (HDSO). Destaque das vantagens de novas estruturas e referência para pesquisas futuras.
- Foco na eficiência energética: Eficiência energética, importante no contexto do crescente tráfego de dados e proliferação de dispositivos IP. Otimização do uso de recursos para reduzir o consumo geral de energia da rede.
- Avaliação abrangente de métricas de desempenho: Avaliação de várias métricas de desempenho, incluindo atraso, jitter e perda de pacotes. Fornece uma visão holística da eficácia da estrutura no desempenho geral da rede.

6.3.1 Publicações

Principais publicações relacionadas à área de orquestração de recursos e eficiência energética ao longo do desenvolvimento desta tese:

1. DA SILVA GONÇALVES, Mariane de Paula et al. FA-CRAN: A Firefly Algorithm for Dynamic BBU-RRH Mapping in Cloud/Centralized Radio Access Networks. *IEEE Access*, 2023.
2. PAIXÃO, Ermínio Ramos et al. Multilayer *framework* for Resource Orchestration in Next Generation Networks. *Journal of Communication and Information Systems*, v. 38, n. 1, p. 1-8, 2023.
3. TEIXEIRA, Reyso C. et al. Otimização de eficiência energética em redes RSMA 6G utilizando meta-heurística. *SBRT*, 2024. 10.14209.
4. DOS SANTOS, Albert Einstein C.; CARDOSO, Diego L.; DA PAIXÃO, Ermínio Augusto R. Algoritmo Genético Aplicado à Configuração Adaptativa da Potência de Transmissão de Antenas no 5G. In: *Anais da II Escola Regional de Alto Desempenho Norte 2 e II Escola Regional de Aprendizado de Máquina e Inteligência Artificial Norte 2*. SBC, 2022. p. 5-8.

5. SANTOS, A. E. C. ; PAIXAO, J. G. M. ; PAIXAO, E. A. R. ; FALCAO, I. W. S. ; CARDOSO, DIEGO . Integração e Diferenciação de Células de Cobertura em uma Rede Centralizada de Acesso via Rádio Considerando Efeito de Maré. In: 12ª Conferência Nacional em Comunicações, Redes e Segurança da Informação, 2022, Guaramiranga - CE. Conferência Nacional em Comunicações, Redes e Segurança da Informação, 2022.
6. SANTOS, A. E. C. ; PAIXAO, E. A. R. ; FALCAO, I. W. S. ; CARDOSO, DIEGO . DESAFIOS NA IMPLEMENTAÇÃO DE UMA REDE H-CRAN UTILIZANDO O SIMULADOR NS-3. In: 5 CONGRESSO DE TECNOLOGIA E DESENVOLVIMENTO DA AMAZÔNIA, 2022, Paragominas. CONGRESSO DE TECNOLOGIA E DESENVOLVIMENTO DA AMAZÔNIA, 2022

6.4 Trabalhos Futuros

Como possíveis desdobramentos desta tese, destacam-se:

- Decisão Multinível Aprimorada: Desenvolver algoritmos mais sofisticados que incorporem processos de tomada de decisão multinível. Melhorar a eficiência do balanceamento de carga e da orquestração de recursos. Abordar a lacuna identificada na pesquisa atual.
- Integração de Técnicas de Aprendizado de Máquina: Incorporar algoritmos de aprendizado de máquina para otimizar ainda mais o processo de alocação de recursos. Analisar o comportamento do usuário e as condições da rede para ajustar dinamicamente a distribuição de recursos. Melhorar o desempenho e a eficiência energética.
- Implementação e Testes em Cenários Reais: Testar o *framework* e os algoritmos propostos em cenários reais para validar sua eficácia. Realizar projetos piloto com empresas de telecomunicações para avaliar as implicações práticas dos resultados da pesquisa.
- Exploração de Arquiteturas de Rede Adicionais: Investigar a aplicabilidade das soluções propostas em outras arquiteturas de rede além do H-CRAN. Adaptar o *framework* para diferentes tipos de redes móveis e tecnologias.
- Foco na Eficiência Energética: Aprofundar estratégias de eficiência energética, dada a crescente importância da sustentabilidade nas telecomunicações. Otimizar os algoritmos para minimizar o consumo de energia, mantendo ou melhorando a Qualidade de Serviço (QoS) para os usuários.
- Abordagens Centradas no Usuário: Considerar abordagens centradas no usuário que levem em conta as preferências e comportamentos dos usuários. Projetar serviços de rede mais responsivos e adaptáveis às necessidades específicas dos usuários.

- Colaboração com a Indústria: Engajar-se com stakeholders da indústria para obter insights e recursos valiosos para o desenvolvimento futuro. Esforços colaborativos podem levar a inovações que abordem desafios práticos enfrentados pelos operadores de redes móveis.

6.5 Dificuldades Encontradas

O desenvolvimento deste trabalho apresentou um desafio significativo nos contextos acadêmico, pessoal e profissional. Durante o processo, foi necessário mobilizar uma ampla gama de competências, incluindo programação de computadores, conhecimentos em orquestração de recursos e uma compreensão profunda dos conceitos e tecnologias de redes de comunicação. Além disso, a aplicação de habilidades matemáticas, estatísticas e de algoritmos bioinspirados foram cruciais para o sucesso do projeto. Ademais, a criação de um *framework* voltado para orquestração de recursos multiníveis e eficiência energética com qualidade de QoS. Vale ressaltar que a realização da tese tornou-se ainda mais desafiadora devido às restrições impostas pela pandemia de COVID-19.

REFERÊNCIAS

- ADIRAJU, Prasanth Rao; RAO, Voore Subba. Dynamically energy-efficient resource allocation in 5G CRAN using intelligence algorithm. **EMITTER International Journal of Engineering Technology**, p. 217–230, 2022.
- AKPAKWU, Godfrey Anuga et al. A survey on 5G networks for the Internet of Things: Communication technologies and challenges. **IEEE access**, IEEE, v. 6, p. 3619–3647, 2017.
- ALAM, Iqbal et al. A survey of network virtualization techniques for internet of things using sdn and nfv. **ACM Computing Surveys (CSUR)**, ACM New York, NY, USA, v. 53, n. 2, p. 1–40, 2020.
- BABA, Majid Irfan et al. Evolution of mobile wireless communication systems from 1g to 5g: A comparative analysis. **International Journal of Scientific Research in Computer Science, Engineering and Information Technology**, v. 4, n. 1, p. 1–8, 2018.
- BONFIM, Michel S; DIAS, Kelvin L; FERNANDES, Stenio FL. Integrated NFV/SDN architectures: A systematic literature review. **ACM Computing Surveys (CSUR)**, ACM New York, NY, USA, v. 51, n. 6, p. 1–39, 2019.
- CASTRO, BSL et al. COST231-Hata and SUI Models performance using a LMS tuning algorithm on 5.8 GHz in Amazon Region cities. In: IEEE. PROCEEDINGS of the Fourth European Conference on Antennas and Propagation. 2010. P. 1–3.
- CHECKO, Aleksandra et al. Cloud RAN for mobile networks—A technology overview. **IEEE Communications surveys & tutorials**, IEEE, v. 17, n. 1, p. 405–426, 2014.
- CHEN, Na; RONG, Bo; MOUAKI, Abdel et al. Self-organizing scheme based on NFV and SDN architecture for future heterogeneous networks. **Mobile Networks and Applications**, Springer, v. 20, n. 4, p. 466–472, 2015.
- CHEN, Na; RONG, Bo; ZHANG, Xinran et al. Scalable and flexible massive MIMO precoding for 5G H-CRAN. **IEEE Wireless Communications**, IEEE, v. 24, n. 1, p. 46–52, 2017.
- CHIH-LIN, I et al. Recent progress on C-RAN centralization and cloudification. **IEEE Access**, IEEE, v. 2, p. 1030–1039, 2014.

CISCO, U. **Cisco annual internet report (2018–2023) white paper**. 2020.

<https://www.cisco.com/c/en/us/solutions/collateral/executive-perspectives/annual-internet-report/white-paper-c11-741490.html>.

CISCO SYSTEMS, Inc. **Cisco Annual Internet Report (2018–2023)**. 2023. Projeções sobre dispositivos móveis e consumo de dados até 2028. Disponível em:

<<https://www.cisco.com/c/en/us/solutions/executive-perspectives/annual-internet-report/index.html>>. Acesso em: 16 nov. 2024.

COHN, Harry; FIELDING, Mark. Simulated annealing: searching for an optimal temperature schedule. **SIAM Journal on Optimization**, SIAM, v. 9, n. 3, p. 779–802, 1999.

DE BRUYN, Arnaud et al. Artificial intelligence and marketing: Pitfalls and opportunities. **Journal of Interactive Marketing**, SAGE Publications Sage CA: Los Angeles, CA, v. 51, n. 1, p. 91–105, 2020.

DE FIGUEIREDO, Felipe AP et al. On the application of massive MIMO systems to machine type communications. **IEEE access**, IEEE, v. 7, p. 2589–2611, 2018.

EBERHART, R.; KENNEDY, J. A new optimizer using particle swarm theory. In: MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science. 1995. P. 39–43. DOI: 10.1109/MHS.1995.494215.

EBERHART, Russell; KENNEDY, James. A new optimizer using particle swarm theory. In: IEEE. MHS'95. Proceedings of the sixth international symposium on micro machine and human science. 1995. P. 39–43.

ERCEG, Vinko. Channel models for fixed wireless applications. **IEEE 802.16. 3c-01/29r1**, 2001.

ERICSSON. **Ericsson Mobility Report - November 2022**. 2022. Previsões sobre assinaturas e crescimento de redes 5G. Disponível em: <<https://www.ericsson.com/en/reports-and-papers/mobility-report>>. Acesso em: 16 nov. 2024.

ERICSSON. **Ericsson's fiber fronthaul solution deployed for China Mobile's LTE C-RAN**. 2020. http://www.ericsson.com/news/140707-ericssons-fiber-fronthaul-solutiondeployed_244099436_c.

HASSAN, Najmul; YAU, Kok-Lim Alvin; WU, Celimuge. Edge computing in 5G: A review. **IEEE Access**, IEEE, v. 7, p. 127276–127289, 2019.

KIRKPATRICK, Scott; GELATT JR, C Daniel; VECCHI, Mario P. Optimization by simulated annealing. **science**, American association for the advancement of science, v. 220, n. 4598, p. 671–680, 1983.

MAROTTA, Marcelo Antonio et al. Resource sharing in heterogeneous cloud radio access networks. **IEEE Wireless Communications**, IEEE, v. 22, n. 3, p. 74–82, 2015.

MEDEIROS, Gleison O et al. An Intelligent SDN Framework Based on QoE Predictions for Load Balancing in C-RAN. **Wireless Communications and Mobile Computing**, Hindawi, v. 2020, 2020.

MOBILE, China. C-RAN: the road towards green RAN. **White paper, ver.**, v. 2, n. 5, p. 15–16, 2011.

OSMAN, Ibrahim H; KELLY, James P. Meta-heuristics theory and applications. **Journal of the Operational Research Society**, Taylor & Francis, v. 48, n. 6, p. 657–657, 1997.

PAIXÃO, Erminio Augusto Ramos da et al. Optimized load balancing by dynamic BBU-RRH mapping in C-RAN architecture. In: IEEE. 2018 Third International Conference on Fog and Mobile Edge Computing (FMEC). 2018. P. 100–104.

PENG, Mugen et al. Energy-efficient resource assignment and power allocation in heterogeneous cloud radio access networks. **IEEE Transactions on Vehicular Technology**, IEEE, v. 64, n. 11, p. 5275–5287, 2014.

POPOOLA, Segun I et al. Path loss dataset for modeling radio wave propagation in smart campus environment. **Data in brief**, Elsevier, v. 17, p. 1062–1073, 2018.

RATHOD, Tejal et al. Blockchain for Future Wireless Networks: A Decade Survey. **Sensors**, MDPI, v. 22, n. 11, p. 4182, 2022.

RAY, Partha Pratim; KUMAR, Neeraj. SDN/NFV architectures for edge-cloud oriented IoT: A systematic review. **Computer Communications**, Elsevier, v. 169, p. 129–153, 2021.

SHAFIQUE, Kinza et al. Internet of things (IoT) for next-generation smart systems: A review of current challenges, future trends and prospects for emerging 5G-IoT scenarios. **Ieee Access**, IEEE, v. 8, p. 23022–23040, 2020.

SHLEZINGER, Nir et al. Dynamic metasurface antennas for 6G extreme massive MIMO communications. **IEEE Wireless Communications**, IEEE, v. 28, n. 2, p. 106–113, 2021.

- SIGWELE, Tshiamo; HU, Yim Fun; SUSANTO, Misfa. Energy-efficient 5G cloud RAN with virtual BBU server consolidation and base station sleeping. **Computer Networks**, Elsevier, v. 177, p. 107302, 2020.
- SILVA GONÇALVES, Mariane de Paula da et al. FA-CRAN: A Firefly Algorithm for Dynamic BBU-RRH Mapping in Cloud/Centralized Radio Access Networks. **IEEE Access**, IEEE, 2023.
- SRIVASTAVA, Akanksha; GUPTA, Mani Shekhar; KAUR, Gurjit. Energy efficient transmission trends towards future green cognitive radio networks (5G): Progress, taxonomy and open challenges. **Journal of Network and Computer Applications**, Elsevier, v. 168, p. 102760, 2020.
- VAN LAARHOVEN, Peter JM; AARTS, Emile HL. Simulated annealing. In: SIMULATED annealing: Theory and applications. Springer, 1987. P. 7–15.
- VORA, Lopa J. Evolution of mobile generation technology: 1G to 5G and review of upcoming wireless technology 5G. **International journal of modern trends in engineering and research**, v. 2, n. 10, p. 281–290, 2015.
- WANG, Lu et al. Statistical Multiplexing Analysis with Quantized Computing Resource for Practical C-RAN. In: IEEE. ICC 2019-2019 IEEE International Conference on Communications (ICC). 2019. P. 1–6.
- YAN, Boyuan et al. Tidal-traffic-aware routing and spectrum allocation in elastic optical networks. **Journal of Optical Communications and Networking**, Optical Society of America, v. 10, n. 11, p. 832–842, 2018.
- YAN, Boyuan et al. Tidal-traffic-aware routing and spectrum allocation in elastic optical networks. **Journal of Optical Communications and Networking**, v. 10, n. 11, p. 832–842, 2018. DOI: 10.1364/JOCN.10.000832.
- YANG, Hui; YAO, Qiuyan et al. Multi-associated parameters aggregation-based routing and resources allocation in multi-core elastic optical networks. **IEEE/ACM Transactions on Networking**, IEEE, v. 30, n. 5, p. 2145–2157, 2022.
- YANG, Hui; ZHANG, Jie et al. C-RoFN: Multi-stratum resources optimization for cloud-based radio over optical fiber networks. **IEEE Communications Magazine**, IEEE, v. 54, n. 8, p. 118–125, 2016.
- YANG, Xin-She. Firefly algorithms for multimodal optimization. In: SPRINGER. INTERNATIONAL symposium on stochastic algorithms. 2009. P. 169–178.

7 ANEXO

7.1 Considerações Iniciais

Neste capítulo, abordamos os principais trabalhos que agregam está tese

Multilayer Framework for Resource Orchestration in Next Generation Networks

Ermínio A. R. da Paixão, Albert E. Santos, Daniel da S. Souza, Diego L. Cardoso

Abstract—Due to the significant increase in data traffic and the large number of Internet Protocol (IP) devices, operators and researchers are seeking solutions to address the greater demand. One of the most attractive of these is Heterogeneous Cloud Radio Access Networks (H-CRAN), which has the capacity to solve problems of the current generation and add several improvements, such as centralized processing and greater energy efficiency. However, resource orchestration such as radio, mapping between radio and BaseBand Unit (BBU) and load balance in BBU pool are still of the utmost importance. This paper proposes a multilayer approach that enables Peak Remote Radio Head (PRRH)-underutilized reconfiguration model and optimized mapping between PRRH and BBU, with the aim of achieving high availability, energy savings and a reduction in high-speed processing. Obtained results were compared with other approaches in the literature and showed that our model offers a more efficient means of mitigating the problems addressed in this paper.

Index Terms—H-CRAN, Resource Orchestration, Load Balance, Multilayer.

I. INTRODUCTION

The growth in the number of connected devices in the network, with valid IPs by 2023, is estimated to be 29.3 billion devices, about 3.6 devices per person [1]. Also in this survey, it was found that the support for mobile telephony will correspond to 71% of the global market by 2023, an increase of 5% compared with 2018. This underlines that it is expected there will be an exponential increase in Internet-connected User Equipment (UE) globally, and this will reach 5.3 billion by 2023, a rise of 1.4 billion UE compared with 2018.

With the emergence of more network-oriented devices and applications, there is a need to restructure the architecture, since the current Distributed Radio Access Network (D-RAN) cannot be adapted to the new requirements, since it incurs high costs of capital expenditure and higher operational processing rates with an increase in the number of Base Stations (BSs) [2]. In response to the new challenges raised by the current mobile networks, Centralized Radio Access Network (C-RAN) has emerged as a possible solution, since it is able to centralize the UE processing, improve the energy efficiency and has the

capacity to restructure the network data [3]. In addition, another promising technology is the Software Defined Network (SDN) which incorporates new features and applicability, such as self-adjusting scheduling, centralized management and a low cost deployment strategy [4].

The C-RAN architecture has robust requirements, such as low latency, low jitter, and high infrastructure deployment costs that are difficult to achieve [5]. However, all these obstacles can be overcome by H-CRAN which makes it possible to integrate the decentralized Heterogeneous Networks (HetNets) and C-RAN architectures, with the aim of meeting the requirements of signal processing, centralized workload management, and energy efficiency [5].

One of the main points of discussion in these new architectures is the question of deployment, because when planning the total capacity of a mobile network and the number of BSs, an attempt is usually made to meet the maximum traffic capacity. In this scenario all the BSs remain active regardless of the change in load throughout the day, thus incurring high energy costs and leading to an underutilization of equipment. This pattern of behavior is described as the Tidal Effect [6].

It is stipulated that processing rate for each BBU must be the total number of simultaneously active UEs in the sectors of the BBUs [7]. However, with regard to hardware or software, there is a restriction in the number of active UEs in the BBU, called the Hard Capacity (HC), which if not met can lead to a loss of data or decline in performance. Thus, networks must support the concept of Self-Organization (SO) so that they can address the problem of resource mapping efficiently.

In light of this, this paper proposes a framework for H-CRAN/SDN networks that integrates the monitoring of the network, the optimization of PRRHs and the efficient orchestration of resources in the BBU pool, even in different traffic conditions, aiming to maximize the UE experience, as well as reduce the number of operational resources. A bio-inspired multi-objective approach is adopted for this, and, in its first stage the Simulated Annealing On/Off algorithm (SAoff) is responsible for the intelligent disconnection and re-distribution of UEs among the remaining PRRHs. In the second stage, the Balance Particle Swarm Optimization (BPSO) algorithm is executed, and is responsible for re-orchestrating the resources of the PRRHs in the BBU. The whole process is monitored and carried out by a manager called the SDN Controller.

This paper is structured as follows: Section 2 examines the related works that are drawn on for this work, Section 3 shows the features of the architecture and the problem being investigated. Section 4 outlines the main characteristics of the algorithms used in this work and Section 5 describes the

Ermínio A. R. da Paixão, Albert E. Santos, Daniel da S. Souza, and Diego Lisboa Cardoso are with the Operational Research Laboratory, Federal University of Pará, 66075-110 Belém, PA, Brazil (e-mail: ermínio.paixao@itec.ufpa.br, albert@ufpa.br, danielssouza@ufpa.br, diego@ufpa.br).

This work was partly funded by the Coordination for the Improvement of Higher Education Personnel (CAPES), Federal University of Pará (UFPA), National Council of Technological and Scientific Development (CNPq), and Dean of Research and Graduate Studies.

Digital Object Identifier: 10.14209/jcis.2023.1

parameters that are used for the simulations carried out in this work. Section 6 analyzes the results and discussions, and Section 7 concludes with the final considerations of this work and makes suggestions for further research in the field.

II. RELATED WORK

The use of HetNets has been widely discussed as a feasible solution meeting the requirements of 5G networks (CRAN and H-CRAN). However, the failure to deploy PRRHs correctly has led to a wide range of problems, from interference management to financial concerns, such as high deployment costs or a significant increase in energy consumption, factors that can make the use of this technology unfeasible. Thus, several works in the literature employ an intelligent-driven methodology for matters related to deployment and operations.

In [8] there is a discussion of the two-level energy efficiency optimization problem in an H-CRAN network. In the first stage, a dynamic shutdown algorithm for picocell is executed, based on a utility function which maintains the UE Quality Of Service (QoS). In the second stage, two algorithms are used to reduce the number of BBU servers, and thus save energy. Both these solutions achieved good results and ensured energy savings without losing QoS quality.

The study by [9], examines what measures need to be taken in the face of the exponential increase in global data traffic, since the current network structure will not be able to support this demand. The work also highlights the C-RAN architecture as a possible alternative, because of its higher processing power, capacity for reconfiguration and intelligent mapping of UE. This was investigated through a Key Performance Indicator (KPI), which seeks to reduce the number of blocked UEs so that it can optimize the QoS of the architecture. This involved using a Discrete Particle Swarm algorithm (DPSO) to match UE to the KPI and optimize the QoS. The results obtained for validation purposes were compared with those of the literature, and found that in periods of low traffic, it can turn off up to 99% of BSs.

Another work addresses the PRRH-BBU assignment problem in [10]. An optimization problem is formulated that models the allocation of resources at these two levels. At the level between cells and UEs, resources are distributed among UEs, who have different QoS requirements. As a result, the system must optimize the allocation of resources accordingly, while maintaining other features such as the availability of physical resources, QoS satisfaction, and continuity of service. At the PRRH and BBU level, computing requirements have to be processed instantaneously in the available BBU pool, while maintaining power consumption and optimizing computing resources.

The authors in [11] mathematically formulate a tidal traffic model and then propose tidal traffic-aware routing and spectrum allocation algorithms for elastic optical networks. Based on the traditional Routing and Spectrum Allocation (RSA) algorithm, the authors created Pre-Deviation RSA (PD-RSA) and Pre-Deviation K-Path Shorter RSA (PDK-RSA) algorithms to increase bandwidth efficiency in elastic optical networks.

It is clear from the analysis of the works conducted here, that although the resource allocation problems of PRRHs and BBUs have been addressed extensively (either separately or together), none of the above-mentioned studies has effectively dealt with the problem of mapping and load balancing nor have they taken into account the question of multi-level based decision-making, which is a determining factor for efficient resource orchestration. In view of this, it can be stated that this work makes two key research contributions: a) the implementation of a new algorithm for PRRH shutdown, based on Simulated Annealing; b) optimized BPSO-based load balancing algorithm for a redefinition of BBU-RRH mapping based on the results of the previous stage.

III. PROPOSED SCENARIO

Fig. 1 explains the framework established for this work. The map of available PRRHs, as well as the arrangement of UE, per hour, are used as input data for triggering the SAoff algorithm, which is responsible for turning off underutilized PRRHs. This PRRHs traffic has to be forwarded to a BBU, and, for this the BPSO is used for balancing the load between the BBU sectors, and thus reducing the number of blocked UEs between the BBU sectors. The proposed architecture is triggered at pre-established time intervals to ensure it always provides an appropriate configuration for each fluctuation of the UEs. The modules are described below:

1. Coverage Area: PRRHs are randomly placed, the UEs have the same traffic profiles and their traffic requirements were obtained from [6].
2. SDN controller: The SDN controller is the manager of all the processes in this diagram, as described below:
 - 2.1. Traffic profile: Uses the traffic extracted from [6].
 - 2.2. SAoff: This algorithm is explained in section IV.A.
 - 2.3. Convert UE traffic to blocked UEs: UE data are converted to blocked UEs and sent to BBU pool.
 - 2.4. Mapping UE: Maps the blocked UEs and determines where they will be allocated.
 - 2.5. Initial UE-PRRH-BBU allocation: Starts the allocation of UE in the PRRHs and PRRHs in the BBUs.
 - 2.6. Load Balancing on BBUs: Performs resource balancing on BBUs, which have a capacity that is determined by the KPI of the blocked UEs.
 - 2.7. Load Balancing on BBU sectors: Carries out resource balancing among the BBU sectors.
 - 2.8. BPSO: Used to optimize load balancing; Its operation is described in Section IV.B.
 - 2.9. Re-orchestrated Resources: After going through all the balancing stages, the re-orchestrated resources are revealed in their respective BBUs and sectors.

The sequence diagram shows the operating stages of the SDN controller within the framework of BBU pool load balancing. In the first stage, the data decisions are transmitted; in the second stage these data are distributed among the available BBUs and the third is responsible for restructuring the resources among the sectors of the BBUs. The stages followed in this diagram are shown in Fig. 2.

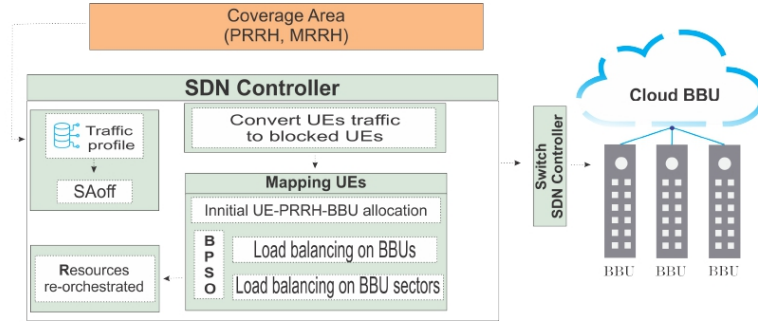


Fig. 1. Proposed framework.

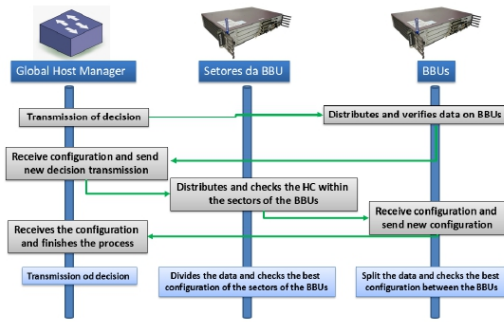


Fig. 2. BBU mapping and balancing process.

IV. OPTIMIZATION ALGORITHMS

In this section, the choice of the algorithms used and their characteristics will be outlined in detail. According to [12], bio-inspired algorithms are among the best for solving optimization-based problems, especially Nondeterministic Polynomial (NP)-hard problems.

Two search algorithms were used for this study. The first algorithm is SA which in this work is referred to as SAoff, and is based on annealing. This method is used for the improvement of steel, by heating it to high temperatures [13]. The second is PSO which will be called BPSO. This mimics the social habits of animals, such as insects, fish and birds. Each potential solution (called particles) is also assigned a randomized velocity, and then are “flown” through hyperspace. Each particle tracks its coordinates in hyperspace and is linked to the best solution (fitness) that it has reached so far [14].

A. Simulated Annealing on/off (SAoff)

Fig. 3 and Algorithm 1 illustrates how SAoff works. The SAoff starts the search for the optimal solution using a random initial solution represented by a vector of size equal to the maximum number of PRRHs. This vector has binary values that correspond to the on/off state of the PRRH, where 1

represents the active PRRH and 0 represents the off state. To generate new solutions, SAoff modifies the binary values of this vector. It is worth noting that the SAoff must be performed for each period of study, separately, thus turning on only the PRRHs needed for that specific demand. This solution is evaluated through its objective function, which is calculated by equation 1.

$$MIN_TPRRH_{(i)} = \sum_{j=0}^n A_j \quad (1)$$

subject to

$$BP_{(i)} - MAX \leq x \quad (2)$$

Where:

$TPRRH_{(i)}$ is the total number of PRRHs on at hour i ;
 n is total number of PRRHs in the network;
 A is binary variable that indicates whether PRRH j is active or not;
 $BP_{(i)}$: is the maximum blocking probability for hour i .

The blocking Probability is calculated according to the equation 3:

$$BP_{(i)} = \frac{Nc_{(i)}}{Tuc_{(i)}} \quad (3)$$

Where:

$Nc_{(i)}$ is number of users not covered at hour i ;
 $Tuc_{(i)}$ is total users available on the network.

The stopping criterion used in this algorithm is given by equation 1, that is, a vector with the smallest combination of PRRHs that must be active, in each period. Rest of the parameters can be found in Table 1.

B. Balance Particle Swarm Optimization (BPSO)

The objective function of the algorithm 2 was changed, where the algorithm starts by creating a swarm of particles where each particle corresponds to a candidate solution. Then the particles randomly ascertain the solution area with different velocities. After passing through the *fitness* of the algorithm the particles are directed to their best fitness values. The velocity of an individual particle is changed stochastically in

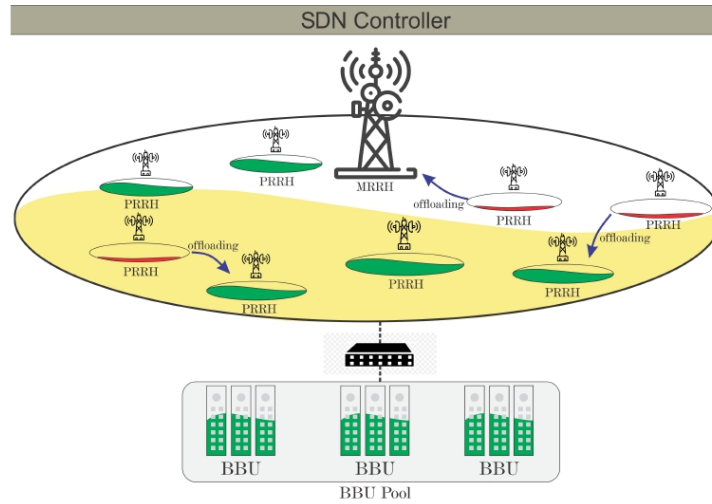


Fig. 3. SAoff.

Algorithm 1: SAoff Pseudocode

```

Generates the initial solution  $x_i (i = 1, 2, \dots, n)$ 
Objective Function equation 1
begin
     $\sigma(S) = 0$ 
    while  $t < MaxGenerations$  do
        for  $i = 1$  until  $n$  do
            for  $j = 1$  until  $n$  do
                if  $I_j > I_i$  then
                    verifies the probability is less than
                    or equal to 0.1%
                end
                evaluate the solution
            end
        end
    end
    Presents the solution
end
end
    
```

TABLE I
SAOFF PARAMETERS

Parameters	Values
Hybridization rate	0.8
Mutation rate	0.1
blocking probability	10%
Number of iterations	100

each iteration and its update stems from the experience of the best historical position of the respective particle and the best position experience of neighboring particles, i.e., the global best position.

In this second step, the algorithm uses a performance indicator based on the one proposed in [9], to minimize

the number of blocked UEs. The objective function of the algorithm was changed, to equally distribute the amount of UEs by the number of available sectors in the BBU pool. To do this, initially, a vector of UEs per sector is created, as modeled in equation 4.

$$U_{s(i)} = \sum_{j=1}^N C_j R_s, S = 1, 2, \dots, K \quad (4)$$

Where:

$U_{s(i)}$ is the number of UEs in the sector;

N is the total PRRHs;

K is the total sectors;

C is the number of UEs connected in PRRHj;

R is a binary variable where it takes the value 1 if PRRHj is allocated to sector s ;

For each period i , and for each sector s , a vector $U_{s(i)}$ is created, which is used in the objective function, respecting the maximum capacity of each sector, which is given by the variable HC (Hard Capacity). All $U_{s(i)}$ are tested to obtain the combination that generates the lowest possible $KPI_{(i)}$ value. This process involves reducing the number of blocked UEs and consequently maximizing QoS, as shown in equation 5.

$$MIN_KPI_{(i)} = \sum_{s=1}^k (U_{s(i)} - HC), \quad (5)$$

$$(0, if (U_{s(i)} - HC) < 0) or ((U_{s(i)} - HC) if (U_{s(i)} - HC) \geq 0) \quad (6)$$

Where:

$KPI_{(i)}$ is the total number of UEs per sector on at hour i ;

HC is the maximum capacity per BBU sector.

The output of the model is given by the vector: $S_j^i = \{S_1^i, S_2^i, \dots, S_N^i\}$, representing the sectors of the BBUs S_j^i and PRRHs that have been allocated to these sectors. Rest of the parameters can be found in Table II.

Algorithm 2: BPSO Pseudocode

```

Objective Function equation 2
Generates the initial particle pop
Determines the acceleration factor  $l \ c1 = 1.8$ 
begin
  Initial Swarm
  while  $t < MaxGenerations$  do
    for  $i = 1$  until  $n$  do
      for  $j = 1$  until  $n$  do
        if  $I_j > I_i$  then
          | search  $i$  search for solutions  $j$ 
        end
        Evaluates new solutions and updates
        particles
      end
    end
    Rank the particles and find the best one
  end
end

```

TABLE II
BPSO PARAMETERS

Parameters	Values
Local acceleration factor(Pbest)	1.8
HC	200
Global acceleration factor (Gbest)	1.8
Total size	220
Number of interactions	100

V. SIMULATION

In this section, the details of the scenario implemented in this work will be outlined. These involved procedures that were carried out in a machine with an Intel(R) Core(TM) i5-3317u processor and with a 1.7GHz clock and 8GB DDR3 RAM. The simulator chosen to perform the simulations was Matlab¹, since it has vast documentation.

A. Network Parameters

Cellular coverage can be defined based on coverage, power, coding methods and propagation losses [15]. Effectively, the path loss can be measured from the Hata model and its COST231 extension for Carrier Frequency (CF) below 2 GHz and from the Stanford University Interim (SUI) model for CF above 2 GHz [16]. The Signal-to-Interference-Plus-Noise Ratio (SINR) of the downlink for a given sub-carrier N is assigned to UE k in the PRRH to which it is connected. This can be expressed as equation 7:

$$SINR_k = \frac{P_{k,b(j)}}{\sigma^2 + I_k} \quad (7)$$

¹<https://la.mathworks.com/products/matlab.html>

Where $P_{k,b(j)}$ is the received power (in watts) on subcarrier N assigned to UE k by the PRRH $b(j)$ serving it, σ^2 is the thermal noise power and I_k is the intercellular interference from neighboring PRRHs. All the PRRHs are assumed to be transmitting at maximum power P . The received power at UE k of PRRH $b(j)$ can be calculated using equation 8, which expresses the received power of a UE k based on transmitted power and signal fading. The SUI [17] propagation model was used to calculate the fading signal.

$$P_{k,b(j)} = \frac{10^{\frac{TP+G(k)-L_{SUI}}{10}}}{1000} \quad (8)$$

Where TP is total power of the incoming signal of interest, G is the Gain and L_{SUI} it is the value in dB of the fading signal which is calculated by the SUI propagation model, and expressed by the following equations:

$$L_{SUI} = A + 10\gamma \log \frac{d}{d_o} + W, d > d_o, \quad (9)$$

$$A = 20 \log \frac{4\pi d_o}{\lambda}, \quad (10)$$

$$\gamma = a - bh_b + \frac{c}{h_b} \quad (11)$$

In which d is the distance from the PRRH to the measured point in meters, d_o is equal to 1 meter in accordance with [18]; λ is the wavelength in meters; γ is the exponent of the path loss; h_b is the height of the PRRH, which can be between 10 and 80 meters; a , b and c are the constants that depend on the type of terrain of the scenario; in this case, c was used ($a = 3.6$, $b = 0.005$ and $c = 20$); W is the shading effect, which can be between 8.2 and 10.6 dB.

It was assumed that each UE reaches the limit set by the Shannon capacity theorem, that is, the data rate for k is expressed as [18], where B is the system bandwidth equation 12.

$$C_k = B \log_2(1 + SINR_k) \quad (12)$$

In the proposed scenario, a mobile H-CRAN network was implemented, where, the network flow was based on the UE profile of districts of New York City, which have an area is 4km long [6]. This scenario will make it possible to investigate a large amount of information that plays a vital role in traffic engineering, network design, load balancing and pricing, which can be observed in Fig.4. 100 PRRHs were randomly placed, one MRRH, one BBU pool with five resident BBUs and 3600 UEs with uniform characteristics, so that all the UEs could have the same requirements. The dimensions of the scenario were normalized according to the territorial limits of the New York [6] region. The rest of the parameters can be found in Table 3.

The problem discussed in this paper is divided into two phases. The first stage seeks to reduce the number of under-utilized PRRHs during their daily operation; this process is explained in Section IV.A. In the second, after obtaining the results from the first stage, a balancing between the active BBUs and their respective sectors; this methodology is explained in Section IV.B.




Fig. 4. Traffic Patterns per Hours from New York city [6].

TABLE III
SIMULATION PARAMETERS

Parameters	Values
Propagation loss (MRRH)	COST231
Propagation loss (PRRH)	SUITYPE A
Transmit Power (MRRH)	43 dBm
Transmit Power (PRRH)	23 dBm
Total Scene Area	4km ²
PRRH Height	16m
Coverage area PRRH	150m
Coverage area MRRH	4km
Confidence Interval	95%
Number of Experiments	31

VI. RESULTS

In this section, the results obtained from our framework will be examined and compared with other approaches in the literature, LTE-A, HDSO and DPSO [3], [8], [9]. In Fig. 5 the averages of active PRRHs are displayed over a period of 24 hours, where it can be observed that the SAoff algorithm proved to be more effective in solving the problem being studied. On average, it maintained 89% of their active PRRHs, 9% less than HDSO and 10% less than LTE-A. In the period when there was a lower data flow, SAoff managed to turn off 44% of underutilized PRRHs, 20% more than HDSO and 44% more than LTE-A, thus showing the high capacity of the algorithm to deal with the heavy traffic of big cities.

In Fig. 6 the average throughput of the UEs in the network is analyzed. It can be seen that both the approaches discussed here can maintain the minimum throughput, although the SAoff can keep more UEs connected even with an average throughput 0.5% lower than HDSO. This fact can be attributed to the effective decision to keep the PRRHs active and, hence ensure a better distribution of resources among all the UEs.

In the context of load balancing between the sectors of the BBUs, three different techniques have been applied to mitigate the problem studied. The first is called Random Balance, which is an approach without any load balancing or intelligent mapping; the second, called BPSO, uses the two-level balancing system proposed here; finally, DPSO also uses intelligent balancing, as advocated by [9].

Fig. 7 presents the results obtained, where it can be seen that the convergence curve of UEs per sector of the BBUs in BPSO has a lower average than the other approaches,




Fig. 5. Number of PRRHs in 24 hours.




Fig. 6. Average UEs throughput rate during 24 hours.




Fig. 7. Load balancing between BBU sectors.




Fig. 8. Normalized average of UEs per sector in 24 hours.

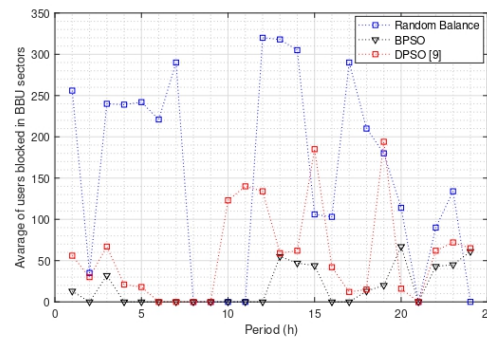


Fig. 9. Number of users blocked in 24 hours.

which results in a more balanced and optimized network, thus reducing the number of blocked UEs. In Fig.8 the average of UEs allocated in the sectors is presented but normalized by the current number of active UEs in a given hour, it can be seen that the algorithm better distributes users among the sectors, where it should be highlighted hours 15 to 17, where there was an increase in the number of users per sector when compared to the other approaches. This fact is attributed to the mapping process between RRHs and the sectors of BBUs, where a load coming from a RRH cannot be divided among different sectors.

This statement is supported by the average number of blocked UEs, which is shown in Fig. 9, over the 24h. The Random Balance which, using random assignment, averaged 153.8 blocked UEs, while DPSO averaged 57.2 and BPSO averaged 18.3. This represents a decrease of approximately 88.1% and 68% in the number of blocked UEs, respectively, thus demonstrating the effectiveness of the proposed resource orchestration.

VII. CONCLUSION

The constant increase in the number of cell phones and IP devices has driven the industry and academia to seek new solutions to meet this new demand. For this reason, the problem investigated in this paper is the intelligent orchestration of the resources of an H-CRAN network, through the intelligent turn off of PRRHs and optimized load balancing of UEs between the BBUs. In the context of PRRH sleep, the SAoff that had been designed, was able to 'sleep' more PRRHs than the algorithm used in the literature and maintain the stipulated QoS. Regarding resource balancing, BPSO averaged 68% fewer blocked users during the 24h analyzed when compared to DPSO, thus resulting in a more balanced network. In future work, it is recommended that the new KPIs should be incorporated to evaluate new factors and test the balancing in several scenarios.

REFERENCES

- [1] Cisco, "Cisco Annual Internet Report (2018–2023) White Paper", Last accessed 10 november 2021. [Online]. Available: <https://www.cisco.com/c/en/us/solutions/collateral/executive-perspectives/annual-internet-report/white-paper-c11-741490.html>.
- [2] Wang, Lu et al. "Statistical Multiplexing Analysis with Quantized Computing Resource for Practical C-RAN." In: *ICC 2019-2019 IEEE International Conference on Communications (ICC)*. IEEE, 2019, p. 1-6, doi: 10.1109/ICC.2019.8761515.
- [3] Ericsson, "Ericsson's fiber fronthaul solution deployed for China Mobile's LTE C-RAN". Last accessed 15 november 2021. [online]. Available: http://www.ericsson.com/news/140707-ericssons-fiber-fronthaul-solutiondeployed_244099436_c.
- [4] Morais, Fernando Zanferrari et al. "When SDN meets C-RAN: A survey exploring multi-point coordination, interference, and performance." *Journal of Network and Computer Applications*, v. 162, p. 102655, 2020, doi: 10.1016/j.jnca.2020.102655.
- [5] Marotta, Marcelo Antonio et al. "Resource sharing in heterogeneous cloud radio access networks". *IEEE Wireless Communications*, v. 22, n. 3, p. 74-82, 2015, doi: 10.1109/MWC.2015.7143329.
- [6] Chen, Na et al. "Scalable and flexible massive MIMO precoding for 5G H-CRAN". *IEEE Wireless Communications*, v. 24, n. 1, p. 46-52, 2017, doi: 10.1109/MWC.2017.1600139WC.
- [7] Yan, Boyuan et al. "Tidal-traffic-aware routing and spectrum allocation in elastic optical networks". *Journal of Optical Communications and Networking*, v. 10, n. 11, p. 832-842, 2018, doi: 10.1364/JOCN.10.000832.
- [8] Sigwele, Tshiamo; Hu, Yim Fun; Susanto, Misfa. "Energy-efficient 5G cloud RAN with virtual BBU server consolidation and base station sleeping". *Computer Networks*, v. 177, p. 107302, 2020, doi: 10.1016/j.comnet.2020.107302.
- [9] Khan, M.; Fakhri, Zainab H.; Al-rawashidy, Hamed S. "Semistatic cell differentiation and integration with dynamic BBU-RRH mapping in cloud radio access network". *IEEE Transactions on Network and Service Management*, v. 15, n. 1, p. 289-303, 2017, doi: 10.1109/TNSM.2017.2771622.
- [10] Aqeli, Emad; Moubayed, Abdallah; Shami, Abdallah. "Power-aware optimized RRH to BBU allocation in C-RAN". *IEEE Transactions on Wireless Communications*, v. 17, n. 2, p. 1311-1322, 2017, doi: 10.1109/TWC.2017.2777825.
- [11] Tian, Lin et al. "Energy efficiency analysis of base stations in centralized radio access networks". In: *2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*. IEEE, 2015, p. 133-136, doi: 10.1109/GlobalSIP.2015.7418171.
- [12] Yang, Xin-She. "Firefly algorithms for multimodal optimization". In: *International symposium on stochastic algorithms*. Springer, Berlin, Heidelberg, 2009, p. 169-178, doi: 10.1007/978-3-642-04944-6-14.
- [13] Kirkpatrick, Scott; Gelatt, C. Daniel; Vecchi, Mario P. "Optimization by simulated annealing". *science*, v. 220, n. 4598, p. 671-680, 1983, doi: 10.1126/science.220.4598.671.
- [14] Eberhart, Russell; Kennedy, James. "A new optimizer using particle swarm theory". In: *MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science*. Ieee, 1995, p. 39-43, doi: 10.1109/MHS.1995.494215.

- [15] Popoola, Segun I. et al. "Path loss dataset for modeling radio wave propagation in smart campus environment". *Data in brief*, v. 17, p. 1062-1073, 2018, doi: 10.1016/j.dib.2018.02.026.
- [16] Castro, B. S. L. et al. "COST231-Hata and SUI Models performance using a LMS tuning algorithm on 5.8 GHz in Amazon Region cities". In: *Proceedings of the Fourth European Conference on Antennas and Propagation*. IEEE, 2010, p. 1-3.
- [17] Nassar, A. T., Sulyman, A. I., and Alsanie, A. "Radio capacity estimation formillimeter wave 5g cellular networks using narrow beamwidth antennas at the basestations". *International Journal of Antennas and Propagation*, 2015, doi: 10.1155/2015/878614.
- [18] Checko, Aleksandra et al. "Cloud RAN for mobile networks—A technology overview". *IEEE Communications surveys tutorials*, v. 17, n. 1, p. 405-426, 2014, doi: 10.1109/COMST.2014.2355255.



Diego Lisboa Cardoso obtained a Bachelor's degree in Computer Science from the University of Amazônia (2002), a Master's degree (2005) and a PhD degree (2010) in Electrical Engineering from the Federal University of Pará and a post-doctoral fellowship at the Royal Institute of Technology of Sweden (KTH). He was Director of Technology at the State Department of Education of the Government of the State of Pará (2008-2009). He was the Rector of Undergraduate Education at the Federal University of South and South-East Pará (UNIFESSPA) (2014). He works as an Associate Professor at the Federal University of Pará in the School of Computer Engineering and Telecommunications and the Graduate Program in Electrical Engineering (PPGEE). He has experience in Computer Science and Computer Engineering, with an emphasis on Performance Evaluation. His work is mainly concerned with the following subject-areas: Digital TV, Access Technologies, Markovian performance and simulation models, applied computational intelligence and optimization techniques.



Ermínio Augusto Ramos da Paixão Graduated in Computer Networks at the University of Amazonia (2015), Master's Degree in Electrical Engineering at the Federal University of Pará (2018), PhD candidate in Electrical Engineering at the Federal University of Pará (2019), and member of the Operational Research Laboratory, where he works in the area of high performance networks, 5G, QoS and computational intelligence, with an emphasis on optimization techniques.



Albert Einstein Coutinho dos Santos Undergraduate in Computer Engineering at the Federal University of Pará (UFPA). He was a fellow of the Laboratory of Didactic Innovation in Physics (LIDF), where he worked on Arduino prototyping and IoT. [give dates] He is interested in Data Science Programming and Computational Intelligence. He is currently the holder of a scientific initiation scholarship which was awarded by the Institutional Program for Scientific Initiation Scholarships (PIBIC) at the Operational Research Laboratory (LPO) of the Federal

University of Pará.



Daniel da Silva Souza obtained a Bachelor's degree in Information Systems in 2016 and a Master's degree in Electrical Engineering with an emphasis on Applied Computing, from the Federal University of Pará (UFPA) in 2018, where he is currently pursuing a Doctoral degree. He is currently a member of the Operational Research Laboratory (LPO). His research areas are focused on Human-Computer Interaction, User Experience, Software Engineering, and Computer Networks. He is an Associate Member of the Brazilian Computer Society (SBC).

This article has been accepted for publication in IEEE Access. This is the author's version which has not been fully edited and content may change prior to final publication. Citation information: DOI 10.1109/ACCESS.2023.3347341

IEEE Access
Multidisciplinary | Rapid Review | Open Access Journal

Date of publication xxxx 00, 0000, date of current version xxxx 00, 0000.

Digital Object Identifier 10.1109/ACCESS.2017.DOI

FA-CRAN: a Firefly Algorithm for dynamic BBU-RRH mapping in Cloud/Centralized Radio Access Networks

MARIANE DE PAULA DA SILVA GONÇALVES IMBIRIBA², ERMÍNIO AUGUSTO RAMOS DA PAIXÃO², ALBERT EINSTEIN COUTINHO DOS SANTOS¹, CARLOS ANDRÉ DE MATTOS TEIXEIRA², RAFAEL FOGAROLLI VIEIRA², DANIEL DA SILVA SOUZA², IGOR WENNER SILVA FALCÃO², DIEGO LISBOA CARDOSO^{1,2}

¹Faculty of Computing and Technology, Federal University of Para, Belém, Pará, Brazil, CO 66075-110 BR

²Post-Graduate Program in Electrical Engineering, Federal University of Para, Belém, Pará, Brazil, CO 66075-110 BR

Corresponding author: Mariane de Paula da Silva Gonçalves Imbiriba (e-mail:goncalvesmariane@itec.ufpa.br).

This work was supported in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior-Brasil - CAPES under Finance 001, in part by the National Counsel of Technological and Scientific Development - CNPq, and in part by the Federal University of Para - UFPA, by the Dean of Research and Graduate Studies at UFPA.

ABSTRACT

C-RAN (Cloud Radio Access Network) is an architecture designed to the new generation of mobile networks. It has handled many problems arising from the 4-generation network, and made several improvements, such as centralized processing and energy efficiency, among others. However, time-varying traffic, known as the tidal effect, impairs the network by making resource allocation less efficient, and this affects network performance in terms of problems related to blocked users and power consumption. This study seeks to evaluate an optimized mapping model between RRH (Remote Radio Head) and BBU (Base Band Unit) by providing a fairer and more efficient load balancing. In addition, this solution is compared with some key algorithms used in the literature for addressing optimization problems. The results demonstrated that, owing to its effective search feature, the Firefly algorithm, was the most promising system, since it obtained better performance measures than the others.

INDEX TERMS C-RAN; Balancing; Firefly Algorithm.

I. INTRODUCTION

According to Cisco's projections [1], by the end of 2028, there is expected to be 9.2 billion mobile devices, with an average consumption of 46 GB per month and a 26% growth in mobile data traffic. At the same time, Ericsson [26] predicts that five billion 5G subscriptions (55% of the total), will be activated, and ensure an extensive coverage of 85%. It is also expected that 5G networks will be responsible for 70% of mobile traffic, and thus handle all the current growth. This convergence of forecasts by Cisco and Ericsson envisages a distinct scenario for the evolution of mobile technology until 2028.

The exponential increase in connected devices and the growing demand for communication services necessitate a reevaluation of existing network architectures. The Dis-

tributed Radio Access Network (D-RAN), which traditionally has decentralized functions to base stations, faces challenges in meeting new requirements, since it incurs high capital costs and significant operational charges resulting from additional base stations [2]. In response to these drawbacks, the Cloud Radio Access Network (C-RAN) architecture has emerged, and made far-reaching innovations. In C-RAN, the processing and control functions, which were traditionally performed at base stations, are centralized in what is called the Baseband Unit (BBU). This component is responsible for signal processing, resource management, and coordinating communication with Remote Radio Heads (RRH), which, in turn, are responsible for specific radio functions such as wireless signal transmission and reception. An approach that is adopted by centralizing processing in a cloud environment,

This article has been accepted for publication in IEEE Access. This is the author's version which has not been fully edited and content may change prior to final publication. Citation information: DOI 10.1109/ACCESS.2023.3347341

IEEE Access

Author et al.: Preparation of Papers for IEEE TRANSACTIONS and JOURNALS

offers benefits such as enhanced energy efficiency, better resource utilization, and increased flexibility when addressing the challenges of modern communication networks [3].

FIGURE 1. Traditional C-RAN architecture.

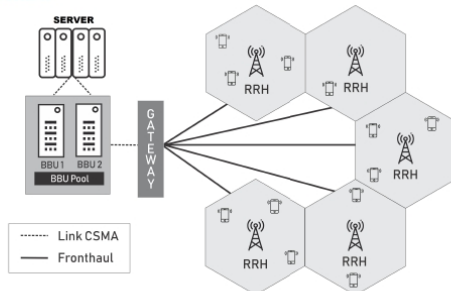


Figure 1 illustrates the C-RAN architecture, which has base stations that can be divided into three main components: RRH, fronthaul / backhaul links, and BBU [6] [7]. The main features of these units are explained below.

- RRH: RRHs are made up of RF circuitry, such as up-and-down signal converters, ADC/DAC circuitry, and an optical interface to handle the physical-layer signals. The user equipment is connected to the antenna unit located at the RRH via a fronthaul or microwave link. The RRH increases coverage and reduces the C-RAN CAPEX (Capital Expenditure).
- Front and backhaul links: the connection between RRH and BBU is referred to as the fronthaul. A fronthaul link can be either wired or wireless. Fiber is more suitable for the fronthaul network because of its higher bandwidth and lower cost. The backhaul in C-RAN, on the other hand, connects the BBU and the main network for data and application control. The use of advanced features such as SDN and NFV in the backhaul enhances both the capacity and QoS efficiency of the C-RAN.
- BBU: the BBU is a centralized management and processing unit residing in a BBU pool. The BBU uses cloud computing and virtualization technologies to achieve a scalable sharing of physical resources and spectrum control. Each BBU represents a packet classifier and a hypervisor in a group of Virtual Boxes (VBs). The baseband processing is performed in a VB. The hypervisor manages all the VB executions carried out in the BBU [8].

C-RAN has the advantages of high capacity, wide coverage, low costs, high energy efficiency, and load balancing, and has been extensively implemented in the industry. In addition to the traditional spectrum resources (channel, bandwidth and power), C-RAN has new additional resources that can be orchestrated - the BBU resources. According to [9], the processing charge in each BBU is determined by the total number of simultaneous active users in the BBU sectors. However, there are both hardware and software restrictions,

traditionally called Hard Capacity (HC), which are designed to define the limit of the number of active users in each sector of the BBU, and if they are poorly managed, it can lead to data and performance losses.

The variability in demand for Internet connection traffic, known as the tidal effect, can cause an underutilization of resources and deterioration of network performance, which represents one of the main challenges of the C-RAN architecture [6]. Poor radio and BBU resource orchestration can result in some sectors being overloaded, while others are underutilized, and make it impossible for new users to gain access to the network. Thus, appropriate resource management and configuration methods must be introduced to optimize C-RAN performance, while including a suitable response time and maximizing the number of users served.

Resource balancing and orchestration optimization is a high-dimensional, nonlinear, multi-constraint discrete optimization problem. Researchers have employed several methods to solve this problem, which can be roughly divided into three categories: an accurate algorithm, a heuristic algorithm based on priority rules, and an intelligent algorithm [1]- [3]. The results of the precise algorithm are accurate but very time-consuming, and are thus difficult to apply to large and complex problems; a heuristic algorithm based on optimization rules is fast but the quality of the optimization results depends on the merits of the rules and the universal application of the algorithm is poor. An intelligent algorithm is a kind of metaheuristic algorithm that simulates physical phenomena during its biological evolution in nature [4], [5]. It has global, parallel, efficient, and universal features, and is of often used to solve complex engineering optimization problems.

The aim of this study is to examine in greater depth the use of metaheuristics for resource orchestration in 5G networks and beyond, while taking into account aspects of performance and effectiveness. In this way, this paper seeks to make an evaluation of a self-organizing C-RAN architecture with the ability to reconfigure its resources, even in varying traffic conditions, as well as to improve network efficiency through a Key Performance Indicator (KPI). A controller residing within the BBU pool is used to monitor load conditions and determine the appropriate RRH-BBU configuration in the network. This problem is handled by the bio-inspired Firefly Algorithm (FA), an algorithm proposed by [13] which belongs to the group of stochastic algorithms, as it performs its search for solutions at random. Their search method is based on the intensity of the light that the fireflies emit. [13]. Other bio-inspired techniques were used for benchmarking purposes to determine the best algorithm that can carry out this optimization task. One is based on Particle Swarm Optimization (PSO), which is designed and implemented for this end [8][11] and another on the Bat Algorithm (BAT). A more recently created algorithm was used for an equivalent purpose [12], and both algorithms have been widely used in the literature to solve optimization problems such as resource allocation.

It is important to make a proper choice of the metaheuristic that will be used, as the performance of these algorithms when tackling each type of problem must be noted. This is because their performance may vary, depending on the particular features of the load balancing problem, the extent of the problem and the parameters of the algorithm. In light of this, this study concentrates on conducting experiments and making a comparison of the performance of different algorithms when addressing a given RRH- BBU resource and load-balancing orchestration problem

The research contributions of this article are as follows:

- Designing an efficient mapping model between RRH and BBU to optimize load balancing in the C-RAN network, while taking account of the tidal effect and its implications for resource allocation, with an emphasis on equity, efficiency, and the reduction of blocked users. The purpose of this is to improve network performance globally, through an additional focus on energy efficiency.
- Making a detailed comparison of the proposed system with the main algorithms used in optimization problems in the literature. This involves highlighting the effectiveness of the Firefly algorithm in seeking promising solutions and achieving a better performance, as well as emphasizing its capacity optimization.
- Assisting in the advancement of mobile networks, especially by transitioning to the next generation, gaining insights and finding appropriate solutions for advanced networks like 5G and future technologies.

This article is structured as follows: Section II discusses the literature with regard to the main features of the architecture and the problems addressed in this paper. Section 3 describes the Firefly Algorithm. Section 4 examines the architecture and simulation methodology employed in this study. The results are shown in Section 5, followed by the conclusion in Section 6.

II. RELATED WORK

Optimization problems are common in many areas of real-world applications. In this context, several bio-inspired techniques based on swarm intelligence have been applied in several areas such as power systems, vehicle routing, robot planning, and telecommunications. This especially applies to the concern about the current and upcoming increase in traffic flow in the next few years, particularly since the C-RAN architecture was designed to mitigate the problem of these demands. This architecture has dynamic features, such as self-organization and an ability to intelligently redistribute resources in different scenarios.

It was recommended that a resource manager should be located inside the BBU to monitor the traffic conditions and adjust the BBU-RRH mapping. A bio-inspired AB algorithm was used to optimize this process. In addition, two algorithms from the literature were implemented for benchmarking purposes. The results showed that the AB algorithm proved to be more efficient and had a shorter execution time.

The authors of [11], also highlight the C-RAN architecture as a possible alternative, owing to its processing power and ability to reconfigure and map users in an intelligent way. A method to optimize the quality of service (QoS) of the architecture was investigated by using a KPI to reduce the number of blocked UEs. The PSO algorithm was used to this end to match users with the KPI and optimize the QoS. The authors obtained satisfactory results, which in fact proved to be potentially better than the results in the literature.

The study carried out in [13] underlines the effectiveness of bio-inspired algorithms in the field of optimization. It also introduces a new, carefully designed and well explained technique, referred to as Firefly Algorithm (FA). The authors compare the effectiveness of the FA with other consolidated metaheuristic approaches such as Particle Swarm Optimization (PSO). The new algorithm was used to solve a series of optimization problems with several functions. The results show that the FA outperformed both algorithms when they were compared, which proved that it might be more powerful in solving these problems and more suitable for dealing with future problems. An attempt will be made to further validate and embed this new method in future research.

In seeking to optimize the mapping between the BBUs and RRHs, the authors of [14] applied the Particle Swarm Optimization (PSO) algorithm, which belongs to the area of Swarm Intelligence, to ensure intelligent utilization of C-RAN resources. The key objective of this study is to reduce network costs through dynamic resource allocation, while also seeking to reduce the energy consumption of C-RAN resources, which directly affects the allocation of RRHs. The results showed a significant reduction in energy consumption, together with a maximum conservation of energy efficiency, which led to research aimed at more sustainable and economically viable communication networks.

In [17] an energy-efficient C-RAN is proposed for the 5G network. To achieve this, the authors use a Particle Swarm Optimization (PSO) algorithm for resource allocation in C-RAN. The main objective of the study is to dynamically allocate BBU resources to RRHs that are based on traffic and reduce the energy consumption of centralized BBU resources. The proposed PSO algorithm achieves a 90% reduction in energy consumption and maximizes energy efficiency, when compared with the existing works in the literature.

The author in [18] proposes a solution for load balancing in 5G C-RAN based on BBU-RRH dynamic mapping that supports IoT communications. For this, the Markov model is employed to predict the traffic load based on the current location of users for each cell. The Ant Colony Optimization (ACO) technique is employed to find the optimized mapping between BBU and RRH. The proposed solution reconfigures BBU and RRH logical connections based on IoT network traffic prediction, resulting in a balanced load across the IoT network. The proposed solution aims to minimize the number of blocked connections in the IoT network to the lowest possible value, leading to maximizing QoS.

In [10], finds a solution for load balancing in 5G C-RAN

which is based on the BBU-RRH dynamic mapping that supports IoT communications. The Markov model is employed for this to predict the traffic load that is based on the current location of users for each cell. The Ant Colony Optimization (ACO) technique is employed to find the optimized mapping between BBU and RRH. The proposed solution reconfigures BBU and RRH logical connections on the basis of IoT network traffic prediction, and results in a balanced load across the IoT network. The aim of this solution is to reduce the number of blocked connections in the IoT network to the lowest possible value, as a means of maximizing the QoS.

In [17] there is a discussion about the two-level coverage. In the second stage, two algorithms are used to reduce the number of BBU servers, and hence save energy, which is carried out by consolidating BBUs. Both proposed solutions achieve good results, and thus can ensure energy savings without losing QoS quality.

The architectures proposed in [24] and [25] demonstrate their effectiveness in the comprehensive optimization of radio frequency, optical spectrum, and BBU processing resources, and seek to maximize radio coverage and meet Quality of Service (QoS) requirements. The works show promising results with regard to these essential factors. However, it should be noted that they do not delve into the orchestration of resources in BBU pools in detail. In particular, there is a failure to fully address the question of the effects of the tidal effect, which can result in user blocking caused by an inadequate distribution of resources. This gap in the analysis could have an adverse effect on operational efficiency in dynamic scenarios where traffic demand varies.

In [19], energy efficiency of the system through the allocation of resources and power control. The authors also reduced energy consumption by turning on/off RRHs on the basis of the current user distribution. The problem was modeled with an energy efficiency (EE) maximization that was constrained to provide full frequency reuse across RRHs. The solution breaks the problem down into several stages to reduce the complexity. First, the RRHs that must be turned on/off are selected and then based on the operational RRHs; the assignment of users and the transmission power of the RRHs are optimized. Finally, any unattended user is assigned to the macro base station. A performance review shows that the solution significantly improves the EE system and energy consumption, when compared with other solutions in the literature and achieves an improvement in EE of more than 57%.

III. RRH-BBU MAPPING AND RELATED KPIS

Resource orchestration or RRH-BBU mapping involves determining what is suitable for making logical connections between BBU, RRH, and sectors where there is load balancing. This improves the network performance function at period $t + 1$ under a given network condition at period t that is based on selected 11 KPIS [16]. Thus it is necessary to know the position and throughput demand of the user in the period t . This section describes the essential features

needed to orchestrate radio and BBU resources for 5G and beyond networks, including the RRH-UE allocation process, propagation modeling, and the KPIS used for load balancing across BBU sectors.

A. SYSTEM MODEL

The Stanford University Interim model (SUI) was used to calculate the propagation loss in metropolitan environments [20]. Equation 1 presents a model of the SINR (Signal to Interference plus Noise Ratio) relationship for a specific user k connected to an RRH (n):

$$SINR_k = \frac{P_r(k)}{\alpha^2 + I_k} \quad (1)$$

Where $P_r(k)$ is the power received by the user k , α^2 is the thermal noise power, and I_k is the intercellular interference of RRH. The power received by the user can be calculated by Equation 2 that links the transmission power P_{ot} with the propagation loss obtained by the SUI-Type-A model.

$$P_{rk} = \frac{10^{P_{ot}}}{\alpha^2 + I_k} \quad (2)$$

The three values that make up L_{SUI} can be calculated by means of the following three equations:

$$L_{SUI} = A + 10\gamma \log \frac{d}{d_o} + SE, d > d_o, \quad (3)$$

$$A = 20 \log \frac{4\pi d_o}{\lambda}, \quad (4)$$

$$\gamma = a - bh_b + \frac{c}{h_b} \quad (5)$$


The data rate of each user is estimated using the Shannon capacity expressed in the Equation 6, with B being the system bandwidth [20].

$$C_k = B * \log_2(1 + SINR_k) \quad (6)$$

The tidal effect, known as the influence by predictable patterns of human movement with mobile devices, impacts in the network pattern [21].

Figure 2 highlights this phenomenon, by showing the traffic load measurement calculated by the article [6] in the districts of New York. This dynamic requires an in-depth investigation on account of the crucial information it provides for areas such as traffic engineering, network design, load balancing, and pricing, as is proved by the evidence in the study [6]. The measurement of traffic loads, expressed in kilobits per second (kbps) throughout the day, relies on monitoring tools to collect data on the volume of data transmitted and received at regular intervals, usually every hour. The calculation involves adding up the total volume of data in bits during each interval and converting the sum total to kbps, which is a means of gaining a valuable insight into daily usage patterns, traffic peaks, and temporal variations. This process facilitates the optimization of network capacity and efficient resource planning.

FIGURE 2. Traffic Flow Patterns per hour in New York city



B. KPI FOR BBU BALANCING

To optimize RRH-BBU mapping and analyze its effectiveness in a dynamic traffic network, an objective function (Equation 7) was used as a KPI with the aim of distributing UEs as uniformly as possible between the sectors of each BBU; this took account of the maximum number of UEs that each sector can support. The KPI was based on [16].

$$U_{s(i)} = \sum_{j=1}^N C_j R_{s,j}, S = 1, 2, \dots, K \quad (7)$$

Where:

- $U_{s(i)}$ is the number of UEs in the sector;
- N is the total PRRHs;
- K is the total sectors;
- C is the number of UE connected in PRRHj;
- R is a binary variable where it takes the value 1 if PRRHj is allocated to sector s .

The vector U_s used in the objective function will vary in accordance with the number of UEs in the network to ensure that the sectors are balanced, and hence their respective BBUs are balanced as well. All the possible U_s for all the K (sectors) will be tested to obtain the smallest possible value (KPImin).

The equation proposed in [14] was used as a restrictive measure. This process involves reducing the number of blocked UEs and, hence, maximizing QoS, as shown in Equation 8.

$$0, \text{ if } (UsHC) < 0 \text{ or } (UsHC) \text{ if } (UsHC) \geq 0 \quad (8)$$

The output of the model is given by the following vector: $S_i + 1j = S_i + 11, S_i + 12, \dots, S_i + 1N$, which represents the sectors of the BBUs $S_i + 1j$ and PRRHs that have been allocated to these sectors.

IV. IMPLEMENTATION OF FIREFLY ALGORITHM FOR RRH-BBU BALANCE OPTIMIZATION

In recent decades, several algorithms have emerged that are inspired by natural phenomena, especially in the field of

metaheuristic numerical optimization. Techniques such as those employed by evolutionary algorithms and swarm algorithms, are often based on populations. The former comprise computational techniques based on biological evolutionary principles such as natural selection, mutation, and genetic inheritance. Swarm algorithms, on the other hand, correspond to systems that seek to replicate the swarm intelligence that is generally observed in nature, in which a group of agents cooperates collectively to achieve some objective [13], [15].

The Firefly Algorithm stands out among bio-inspired algorithms as a swarm intelligence technique based on the bioluminescence of fireflies. According to the authors of [13], some properties of fireflies were simplified to develop FA, such as the following: (1) the fact that all fireflies are attracted to one another regardless of gender; (2) the capacity for attraction capacity is proportional to their brightness, and diminishes as decreasing with the distance between them widens; (3) if there was no firefly brighter than the others, they all moved randomly. Thus, it is understood that the brightness of a firefly can be directly affected by the medium or by the objective function of the problem in question. In a maximization problem, for example, the brightness can be proportional to the value of the objective function. Taking these characteristics into account and based on the three previous rules, the operation of the algorithm is summarized by Algorithm 1.

Algorithm 1: Firefly Algorithm pseudocode.

Data: Objective Function $f(x)$, $x = (x_1, \dots, x_d)^T$;
 Generate initial firefly population x_i
 ($i = 1, 2, \dots, n$); Sets light intensity I_i in x_i
 using $f(x_i)$; Sets absorption coefficient γ

Result: Best solution found

```

1  $\sigma(S) = 0$ ;
2 while  $t < MaxGeneration$  do
3   for  $i = 1$  to  $n$  do
4     for  $j = 1$  to  $n$  do
5       if  $I_j > I_i$  then
6         | Move the firefly  $i$  towards the firefly  $j$ ;
7       end
8       Calculate  $\beta(r) = \beta_0 e^{-\gamma r^2}$ ;
9       Evaluate new solutions and update light intensities;
10      end
11    end
12    Rank the fireflies and find the best one;
13 end

```

Initially, the population of fireflies is generated at random. The light intensity values, which correspond to the value of the objective function, are then calculated and assigned to each firefly. The absorption coefficient of the medium is defined in line 4. If the light intensity of firefly i is less than that of j , i is attracted by j (lines 10-12). Then, on line 13, the attraction value of a firefly is calculated by means of

the equation $\beta(r) = \beta_0 e^{-\gamma r^2}$, in which r corresponds to the Euclidean distance between fireflies i and j , β_0 the initial attractiveness at r_0 and γ the absorption coefficient of the medium. The generated solutions are evaluated on line 16 after their respective light intensities have been calculated. Finally, after the fireflies have been ranked in terms of their brightness, the one with the highest luminous intensity is chosen as the best solution.

V. ARCHITECTURE AND SIMULATION

In the proposed method, the BBU pool host manager uses a bioinspired algorithm to perform the RRH-BBU mapping by taking note of the performance indicator recommended in [12], through which it obtained acceptable balancing metrics for its users. The use of hardware-embedded metaheuristics has already been widely discussed in the literature in various branches of engineering, and further references/discussion on this point can be found in [22] [23]. In this context, a simulation is carried out that is designed to optimize the mapping process and evaluate the best bioinspired algorithm in the network that can perform resource balancing. However, this paper intends to conduct a performance analysis to investigate which will outclass [11] as a means of mitigating this problem, and find a good solution with a shorter convergence time, that will improve the QoS of real-time flows in a context of high user mobility.

The scenario consists of 19 RRHs that are randomly distributed between two BBUs divided into three sectors, which are managed by a BBU pool. The RRHs serve a total number of 1500 users. The prospect of reducing the number of blocked UEs is evaluated after the RRHs have been distributed and allocated to their respective BBUs, since an unbalanced network overloads certain sectors, thus leading them to overheat and perhaps cause performance losses. The simulations were performed by means of the Matlab1 simulator because of its extensive documentation, and the fact that it makes it easier to create new scenarios or adjust them.


The scene is made up of the H-C-RAN architecture shown in Figure 3. RRHs, UEs, Macro, and BBUs are located in the New York area and are interconnected by optical fiber; the BBUs are grouped in the BBU pool and managed by the host manager. The design of these devices allows algorithms to be implemented that can optimize the resource reconfiguration process. After the RRHs have been distributed and allocated to their respective BBUs, a decision is made about whether or not more BBU sectors are necessary. Owing to their extensive documentation, (which makes it easier to create and adjust scenarios), the simulations were carried out by means of Matlab.

As shown in Figure 3, the infrastructure consists of BBU processors, RRH Macrocells, and user-facing devices. The host manager is responsible for implementing the network functions that are a) based on a physical infrastructure, b) in infrastructure cabinets and c) running bio-inspired algorithms. In our scenario, the host manager activates the

hourly algorithms to ensure the network is more effectively balanced.

The three algorithms followed the steps outlined in Figure 3.

FIGURE 3. Simulation Scenario.



VI. SIMULATION AND ANALYSIS

This section outlines a performance evaluation of the proposed optimization for load balancing and resource orchestration with the aid of the Firefly Algorithm (FA). The evaluation takes account of three essential metrics: execution time, number of iterations, and standard deviation. Two widely recognized algorithms with regard to this type of problem [12] and [8] were chosen as benchmarks for purposes of comparison. The first, Particle Swarm Optimization (PSO), is grounded on the social behavior of birds and shoals of fish, where a population of candidate solutions, called particles, collaborates and moves about in the search space, influenced by the optimal positions that can be found both individually and globally. The second benchmark, Bat Algorithm (BAT), emulates the habits of bats when foraging for food, and adopts manoeuvres such as echolocation and adaptive movement to adjust candidate solutions in the search space. The results of the balancing technique were calculated by a machine equipped with an Intel(R) Core (TM) i5-3317u processor, clocked at 1.7GHz, and with 8GB of DDR3 RAM. A population of 30 particles was generated, and the stopping criterion was set at 100 iterations for each algorithm. The rest of the parameters can be found in Table 1.

Given the inherent stochastic nature of the algorithms, it is essential to subject the techniques to multiple iterations and employ descriptive statistical metrics to obtain a more reliable analysis of the results. In the context of this study, 30 executions were carried out, by employing median and deviation from the norm, as metrics to calculate the measure of dispersion in the generated values.

Furthermore, we incorporated three distinct scenarios in the simulation, each featuring varying numbers of users and BBUs. The purpose of this deliberate variation was to provide

This article has been accepted for publication in IEEE Access. This is the author's version which has not been fully edited and content may change prior to final publication. Citation information: DOI 10.1109/ACCESS.2023.3347341

Author et al.: Preparation of Papers for IEEE TRANSACTIONS and JOURNALS

TABLE 1. Simulation Parameters

Parameters	Values
Propagation loss (<i>MRRH</i>)	COST231
Propagation loss (<i>PRRH</i>)	SUL-TYPE A
Transmit Power (<i>MRRH</i>)	43 dBm
Transmit Power (<i>PRRH</i>)	23 dBm
Total Scene Area	4km ²
PRRH Height	16m
Coverage area PRRH	150m
Coverage area MRRH	4km
Confidence Interval	95%
Number of Experiments	31

TABLE 2. Results of the Bioinspired Algorithms 500.

Evaluated Metrics	Firefly	PS.O.	B.A.T.
Mean Execution Time	1,23 ms	7,36 ms	6,1 ms
Execution Time Std. Deviation	0,23	0,39	0,36
Mean Number of Iterations	3^a	11 ^a	10 ^a
Number of Iterations Std. Deviation	0,17	0,32	0,30

TABLE 3. Results of the Bioinspired Algorithms 1000.

Evaluated Metrics	Firefly	PS.O.	B.A.T.
Mean Execution Time	2,19 ms	10,13 ms	9,80 ms
Execution Time Std. Deviation	0,34	0,56	0,48
Mean Number of Iterations	10^a	36 ^a	31 ^a
Number of Iterations Std. Deviation	0,30	0,46	0,42

TABLE 4. Results of the Bioinspired Algorithms 1500.

Evaluated Metrics	Firefly	PS.O.	B.A.T.
Mean Execution Time	3,91 ms	18,25 ms	16,34 ms
Execution Time Std. Deviation	0,45	0,81	0,78
Mean Number of Iterations	17^a	42 ^a	37 ^a
Number of Iterations Std. Deviation	0,36	0,48	0,46

a more comprehensive understanding of the effectiveness of each technique.

Tables 2, 3, and 4 display the average execution time and standard deviation of the number of iterations required to achieve convergence in scenarios with 500, 1000, and 1500 users, respectively.

The data in Table 2 confirm this effectiveness, by showing that, on average, FA had an approximately 83.29% faster execution time than PSO and was 79.84% faster than BAT. Furthermore, in terms of iterations, FA reached the desired solution approximately 72.73% faster than PSO and about 70% than BAT. Table 3 further underlines the remarkable efficiency of FA. With regard to its average execution time, the algorithm had an acceleration rate of approximately 78.38% compared with PSO and an improvement in speed of 77.65% when compared with BAT. As regards the iteration count, FA reached the expected solution about 72.22% times faster than PSO and was approximately 67.74% faster than BAT.

Following the same line of analysis, Table 4 corroborates the consistent effectiveness of the FA algorithm. Concerning the average execution time, the FA performed approximately 78.58% faster than PSO and 76.07% than BAT. In terms of iteration count, the FA reached the expected solution about

59.52% times faster than PSO and approximately 54.05% faster than BAT.

An analysis of the three displayed tables, consistently shows the clear superiority of FA over traditional methods. In Tables 2, 3, and 4, FA demonstrated exceptional efficiency by significantly outperforming PSO and BAT in average execution time and iteration counts.

In assessing the algorithm's robustness, both the population and the sample space were expanded to test the performance when stretched to the limit. Even with this notable increase, the FA algorithm maintained a superior performance to that of its competitors.

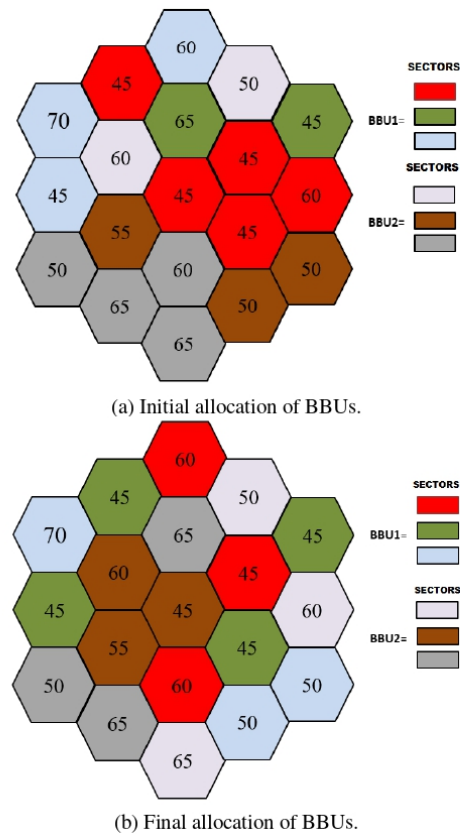


FIGURE 4. 19 RRHs governed by 2 BBU in the BBU pool, each BBU covers 3 sectors.

Figure 4 illustrates the practical results of this performance. From an observation of the hexagons representing the Remote Radio Heads (RRHs) and the allocation of blocked User Devices (UDs), the visual display in (a) without the balancing process highlights that there are network losses. In contrast, with the algorithm's execution, (b) displays a fairer, more balanced, and optimized distribution. This process re-

sults in the reduction of UDs, and confirms the effectiveness of the balancing when it is facilitated by the FA algorithm in network optimization.

The graph that displays a convergence curve of the evaluated algorithms is shown in 567. In 5, when 500 UEs were added, the FA converged 83% faster than PSO, compared with the 79.8% of BAT, respectively. Conversely, in 6, the FA outperforms the others while maintaining a high efficiency ratio, with a difference of 78.3% compared with PSO and 77.6% compared with BAT. Finally, in 7, where the number of UEs is tripled, the FA obtains the best solution with just half as many interactions as the others, and kept an efficiency rate that is at least 70% higher than that of the others.

It should be remembered that a performance comparison between different optimization algorithms often depends on the nature of the problem. An algorithm that performs well in one problem may not be as effective in another. Thus, the context and features of an optimization problem must be carefully taken into account when selecting an algorithm. In the context of load balancing optimization, the FA can achieve faster convergence than PSO or BAT. This can be attributed to several distinctive features: a) Attraction Mechanism: The FA employs a mechanism where fireflies are attracted to brighter fireflies, and thus represent better solutions. This mechanism helps the algorithm adapt quickly to promising solutions, and assist load balancing. b) Intensity-Based Communication: Fireflies communicate on the basis of their light intensities, and this enables them to share load information and adapt to positions more effectively. c) Adaptive Behavior: Fireflies in the FA behave in an adaptive manner by adjusting their powers of attraction and movement to the local and global environment. This adaptability allows them to have a dynamic response to changes in load conditions. d) Exploration-Exploitation Tradeoff: like other meta-heuristic algorithms, the FA seeks to balance the exploration of the search space (i.e. attempt to find new solutions) with an exploitation of known solutions (i.e. by optimizing existing solutions). In load balancing optimization, this balance is crucial to ensure that the search space can be efficiently explored to find the best load distribution solutions while continuing to optimize measures that can clearly maintain a good balance.

The 8 shows how these three tactics are planned. Remarkably, the methodology employed used in the published literature results in sectors that are free of blocked calls, although with a significantly imbalanced user distribution. On the other hand, the suggested approach demonstrated that there could be a more equal allocation of sectors and led to zero blocked calls.

Our statement explains that the adaptability of the algorithms allows them to dynamically respond to changes in load conditions by effectively balancing the load and making adjustments to position and intensity. More specifically, the Firefly Algorithm (FA) establishes a trade-off between exploration (finding new solutions) and exploitation (optimizing existing solutions) in the context of load balancing opti-

FIGURE 5. Convergence curve for 500 UEs.




FIGURE 6. Convergence curve for 1000 UEs.




FIGURE 7. Convergence curve for 1500 UEs.


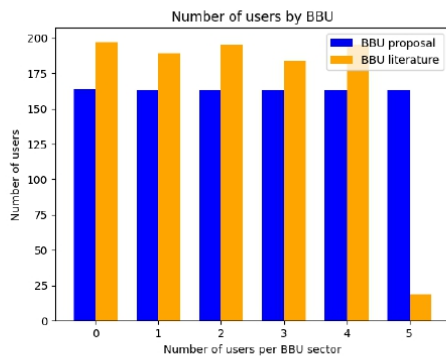


FIGURE 8. Convergence curve for 500 UEs.



mization. This balance is essential for efficiently exploring the search space while making use of previously identified solutions that have a good balance.

It should also be emphasized that the performance of these algorithms can vary, depending on the particular features they have such as the nature of the load balancing problem, the extent of the problem, and the parameters of the algorithm. A recognition of this underscores the importance of taking account of the specific context and requirements of the load balancing scenario when evaluating the performance of algorithms.

Furthermore, the following factors should be noted with regard to the complexity of the algorithms. In each iteration, the Firefly algorithm updates the position and velocity of n populations of the created fireflies and then determines the best population. Thus, the complexity of the algorithm is $O(M * n)$, where M represents the maximum number of iterations and n represents the number of created populations. On the other hand, the PSO algorithm has a complexity of $O(M * n * nBBU + nBBU)$, where $nBBU$ represents the number of sectors in the current BBU. The first part, $M * n * nBBU$, represents the update of positions and velocities of the particles, while $nBBU$ represents the assignment of values for the best swarm found. Finally, the BAT algorithm has a complexity of $O(M * n * nBBU)$, which corresponds to the update of the position and velocities of the bats that make up the population. In light of this, it is clear that the Firefly algorithm has a better scalability and performance.

VII. CONCLUSION

The focal point of this study is on C-RAN networks, which have an architecture that centers on optimizing the mapping between RRH (Remote Radio Head) and BBU (Baseband Unit). Bio-inspired algorithms that are widely used in the literature were created to act as benchmarks with the aim of enhancing the mapping and load balancing of data in the network. Thus, it was possible to assess which of them performs better for this task. After analyzing the results, it was found that the Firefly Algorithm (FA) proved to be superior to the others in terms of efficiency and resource allocation. In view of this, future research could focus on quantifying and analyzing the specific benefits of these algorithms in reducing energy consumption, as this would make a valuable contribution to the sustainable and efficient development of mobile communication networks.

A. COPYRIGHT FORM

Authors must submit an electronic IEEE Copyright Form (eCF) upon submitting their final manuscript files. You can access the eCF system through your manuscript submission system or through the Author Gateway. You are responsible for obtaining any necessary approvals and/or security clearances. For additional information on intellectual property rights, visit the IEEE Intellectual Property Rights department web page

This article has been accepted for publication in IEEE Access. This is the author's version which has not been fully edited and content may change prior to final publication. Citation information: DOI 10.1109/ACCESS.2023.3347341


IEEE Access

Author et al.: Preparation of Papers for IEEE TRANSACTIONS and JOURNALS

at http://www.ieee.org/publications_standards/publications/rights/index.html.

REFERENCES

- [1] "Ericsson mobility report," Ericsson.com, Nov. 2022.
- [2] L. Wang et al., "Statistical Multiplexing Analysis with Quantized Computing Resource for Practical C-RAN," in ICC 2019-2019 IEEE International Conference on Communications (ICC), pp. 1-6, IEEE, 2019.
- [3] Ericsson, "Ericsson's fiber fronthaul solution deployed for China Mobile's LTE C-RAN," http://www.ericsson.com/news/140707-ericssons-fiber-fronthaul-solution-deployed_244099436_c, Nov. 2017.
- [4] Y. Lin, L. Shao, Z. Zhu, Q. Wang, and R. K. Sabhikhi, "Wireless network cloud: architecture and system requirements," IBM J. Res. Dev., vol. 54, no. 1, pp. 4-1, 2010.
- [5] Y. Zhang, L. Budzisz, M. Meo, A. Conte, I. Haratcherev, G. Koutitas, L. Tassiulas, M. Ajmone Marsan, and S. Lambert, "An overview of energy-efficient base station management techniques," in: Digital Communications-Green ICT (TIWDC), 24th Tyrhenian International Workshop on, pp. 1-6, 2013.
- [6] K. Chen and R. Duan, "C-RAN: The Road Towards Green RAN," China Mob. Res. Inst., vol. 2, 2011.
- [7] M. Makhanbet, X. Zhang, H. Gao, and H. A. Suraweera, "An overview of cloud RAN: architecture, issues and future directions," in: International Conference on Emerging Trends in Electrical, Electronic and Communications Engineering, Springer, pp. 44-60, 2016.
- [8] D. Mishra, P. C. Amogh, A. Ramamurthy, A. A. Franklin, and B. R. Tamma, "Load-aware dynamic RRH assignment in cloud radio access networks," in: Wireless Communications and Networking Conference (WCNC), pp. 1-6, 2016.
- [9] N. Chen et al., "Self-organizing scheme based on NFV and SDN architecture for future heterogeneous network", Mobile Networks and Applications, vol. 20, no. 4, pp. 466-472, 2015.
- [10] M. Mouawad, Z. Dziong, and K. Addali, "RRH selection and load balancing through Dynamic BBU-RRH Mapping in C-RAN" in: 2019 IEEE Canadian Conference of Electrical and Computer Engineering (CCECE), pp. 1-5, IEEE, 2019.
- [11] E. A. Ramos da Paixão, R. F. Vieira, W. V. Araújo and D. L. Cardoso, "Optimized load balancing by dynamic BBU-RRH mapping in C-RAN architecture," 2018 Third International Conference on Fog and Mobile Edge Computing (FMEC), Barcelona, Spain, 2018, pp. 100-104, doi: 10.1109/FMEC.2018.8364051.
- [12] T. Yuvaraj, K. Ravi, and K. Devabalaji, "DSTATCOM allocation in distribution networks considering load variations using bat algorithm," Ain Shams Engineering Journal, vol. 8, no. 3, pp. 391-403, 2017.
- [13] Xin-She. Yang, "Firefly algorithms for multimodal optimization," in: International symposium on stochastic algorithms, Springer, Berlin, Heidelberg, pp. 169-178, 2009.
- [14] P. R. Adiraju and V. S. Rao, "Dynamically Energy-Efficient Resource Allocation in 5G C-RAN Using Intelligence Algorithm," EMITTER International Journal of Engineering Technology, pp. 217-230, 2022.
- [15] Xin-She. Yang, "A New Metaheuristic Bat-Inspired Algorithm," Springer, Berlin Heidelberg, pp. 65-74, 2010.
- [16] M. Khan, Z. H. Fakhri, and H. S. Al-Raweshidy, "Semistatic cell differentiation and integration with dynamic BBU-RRH mapping in cloud radio access network," IEEE Transactions on Network and Service Management, vol. 15, no. 1, pp. 289-303, 2017.
- [17] ADIRAJU, Prasanth Rao; RAO, Voore Subba. Dynamically Energy-Efficient Resource Allocation in 5G C-RAN Using Intelligence Algorithm. EMITTER International Journal of Engineering Technology, p. 217-230, 2022.
- [18] MOUAWAD, Mostafa; DZIONG, Zbignew; EL-ASHMAWY, Ahmed. Load balancing in 5G C-RAN based on dynamic BBU-RRH mapping supporting IoT communications. In: 2018 IEEE Global Conference on Internet of Things (GCIoT). IEEE, 2018, p. 1-6.
- [19] A. Srivastava, M. S. Gupta, and G. Kaur, "Energy efficient transmission trends towards future green cognitive radio networks (5G): Progress, taxonomy and open challenges," Journal of Network and Computer Applications, vol. 168, p. 102760, 2020.
- [20] L. S. B. Castro, et al. "COST231-Hata and SUI Models performance using a LMS tuning algorithm on 5.8 GHz in Amazon Region cities." Proceedings of the Fourth European Conference on Antennas and Propagation. IEEE, pp. 1-3, 2010.
- [21] I. W. S. Falcão et al., "The Heuristic for Hardware Dimensioning Considering Tidal Effect," Journal of Communication and Information Systems, vol. 35, no. 1, pp. 311-319, 2020.
- [22] A. Ortiz et al., "Hardware implementation of metaheuristics through LabVIEW FPGA," Applied Soft Computing, vol. 113, p. 107908, 2021.
- [23] H. Chen et al., "SEFSD: an effective deployment algorithm for fog computing systems," Journal of Cloud Computing, vol. 12, no. 1, pp. 1-15, 2023.
- [24] H. Yang, J. Zhang, Y. Ji and Y. Lee, "C-RoFN: multi-stratum resources optimization for cloud-based radio over optical fiber networks," in IEEE Communications Magazine, vol. 54, no. 8, pp. 118-125, August 2016, doi: 10.1109/MCOM.2016.7537186.
- [25] H. Yang, Q. Yao, B. Bao, A. Yu, J. Zhang and A. V. Vasilakos, "Multi-Associated Parameters Aggregation-Based Routing and Resources Allocation in Multi-Core Elastic Optical Networks," in IEEE/ACM Transactions on Networking, vol. 30, no. 5, pp. 2145-2157, Oct. 2022, doi: 10.1109/TNET.2022.3164869.
- [26] Ericsson, "Ericsson Mobility Report: Global 5G Growth Amid Macroeconomic Challenges," 2022, <https://www.ericsson.com/en/press-releases/2022/11/ericsson-mobility-report-global-5g-growth-amid-macroeconomic-challenges>, Acessado em 11 de novembro de 2023.



MARIANE DE PAULA DA SILVA GONÇALVES IMBIRIBA is a doctoral student with an emphasis on applied computing and Research in Networks and Distributed Systems, in the Graduate Program in Electrical Engineering (PPGEE) at the Federal University of Pará. She works at the Operational Research Laboratory and is dedicated to the area of research on new architectures for 5G, load balancing, resource allocation, applied computational intelligence and optimization techniques.



ERMÍNIO AUGUSTO RAMOS DA PAIXÃO Graduated in Computer Networks at the University of Amazonia (2015), Master's Degree in Electrical Engineering at the Federal University of Pará (2018), PhD candidate in Electrical Engineering at the Federal University of Pará (2019), and member of the Operational Research Laboratory, where he works in the area of high performance networks, 5G, QoS and computational intelligence, with an emphasis on optimization techniques.



ALBERT EINSTEIN COUTINHO DOS SANTOS Undergraduate in Computer Engineering at the Federal University of Pará (UFPA). He was a fellow of the Laboratory of Didactic Innovation in Physics (LIDF), where he worked on Arduino prototyping and IoT. [give dates] He is interested in Data Science Programming and Computational Intelligence. He is currently the holder of a scientific initiation scholarship which was awarded by the Institutional Program for Scientific Initiation Scholarships (PIBIC) at the Operational Research Laboratory (LPO) of the Federal University of Pará.

This article has been accepted for publication in IEEE Access. This is the author's version which has not been fully edited and content may change prior to final publication. Citation information: DOI 10.1109/ACCESS.2023.3347341



Author et al.: Preparation of Papers for IEEE TRANSACTIONS and JOURNALS



CARLOS ANDRÉ DE MATTOS TEIXEIRA is a PhD candidate in Machine Learning at the Federal University of Pará (UFPA), Brazil. He earned his Bachelor's degree in Communications Engineering from the same institution, and spent a semester studying abroad at Kagawa University, Japan. He also holds a Master's degree in Machine Learning from UFPA. Mr. Teixeira's current research interests include the application of optimization techniques, computer vision, and machine and deep learning in the context of smart cities.

learning in the context of smart cities.



DIEGO LISBOA CARDOSO obtained a Bachelor's degree in Computer Science from the University of Amazônia (2002), a Master's degree (2005) and a PhD degree (2010) in Electrical Engineering from the Federal University of Pará and a post-doctoral fellowship at the Royal Institute of Technology of Sweden (KTH). He was Director of Technology at the State Department of Education of the Government of the State of Pará (2008-2009). He was the Rector of Undergraduate Education at the Federal University of South and South-East Pará (UNIFESSPA) (2014). He works as an Associate Professor at the Federal University of Pará in the School of Computer Engineering and Telecommunications and the Graduate Program in Electrical Engineering (PPGEE). He has experience in Computer Science and Computer Engineering, with an emphasis on Performance Evaluation. His work is mainly concerned with the following subject-areas: Digital TV, Access Technologies, Markovian performance and simulation models, applied computational intelligence and optimization techniques.

education at the Federal University of South and South-East Pará (UNIFESSPA) (2014). He works as an Associate Professor at the Federal University of Pará in the School of Computer Engineering and Telecommunications and the Graduate Program in Electrical Engineering (PPGEE). He has experience in Computer Science and Computer Engineering, with an emphasis on Performance Evaluation. His work is mainly concerned with the following subject-areas: Digital TV, Access Technologies, Markovian performance and simulation models, applied computational intelligence and optimization techniques.



RAFAEL FOGAROLLI VIEIRA Graduated in computer engineering, specialist in artificial intelligence applied to industry and master in electrical engineering with emphasis in applied computing from the Federal University of Pará (UFPA). Member of the Operational Research Laboratory (LPO) - UFPA. His research interests include evolutionary computing, machine learning, telecommunications networks, and computer networks. He is an Associate Member of the Brazilian Computing Society (SBC).

He is an Associate Member of the Brazilian Computing Society (SBC).

...



DANIEL DA SILVA SOUZA obtained a Bachelor's degree in Information Systems in 2016 and a Master's degree in Electrical Engineering with an emphasis on Applied Computing, from the Federal University of Pará (UFPA) in 2018, where he is currently pursuing a Doctoral degree. He is currently a member of the Operational Research Laboratory (LPO). His research areas are focused on Human-Computer Interaction, User Experience, Software Engineering, and Computer Networks. He is an Associate Member of the Brazilian Computer Society (SBC).

He is an Associate Member of the Brazilian Computer Society (SBC).



IGOR WENNER SILVA FALCÃO has a Bachelor's degree in Information Systems from the Federal University of Pará (UFPA-2018). Master's degree in Electrical Engineering from the Graduate Program in Electrical Engineering (PPGEE), Federal University of Pará (UFPA - 2020). Worked as a scientific initiation scholar by the Institutional Program of Scientific Initiation Scholarships (PIBIC) and as a monitor at the Federal University of Pará. Has experience in Computer Science, focusing on Communication Networks. His research interests are in Communication Networks, Computer Networks, Cloud Computing, and Human-Computer Interaction. Works at the Operational Research Laboratory (LPO).

Science, focusing on Communication Networks. His research interests are in Communication Networks, Computer Networks, Cloud Computing, and Human-Computer Interaction. Works at the Operational Research Laboratory (LPO).