



UNIVERSIDADE FEDERAL DO MARANHÃO
UNIVERSIDADE FEDERAL DO PIAUÍ
Doutorado em Ciência da Computação Associação
UFMA/UFPI

Thiago Nelson Faria dos Reis

**Sustentabilidade na Nuvem: Um Modelo de Eficiência
Energética em Ambientes de Computação Verde**

Orientador: Prof. Dr. Mário Antônio Meireles Teixeira
Co-orientador: Prof. Dr. Carlos de Salles Soares Neto

São Luís - MA
Outubro, 2024

Thiago Nelson Faria dos Reis

Sustentabilidade na Nuvem: Um Modelo de Eficiência Energética em Ambientes de Computação Verde

TESE DE DOUTORADO

Tese apresentada como requisito parcial
para obtenção do título de Doutor em Ciência
da Computação ao Doutorado em Ciência
da Computação, Associação UFMA/UFPI.

Orientador: Prof. Dr. Mário Antônio Meireles Teixeira
Co-orientador: Prof. Dr. Carlos de Salles Soares Neto

São Luís - MA
Outubro, 2024

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Diretoria Integrada de Bibliotecas/UFMA

Reis, Thiago Nelson Faria dos.

Sustentabilidade na Nuvem: Um Modelo de Eficiência Energética em Ambientes de Computação Verde / Thiago Nelson Faria dos Reis. - 2024.

127 p.

Coorientador(a) 1: Carlos de Salles Soares Neto.

Orientador(a): Mário Antônio Meireles Teixeira.

Tese (Doutorado) - Programa de Pós-graduação Doutorado em Ciência da Computação - Associação UFMA/UFPI, Universidade Federal do Maranhão, São Luís, 2024.

1. Emissão de Carbono. 2. Computação Verde. 3. Computação Em Nuvem. 4. Eficiência Energética. 5. Inteligência Artificial. I. Neto, Carlos de Salles Soares. II. Teixeira, Mário Antônio Meireles. III. Título.

Thiago Nelson Faria dos Reis

Sustentabilidade na Nuvem: Um Modelo de Eficiência Energética em Ambientes de Computação Verde

A presente Tese de Doutorado foi avaliada e aprovada por banca examinadora composta pelos seguintes membros:

Prof. Dr. Mário Antônio Meireles Teixeira

Orientador

Universidade Federal do Maranhão

Prof. Dr. Carlos de Salles Soares Neto

Co-orientador

Universidade Federal do Maranhão

Prof. Dr. Anselmo Cardoso de Paiva

Examinador Interno

Universidade Federal do Maranhão

Prof. Dr. Francisco Airton Pereira da Silva

Examinador Interno

Universidade Federal do Piauí

Profa. Dra. Kalinka Regina Lucas Jaquie Castelo Branco

Examinador Externo

Instituto de Ciências Matemáticas e de Computação - ICMC - USP

Prof. Dr. Carlos Renato Lisboa Francês

Examinador Externo

Universidade Federal do Pará

Certificamos que esta é a versão original e final da Tese de Doutorado que foi julgada adequada como requisito parcial para a obtenção do título de Doutor em Ciência da Computação.

Prof. Dr. Mário Antônio Meireles Teixeira

Orientador

Prof. Dr. Rodrigo de Melo Souza Veras

Coordenador

São Luís - MA, 25 de Outubro, de 2024

Este trabalho é dedicado a minha família

Agradecimentos

A Deus em primeiro lugar.

A minha família, em especial a meu pai, pelo constante estímulo à evolução e apoio e pela revisão segura e cuidadosa desta tese e aos meus irmãos e irmã pelos incentivos.

A minha esposa Apoená, pelo companheirismo, incentivo, paciência e dedicação; aos meus filhos Bianca e Guilherme pela compreensão quanto às horas dedicadas aos estudos; a Sofia, minha filha mais nova, cuja expectativa de chegada trouxe ainda mais alegria a este momento de conclusão acadêmica; e a Rosângela pelo apoio.

A todos que acreditaram no meu potencial e sempre estiveram dispostos a me ajudar em tudo que fosse necessário.

Ao professor Mário Meireles Teixeira, meu sempre orientador, ao professor Carlos Salles, meu co-orientador e ao professor Anselmo Paiva, pela paciência, dedicação e conhecimentos compartilhados.

Aos demais professores do Doutorado, pelos ensinamentos e orientações que me proporcionaram e por terem me mostrado o que existe fora da caverna.

Aos meus colegas da UFMA e UFPI.

Aos professores membros da banca examinadora.

Aos meus amigos Nazareth Mendes, Antônio Palmeira, Dadilton Melo e Aline Lopes, pelo apoio fundamental que me permitiu a dedicação aos estudos.

Por fim, agradeço a todos que direta ou indiretamente contribuíram para a realização deste trabalho.

“... Para os acorrentados, as sombras eram cópias de objetos reais e os ecos eram emitidos pelas sombras. Sombras nas paredes e ecos pela caverna eram a única realidade verdadeira para aqueles homens ali presentes. Porém, um dos homens consegue se libertar das correntes. Quando ele vai em direção à entrada da caverna, sente inúmeras dificuldades devido a sua não adaptação à luz e aos sons fora da caverna. Após a acomodação fora da caverna e estranhamento, pois até então, tudo aquilo era impossível e irreal, ele compreende o tamanho de sua ignorância. E logo, depois de várias reflexões, percebe que a realidade verdadeira está fora da caverna e é muito mais bela. ... ”

Platão

Resumo

Esta tese explora a crescente relevância da computação em nuvem no cotidiano e no contexto empresarial, destacando a importância de abordagens proativas para mitigar seu impacto ambiental. A computação em nuvem verde constitui iniciativa importante para reduzir o consumo de energia e as emissões de CO₂ associadas à nuvem, sem comprometer sua funcionalidade e desempenho. O foco deste trabalho é avaliar a eficácia de algoritmos de escalonamento de recursos em data centers de computação em nuvem e desenvolver metodologia inovadora para calcular scores de eficiência energética e classificar o desempenho energético. Utiliza o ambiente de simulação CloudSim Plus, quatro algoritmos – Round Robin (RR), Dynamic Voltage and Frequency Scaling (DVFS), Particle Swarm Optimization (PSO) e Ant Colony System (ACS) – e os compara através de 800 simulações. Além das simulações, a metodologia envolveu a análise dos dados através de técnicas estatísticas rigorosas, incluindo o uso da tabela T-Student, e a criação de índice de desempenho energético derivado dos resultados obtidos. A pesquisa também incorporou inteligência artificial, especificamente classificadores baseados em redes neurais, para aprimorar a classificação dos níveis energéticos. Os resultados indicaram redução significativa no consumo de energia e emissões de CO₂ – aproximadamente 55% – e melhoria na eficiência do custo de alocação de máquinas virtuais em torno de 28%. O estudo demonstrou que a adoção de estratégias de escalonamento inovadoras e a implementação de modelo quantitativo de avaliação energética podem otimizar significativamente a eficiência da computação em nuvem. Além disso, propôs um novo cálculo de scores e a criação de escala de nível energético que oferecem ferramentas valiosas para a otimização e sustentabilidade em data centers.

Palavras-chave: Emissão de carbono; Computação Verde; Computação em Nuvem; Eficiência Energética; Inteligência Artificial.

Abstract

This thesis explores the growing relevance of cloud computing in everyday life and the business context, emphasizing the importance of proactive approaches to mitigate its environmental impact. Green cloud computing is an initiative aimed at reducing energy consumption and CO₂ emissions associated with cloud, without compromising its functionality and performance. The main focus of this work is to evaluate the effectiveness of resource scheduling algorithms in cloud computing data centers and to develop an innovative methodology for calculating energy efficiency scores and classifying energy performance. Using the CloudSim Plus simulation environment, four algorithms - Round Robin (RR), Dynamic Voltage and Frequency Scaling (DVFS), Particle Swarm Optimization (PSO), and Ant Colony System (ACS) - have been compared through 800 simulations. In addition to the simulations, the methodology involved analyzing the data through rigorous statistical techniques, including the use of the T-student table, and creating an energy performance index derived from the results obtained. The research also incorporated artificial intelligence, specifically neural network-based classifiers, to improve the classification of energy levels. The results indicated a significant reduction in energy consumption and CO₂ emissions, approximately 55%, and an improvement in the cost-effectiveness of virtual machine allocation, around 28%. This study demonstrates that the adoption of innovative scheduling strategies and the implementation of a quantitative energy evaluation model can significantly optimize cloud computing efficiency. Additionally, the proposal of a new score calculation and the creation of an energy performance scale offer valuable tools for optimization and sustainability in data centers.

Keywords: Carbon Emission; Green Computing; Cloud Computing; Energy Efficiency; Artificial Intelligence.

Lista de ilustrações

Figura 1 – Modelos de Serviços em Nuvem.	27
Figura 2 – Modelos de Arquitetura em Nuvem	29
Figura 3 – Algoritmos de Autoescalamento	31
Figura 4 – Modelo de Eficiência Energética	66
Figura 5 – Definição da Infraestrutura do Experimento	79
Figura 6 – Consumo Energético	85
Figura 7 – Consumo de Energia por Cloudlet	86
Figura 8 – Custo de Alocação	88
Figura 9 – Emissão de CO _{2eq} para os Modelos	89
Figura 10 – Modelo de Predição do Nível Energético	104

Lista de tabelas

Tabela 1 – Comparativo entre trabalhos relacionados ao tema	60
Tabela 2 – Estatística de validação do tempo de execução (s)	81
Tabela 3 – Estatística de validação da emissão de CO _{2eq}	82
Tabela 4 – Resultados do tempo de execução (s)	84
Tabela 5 – Relação do tempo de execução	84
Tabela 6 – Consumo energético das simulações (w)	85
Tabela 7 – Consumo de energia por cloudlet (w)	86
Tabela 8 – Custo dos ambientes em simulação (US\$)	87
Tabela 9 – Cálculo de emissão CO _{2eq}	89
Tabela 10 – Resultados dos scores com pesos iguais	96
Tabela 11 – Resultados dos scores com pesos diferentes	97
Tabela 12 – Classificação dos scores por nível	100
Tabela 13 – Resumo dos scores com pesos diferentes	100
Tabela 14 – Escala de Nível Energético – Data Center Hipotético	102

Lista de abreviaturas e siglas

ACS	Sistema de Colônia de Formigas
AWS	<i>Amazon Web Service</i>
CO ₂	Gás Carbônico
CO ₂ eq	Gás Carbônico Equivalente
CPUs	Processadores
CUE	<i>Carbon Usage Effectiveness</i>
DCeP	<i>Data Center Energy Productivity</i>
DCiE	<i>Data Center Infrastructure Efficiency</i>
DCP	<i>Data Center Productivity</i>
DENS	<i>Data Center Energy-efficient Network-aware Scheduling</i>
DPSO	<i>Dissipative Particle Swarm Optimization</i>
DVFS	<i>Dynamic Voltage and Frequency Scaling</i>
GEC	<i>Green Energy Coefficient</i>
IaaS	Infraestrutura como Serviço
iSPD	<i>Iconic Simulator of Parallel and Distributed Systems</i>
RAM	Memória <i>Random Access Memory</i>
PaaS	Plataforma como Serviço
PM - cloudsim	<i>Physical Machine in Cloudsim</i>
PSO	Otimização por Enxame de Partículas
PUE	<i>Power Usage Effectiveness</i>
RR	<i>Round Robin</i>
SaaS	Software como Serviço
SANs	<i>Storage Area Networks</i>

SLA	Indicador de Qualidade de Serviço
TDP	<i>Thermal Design Power</i>
TI	Tecnologia da Informação
VM	Máquina Virtual
VMs	Máquinas Virtuais

Sumário

1	INTRODUÇÃO	16
1.1	Contextualização	16
1.2	Motivação	17
1.3	Hipótese	18
1.4	Objetivos	19
1.4.1	Objetivo Geral	19
1.4.2	Objetivos Específicos	19
1.5	Metodologia	19
1.6	Estrutura da Tese	21
2	FUNDAMENTAÇÃO TEÓRICA	23
2.1	Conceitos sobre Energia	24
2.1.1	Terminologias do Setor Elétrico	24
2.1.2	Importância da Gestão da Demanda e do Consumo	25
2.2	Computação em Nuvem	26
2.2.1	Serviços em Nuvem	26
2.2.2	Arquitetura em Nuvem	28
2.2.3	Características da Computação em Nuvem	29
2.2.4	Escalabilidade e Elasticidade	30
2.3	Computação em Nuvem Verde	31
2.3.1	Sustentabilidade em Computação em Nuvem	32
2.3.2	Eficiência Energética	33
2.3.3	Princípios de Sustentabilidade Aplicados a TI	34
2.3.4	Uso Sustentável de Recursos	35
2.3.5	Categorias e Áreas da Computação em Nuvem Verde	36
2.3.6	Metodologias, Tecnologias e Inovações	37
2.3.6.1	Metodologias	37
2.3.6.2	Métricas Computacionais	38
2.3.6.3	Design Sustentável de Data Centers	40
2.3.6.4	Técnicas Eficientes de Refrigeração	41
2.3.6.5	Uso de Energias Renováveis	43
2.3.7	Benefícios da Computação em Nuvem Verde	45
2.4	Ambiente de Simulação CloudSim Plus	46
2.4.1	Execução do CloudSim Plus	48
2.5	Redes Neurais Recorrentes (RNNs)	50

2.6	Algoritmos Bioinspirados	52
2.7	Considerações Finais	55
3	TRABALHOS RELACIONADOS	57
3.1	O Estado da Arte	57
3.2	Comparativo entre Trabalhos Relacionados ao Tema	60
3.3	Considerações Finais	64
4	METODOLOGIA	65
4.1	Metodologia Adotada	66
4.1.1	Modelo de Eficiência Energética	66
4.2	Processo de Coleta de Dados	67
4.3	Análise dos Resultados	68
4.3.1	Estratégia de Análise	68
4.3.2	Interpretação dos Dados	69
4.3.3	Impacto Ambiental e Operacional	69
4.3.4	Metodologia de Análise	69
4.3.5	Indicadores Avaliados	69
4.4	Scores de Eficiência Energética	70
4.4.1	Inicialização dos Dicionários e Métricas	70
4.4.2	Normalização dos Dados	70
4.4.3	Definição da Baseline	70
4.4.4	Cálculo dos Scores	71
4.4.5	Classificação dos Algoritmos	71
4.5	Modelo de Nível Energético	71
4.5.1	Critérios de Classificação	71
4.5.2	Escala Vertical	71
4.5.3	Escala Horizontal	72
4.5.4	Classificadores de Inteligência Artificial	72
4.5.5	Utilização de Redes Neurais	72
4.6	Considerações Finais	73
5	RESULTADOS E DISCUSSÃO	75
5.1	Ambiente de Simulação do Consumo Energético	75
5.1.1	Algoritmos de Escalonamento de Recursos	75
5.1.2	Escolha dos Algoritmos	76
5.1.3	Definição da Infraestrutura	78
5.2	Validação Funcional	80
5.2.1	Aplicação da Validação Funcional	81
5.3	Análise dos Resultados	83

5.3.1	Cenário 1: Tempo de Execução das Aplicações	84
5.3.2	Cenário 2: Consumo de Energia das Aplicações	85
5.3.3	Cenário 3: Custo de Execução das Aplicações	87
5.3.4	Cenário 4: Emissão de CO ₂	88
5.3.5	Considerações Adicionais	89
5.4	Considerações Finais	90
6	CONTRIBUIÇÕES DA PESQUISA E EXPANSÃO DO ESCOPO . .	92
6.1	Cálculo dos Scores	92
6.1.1	Definição dos Pesos	93
6.1.2	Algoritmo de Cálculo dos Scores	94
6.1.3	Resultados dos Scores	96
6.2	Escala de Nível Energético	97
6.3	Predição dos Scores e do Nível Energético	103
6.4	Quantização como Proposta para Eficiência Energética	106
6.5	Considerações Finais	107
7	CONCLUSÃO	109
7.1	Conclusões da Tese	109
7.2	Principais Resultados e Contribuições	110
7.3	Trabalhos Futuros	116
	REFERÊNCIAS	117

1 Introdução

Este capítulo aborda o escopo da tese, partindo de sua contextualização e justificativa da pesquisa, direcionada à eficiência energética aplicada a data centers através da otimização de recursos utilizando algoritmos de escalonamento em ambientes de computação em nuvem. Trata do cenário atual e dos desafios energéticos enfrentados por infraestruturas computacionais, delineando os problemas que motivaram o estudo e as abordagens adotadas para mitigá-los.

São explorados os conceitos fundamentais que sustentam a pesquisa, bem como os motivos que justificam a adoção de técnicas de escalonamento inteligentes, visando tanto à economia de energia quanto à sustentabilidade ambiental, através da computação em nuvem verde.

A hipótese da pesquisa e seus objetivos são apresentados a seguir, sendo feita ainda uma abordagem inicial da metodologia adotada, esta objeto de capítulo específico, além de explorar a estrutura da tese.

1.1 Contextualização

A migração para a computação em nuvem traz consigo uma série de vantagens que abrangem diversas áreas, incluindo a computacional. Entre esses benefícios, destaca-se a redução do gasto das empresas com energia e refrigeração.

No entanto, é importante observar que essa redução não deve ser considerada como uma forma de comprometimento com o meio ambiente, uma vez que na realidade os custos e impactos estão apenas sendo transferidos. Aqueles que utilizam serviços de computação em nuvem também possuem responsabilidade compartilhada, direta ou indiretamente, quanto ao impacto ambiental.

Em sua pesquisa, (LIU et al., 2020) afirmam que cerca de 4,5% do consumo global de energia até 2025 é atribuído aos data centers. Isso os torna os principais consumidores de energia em todo o mundo e também responsáveis pelo impacto ambiental gerado pela produção dessa energia, tanto direta quanto indiretamente. Adicionalmente, (MASDARI; ZANGAKANI, 2020) apontam que metade da energia utilizada em um data center é empregada na dissipação térmica, isto é, em sistemas de refrigeração.

É fundamental reconhecer que é responsabilidade de todos manter um ecossistema computacional eficiente e ambientalmente responsável. No debate com relação à computação convencional e à computação verde, é importante entender suas diferenças

fundamentais. A computação verde objetiva reduzir o consumo de energia, incentivar o uso de fontes renováveis de energia e otimizar a eficiência na utilização dos recursos disponíveis.

Para alcançar esses objetivos, é fundamental explorar a interseção entre a ciência da computação e a sustentabilidade ambiental, evidenciando como a computação em nuvem verde pode contribuir significativamente para a redução do impacto ambiental dos data centers. Ao investigar estratégias de eficiência energética, esta pesquisa adota uma abordagem interdisciplinar, que abrange princípios de engenharia de software, otimização de algoritmos, gestão de energia e estudos ambientais. A integração desses conhecimentos permite compreender como as escolhas tecnológicas afetam diretamente os padrões de consumo energético, fornecendo soluções inovadoras que beneficiam tanto a computação quanto a sustentabilidade.

A interdisciplinaridade é essencial no contexto da gestão de data centers, considerando que aborda questões de eficiência energética, modelos de gerenciamento de recursos e métricas de avaliação de desempenho. A análise combina princípios de engenharia elétrica, computação e economia, tendo em vista desenvolver uma metodologia que propicie ganhos significativos na redução de custos operacionais e no impacto ambiental (GADE, 2018).

1.2 Motivação

Neste trabalho, o interesse é explorar e avaliar metodologias e algoritmos de escalonamento de tarefas para a nuvem, de modo a otimizar e reduzir o consumo da energia necessária para a execução dessas tarefas. Os algoritmos de escalonamento dependem de um considerável número de fatores. Dentre estes, pode-se citar: minimizar o tempo de resposta, maximizar o número de requisições atendidas e minimizar o descarte de requisições, entre outros (PARDO, 2016). Sendo assim, tem-se como principal objetivo dos escalonadores de tarefas a redução do consumo energético.

O ambiente computacional é por sua natureza complexo, onde os fatores supracitados constituem parte dos desafios existentes na concepção do projeto e na implementação da computação verde, dado que medir a sua eficiência energética se torna também uma tarefa complexa (SAHA, 2018). Desta forma, torna-se efetivamente relevante fornecer um modelo que torne essa etapa mais simples e que permita acompanhar a evolução da eficiência energética do data center através de um método objetivo, excluindo critérios subjetivos.

Por outro lado, a abordagem da computação verde vai além do consumo de energia, envolvendo também a gestão eficiente dos recursos hídricos, o uso de fontes renováveis e a minimização do desperdício computacional, através da utilização apenas

dos recursos necessários.

Além das questões operacionais citadas acima, tem-se também as questões gerenciais, no que diz respeito ao acompanhamento da evolução da eficiência energética, bem como à tomada de decisão acerca de quais intervenções são mais eficientes e/ou possuem o custo benefício melhor. Sendo assim, possuir uma escala energética se faz necessário bem como pontuar ou classificar numericamente os algoritmos analisados, de forma a ficar claro em qual estado de eficiência energética o data center se encontra, além de identificar os próximos níveis possíveis.

Esta tese de doutorado posiciona-se nestas lacunas, entre a execução, através da proposta de novos métodos de escalonamento de tarefas, e a gerencial, por meio das propostas do cálculo de scores e do nível de eficiência energética. Com isso, será possível mensurar de forma eficaz e exata o "status quo" e as possibilidades de evolução energética.

1.3 Hipótese

Esta tese tem por hipótese: é possível melhorar o desempenho dos data centers, ao mesmo tempo em que se reduz o consumo energético e o impacto ambiental, especificamente em termos de emissão de $\text{CO}_{2\text{eq}}$, através de uma alocação de recursos mais eficiente utilizando princípios da computação em nuvem verde?

A proposição desta hipótese considerando a existência de várias metodologias, frameworks e técnicas de alocação de recursos relacionados à computação em nuvem verde, poderá contribuir para a redução energética sem prejudicar os indicadores de qualidade de serviço (SLA) ou, dependendo da situação, inclusive permitirá melhorar o desempenho esperado na execução das requisições, minimizando, desta forma, o tempo, o custo e o impacto ambiental para a execução dos serviços. Considera-se, neste trabalho, a utilização de simuladores de computação em nuvem, em especial, quanto à computação em nuvem verde, uma vez que se torna inviável a avaliação em ambiente real.

Entre os ganhos esperados com a confirmação desta hipótese estão duas proposições. A primeira consiste no cálculo de um índice de desempenho baseado nos resultados das simulações dos algoritmos, permitindo a comparação e avaliação da eficiência entre eles.

Já a segunda proposição envolve o desenvolvimento de uma escala de eficiência energética utilizando os índices calculados combinada com técnicas de inteligência artificial, para classificar e prever o desempenho energético dos algoritmos em diferentes cenários de computação em nuvem verde.

1.4 Objetivos

1.4.1 Objetivo Geral

O objetivo central deste trabalho é desenvolver um modelo inovador que otimize a eficiência energética de data centers em ambientes de computação em nuvem, combinando algoritmos avançados de escalonamento e inteligência artificial, de modo que permita reduzir o impacto ambiental e melhorar a alocação de recursos de forma sustentável.

1.4.2 Objetivos Específicos

- Caracterizar e simular ambiente computacional em nuvem verde.
- Avaliar abordagens e algoritmos de eficiência energética.
- Construir base de dados da análise detalhada dos resultados das simulações.
- Desenvolver sistemática que indique a abordagem mais eficiente por meio de sistema de pontuação.
- Criar modelo de classificação energética para data centers em nuvem.
- Desenvolver modelo de predição de nível energético.

1.5 Metodologia

A fim de atingir os objetivos específicos definidos e comprovar a hipótese desta tese, é indispensável seguir uma série de etapas metodológicas. Essas etapas compreendem, primordialmente, a realização de comparações em ambiente controlado. Para garantir a validade e a reprodutibilidade dos resultados, as comparações serão efetuadas sob condições padronizadas, em ambiente de nuvem simulado. Esta abordagem é necessária devido à variedade de modelos de nuvem existentes e ao impacto significativo que o desempenho e o custo final das tarefas têm sobre a eficiência na utilização da infraestrutura de data centers.

A simulação de ambientes de computação em nuvem constitui desafio notável, dados a complexidade intrínseca desses ambientes, o volume substancial de dados envolvidos e o extenso tempo de processamento requerido para gerar parâmetros realísticos. Com base nas recomendações e análises realizadas por ([BARBIERATO et al., 2019](#); [FILHO et al., 2017](#); [JUNIOR; BRUSCHI, 2020a](#)), este estudo adotará o CloudSim Plus como ferramenta de simulação.

O CloudSim Plus é um ambiente de simulação baseado em Java que oferece recursos para modelagem e simulação de diversos serviços de computação em nuvem, desde a infraestrutura como serviço (IaaS) até software como serviço (SaaS). Este ambiente possibilita a implementação e avaliação de cenários de simulação variados, facilitando a experimentação, avaliação e validação de algoritmos com diferentes objetivos.

Para alcançar os resultados experimentais almejados, o método adotado nesta pesquisa leva em consideração estudos correlatos no campo da computação em nuvem verde. Além disso, será utilizada abordagem que envolve a implementação de cenários de simulação de computação em nuvem. A abordagem mencionada é fundamental para o desenvolvimento de uma arquitetura de computação em nuvem que integre de forma eficaz todos os elementos estabelecidos nos objetivos deste trabalho.

Os algoritmos de escalonamento desempenham papel fundamental na eficiência da computação em nuvem, permitindo a alocação dinâmica e personalizada de recursos para atender às necessidades de cada aplicação. Para realizar simulações, será explorada a eficácia de quatro algoritmos: Round Robin (RR), Dynamic Voltage and Frequency Scaling (DVFS), Particle Swarm Optimization (PSO) e Ant Colony System (ACS). Cada algoritmo tem sua abordagem própria para a gestão dos recursos em data centers, seja por meio da distribuição equitativa (RR), ajuste da voltagem e frequência (DVFS), otimização inspirada no comportamento dos enxames (PSO) ou no comportamento das colônias de formigas (ACS).

Dentre os algoritmos estudados, o RR já está presente na ferramenta de simulação e os DVFS e PSO foram incorporados a partir de trabalhos relacionados constantes na literatura acadêmica. A implementação do Ant Colony System (ACS) no CloudSim Plus destacou-se não apenas por oferecer um modelo inovador de escalonamento de recursos, mas também como uma contribuição importante desta tese, visto que este modelo ainda não havia sido explorado em outros trabalhos nem implementado em simuladores como modelo de escalonamento para a computação em nuvem verde.

As etapas metodológicas seguidas no desenvolvimento deste trabalho, foram pela ordem:

1. Estudo de trabalhos que apresentam arquiteturas de computação em nuvem verde, métricas, metodologias, técnicas ou algoritmos de escalonamento para ambientes em nuvem.
2. Análise permitindo identificar e selecionar os elementos básicos a serem utilizados.
3. Estudo e implementação de diferentes modelos de escalonamento de operação nos simuladores.

4. Elaboração de projeto e execução de experimentos, objetivando possibilitar a obtenção de resultados cujas informações foram usadas para comprovar a importância da nova arquitetura nos cenários de computação em nuvem verde e a eficiência da mesma em manter os níveis de SLA.
5. Caracterização de modelo de cálculo de scores e de nível energético com base nos resultados obtidos nas simulações.

1.6 Estrutura da Tese

Esta tese tem sua estrutura distribuída em sete capítulos. Seguindo-se à Introdução, o Capítulo 2 apresenta a fundamentação teórica necessária relativa à computação em nuvem. Nele estão descritos os conceitos associados, definições, características, modelos e seus componentes.

Ainda no capítulo 2, na seção 2.3 é apresentada a fundamentação teórica sobre computação em nuvem verde, incluídos os conceitos de eficiência energética, sustentabilidade em TI, bem como as métricas mais utilizadas relacionadas à eficiência energética que permitem avaliar a eficiência de um data center, bem como as principais abordagens, metodologias, técnicas e frameworks utilizados na redução do consumo de energia e na garantia da qualidade da prestação dos serviços.

No capítulo 3 são apresentados os trabalhos recentes relacionados ao tema da tese.

O capítulo 4 discorre sobre a metodologia e arquitetura utilizadas na execução dos experimentos e provê o detalhamento de sua implementação, apresentando ainda os modelos propostos.

O capítulo 5 trata dos resultados e discussão, contendo a avaliação de desempenho realizada para validar o funcionamento da arquitetura em diferentes cenários. Também são feitas considerações a respeito da análise realizada após a obtenção dos resultados experimentais.

Após análise e discussão sobre as etapas das simulações, as propostas são detalhadas no Capítulo 6. A primeira consiste no cálculo de um índice de desempenho baseado nos resultados das simulações dos algoritmos, permitindo a comparação e avaliação da eficiência entre eles. Já a segunda proposta envolve o desenvolvimento de uma escala de eficiência energética utilizando os índices calculados, combinada com técnicas de inteligência artificial para classificar e prever o desempenho energético dos algoritmos em diferentes cenários de computação em nuvem verde.

Além das duas propostas mencionadas, são apresentadas a expansão do escopo e as contribuições da pesquisa, destacando o sistema preditivo do cálculo de scores e do

índice de eficiência energética baseado em Redes Neurais Recorrentes, fornecendo uma ferramenta objetiva para avaliar e comparar diferentes configurações e algoritmos de escalonamento em ambientes de data centers. Além disso, introduz a quantização como metodologia inovadora e eficaz para a computação em nuvem verde, visando à redução do consumo energético em data centers. Essa técnica permite a otimização dos recursos computacionais ao converter dados e operações em formatos mais compactos, resultando em menor consumo de energia e emissão de CO₂, alinhando-se aos princípios da sustentabilidade e eficiência energética

No capítulo 7 destacam-se os resultados alcançados e as contribuições significativas para a área de eficiência energética em data centers de computação em nuvem. Esses resultados reforçam a importância da pesquisa contínua e do desenvolvimento de tecnologias que promovam a eficiência energética e a sustentabilidade em ambientes de computação em nuvem verde, tendo em vista a continuidade da linha de pesquisa.

2 Fundamentação Teórica

Este capítulo trata dos conceitos explorados para o desenvolvimento do estudo, o que é importante para compreensão das técnicas e ferramentas utilizadas para alcançar os objetivos propostos.

O capítulo dedica-se a construir a base teórica necessária para compreender os conceitos-chave e as abordagens metodológicas aplicadas neste estudo relativas à computação em nuvem verde. A ênfase é colocada na exploração dos aspectos multifacetados da computação em nuvem, com especial atenção às práticas sustentáveis e ao impacto ambiental.

A investigação começa com uma exploração abrangente dos conceitos sobre energia e o setor elétrico (Seção 2.1), e prossegue para a computação em nuvem (Seção 2.2), traçando suas origens, evolução e as várias modalidades e serviços abrangidos. Esta seção busca contextualizar a computação em nuvem no quadro tecnológico atual e destaca seu papel crescente em diversos setores. A discussão se estende para os desafios e oportunidades que a computação em nuvem enfrenta, particularmente em relação à sustentabilidade e à eficiência energética.

Em seguida, o foco se desloca para a esfera da sustentabilidade na computação em nuvem (Seção 2.3), tema de importância crescente tanto para a comunidade científica quanto para a indústria de TI. Serão examinados os impactos ambientais dos data centers, as questões da eficiência energética e estratégias para reduzir a emissão de carbono associada ao armazenamento e processamento de dados em larga escala.

Em continuação, são discutidas as metodologias e técnicas que estão na vanguarda da pesquisa em computação em nuvem verde (Seção 2.3.6). Esta seção se volta para abordagens inovadoras, como a otimização do uso de recursos, o uso de fontes de energia renováveis e o desenvolvimento de algoritmos eficientes para o escalonamento de máquinas virtuais. A ideia é investigar como estas técnicas podem contribuir para a construção de data centers mais sustentáveis e eficientes em termos energéticos.

Além disso, o capítulo também aborda as métricas de sustentabilidade em data centers (Seção 2.3.6.2), explorando como a eficiência energética pode ser mensurada e otimizada. Essa discussão é fundamental para entender os desafios empíricos de implementar práticas sustentáveis em ambientes de computação em nuvem e avaliar o sucesso das estratégias adotadas.

2.1 Conceitos sobre Energia

A compreensão de conceitos fundamentais sobre energia é essencial para a gestão eficaz do uso de energia em data centers. Dois conceitos chave são o consumo e a demanda de energia elétrica, de acordo com ([Agência Nacional de Energia Elétrica \(ANEEL\), 2021](#); [Agência Nacional de Energia Elétrica \(ANEEL\), 2022c](#)).

O consumo de energia refere-se à quantidade total de energia utilizada ao longo de determinado período, geralmente medido em quilowatt-hora (kWh) ou megawatt-hora (MWh). O consumo é resultado da energia efetivamente utilizada pelos dispositivos e equipamentos, sendo proporcional ao tempo e à potência dos mesmos.

Por outro lado, a demanda de energia refere-se à potência máxima requerida em um dado momento, também medida em quilowatts (kW) ou megawatts (MW). É a potência máxima necessária para operar todos os equipamentos e dispositivos ao mesmo tempo, sendo considerada para dimensionar a infraestrutura necessária para atender às necessidades de energia, pois representa o pico de consumo que deve ser suportado.

2.1.1 Terminologias do Setor Elétrico

A gestão eficiente do consumo e da demanda de energia é essencial para a sustentabilidade e a operação econômica de grandes consumidores de energia, como os data centers. A correta compreensão e gestão dos parâmetros do setor não apenas podem evitar penalizações e custos adicionais, mas também otimizam o uso de recursos, promovendo uma operação mais sustentável e economicamente viável. Sendo assim, são apresentados a seguir alguns termos do setor elétrico relacionados a esta tese, conforme ([Agência Nacional de Energia Elétrica \(ANEEL\), 2021](#); [Agência Nacional de Energia Elétrica \(ANEEL\), 2022a](#); [Agência Nacional de Energia Elétrica \(ANEEL\), 2022b](#)):

- **Potência Ativa (kW):** É a quantidade de energia efetivamente convertida em trabalho. É medida em quilowatts (kW) e representa a energia consumida para realizar trabalho útil, como acionar motores ou iluminar lâmpadas.
- **Potência Reativa (kVAr):** É a energia que oscila entre a fonte e a carga sem ser convertida em trabalho útil. É necessária para a criação de campos magnéticos em motores e transformadores e é medida em quilovolt-ampere reativo (kVAr).
- **Potência Aparente (kVA):** É a combinação da potência ativa e reativa e representa a capacidade total necessária para suprir a carga. É medida em quilovolt-ampere (kVA) e é importante para o dimensionamento de equipamentos e sistemas elétricos.

- **Demanda Máxima:** Refere-se ao pico de consumo de energia registrado em um determinado período. Este valor é crítico para dimensionar a infraestrutura elétrica e evitar sobrecargas no sistema.
- **Energia Ativa (kWh):** É a energia consumida ao longo do tempo, medida em quilowatt-hora (kWh). Representa o consumo total de energia elétrica em um período dado.

2.1.2 Importância da Gestão da Demanda e do Consumo

A gestão eficiente do consumo e da demanda de energia é essencial para minimizar custos operacionais e prevenir penalizações ligadas à ultrapassagem da demanda contratada. Organizações que controlam efetivamente esses indicadores não só conseguem diminuir despesas, como também aumentam sua eficiência energética e contribuem para a sustentabilidade ambiental.

Ainda segundo ([Agência Nacional de Energia Elétrica \(ANEEL\), 2021](#); [Agência Nacional de Energia Elétrica \(ANEEL\), 2022a](#); [Agência Nacional de Energia Elétrica \(ANEEL\), 2022b](#); [Agência Nacional de Energia Elétrica \(ANEEL\), 2022c](#)), diversas estratégias de eficiência energética são recomendadas para garantir uma gestão eficaz da demanda e do consumo de energia. A seguir, são apresentadas algumas destas estratégias que se relacionam diretamente às contribuições desta pesquisa, representando soluções alinhadas com as recomendações do setor elétrico:

- **Tecnologias de Medição e Monitoramento:** utilizar medidores inteligentes e sistemas de monitoramento contínuo para identificar padrões de consumo e oportunidades de economia de energia.
- **Sistemas de Energia Renovável:** integrar fontes de energia renovável, como solar e eólica, para reduzir a dependência de fontes não-renováveis e diminuir a emissão de carbono.
- **Programas de Eficiência Energética:** participar de programas de eficiência energética oferecidos por governos ou distribuidoras, que podem incluir incentivos financeiros para a adoção de práticas e tecnologias eficientes.
- **Sustentabilidade e Impacto Ambiental:** além de reduzir custos, a eficiência energética contribui para a sustentabilidade ambiental, reduzindo as emissões de gases de efeito estufa e preservando recursos naturais.

2.2 Computação em Nuvem

A definição de computação em nuvem segundo (MELL; GRANCE, 2011; HERBST; KOUNEV; REUSSNER, 2013) é "um modelo para permitir acesso à rede de modo onipresente, conveniente e sob demanda a um conjunto compartilhado de recursos de computação configuráveis (redes, servidores, armazenagem, aplicativos e serviços) que possam ser rapidamente provisionados e liberados com o mínimo de esforço de gerenciamento ou interação do prestador de serviços."

Ademais (PARIKH, 2013) observa que "computação em nuvem é um tipo de sistema distribuído e paralelo que consiste na interconexão de computadores virtualizados que são dinamicamente provisionados e apresentados como um ou mais recursos computacionais unificados baseados em acordos de nível de serviço, estabelecidos através de negociação entre o provedor de serviços e consumidores."

2.2.1 Serviços em Nuvem

Segundo (LORIDO-BOTRAN; MIGUEL-ALONSO; LOZANO, 2014; KUPFERMAN JEFF SILVERMAN, 2016; PARIKH, 2013; REIS et al., 2018), existem quatro modelos básicos de serviços que podem ser oferecidos quando se trata de computação em nuvem, detalhados abaixo e representados na Figura 1:

- **SaaS (*Software as a Service*):** *software* como serviço é provavelmente o mais comum e popular entre as empresas e usuários. No SaaS, o software é utilizado diretamente na nuvem e se torna, assim, livre do pagamento de licenças por sua utilização.
- **PaaS (*Platform as a Service*):** o objetivo das Plataformas como Serviço, PaaS, é o de disponibilizar ambiente de desenvolvimento em nuvem com ferramentas e bibliotecas.
- **IaaS (*Infrastructure as a Service*):** na Infraestrutura como Serviço é colocado à disposição do usuário um conjunto de recursos de hardware, como CPUs, memória RAM, roteadores, racks, *firewall*, os quais podem e devem ser configurados livremente pelo usuário contratante.
- **FaaS (*Function as a Service*):** este é um subconjunto do PaaS, que permite aos desenvolvedores executar código em resposta a eventos específicos sem se preocupar com a infraestrutura completa que executa o programa. Em vez de gerenciar um servidor ou uma instância de aplicativo, os desenvolvedores utilizam funções individuais que são executadas em containers efêmeros.

- **DBaaS (Database as a Service)**: é um serviço que oferece suporte ao armazenamento e gerenciamento de bancos de dados na nuvem. Isso elimina a necessidade de hardware físico e tarefas de gerenciamento de banco de dados, permitindo que as empresas se concentrem na utilização dos dados.
- **CaaS (Containers as a Service)**: este modelo é voltado para a entrega de containers como um serviço, a exemplo do Docker. Permite que os desenvolvedores gerenciem containers, orquestram e escalem aplicativos e mais.
- **MLaaS (Machine Learning as a Service)**: permite que as empresas usem soluções de aprendizado de máquina sem necessidade de criar modelos partindo do zero. Os usuários podem se concentrar na inserção e análise de dados enquanto o provedor gerencia a infraestrutura subjacente e as ferramentas de aprendizado de máquina.
- **STaaS (Storage as a Service)**: refere-se a soluções de armazenamento baseadas na nuvem, oferecidas como um serviço. Isso pode incluir armazenamento de objetos ou soluções de armazenamento em bloco.




Figura 1 – Modelos de Serviços em Nuvem.

Fonte: (SEGURANCA, 2016)

Por outro lado, ao avaliar qual modelo de serviço é mais adequado, é vital considerar os seguintes pontos:

Nível de controle desejado: enquanto o IaaS dá mais controle sobre a infraestrutura, SaaS e FaaS são mais abstratos e permitem gerenciamento.

Especialização da aplicação: caso seja necessária solução especializada, como MLaaS ou DBaaS, pode ser mais eficaz escolher um serviço dedicado, uma vez que os serviços estão prontos para serem usados.

Custo: o modelo de precificação varia significativamente entre os diferentes modelos de serviço. Ou seja, enquanto o IaaS pode cobrar com base em horas de máquina virtual, o FaaS geralmente cobra com base no número de execuções de função.

2.2.2 Arquitetura em Nuvem

No contexto da Arquitetura em Nuvem, normalmente são aceitos quatro modelos, segundo (CUNHA et al., 2017; PARIKH, 2013), detalhados a seguir e representados na Figura 2:

- **Nuvem privada:** a ideia de nuvem privada é de que a infraestrutura esteja, se não na totalidade, na maior parte dentro de uma estrutura privada e que funcione somente para uma única organização. Alguns dos softwares utilizados para implementar essa arquitetura são o HPE Eucalyptus e o Openstack.
- **Nuvem pública:** a nuvem pública é o exemplo mais clássico de nuvem, principalmente pelo fato de os serviços serem entregues através da internet. Sua principal característica é o compartilhamento de recursos na internet. Como exemplo tem-se a Amazon AWS e o Google Cloud.
- **Nuvem híbrida:** A nuvem híbrida é uma mistura dos modelos acima. Utiliza recursos da nuvem privada e da nuvem pública, agregando serviços de ambos. A grande questão neste modelo é a de definir o que irá para a nuvem pública e o que ficará na nuvem privada. Como exemplo, pode-se citar a utilização da nuvem privada com o HPE Eucalyptus, e quando não existirem mais recursos disponíveis, podem ser usados recursos da pública, como os da Amazon AWS.
- **Nuvem comunitária:** a nuvem comunitária possui partes em comum entre a nuvem privada e a pública, pois é uma nuvem privada embora utilize estrutura do tipo pública para disponibilizar recursos para um grupo específico de organizações que tenham o mesmo objetivo. Ou seja, seria uma nuvem pública para um grupo restrito de usuários.




Figura 2 – Modelos de Arquitetura em Nuvem

Fonte: (SEGURANCA, 2016)

Estes modelos podem ser utilizados de forma específica e isolada ou podem ser combinados de acordo com a infraestrutura desejada, como por exemplo se dá com a criação de uma infraestrutura híbrida de nuvem privada e pública, conforme (JOHNSON, 2011; SOUSA et al., 2016).

2.2.3 Características da Computação em Nuvem

De acordo com (CUNHA et al., 2017; HERBST; KOUNEV; REUSSNER, 2013; LORIDO-BOTRAN; MIGUEL-ALONSO; LOZANO, 2014), existem cinco características essenciais para que se tenha um serviço em nuvem:

- **Autoserviço sob demanda:** possibilidade de alterar os recursos disponibilizados, como armazenamento, memória e outros, através do próprio usuário.
- **Acesso amplo à rede:** leva em consideração a independência da localização física com relação aos recursos, ou seja, não importa onde o recurso está sendo provisionado e sim que esteja disponível.
- **Agrupamento de recursos:** possibilidade de compartilhar e agrupar vários recursos entre diversos usuários.
- **Elasticidade rápida:** possibilidade de os recursos serem provisionados de forma automática ou com o mínimo de esforço possível, permitindo uma rápida resposta à demanda.

- **Serviço medido:** os serviços são monitorados e medidos, como forma de cobrar somente pelos recursos realmente utilizados.

2.2.4 Escalabilidade e Elasticidade

A ideia básica de um sistema escalável é a possibilidade de se adicionar recursos, seja por meio de cópias de máquinas virtuais seja pela expansão das já existentes, a exemplo de processador ou memória, de acordo com a demanda exigida e de forma satisfatória, conforme afirmam (LORIDO-BOTRAN; MIGUEL-ALONSO; LOZANO, 2014). Escalabilidade e elasticidade são inter-relacionadas mas possuem conceitos distintos, apesar de a escalabilidade ser uma condição para que a elasticidade possa acontecer.

- **Elasticidade:** conforme (BREBNER, 2012), é a habilidade que um sistema tem de se adaptar a mudanças de carga de trabalho e de demanda de recursos, seja de forma manual ou automática.
- **Escalabilidade:** também de acordo com (BREBNER, 2012), a escalabilidade é dada pelo sistema, que inclui o hardware, a virtualização e os softwares necessários para permitir a elasticidade.

O escalonamento no sistema em nuvem pode ser realizado de duas formas:

- **Horizontal:** nesse caso adicionam-se novas máquinas virtuais ao sistema, aumentando assim a quantidade de nós que fazem parte do mesmo.
- **Vertical:** nessa situação são adicionados novos recursos às máquinas virtuais já existentes em tempo de execução, como processadores, memória, etc.

Na Figura 3, tem-se uma representação do funcionamento dos algoritmos reativos e dos proativos. Nos Reativos (3a), a submissão é feita ao serviço em nuvem e executada com os nós existentes. Ao longo do tempo, o autoescalonador monitora os recursos das instâncias através dos alarmes criados e das políticas de escalonamento. Caso um alarme seja disparado, são criadas ou destruídas instâncias ou adicionados ou removidos recursos ao grupo, e após essas tarefas estes ficam disponíveis ao usuário. Já no modelo Proativo (3b), antes da execução é feita uma análise pelo autoescalonador, juntamente com os alarmes e as políticas de escalonamento, e a infraestrutura é preparada para a submissão das requisições. Somente após os recursos estarem disponíveis é que a execução é iniciada. Os modelos híbridos iniciam o seu funcionamento no modelo proativo e, durante a execução, adotam o comportamento do modelo reativo, monitorando e adequando os recursos ao longo da execução, de acordo com (LORIDO-BOTRAN; MIGUEL-ALONSO; LOZANO, 2014; REIS et al., 2018).




Figura 3 – Algoritmos de Autoescalamento

Fonte: (REIS et al., 2018)

2.3 Computação em Nuvem Verde

A computação em nuvem verde representa um importante avanço na interseção da tecnologia com a sustentabilidade. Esta seção explora as práticas e inovações que caracterizam a computação em nuvem verde, destacando tanto os desafios quanto as oportunidades para melhorias ambientais e eficiência energética (GOYAL; GARG, 2022; JUMDE; DONGRE, 2021; MANSOURI; GHAFARI; ZADE, 2020; KATAL; DAHIYA; CHOUDHURY, 2023).

A computação em nuvem verde é definida pela integração de práticas ambientalmente sustentáveis no design, operação e manutenção de infraestruturas de nuvem. Conforme indicado pelos supracitados autores, este conceito vai além da eficiência energética, ao englobar a redução do impacto ambiental, o uso eficiente de recursos e a promoção da sustentabilidade a longo prazo.

A eficiência energética constitui um dos pilares da computação em nuvem verde. Estratégias como a consolidação de servidores e o aprimoramento dos sistemas de resfriamento são fundamentais para reduzir o consumo de energia em data centers. Associado ainda a essas estratégias, o emprego de fontes de energia renovável para alimentar data centers, como solar e eólica, é uma prática crescente no setor.

Além da energia, a gestão eficiente de outros recursos, incluindo hardware e água para sistemas de resfriamento, é vital. A reciclagem e reutilização de componentes eletrônicos também são aspectos importantes para a computação em nuvem verde.

Embora os benefícios da computação em nuvem verde sejam evidentes, existem desafios significativos na sua implementação. Estes incluem o custo inicial de implementação, a necessidade de expertise técnica e a resistência à mudança em organizações já estabelecidas. A migração para soluções sustentáveis de nuvem verde pode exigir investimentos substanciais, tanto em tecnologias quanto em capacitação de pessoal.

A computação em nuvem verde é um campo em evolução, que oferece oportunidades significativas para avançar em direção a práticas de TI mais sustentáveis. Apesar dos desafios, os benefícios a longo prazo, incluindo redução dos custos operacionais, redução do impacto ambiental e melhoria da imagem corporativa tornam-na opção atrativa e válida para organizações conscientes do seu papel ambiental responsável.

2.3.1 Sustentabilidade em Computação em Nuvem

A computação em nuvem revolucionou o armazenamento, o processamento de informações e o acesso aos serviços, mas também trouxe à tona questões importantes relacionadas à sustentabilidade. ([KATAL; DAHIYA; CHOUDHURY, 2023](#); [CHENG et al., 2021](#)) discutem como a nuvem, ao centralizar recursos, oferece oportunidade única para implementar estratégias de sustentabilidade. A eficiência energética, a redução da emissão de carbono e o uso responsável de recursos são aspectos centrais nessa discussão.

Redução da Emissão de Carbono: a migração para a nuvem pode resultar em redução significativa da emissão de carbono por parte das operações de TI. Segundo estudo da ([AMAZON, 2023a](#)), a migração para a nuvem pública pode reduzir as emissões de carbono em até 85% em comparação com data centers tradicionais. Isso é atribuído à eficiência aprimorada, uso de energia renovável e melhor utilização de recursos em data centers em nuvem.

Gestão de Recursos e E-Waste: a centralização de recursos em data centers em nuvem reduz o desperdício associado ao E-Waste. Conforme explicado por ([KATAL; DAHIYA; CHOUDHURY, 2023](#)), a adoção da nuvem permite que as organizações reduzam a necessidade de hardware no local, o que por sua vez diminui a quantidade de E-Waste gerado.

Eficiência Energética na Computação em Nuvem: a eficiência energética é um aspecto crítico da sustentabilidade em computação em nuvem. Conforme ressaltado por ([CHENG et al., 2021](#)), a otimização do consumo de energia em data centers é essencial para minimizar o impacto ambiental.

Estratégias de Otimização: diversas estratégias podem ser empregadas para

melhorar a eficiência energética. (KATAL; DAHIYA; CHOUDHURY, 2023; CHENG et al., 2021) propõem soluções como a consolidação dinâmica de servidores e o uso de técnicas de resfriamento eficientes.

Uso de Fontes Renováveis: a utilização de fontes de energia renováveis em data centers é outra estratégia-chave, conforme (NAYAK; PANDA; DAS, 2020).

A computação em nuvem, enquanto traz desafios para a sustentabilidade, também oferece oportunidades significativas para melhorias ambientais, especialmente quanto à eficiência energética. A implementação de estratégias sustentáveis na computação em nuvem não somente atenua o impacto ambiental, mas também pode acarretar vantagens econômicas. Esses benefícios incluem a redução de custos operacionais e ainda a melhoria da imagem corporativa.

2.3.2 Eficiência Energética

A eficiência energética é um dos aspectos mais críticos e desafiadores na gestão de data centers e na infraestrutura da computação em nuvem. Ela não apenas influencia o custo operacional mas também tem impacto significativo sobre o meio ambiente. De acordo com (MASANET et al., 2020; KATAL; DAHIYA; CHOUDHURY, 2023; CHENG et al., 2021; NAYAK; PANDA; DAS, 2020) são apresentados a seguir alguns conceitos, estratégias e desafios em relação à eficiência energética na computação em nuvem:

Desafios da Eficiência Energética em Data Centers: o consumo de energia em data centers tem sido ponto de preocupação crescente, dado o aumento exponencial na demanda por serviços de computação em nuvem. Os data centers são responsáveis por parcela considerável do consumo mundial de energia, levando à necessidade de estratégias eficazes para gerenciamento de energia.

Estratégias de Otimização de Energia: várias abordagens foram propostas e implementadas para melhorar a eficiência energética em data centers. Algumas dessas estratégias incluem:

- **Consolidação de Servidores:** os autores citados discutem como a consolidação de servidores, que envolve a migração de workloads para um número menor de servidores mais eficientes, pode reduzir significativamente o consumo de energia.
- **Resfriamento Eficiente:** afirmam ainda que a otimização dos sistemas de resfriamento é essencial, pois o resfriamento pode representar uma grande parte do consumo de energia em data centers.

Tecnologias Emergentes: além das estratégias operacionais, o avanço tecnológico desempenha papel fundamental na melhoria da eficiência energética. Estão

ganhando destaque inovações como a computação em névoa (Fog Computing) e o uso de inteligência artificial para gerenciamento de energia:

- **Computação em Névoa:** o conceito de computação em névoa é introduzido como uma abordagem para reduzir a latência e o consumo de energia, processando dados de forma mais próxima do usuário final.
- **IA para Gerenciamento de Energia:** a Inteligência Artificial está sendo cada vez mais utilizada para prever e gerenciar o consumo de energia em data centers, conforme destacam estudos sobre IA aplicada a sistemas de energia.

A eficiência energética em data centers e na computação em nuvem é uma área de pesquisa em desenvolvimento contínuo. Com a adoção de estratégias operacionais inteligentes e a integração de novas tecnologias, é possível não só reduzir o consumo de energia mas também minimizar o impacto ambiental da indústria de TI.

2.3.3 Princípios de Sustentabilidade Aplicados a TI

A integração dos princípios de sustentabilidade na Tecnologia da Informação (TI) é um desafio multifacetado, que envolve considerações ambientais, sociais e econômicas. Para compreender plenamente como a TI pode ser alinhada com práticas sustentáveis, é essencial explorar mais profundamente cada um desses pilares, conforme ([KATAL; DAHIYA; CHOUDHURY, 2023](#); [SILVA, 2023](#); [BCS, 2012](#)).

- **Pilar Ambiental**

- **Redução do Consumo de Energia:** este é um dos focos principais da sustentabilidade na TI. A eficiência energética pode ser alcançada através do uso de equipamentos com menor consumo de energia e data centers mais eficientes.
- **Uso de Energias Renováveis:** a transição para fontes de energia renovável é fundamental para reduzir o impacto ambiental dos data centers e das operações de TI.
- **Gerenciamento de Resíduos Eletrônicos:** o descarte e reciclagem adequados de E-Waste é um aspecto crítico, dada a rápida obsolescência dos dispositivos eletrônicos.

- **Pilar Social**

- **Acessibilidade e Inclusão Digital:** garantir que a tecnologia seja acessível e inclusiva para as diversas populações e estratos sociais é essencial para um desenvolvimento mais equitativo.

- Ética no Uso da Tecnologia: envolve considerar os impactos sociais do uso da TI, como privacidade de dados, segurança cibernética e os efeitos do uso de TI na saúde mental e no bem-estar das pessoas.

- **Pilar Econômico**

- Eficiência Operacional e Redução de Custos: a implementação de práticas sustentáveis pode levar a uma redução significativa nos custos operacionais, tanto a curto quanto a longo prazo.
- Inovação e Competitividade de Mercado: empresas que adotam práticas sustentáveis em TI podem se beneficiar de uma melhor imagem e conceito, além das inovações poderem abrir novos mercados e oportunidades de negócios.

Os princípios de sustentabilidade na TI não são apenas uma responsabilidade ética, mas também uma oportunidade estratégica. O desafio está em equilibrar efetivamente os aspectos ambientais, sociais e econômicos, de modo a promover um desenvolvimento tecnológico que seja verdadeiramente sustentável.

2.3.4 Uso Sustentável de Recursos

A sustentabilidade em Tecnologia da Informação (TI) envolve práticas que visam o uso eficiente e responsável dos recursos, com o objetivo de minimizar o impacto ambiental e promover a conservação de recursos para gerações futuras. Esta seção explora o conceito de uso sustentável de recursos na TI, focando em estratégias para a eficiência de recursos, reciclagem e reutilização, além da adoção de energias renováveis.

Data centers são um dos principais pontos quando se trata de uso sustentável de recursos na TI. A eficiência no uso de recursos pode ser alcançada através da consolidação de servidores, da adoção de tecnologias de virtualização e da implementação de sistemas de resfriamento mais eficientes. Segundo (NAYAK; PANDA; DAS, 2020), melhorias na eficiência dos data centers podem resultar em redução significativa no consumo de energia elétrica, o que é crucial, considerando que os data centers são responsáveis por parcela considerável do consumo de energia na área de TI.

Uma outra abordagem em relação ao uso de recursos de forma sustentável está relacionada ao ciclo de vida dos equipamentos de TI. Práticas de reciclagem e reutilização são essenciais para reduzir o E-Waste. De acordo com (SHAHABUDDIN et al., 2023), a gestão adequada do E-Waste não apenas evita danos ambientais e à saúde, mas também recupera materiais valiosos. Além disso, programas de reutilização de equipamentos de TI podem prolongar a vida útil dos dispositivos e reduzir a necessidade de produção de novos equipamentos.

Segundo (NAYAK; PANDA; DAS, 2020), o uso de energias renováveis é uma estratégia-chave para promover o uso sustentável de recursos na TI. Empresas líderes de TI têm investido cada vez mais em fontes de energia limpa e renovável para suas operações. Esta mudança não apenas reduz a dependência de combustíveis fósseis, mas também apoia o desenvolvimento de uma infraestrutura energética mais sustentável a longo prazo.

Apesar do progresso na adoção de práticas de uso sustentável de recursos na TI, ainda permanecem desafios significativos. Estes incluem o custo inicial de implementação de infraestruturas sustentáveis, a necessidade de mudanças na cultura organizacional e a adaptação às regulamentações ambientais em constante mudança. No entanto, com o avanço contínuo das tecnologias e um maior reconhecimento da importância da sustentabilidade, espera-se que o uso sustentável de recursos na TI se torne cada vez mais viável e prevalente.

2.3.5 Categorias e Áreas da Computação em Nuvem Verde

Existem inúmeros estudos no campo da computação em nuvem verde que permitem embasar pesquisadores e profissionais da área quanto à adoção desse modelo, bem como em relação ao processo de migração entre as arquiteturas. Por serem ambientes altamente complexos, caros e nos quais não podem ocorrer interrupções dos serviços, faz-se necessário um estudo e planejamento preliminar, além do uso de simuladores, de forma a garantir sua adoção de modo seguro e eficaz.

A seguir são destacadas algumas categorias reconhecidas e usadas na comunidade acadêmica relacionadas à adoção ou transformação para a computação em nuvem verde. Vale ressaltar que quanto mais categorias são incorporadas ao modelo, maior a abrangência e o nível de adoção da computação em nuvem verde (RADU, 2017; AGRAWAL; SAINI; WANKHEDE, 2020; GARG; YEO; BUYYA, 2011).

Modelos e Métodos: nesta categoria encontram-se abordagens referentes a modelos e métodos, como abordagens de medições, etiquetas de computação verde, classificação de nível de computação verde, dentre outras.

Arquiteturas: as arquiteturas dizem respeito mais à infraestrutura, virtualização, uso de containers, uso de nuvem privada, pública ou híbrida, e tipos de processadores e demais dispositivos, dentre outros.

Frameworks: existem vários frameworks já disponíveis quando se trata de computação em nuvem verde, sendo que esta categoria se relaciona à adaptação, criação ou uso de alguns modelos já existentes. Como exemplo pode-se citar (GARG; YEO; BUYYA, 2011), que definem um broker que recebe as solicitações e a partir de serviços de monitoramento de recursos e de data centers, sugerindo a melhor solução em

termos de computação verde.

Algoritmos: a maior parte das abordagens ou áreas de pesquisa diz respeito a esta categoria, englobando desde o uso mais eficiente dos núcleos de processamento pelas aplicações até algoritmos específicos para a infraestrutura, como migração de VM's, escalonamento de voltagem de processadores, dentre outros.

Questões Gerais: nesta categoria estão compreendidas questões e abordagens de aspectos mais amplos, que não se enquadram nas demais, como por exemplo a redução do desperdício ou reutilização de recursos, dentre outros fatores.

2.3.6 Metodologias, Tecnologias e Inovações

2.3.6.1 Metodologias

Dentre as categorias discutidas na seção 2.3.5, estão as diversas abordagens que podem ser utilizadas de forma a implementar ou otimizar a redução energética e de custos, além de reduzir o impacto ambiental. De modo semelhante, tais abordagens também podem ser associadas entre si, garantindo um melhor benefício nas mais diversas categorias, podendo ser citadas, de acordo com (RADU, 2017; BASH et al., 2011; AGRAWAL; SAINI; WANKHEDE, 2020; GARG; YEO; BUYYA, 2011; KHAN; KHAN, 2016; MASDARI; ZANGAKANI, 2020):

1. Gerenciamento mais eficiente de máquinas virtuais

- a) Consolidação de VM nos servidores físicos: com essa abordagem é possível desativar ou suspender os servidores físicos que não estão sendo utilizados.
- b) Redução da velocidade dos processadores das VM: dessa forma há redução do consumo de energia e da refrigeração objetivando dissipar o calor, garantindo de todo modo o desempenho contratado.
- c) Realocação de tarefas entre VM: por meio da realocação de tarefas é possível desativar as que não estão sendo utilizadas e reativá-las somente quando existir uma demanda necessária.
- d) Alocação para data center com melhor eficiência energética: realizar a alocação dos recursos dos serviços que possuem uma melhor eficiência energética e desativar nos centros que não a possuem.

2. Gerenciamento mais eficiente de energia

- a) Por meio do controle da voltagem e frequência dos processadores é possível reduzir tanto a energia quanto a temperatura, utilizando nesse caso recursos da própria arquitetura do processador.

- b) De modo similar ao controle de voltagem e frequência do modelo anterior, mas agora utilizando o recurso de multiníveis de energia nos processadores.
- c) Engenharia de software especializada, de modo a melhorar a utilização dos vários núcleos de processamento pelas aplicações, de forma a executar mais rapidamente e aproveitar melhor os recursos computacionais.
- d) Algoritmos de roteamento mais eficientes em termos de do fluxo ou demanda, desativando assim equipamentos de rede para economizar energia.

3. Abordagens dependentes do hardware

- a) Redução de dissipação do calor, por meio da adoção de processadores que não precisem de dissipadores, como chips de dispositivos móveis.
- b) Planejamento de energia das placas e processadores, permitindo a transmissão separada de energia para os diversos processadores e gerenciando melhor o consumo de acordo com a demanda.
- c) De modo similar ao gerenciamento da velocidade, utilização de processadores mais modernos que permitam gerenciar dinamicamente a voltagem do processador.
- d) Utilização de armazenamento mais eficiente, como por exemplo o uso de SSD no lugar dos discos convencionais.

4. Outras abordagens

- a) Utilização de fontes renováveis de energia, a exemplo da energia eólica, solar e de água.
- b) Reaproveitamento dos recursos já utilizados, como por exemplo o aproveitamento da água utilizada para refrigeração na geração de energia.

Cabe destacar que, para este trabalho, será utilizada a abordagem relacionada ao gerenciamento das máquinas virtuais nos servidores físicos, através da consolidação de VMs e desligamento das não utilizadas, uma vez que estas abordagens não necessitam de modificação de equipamentos físicos e nem investimento em infraestrutura, sendo possível seu uso na adoção de políticas que podem ser implementadas em qualquer ambiente em nuvem.

2.3.6.2 Métricas Computacionais

Entender como transformar a computação convencional em computação verde é um dos grandes desafios atuais e, para que essa transformação seja realizada, é necessário entender e conhecer as métricas que podem ser utilizadas. Este tema é tratado nesta seção.

Para se avaliar a eficácia da mudança para a computação em nuvem e, em seguida, para a computação em nuvem verde, faz-se necessário medir. E para tanto, conhecer o que pode e deve ser medido é de suma importância, tanto quanto identificar quais serviços devem mudar de arquitetura e quais devem permanecer.

Vale ressaltar que o modelo convencional não deve ser simplesmente replicado para a nova plataforma, já que existem particularidades completamente distintas. Nesse contexto também é de suma importância a otimização e parametrizações, de forma a obter o melhor desempenho, demonstrando assim, novamente, a importância das medições.

Os principais parâmetros para medição de consumo são, conforme ([GADE, 2018](#); [SAHA, 2018](#)):

- **TDP:** é a medição de energia necessária para refrigerar ou dissipar o calor do processador. Soma-se a energia máxima que um processador consome ao executar uma tarefa real.
- **PUE:** ele é usado para criar uma relação entre a energia consumida por uma aplicação em relação ao consumo total do data center. O melhor resultado do PUE (Energia total do data center / energia de uma aplicação ou equipamento) é o mais próximo de 1.0, demonstrando que não há desperdício de energia, como em refrigeração, iluminação ou overhead.
- **DCiE:** é a métrica inversa ao PUE, ambas sendo mais utilizadas para comparação entre data centers. É a relação de $1 / \text{PUE}$, ou energia de uma aplicação ou equipamento / energia total do data center.
- **Performance per Watt:** é a medida de eficácia de um processador ou equipamento. Representa a taxa de desempenho por watt de consumo.
- **GEC:** é a medida de energia verde, ou seja, é a medida da quantidade de energia que é consumida pelo data center que tem origem em fontes renováveis, tendo como referência a relação energia renovável / energia total consumida.
- **CUE:** métrica muito importante, que diz respeito à emissão de gás carbônico gerado pelo data center. É a relação entre a emissão de CO_2 e a quantidade de energia consumida. Diz respeito às fontes de energia utilizadas pelo data center.
- **Data Center Productivity:** métrica que relaciona o trabalho efetivamente realizado com relação ao total de recursos utilizados para a sua realização. É semelhante ao DCP, entretanto levando em consideração tanto software quanto hardware.
- **Data Center Energy Productivity:** semelhante ao DCP, mas ao invés de utilizar os recursos leva em consideração a energia utilizada para produzir a tarefa.

- **Emissão de CO₂:** apesar do uso computacional não emitir CO₂ diretamente, existe uma relação entre seu consumo de energia e o impacto ambiental. Neste trabalho será utilizado o cálculo conforme ([EPA, 2022](#)).

A partir do conhecimento das métricas existentes que podem ser usadas é possível tanto medir o nível atual dos data centers quanto, após intervenções, avaliar a melhoria. Inclusive, por meio de simulações, analisar quais intervenções teriam impacto mais significativo.

2.3.6.3 Design Sustentável de Data Centers

O design sustentável de data centers é uma área crítica na interseção da tecnologia da informação (TI) e da sustentabilidade. Com o crescimento exponencial de dados e a demanda por serviços de computação em nuvem, os data centers tornaram-se grandes consumidores de energia e recursos, levantando preocupações ambientais significativas. Esta seção explora as práticas e estratégias adotadas para tornar os data centers mais sustentáveis, focando na eficiência energética, no uso de recursos renováveis e na minimização do impacto ambiental geral ([MANGANELLI et al., 2021](#); [MURINO et al., 2023](#); [MONDAL et al., 2023](#); [VASQUES; MOURA; ALMEIDA, 2019](#); [PATIL; PATIL, 2019](#)).

A eficiência energética é um dos aspectos mais críticos do design sustentável de data centers. Estratégias como a otimização de layouts de data centers, uso de tecnologias de resfriamento avançadas e sistemas de gestão de energia inteligentes são fundamentais para reduzir o consumo de energia. Os autores citados enfatizam a importância de, desde o início, projetar data centers com eficiência energética, integrando soluções como refrigeração líquida e arquiteturas de baixa potência.

- **Uso de Energias Renováveis:** associar também a transição para energias renováveis é um pilar central para data centers sustentáveis. Empresas líderes no setor de TI têm implementado grandes projetos de energia solar e eólica para abastecer seus data centers. Essas iniciativas não apenas reduzem a dependência de combustíveis fósseis mas também demonstram o comprometimento corporativo com a sustentabilidade.
- **Design e Construção Ecológicos:** o design físico dos data centers também desempenha papel importante para a sustentabilidade. Inclui a escolha de materiais de construção ecológicos, a integração de sistemas de energia passiva e a utilização de recursos naturais para resfriamento. A adoção de práticas de construção verde pode reduzir significativamente o impacto ambiental de novos data centers.

- **Gestão de Recursos e Resíduos:** a gestão eficiente de recursos, incluindo água e materiais, é outra consideração importante no design de data centers sustentáveis. A reutilização da água, especialmente em sistemas de resfriamento, e a reciclagem de componentes e equipamentos, desempenham papel crítico na redução do impacto ambiental. O gerenciamento de resíduos não só ajuda a preservar recursos naturais mas também pode resultar em economias operacionais significativas.
- **Edifícios Verdes e Localização Estratégica:** a escolha da localização e a construção de data centers também são fundamentais. Construir data centers em climas mais frios pode reduzir significativamente a necessidade de resfriamento artificial. Além disso, a incorporação de elementos de construção verde, como telhados verdes e sistemas de captação de água da chuva podem complementar as estratégias de sustentabilidade.
- **Inovações Futuras em Data Centers Sustentáveis:** o avanço contínuo na tecnologia de data centers promete novas oportunidades para melhorar a sustentabilidade. Inovações como a inteligência artificial para otimização do uso de energia e o desenvolvimento de novos materiais e técnicas de construção mais sustentáveis são áreas de pesquisa ativa. Essas inovações têm o potencial de transformar o cenário dos data centers, tornando-os mais eficientes e ambientalmente responsáveis.

2.3.6.4 Técnicas Eficientes de Refrigeração

A computação em nuvem verde busca minimizar o impacto ambiental, por meio da eficiência energética e do uso de recursos renováveis. Uma das áreas mais críticas para alcançar esses objetivos é a refrigeração eficiente dos data centers, uma vez que a refrigeração pode representar uma grande parte do consumo de energia total das instalações ([MASDARI; ZANGAKANI, 2020](#)).

Esta seção aborda estratégias com foco em técnicas de refrigeração inovadoras, objetivando reduzir o consumo de energia e promover a sustentabilidade. Diversas abordagens foram exploradas visando aumentar a eficiência na redução de calor, redução dos custos operacionais e minimização do impacto ambiental, conforme ([NIKBAKHTI et al., 2020](#); [ZHANG et al., 2021b](#); [BHARANY et al., 2022](#)):

- **Refrigeração Líquida Direta:** utiliza líquidos refrigerantes para absorver e dissipar o calor diretamente dos componentes críticos, como CPUs e GPUs. Isto pode ser mais eficiente do que a refrigeração tradicional a ar, pois os líquidos têm capacidade térmica superior ao ar, permitindo transferência de calor mais eficaz. Algumas dessas abordagens incluem:

- **Resfriamento por Imersão em Óleo Mineral:** foi proposto um sistema de resfriamento por imersão, onde servidores são encapsulados em óleo mineral, aumentando a capacidade de absorção de calor e reduzindo potencialmente os custos de resfriamento.
- **Desenvolvimento de Novos Pares de Fluidos de Trabalho:** pesquisa e desenvolvimento de novos pares de fluidos de trabalho com propriedades termodinâmicas superiores aos pares convencionais, visando aumentar a eficiência dos sistemas de absorção.
- **Refrigeração gratuita:** a refrigeração gratuita, também conhecida como resfriamento livre ou resfriamento passivo, é uma técnica que aproveita as condições climáticas externas favoráveis para resfriar um ambiente sem a necessidade de equipamentos de refrigeração tradicionais, como compressores de ar condicionado. Alguns aspectos relevantes sobre a refrigeração gratuita incluem:
 - **Uso de Água Gelada:** implementação de sistemas que utilizam água gelada para refrigerar o ar nos corredores dos data centers. Esta técnica pode ser mais eficiente que os sistemas de ar condicionado convencionais, especialmente se a água gelada puder ser produzida utilizando fontes de energia renováveis ou aproveitando as baixas temperaturas ambientais durante os meses mais frios.
 - **Refrigeração Econômica:** aproveita o ar externo para resfriar os ambientes internos quando as condições climáticas estejam favoráveis, reduzindo a necessidade de refrigeração artificial. Isto pode ser particularmente eficaz em climas mais frios ou durante a noite.
- **Reaproveitamento de Calor:** captura o calor residual gerado pelos equipamentos de TI para usos secundários, como aquecimento de espaços ou água. Isso não apenas reduz a necessidade de refrigeração, mas também aproveita uma energia que, de outra forma, seria desperdiçada. Pode-se citar algumas iniciativas:
 - **Armazenamento de Calor Latente (LHSU):** foi desenvolvido modelo de unidade de armazenamento de calor latente para reduzir o consumo significativo de energia em refrigeração de espaços.
 - **Adição de Subcomponentes:** inclusão de subcomponentes, como SHE (trocadores de calor de solução), tanque de flash e coluna de destilação, para aumentar o COP (Coefficient of Performance) e a capacidade de resfriamento dos ciclos de absorção, tornando-os adequados para fontes térmicas de baixa qualidade.
 - **Ciclos de Recuperação de Calor:** os ciclos de recuperação de calor são estratégias utilizadas em sistemas de refrigeração e climatização para

aproveitar o calor residual gerado durante o processo de refrigeração e utilizá-lo de forma eficiente em outras partes do sistema. Esses ciclos visam melhorar a eficiência energética do sistema, reduzir o consumo de energia e otimizar o aproveitamento de recursos térmicos disponíveis.

- **Otimização de Ciclo de Refrigeração:** as mudanças de ciclo em sistemas de refrigeração por absorção são estratégias importantes para melhorar a eficiência e o desempenho do sistema. Algumas mudanças de ciclo comuns incluem:
 - **Melhoria do Design do Ciclo:** o desenvolvimento de ciclos de absorção avançados, como ciclos de efeito único e duplo, mediante seleção adequada de fluidos de trabalho e otimização das condições operacionais.
 - **Resfriamento por Fase Dupla:** o resfriamento por fase dupla é um processo de resfriamento que envolve a utilização de duas fases de mudança de estado para remover o calor de um sistema. Nesse processo, a transferência de calor ocorre durante a condensação e a evaporação de um fluido de trabalho, permitindo uma maior eficiência de resfriamento em comparação com sistemas tradicionais de resfriamento por fase única.
- **Uso de Energia Renovável:** embora não seja uma técnica de refrigeração, a integração de fontes de energia renováveis, como a solar ou eólica, para alimentar sistemas de refrigeração, reduz o impacto ambiental. Além disso, a implementação de sistemas de armazenamento de energia pode ajudar a aproveitar a energia renovável de forma mais eficaz, garantindo que os sistemas de refrigeração possam operar continuamente sem depender inteiramente da rede elétrica.

Em resumo, os estudos destacam a diversidade de estratégias e inovações que são aplicadas visando aprimorar a eficiência e o desempenho dos sistemas de refrigeração e recuperação de calor, tendo em vista a otimização energética e sustentabilidade dos sistemas. Essas técnicas representam importantes avanços na busca por sistemas de refrigeração mais eficientes e ambientalmente responsáveis, com destaque para a importância da inovação contínua e da otimização dos processos para o desenvolvimento futuro da tecnologia de refrigeração por absorção.

2.3.6.5 Uso de Energias Renováveis

A adoção de energias renováveis no âmbito da computação em nuvem emerge como estratégia essencial para promover a sustentabilidade no setor de tecnologia da informação. Este movimento em direção à utilização de fontes de energia limpa é vital para compensar as mudanças climáticas e reduzir as emissões de gases de efeito estufa associadas à operação de data centers. Além disso, a transição para energias renováveis

não somente acarreta benefícios ambientais significativos, mas também apresenta vantagens econômicas consideráveis para os operadores de data centers, como a estabilização dos custos de energia e a elegibilidade quanto a incentivos fiscais e subsídios governamentais (ROSTIROLLA et al., 2022; SONG et al., 2022; NAYAK; PANDA; DAS, 2021; HUANG et al., 2020).

Diversas fontes de energia renovável têm sido exploradas para atender às demandas energéticas dos data centers, incluindo, mas não se limitando a:

- **Energia Solar:** a conversão da luz solar em eletricidade por meio de painéis solares representa uma solução viável para data centers e cada vez mais disseminada, graças à facilidade de implementação e à ampla disponibilidade de radiação solar em diversas regiões do globo.
- **Energia Eólica:** a geração de eletricidade através de turbinas eólicas capitaliza os ventos consistentes e fortes, tornando-se alternativa energética particularmente vantajosa para data centers situados em regiões propícias.
- **Hidroenergia:** utilizando o movimento da água em rios e barragens, a hidroenergia fornece uma fonte de energia constante e renovável, ideal para data centers localizados nas proximidades de recursos hídricos.
- **Energia Geotérmica:** o aproveitamento do calor interno da Terra para a produção de eletricidade ou aquecimento direto oferece uma fonte de energia contínua, embora sua viabilidade seja restrita por fatores geográficos.
- **Biomassa:** a conversão de materiais orgânicos em energia, como resíduos agrícolas ou madeira, constitui opção sustentável para data centers próximos a fontes de biomassa, apesar de ser uma alternativa menos comum.

A integração de energias renováveis na infraestrutura da computação em nuvem não é apenas uma resposta à crescente preocupação ambiental, mas também uma estratégia empresarial recomendável. Contudo, a simples adoção de fontes de energia limpa não é suficiente para qualificar um data center como eficiente do ponto de vista energético. É imperativo que a implementação dessas fontes renováveis seja acompanhada por compromisso contínuo com a melhoria da eficiência energética. Isto implica a realização de auditorias energéticas regulares, a implementação de práticas operacionais otimizadas e o investimento em tecnologias avançadas, visando maximizar a utilização da energia gerada de maneira sustentável.

Em suma, enquanto a computação em nuvem verde se volta para energias renováveis de modo a sustentar suas operações, é fundamental que tais esforços sejam complementados por uma gestão energética rigorosa. Esta abordagem holística não só

reforça o compromisso do setor de TI com a sustentabilidade ambiental, mas também assegura a viabilidade econômica e a resiliência operacional dos data centers no longo prazo.

2.3.7 Benefícios da Computação em Nuvem Verde

A computação em nuvem verde está se tornando cada vez mais vital para organizações que buscam reduzir seu impacto ambiental e operar de maneira mais sustentável. Esta seção explora os múltiplos benefícios associados à adoção da computação em nuvem verde, que não apenas incluem vantagens ambientais mas também benefícios econômicos e sociais, conforme (BHARANY et al., 2022; XU; BUYYA, 2020; GOYAL; GARG, 2022; KATAL; DAHIYA; CHOUDHURY, 2023; SILVA, 2023; SHARMA; GUPTA; ACHARYA, 2021):

- **Benefícios Ambientais**

- **Redução da Emissão de Carbono:** uma das principais vantagens da computação em nuvem verde é a redução significativa da emissão de carbono pelas operações de TI. Ao utilizar data centers otimizados quanto à eficiência energética e alimentados por fontes de energia renováveis, as empresas podem diminuir drasticamente suas emissões de gases de efeito estufa. Conforme os autores destacam, a migração para a nuvem pode reduzir essa emissão em até 30%.
- **Uso Eficiente de Recursos:** além da redução de carbono, a computação em nuvem verde promove o uso eficiente de recursos. Isso inclui redução do consumo de energia elétrica e otimização do uso de outros recursos. A virtualização e a consolidação de servidores permitem que mais trabalho seja feito com menos equipamentos, diminuindo o desperdício e melhorando a eficiência geral.

- **Benefícios Econômicos**

- **Redução de Custos Operacionais:** a eficiência energética e a utilização otimizada de recursos resultam em economias operacionais substanciais. A computação em nuvem verde pode reduzir os custos de energia em até 40% para algumas organizações. Além disso, a redução na necessidade de investimentos em infraestrutura de hardware contribui para uma diminuição significativa nos custos de capital.
- **Vantagem Competitiva:** empresas que adotam a computação em nuvem verde também podem se beneficiar de vantagem competitiva no mercado. Ademais, a demonstração de responsabilidade ambiental pode melhorar a

imagem da marca e atrair clientes e investidores conscientes do ponto de vista ambiental.

- **Benefícios Sociais**

- **Fomento à Inovação e à Sustentabilidade Corporativa:** a adoção da computação em nuvem verde estimula a inovação, levando ao desenvolvimento de novas tecnologias e práticas sustentáveis. Além disso, também promove maior consciência e responsabilidade corporativa em relação à sustentabilidade. Organizações tornam-se modelos quanto à práticas sustentáveis, influenciando positivamente seus stakeholders e a comunidade.
- **Melhoria da Qualidade de Vida e Conscientização Ambiental:** empresas que utilizam a computação em nuvem verde contribuem indiretamente para a melhoria da qualidade de vida ao reduzir a poluição ambiental. Além disso, a adesão a estas práticas aumenta a conscientização sobre questões ambientais, tanto internamente entre os colaboradores quanto na sociedade em geral.

Dessa forma, a computação em nuvem verde oferece uma série de benefícios, que vão além da mera redução do impacto ambiental. Desempenha papel fundamental na transformação do cenário corporativo, levando a economias significativas de custos, incentivando a inovação sustentável e contribuindo para uma imagem corporativa socialmente responsável.

2.4 Ambiente de Simulação CloudSim Plus

Quando se trata de simulação de ambientes de computação em nuvem tem-se um grande desafio, uma vez que são ambientes complexos, necessitam de grande quantidade de informações, além do tempo necessário de processamento para atingir parâmetros realistas.

O uso de simuladores é essencial, pois oferece alternativa viável à execução de experimentos em ambientes reais. O custo e a complexidade logística de configurar data centers em escala tornam a simulação opção preferencial. Além disso, simuladores proporcionam ambiente controlado, permitindo testar cenários de carga, gerenciamento de falhas e estratégias de otimização sem os riscos e custos inerentes ao uso de infraestruturas físicas. Isto permite que os pesquisadores identifiquem possíveis pontos de melhoria nos algoritmos, reduzam riscos ao implementar novas soluções e acelerem o desenvolvimento de tecnologias mais eficientes (MAKARATZIS; GIANNOUTAKIS; TZOVARAS, 2018; MEYER et al., 2018; CHOPRA; RANGARAJAN; SEN, 2021; ZONG, 2020).

Os simuladores fornecem insights valiosos para avaliar o impacto de diferentes estratégias de gerenciamento de recursos em ambientes públicos, privados ou híbridos. A simulação também é útil para analisar como variações de carga e configurações de infraestrutura afetam o desempenho e o custo operacional dos data centers. Além disso, são ideais para comparar modelos de faturamento e qualidade de serviço (QoS), fornecendo diretrizes para implementação em ambientes reais.

Desenvolvido pela Universidade de Melbourne, o CloudSim oferece ambiente de simulação flexível para modelagem de diferentes serviços de nuvem. Sua arquitetura modular é uma de suas principais vantagens, permitindo que pesquisadores personalizem os cenários simulados e adicionem componentes específicos, como brokers, máquinas virtuais, algoritmos de escalonamento e balanceamento de carga. Também é projetado para ser extensível, facilitando a criação de módulos personalizados, que refletem diferentes cenários de data centers. O CloudSim tem sido amplamente utilizado para investigar estratégias de alocação de recursos, gestão de energia, qualidade de serviço (QoS) e até mesmo para simular diferentes modelos de cobrança baseados no uso dos recursos, conforme (WADHWA et al., 2019; YANG et al., 2018).

Como versão aprimorada do CloudSim, o CloudSim Plus, de acordo com (BARBIERATO et al., 2019; JUNIOR; BRUSCHI, 2020b; FILHO et al., 2017; CLOUDSIM, 2016), foi desenvolvido para fornecer uma arquitetura ainda mais modular, otimizando o desempenho e a facilidade de uso. Sua modularidade e extensibilidade são significativamente aprimoradas, permitindo integração mais fácil de novas funcionalidades e algoritmos personalizados. Permite também a modelagem detalhada de data centers, com suporte a diferentes políticas de escalonamento, alocação de recursos e monitoramento. Além disso, o CloudSim Plus tem um desempenho aprimorado, devido a métodos otimizados, reduzindo o tempo de execução das simulações e tornando mais ágil a exploração de cenários

Em virtude dos avanços no CloudSim Plus, que incluem monitoramento de consumo energético mais eficaz e confiável e atualizações regulares, além de ser fruto de investigação realizada por pesquisador brasileiro, decidiu-se adotar sua utilização neste estudo (FILHO et al., 2017).

Este simulador permite que sejam especificadas características do provedor em nuvem, como:

- Recursos físicos, como data centers, máquinas físicas (hosts, servidores ou simplesmente PMs) e ativos de rede;
- Recursos lógicos, como redes de área de armazenamento (SANs), topologias de rede e aplicativos;

- Camada de virtualização, que fornece elementos como máquinas virtuais (VMs), para permitir a virtualização de recursos físicos e lógicos;
- Requisitos e comportamento de aplicativos e cargas de trabalho.

O framework também é responsável por automatizar o gerenciamento dos recursos que são fornecidos como serviço, além do monitoramento de máquinas virtuais, executando tarefas de administração de baixo nível, como:

- Gerenciamento do ciclo de vida da VM (como criação, início, parada, destruição, alocação e migração);
- Gestão de máquinas físicas ativas para economia de energia;
- Escalonamento de execução de VMs e execução de aplicativos dentro de VMs;
- Alocação de VMs para aplicação e gerenciamento do ciclo de vida do aplicativo dentro das VMs.

O CloudSim Plus permite a simulação de arquiteturas inteiras de computação em nuvem, possibilitando ainda a implementação de novos recursos específicos. Ao estender os mecanismos básicos já fornecidos pelo framework, o pesquisador pode se concentrar na implementação das simulações para decidir quando e como essas tarefas são executadas, de modo a atingir os objetivos desejados. Tais objetivos incluem balanceamento de carga, economia de energia, tolerância a falhas, escalabilidade, elasticidade e minimização de custos, violações de SLA, tráfego de rede, atraso de comunicação e outros.

2.4.1 Execução do CloudSim Plus

A execução do simulador CloudSim Plus envolve a modelagem de elementos essenciais do ambiente de computação em nuvem, como data centers, hosts e VMs. A simulação inclui alocação de recursos de processamento, criação e destruição, migração e execução de tarefas nessas VMs. Para tanto faz-se necessário conhecer os recursos, estruturas e extensões existentes no simulador, detalhadas a seguir ([NARANG; GOSWAMI; JAIN, 2021](#); [VIJAY; NANDA, 2021](#); [SINGH; CHATURVEDI; RATHORE, 2020](#); [MARKUS; KERTESZ, 2020](#)):

Arquitetura e Componentes: compreende a arquitetura interna do CloudSim e como seus componentes interagem para simular ambientes de computação em nuvem. Isto inclui a estrutura de classes, módulos e interfaces do simulador.

Modelagem de Recursos: explora como o CloudSim modela recursos de computação em nuvem, como servidores, data centers, máquinas virtuais e como esses recursos são alocados e gerenciados durante a simulação.

Algoritmos de Escalonamento: define os algoritmos de escalonamento implementados no CloudSim para distribuir tarefas e recursos de forma eficiente nos ambientes de nuvem simulados. Determina como esses algoritmos impactam o desempenho e a utilização dos recursos.

Métricas de Avaliação: analisa as métricas de avaliação utilizadas no CloudSim para medir o desempenho e a eficácia dos ambientes de nuvem simulados. Isso pode incluir métricas como tempo de resposta, utilização de recursos e throughput, entre outros.

Extensões e Personalizações: explora como os pesquisadores estendem e personalizam o CloudSim para atender a requisitos específicos da pesquisa. Isso pode envolver a adição de novos recursos, algoritmos ou modelos de simulação.

Integração com Outras Ferramentas: investiga como o CloudSim pode ser integrado com outras ferramentas e plataformas para estender sua funcionalidade e suportar cenários de simulação mais complexos.

Cabe ainda mencionar os mecanismos de monitoramento implementados, para registrar não apenas os tempos de execução da simulação e o tempo simulado do ambiente, mas também para observar a utilização da CPU, memória RAM e o Max Heap do sistema. Estes indicadores são essenciais para compreender o desempenho e a eficiência dos recursos alocados, permitindo aos pesquisadores otimizar suas soluções em nuvem, visando atingir um equilíbrio ideal entre custo, desempenho e consumo energético.

A seguir estão referidas as principais categorias representativas da estrutura e funcionalidades do monitoramento, conforme (NARANG; GOSWAMI; JAIN, 2021; VIJAY; NANDA, 2021; SINGH; CHATURVEDI; RATHORE, 2020; MARKUS; KERTESZ, 2020):

Desempenho do Sistema: métricas relacionadas ao desempenho do sistema, como tempo de resposta, throughput, utilização de recursos (CPU, memória, largura de banda) e latência de rede, entre outros.

Eficiência de Escalonamento: avaliação da eficácia dos algoritmos de escalonamento implementados, incluindo métricas de balanceamento de carga, tempo de espera na fila e tempo de execução das tarefas, entre outros.

Consumo de Energia: em simulações que envolvem aspectos de eficiência energética, é possível monitorar e extrair dados relacionados ao consumo de energia dos recursos de computação em nuvem.

Custos Operacionais: para cenários de simulação que consideram aspectos

econômicos, é possível monitorar os custos operacionais associados à execução de tarefas, alocação de recursos e migração de máquinas virtuais, entre outros.

Segurança e Conformidade: métricas relacionadas à segurança da informação e conformidade com políticas de segurança, como detecção de intrusões, vazamento de dados e conformidade com regulamentações, entre outros.

Confiabilidade e Disponibilidade: monitoramento de eventos de falha, recuperação de falhas, tempo de inatividade do sistema e impacto das falhas no desempenho geral do sistema.

Otimização de Recursos: análise da utilização eficiente dos recursos disponíveis, identificação de gargalos de desempenho, otimização da alocação de recursos para maximizar a eficiência operacional e atendimento de requisitos de QoS.

Estas métricas e dados extraídos das simulações com o CloudSim Plus fornecem insights valiosos para os pesquisadores no desenvolvimento e otimização de estratégias de gerenciamento de recursos em ambientes de computação em nuvem, contribuindo de forma importante para a melhoria contínua da eficiência e desempenho dos sistemas em nuvem.

2.5 Redes Neurais Recorrentes (RNNs)

A previsão do score de pontuação e de nível energético em data centers é tarefa complexa, que envolve a análise de grandes volumes de dados e a identificação de padrões sutis e não lineares. Para realizar essa tarefa eficientemente, utiliza-se inteligência artificial, por meio de aprendizado profundo.

A predição em processos utilizando aprendizado profundo é uma área de pesquisa em constante evolução, que visa prever eventos futuros com base em dados históricos e padrões identificados. O aprendizado profundo, em particular, oferece abordagem robusta para modelar relações complexas e não lineares em dados sequenciais, como os encontrados em contextos empresariais, de saúde, financeiros e em diversas outras áreas (NEU; LAHANN; FETTKE, 2022; VENDRAMINI; SALDIAS; TAVARES, 2023; VILAÇA et al., 2022; ZHOU; DONG; SADDIK, 2020a).

Entre as arquiteturas de aprendizado profundo mais adequadas para lidar com dados sequenciais, com dependências temporais, estão as Redes Neurais Recorrentes (RNNs) (NEU; LAHANN; FETTKE, 2022; ZHOU; DONG; SADDIK, 2020b). Ao aplicar as redes neurais recorrentes (RNNs) é possível capturar dependências temporais e contextuais nos dados. Esses modelos podem aprender padrões sequenciais, identificar correlações ocultas e fazer previsões precisas com base em informações históricas.

O processo de predição utilizando aprendizado profundo usualmente compreende

diversas etapas, tais como a preparação e pré-processamento dos dados, a definição da arquitetura do modelo, o treinamento com dados históricos e a avaliação do desempenho do modelo com dados de teste. Durante a fase de treinamento, o modelo aprende a mapear as entradas sequenciais para as saídas desejadas, ajustando os pesos das conexões neurais de modo a minimizar a discrepância entre as previsões e os valores reais.

Uma das vantagens da aplicação de aprendizado profundo para a predição em processos é a sua capacidade de lidar com dados de alta dimensionalidade e complexidade, bem como a sua habilidade em capturar relações não lineares entre as variáveis. Além disso, a flexibilidade das redes neurais recorrentes em processar sequências de comprimentos variáveis torna-as adequadas para cenários nos quais a duração dos eventos possa variar.

As Redes Neurais Recorrentes foram projetadas para reconhecer padrões em sequência de dados, utilizando conexões cíclicas em sua estrutura, a fim de manter informações contextuais ao longo da sequência. Essa característica torna as RNNs particularmente eficazes para a análise de séries temporais, como dados de consumo de energia, tempo de execução e custos operacionais em ambientes de data centers.

A partir dos estudos de (VENDRAMINI; SALDIAS; TAVARES, 2023; VILAÇA et al., 2022), que empregaram modelos de aprendizado profundo para prever a demanda de energia elétrica diária e projetar cenários da matriz energética nacional até 2050, utilizando redes neurais convolucionais e recorrentes, destaca-se a arquitetura híbrida desses modelos, que possibilitou a extração eficiente de características espaço-temporais dos dados de entrada, o que resultou em desempenho superior em comparação a outros modelos desenvolvidos. Além disso, as Redes Neurais Recorrentes têm sido amplamente utilizadas em diversas aplicações que envolvem análise sequencial e previsão de séries temporais, devido à sua capacidade de lidar com dependências temporais e memória de curto prazo.

Portanto, as principais características das Redes Neurais Recorrentes tem posição de destaque, o que as tornam frequentemente aplicáveis a problemas de análise sequencial, como previsão de séries temporais, processamento de linguagem natural e reconhecimento de padrões em dados sequenciais, como apontado a seguir:

Capacidade de lidar com dependências temporais: As RNNs foram projetadas para processar dados sequenciais, onde a ordem e as relações entre os elementos são relevantes. Elas possuem conexões em forma de loop, permitindo que informações anteriores influenciem as previsões futuras.

Memória de curto prazo: As RNNs exibem uma forma de memória interna que lhes permite reter informações recentes durante a análise de sequências longas. Essa

funcionalidade é particularmente valiosa em tarefas nas quais os contextos anteriores são relevantes para a etapa subsequente.

Flexibilidade e Adaptabilidade: As Redes Neurais Recorrentes apresentam natureza versátil, permitindo sua aplicação a ampla gama de problemas, desde a tradução automática até a previsão de séries temporais. Além disso, existem variações específicas das RNNs, como as Redes LSTM (Long Short-Term Memory) e GRU (Gated Recurrent Unit), que lidam de maneira mais eficaz com desafios como o problema de desaparecimento do gradiente e a capacidade de modelar dependências de longo prazo nos dados.

Adequação para dados sequenciais: Quando os dados apresentam estrutura sequencial, como séries temporais, textos ou áudio, as Redes Neurais Recorrentes se configuram como escolha natural, devido à sua capacidade de processar e aprender com esse tipo de estrutura de dados.

Portanto, a utilização de Redes Neurais Recorrentes na previsão do score de pontuação e nível energético dos data centers é justificada pela necessidade de capturar e modelar as dependências temporais e padrões sequenciais presentes nos dados de consumo energético, tempo de processamento e custos de alocação de recursos. Como discutido, a eficiência energética é um aspecto fundamental na gestão de data centers, e a capacidade de prever com precisão o desempenho energético pode fornecer informações valiosas para a otimização e implementação de melhorias sustentáveis.

Dessa maneira, a implementação de Redes Neurais Recorrentes pode auxiliar na identificação de oportunidades para melhoria da eficiência energética, contribuindo para diminuição do consumo de energia e dos custos operacionais, além de promover uma operação mais sustentável e eficiente dos data centers.

2.6 Algoritmos Bioinspirados

Com o crescimento exponencial de dados e a complexidade crescente de problemas nas mais diversas áreas, tem se intensificado a demanda por métodos de otimização e resolução de problemas que possam lidar com grandes espaços de busca, incertezas e variabilidade. As abordagens tradicionais de otimização, como métodos analíticos e algoritmos de busca exaustiva, muitas vezes falham em encontrar soluções satisfatórias em tempo razoável, quando aplicadas a problemas de grande escala e alta complexidade. Nesse contexto, os algoritmos bioinspirados emergem como solução alternativa promissora, capaz de imitar processos naturais para resolver problemas computacionalmente complexos de forma eficiente e adaptativa (JOHNVICTOR et al., 2022; NGUYEN et al., 2020; HAMMOOD; ZAMIL; ALI, 2017; FAN et al., 2020; SOARES et al., 2021).

Os algoritmos bioinspirados, também conhecidos como algoritmos inspirados na natureza, são abordagens computacionais que emulam processos naturais para resolver problemas de otimização e busca complexos. Baseados em comportamentos e mecanismos biológicos, como a evolução, a cooperação entre organismos e o sistema imunológico, esses algoritmos proporcionam formas eficazes e flexíveis de explorar e encontrar soluções em espaços de busca extensos e complexos. Nos últimos anos sua disseminação aumentou, devido à sua aplicabilidade em diversas áreas, incluindo otimização, machine learning, processamento de imagens, redes de sensores e robótica.

A principal vantagem dos algoritmos bioinspirados está na sua capacidade de se adaptar, pois oferecem abordagem flexível, podendo ajustar suas estratégias de busca em tempo real para se adaptar a diferentes configurações e exigências onde múltiplos objetivos e restrições coexistam. Ou seja, são desenhados para replicar a adaptabilidade e a resiliência observadas em sistemas da natureza, possibilitando a resolução de problemas complexos em contextos onde métodos tradicionais apresentam limitações, como a convergência prematura e a dependência de parâmetros específicos.

Ao utilizar mecanismos naturais de busca e adaptação, algoritmos bioinspirados conseguem equilibrar dois aspectos fundamentais no espaço de busca: exploração e exploração. A exploração envolve a investigação de novas regiões do espaço de busca, ampliando o alcance do algoritmo para identificar áreas com potencial de soluções ótimas. Em contrapartida, a exploração concentra-se no refinamento das melhores soluções encontradas, otimizando-as para atingir um resultado mais preciso e eficaz. Esse equilíbrio entre explorar novas possibilidades e refinar soluções promissoras torna os algoritmos bioinspirados mais eficientes e capazes de oferecer soluções otimizadas, mesmo em cenários de alta incerteza e complexidade (AGARWAL; RANI; VAJPAYEE, 2024).

Nos tópicos seguintes, são apresentados os principais motivos que justificam o uso de algoritmos bioinspirados, destacando sua flexibilidade, eficiência e capacidade de inovação. Esses fatores tornam essa classe de algoritmos uma escolha indicada para problemas onde a complexidade, a variabilidade e a necessidade de otimização simultânea de múltiplos critérios representam um desafio.

Flexibilidade e Adaptabilidade: Diferentemente dos métodos tradicionais de otimização, que exigem configurações específicas para cada tipo de problema, os algoritmos bioinspirados são amplamente aplicáveis e podem ser ajustados para diferentes contextos e parâmetros. A exemplo de ambiente de rede de sensores sem fio, onde a configuração ideal muda dinamicamente, algoritmos como Otimização por Enxame de Partículas (PSO) e Otimização por Colônia de Formigas (ACO) conseguem adaptar-se às condições do ambiente para minimizar o consumo de energia e maximizar a análise das possibilidades.

Solução para Problemas Não Lineares e Multiobjetivos: Muitos problemas reais, como otimização de redes de transporte, planejamento urbano e alocação de recursos, apresentam características não lineares e possuem múltiplos objetivos, às vezes conflitantes. Algoritmos bioinspirados são inerentemente capazes de lidar com tais problemas, pois imitam sistemas naturais que enfrentam condições semelhantes. Através da seleção natural ou da cooperação entre agentes, esses algoritmos encontram soluções que equilibram múltiplos objetivos, proporcionando resultados otimizados que atendem simultaneamente a vários critérios.

Eficiência em Espaços de Busca Complexos: Um dos maiores desafios em problemas de grande escala é a dimensão do espaço de busca, que aumenta exponencialmente com o número de variáveis e restrições. Os algoritmos bioinspirados, como os Algoritmos Genéticos, conseguem reduzir significativamente o tempo de busca ao aplicar operadores como seleção, cruzamento e mutação, que permitem a exploração ampla e diversificada do espaço de busca, evitando, ao mesmo tempo, a convergência prematura. Isso os torna ideais para problemas onde o tempo de processamento é fator importante.

Adaptabilidade e Resiliência: Inspirados em sistemas biológicos que demonstram alta resiliência a falhas e capacidade de adaptação em ambientes adversos, os algoritmos bioinspirados são projetados para operar de modo adaptável em condições desafiadoras, como ambientes com informações incompletas ou incertas. Em aplicações críticas, como detecção de intrusões em segurança cibernética, essas características oferecidas por sistemas imunológicos artificiais permite detectar padrões anômalos e responder rapidamente a ameaças emergentes, garantindo um nível elevado de segurança e confiabilidade.

Inspiração para Soluções Inovadoras: Muitos dos processos naturais que inspiram esses algoritmos possuem características que desafiam a lógica tradicional, como a auto-organização e a emergência de comportamento complexo a partir de interações simples. Ao modelar soluções com base em tais processos, os algoritmos bioinspirados oferecem abordagens inovadoras que podem superar limitações convencionais e abrir novas possibilidades em áreas como robótica autônoma, inteligência artificial distribuída e aprendizado de máquina. Essas características ampliam o leque de aplicações e tornam os algoritmos bioinspirados uma escolha viável para problemas de otimização e aprendizado que exigem adaptabilidade e criatividade.

Os algoritmos bioinspirados continuam a se destacar como ferramentas inovadoras e poderosas para resolver problemas complexos em diferentes áreas. Sua capacidade de adaptar e evoluir soluções com base em processos biológicos oferece vantagens em contextos onde métodos tradicionais de otimização falham ou são inefficientes. No entanto, sua implementação requer um cuidado especial em relação a custos computacionais e

parâmetros de controle, especialmente para evitar convergência prematura e sobrecarga de processamento.

2.7 Considerações Finais

Este capítulo ofereceu uma visão abrangente e detalhada sobre a computação em nuvem, com ênfase especial quanto à sustentabilidade e à eficiência energética, elementos fundamentais para a computação em nuvem verde. As discussões aqui abordadas são essenciais para a compreensão do papel da computação em nuvem no contexto atual de transformação digital e de preocupação ambiental.

A análise dos diferentes modelos de serviços em nuvem, como SaaS, PaaS, IaaS, entre outros, e as arquiteturas de nuvem, incluindo nuvem privada, pública, híbrida e comunitária, fornecem base sólida para compreender as diversas possibilidades de implementação e uso da nuvem. A exploração desses modelos destaca a versatilidade e adaptabilidade da computação em nuvem para diferentes necessidades organizacionais e operacionais.

Um aspecto central abordado é a relevância da eficiência energética e sustentabilidade em data centers e na computação em nuvem, refletindo a crescente conscientização quanto ao impacto ambiental da tecnologia. A computação em nuvem verde, como solução para minimizar esse impacto, surge como campo promissor e necessário, enfatizando práticas como o uso de energias renováveis, otimização de recursos e gestão eficiente de resíduos.

Além disso, a discussão sobre características essenciais da computação em nuvem, como o autoserviço sob demanda e a elasticidade rápida, destaca a capacidade dessa tecnologia de oferecer soluções dinâmicas e escaláveis, características fundamentais para enfrentar os desafios do cenário tecnológico atual.

Por fim, a introdução do uso do CloudSim Plus enquanto ferramenta de simulação para ambientes de computação em nuvem estabelece a base para experimentos práticos e análises que estão detalhados no capítulo seguinte. Esta ferramenta será utilizada para simular cenários de computação em nuvem verde, permitindo uma análise aprofundada dos benefícios e desafios associados à implementação de práticas sustentáveis em ambientes de nuvem.

Em resumo, este capítulo estabelece fundamento teórico robusto e abrangente, conectando-se diretamente ao objetivo de explorar e avaliar a viabilidade e eficácia da computação em nuvem verde.

No capítulo subsequente, o foco se desloca para a revisão de trabalhos relacionados ao campo da computação em nuvem verde e da eficiência energética. Essa análise crítica permitirá identificar lacunas no conhecimento atual, desafios enfrentados e

soluções propostas por pesquisadores e profissionais da área. Assim, o próximo capítulo serve como ponte entre a fundamentação teórica aqui estabelecida e a pesquisa aplicada e experimental que se seguirá, contribuindo para uma maior compreensão do papel e da importância da computação em nuvem verde.

3 Trabalhos Relacionados

Este capítulo é dedicado à análise crítica e sistematizada de estudos e pesquisas correlatas no âmbito da computação em nuvem verde, enfocando especialmente as abordagens adotadas por diferentes pesquisadores para otimizar a eficiência energética em data centers e minimizar o impacto ambiental. O propósito desta revisão é estabelecer um panorama do estado da arte, identificando lacunas, tendências e áreas potenciais para futuras investigações.

3.1 O Estado da Arte

Para embasar o estudo proposto nesta tese e identificar possíveis lacunas na literatura existente, realizou-se pesquisa extensiva em trabalhos relacionados, focando nas seguintes principais palavras-chave de busca:

- Green Cloud Computing
- Green IT
- Cloud Computing Simulator
- Cloudsim Simulator
- Green Cloud Computing Simulation
- Cloud Computing Sustainability
- Renewable Energy Cloud Computing
- Approaches Energy Efficient Cloud
- Management Strategies Cloud Data Centers
- Energy Reduction Strategies Cloud Computing
- Energy Efficiency Cloud Computing
- Green Cloud Computing Algorithms

A pesquisa realizada por ([SRIRAM, 2022](#); [SETYANINGRUM](#); [KHOLID](#); [SUSILO, 2023](#); [ANSER et al., 2021](#)) apresenta análises abrangentes sobre a necessidade e os benefícios da computação verde, destacando a importância de tornar as operações de TI mais sustentáveis nos mais diversos campos. Explora também as relações

dinâmicas entre fatores tecnológicos e emissões de carbono, as características-chave da computação em nuvem verde, identifica barreiras para sua adoção e destaca seu potencial para mitigar o impacto ambiental de data centers.

Adicionalmente, (BHARANY et al., 2022) têm como objetivo realizar pesquisa sistemática sobre técnicas de eficiência energética em computação em nuvem, visando contribuir para a sustentabilidade desse setor. Os resultados apresentam uma visão abrangente das técnicas existentes, seu impacto e eficácia na redução do consumo de energia em data centers em nuvem.

Quanto à análise e previsão de utilização de recursos, os simuladores de computação em nuvem têm se destacado devido à inviabilidade de acessar um ambiente complexo de nuvem para experimentação prática. Por conseguinte, são apresentados estudos que empregam metodologias e simuladores com o propósito de pesquisa em ambientes de nuvem.

Vários pesquisadores têm utilizado o CloudSim como ferramenta de simulação para realizar experimentos com algoritmos tais como DPSO, DENS, Round Robin, Green Scheduler e Algoritmo Genético (YANG et al., 2018; WADHWA et al., 2019; ZONG, 2020; CHOPRA; RANGARAJAN; SEN, 2021). A análise dos resultados visa comparar esses algoritmos, considerando tempos de execução e consumo energético.

Por outro lado, a pesquisa realizada por (SILVA et al., 2022) compara simuladores CloudSim e iSPD, evidenciando a eficácia deste último e oferecendo assim uma alternativa para os pesquisadores investigarem.

Nos estudos de (MEYER et al., 2018; MAKARATZIS; GIANNOUTAKIS; TZOVARAS, 2018; JENA et al., 2020), foram conduzidos testes utilizando diferentes ferramentas de simulação em computação em nuvem, bem como diversos algoritmos, incluindo a abordagem First-Fit e Round Robin. O objetivo dessas pesquisas foi analisar e comparar os resultados alcançados pelos simuladores.

Outras abordagens, como (SHU; CAI; XIONG, 2021) utilizam algoritmos baseados no modelo SARO, no qual avaliam o impacto através da predição, levando em consideração a relação de fatores como fila de requisições, carga dos servidores e o congestionamento da rede em servidores Hadoop, ao passo que (BISWAS et al., 2021) utilizam a regressão para prever o tempo de resposta, de forma a garantir o SLA e consequentemente realizar as migrações das máquinas virtuais.

Ainda como estratégias utilizando algoritmos de alocação, tem-se os estudos de (SHU; CAI; XIONG, 2021; BISWAS et al., 2021; MOHAMMADZADEH et al., 2021), que utilizam algoritmos não convencionais para a otimização do escalonamento de tarefas, como Strong Agile Response Task, Chaotic Binary Grey Wolf e Regressão Linear, com resultados promissores na redução do consumo energético.

O estudo de (STERGIOU; PSANNIS; ISHIBASHI, 2020) explora a computação em nuvem sustentável no contexto da aplicação de Big Data. Em suas análises, confrontam os resultados usando o indicador DCIE, observando-se redução significativa no consumo de energia, alcançando pelo menos 47%. Em contrapartida, (SABOOR et al., 2022) realizam sua pesquisa utilizando algoritmos fundamentados na distribuição e classificação, ao comparar os resultados referentes às métricas relacionadas à emissão de CO₂.

Em relação a abordagens utilizando inteligência artificial, tem-se os estudos de (PANWAR; RAUTHAN; BARTHWAL, 2022; KHAN et al., 2022) que, além da revisão sistemática, têm como objetivo apresentar diferentes estratégias de gerenciamento de energia em data centers em nuvem e avaliar sua eficácia e viabilidade através de métodos heurísticos, metaheurísticos, de aprendizado de máquina e estatísticos para previsão de carga, consumo de energia e gerenciamento de recursos e redução do consumo de energia em data centers.

Por outro lado, a abordagem da eficiência energética por meio da consolidação dinâmica de máquinas virtuais (VMs) foi realizada por (KHAN, 2021; SAYADNAVAR; HAGHIGHAT; RAHMANI, 2022), tendo por objetivo principal reduzir o consumo de energia através da alocação dinâmica das VMs. Os resultados demonstram melhoras significativas na eficiência energética, redução de SLA e aumento da confiabilidade do sistema, destacando-se a relevância da abordagem proposta para aprimorar a gestão de recursos em ambientes de computação em nuvem.

(NGUYEN et al., 2020) investigam o uso de técnicas bioinspiradas na gestão de energia, aplicadas especialmente em sistemas inteligentes de gerenciamento, como HEMS e BEMS. Inspiradas na evolução biológica e em comportamentos coletivos observados na natureza, essas abordagens oferecem soluções inovadoras para otimização em redes elétricas, destacando-se a computação evolutiva e a inteligência de enxame, que se baseiam na seleção natural e nas interações sociais observadas em espécies como formigas e abelhas.

Enquanto que (POP et al., 2022) revisam metaheurísticas bioinspiradas aplicadas à otimização de redes elétricas renováveis, destacando as técnicas mais citadas desde 2016. Utilizando a metodologia PRISMA, o estudo analisa cinquenta e quatro artigos e identifica quatro principais áreas de aplicação, como a previsão de energia renovável e a eficiência em redes inteligentes. Os autores apontam desafios como a necessidade de mapeamentos claros entre técnicas e problemas específicos e metodologias de teste padronizadas, oferecendo base teórica para pesquisas futuras.

Por outro lado, (MUKHERJEE; GANGULY; DAHIYA, 2023) discutem arquiteturas de energia distribuída inspiradas em sistemas biológicos para melhorar a autonomia de robôs. O estudo destaca a demanda energética de 50 a 100 Wh para robôs avançados e propõe o uso de supercapacitores, baterias e técnicas de captação de energia, como

células solares flexíveis. Além disso, aborda desafios como a gestão eficiente de energia e a redução do peso dos dispositivos, sugerindo que tecnologias avançadas são essenciais para robôs autossustentáveis em ambientes sem acesso à rede elétrica.

Quanto a outras metodologias para a computação em nuvem sustentável, (ARAÚJO et al., 2022) oferecem uma visão global do uso de fontes energéticas renováveis, nas quais provedores de nuvem podem não apenas utilizar tais tecnologias, mas também investir e fomentar pesquisas nessa área.

Com referência às abordagens sobre geração de energia verde, o estudo realizado por (FRANÇA et al., 2020) aborda a aplicação de algoritmos de redes neurais na previsão da energia eólica, com o intuito de avaliar a viabilidade desse tipo de modelo para grandes data centers.

3.2 Comparativo entre Trabalhos Relacionados ao Tema

Comparar os resultados obtidos nos trabalhos apontados na Seção 3.1 requereu esforços, devido ao fato de os trabalhos apresentarem diferenças nas metodologias, nos dados históricos e nos objetivos da predição dos seus experimentos. Entretanto, foi possível extrair algumas conclusões, listadas no comparativo apresentado a seguir.

Para facilitar a análise dos trabalhos apresentados neste capítulo, o comparativo contido na Tabela 1 destaca as principais características, metodologias, resultados e contribuições dos estudos analisados. Esta Tabela facilita a visualização das diferenças e semelhanças entre os trabalhos, ajudando a identificar as tendências atuais e suas possíveis lacunas ou limitações.

Tabela 1 – Comparativo entre trabalhos relacionados ao tema

Autores	Foco do Estudo	Metodologias/ Ferramentas	Resultados	Contribuições	Lacunas ou Limitações
ÁREA: COMPUTAÇÃO EM NUVEM VERDE					
(SRIRAM, 2022)	Necessidade e benefícios da computação verde	Análise qualitativa	Importância da sustentabilidade na TI	Destaca a inter-relação entre TI e sustentabilidade	Falta de dados quantitativos
(SETYANINGRUM; KHO-LID; SUSILO, 2023)	Relações entre fatores tecnológicos e emissões de carbono	Revisão de literatura	Características-chave da computação em nuvem verde	Identificação de barreiras para a adoção	Limitado a uma revisão teórica
Continua na próxima página					

Tabela 1 – continuação da página anterior

Autores	Foco do Estudo	Metodologias/ Ferramentas	Resultados	Contribuições	Lacunas ou Limitações
(ANSER et al., 2021)	Importância da computação verde e suas dinâmicas	Análise crítica	Relações entre tecnologia e emissões, barreiras para adoção	Destaque da computação verde para mitigação ambiental	Necessidade de mais estudos aplicados
(BHARANY et al., 2022)	Técnicas de eficiência energética	Pesquisa sistemática	Visão abrangente das técnicas de eficiência energética & Impacto e eficácia na redução do consumo de energia	Contribuição para a sustentabilidade no setor de TI	Falta de experimentação prática

ÁREA: SIMULADORES

(YANG et al., 2018)	Comparação de algoritmos de escalonamento	Simulação com CloudSim	Comparação de eficácia entre algoritmos	Avaliação de eficiência energética de algoritmos	Limitado a simulações
(WADHWA et al., 2019)	Escalonamento de tarefas	Simulação com CloudSim	Comparação de eficiência energética	Avaliação de algoritmos de escalonamento	Limitado a simulações
(ZONG, 2020)	Melhoria em algoritmos de escalonamento	Simulação	Redução de consumo energético	Inovação em algoritmos de escalonamento	Foco em um único algoritmo
(CHOPRA; RANGARAJAN; SEN, 2021)	Sustentabilidade em servidores Hadoop	Análise de desempenho	Otimização de recursos em Hadoop	Propostas para eficiência energética	Restrito ao Hadoop
(SILVA et al., 2022)	Comparação entre CloudSim e iSPD	Análise comparativa	Eficácia do simulador iSPD	Oferece alternativa para pesquisa em nuvem	Foco limitado a dois simuladores
(MEYER et al., 2018)	Testes com diferentes ferramentas de simulação	Experimentação prática	Análise de diferentes ferramentas de simulação	Avalia a adequação de ferramentas para a pesquisa em nuvem	Não aborda técnicas de sustentabilidade

Continua na próxima página

Tabela 1 – continuação da página anterior

Autores	Foco do Estudo	Metodologias/ Ferramentas	Resultados	Contribuições	Lacunas ou Limitações
(MAKARATZIS; GIANNOU-TAKIS; TZOVARAS, 2018)	Testes com ferramentas de simulação e algoritmos	Ferramentas de simulação	Análise de diferentes algoritmos de simulação	Insights sobre uso de ferramentas de simulação	Limitado a comparação com ambientes
(JENA et al., 2020)	Comparação de ferramentas e algoritmos de simulação	Ferramentas e algoritmos diversos	Comparativo de eficácia entre diferentes ferramentas e algoritmos	Avaliação de diferentes algoritmos para computação em nuvem	Restrito a testes em cenários

ÁREA: ALGORITMOS

(SHU; CAI; XIONG, 2021)	Algoritmos baseados no modelo SARO	Simulação de carga de servidores	Impacto na eficiência de servidores Hadoop	Otimização de carga em servidores	Restrito ao contexto Hadoop
(BISWAS et al., 2021)	Previsão do tempo de resposta para garantir SLA	Regressão estatística	Eficiência na previsão do tempo de resposta	Melhoria no gerenciamento de SLAs	Foco em um único aspecto do desempenho
(MOHAMMADZADEH et al., 2021)	Otimização do escalonamento de tarefas	Algoritmos não convencionais	Redução do consumo energético	Inovação em escalonamento de tarefas	Limitações na generalização dos ambientes
(STERGIOU; PSANNIS; ISHIBASHI, 2020)	Big Data e computação em nuvem sustentável	Experimentos com indicador DCIE	Redução significativa no consumo de energia	Abordagens para Big Data sustentável	Restrito a casos de Big Data
(SABOOR et al., 2022)	Análise de emissão de CO2	Algoritmos de distribuição e classificação	Redução de emissões de CO2	Foco em sustentabilidade e redução de carbono	Foco limitado a emissões de CO2

ÁREA: INTELIGENCIA ARTIFICIAL

(PANWAR; RAUTHAN; BARTHWAL, 2022)	Gerenciamento de energia em data centers	Revisão sistemática de IA	Estratégias de gerenciamento de energia	Avaliação de eficácia e viabilidade	Falta de experimentação prática
(KHAN, 2021)	Eficiência energética em VMs	Consolidação dinâmica de VMs	Melhorias na eficiência energética	Abordagem inovadora para gestão de VMs	Foco em uma única estratégia

Continua na próxima página

Tabela 1 – continuação da página anterior

Autores	Foco do Estudo	Metodologias/ Ferramentas	Resultados	Contribuições	Lacunas ou Limitações
(SAYAD-NAVARO; HAGHIGHAT; RAHMANI, 2022)	Consolidação dinâmica de VMs	Algoritmos de alocação dinâmica	Melhorias significativas na eficiência energética	Uso eficaz de consolidação de VMs	Não utilizou diferentes cargas de trabalho

ÁREA: OUTRAS ABORDAGENS

(ARAÚJO et al., 2022)	Uso de fontes energéticas renováveis	Visão global	Viabilidade do uso de tecnologias renováveis	Provedores de nuvem e energias renováveis	Falta de experimentação prática
(FRANÇA et al., 2020)	Previsão de energia eólica	Redes neurais	Viabilidade da energia eólica para data centers	Uso de IA para energia sustentável	Limitado ao contexto da energia eólica

Avançando com relação aos trabalhos acima apresentados, concentrados em aspectos específicos ou isolados da eficiência energética e sustentabilidade, esta tese propõe uma abordagem mais ampla, que combina a caracterização de ambientes computacionais, a aplicação de uma variedade de abordagens e algoritmos de eficiência energética e a construção de base de dados robusta, a partir de simulações. Esta abordagem multidimensional e inovadora permite não apenas a comparação da eficácia de diferentes estratégias de sustentabilidade, mas também identificar padrões e tendências que podem não ser evidentes em análises mais específicas.

Sendo assim, esta tese apresenta contribuições robustas ao campo da computação em nuvem verde, destacando-se dos trabalhos acima relacionados por incorporar uma abordagem metodológica e analítica inovadora.

Tem por objetivo central desenvolver um modelo que relacione consumo de energia, redução energética e emissão de CO₂ equivalente, culminando na criação de metodologia capaz de analisar a eficiência energética por meio do cálculo de scores e de um modelo de labels de eficiência energética. Além disso, a aplicação de técnicas de inteligência artificial no âmbito do trabalho agrega valor, ao identificar padrões e classificar níveis de eficiência com mais precisão, abrindo caminho para novas estratégias de otimização.

Esta pesquisa se diferencia dos estudos existentes, ao proporcionar uma ferramenta quantitativa que facilita a tomada de decisões em data centers, ao relacionar métricas de desempenho com padrões de sustentabilidade. Por meio de análises estatísticas rigorosas e simulações detalhadas no CloudSim Plus, a pesquisa oferece solução abrangente para analisar e melhorar a eficiência energética e operacional de data centers. Desse modo, este trabalho não apenas valida as metodologias existentes,

mas também propõe um avanço significativo, ao contribuir para melhorar a eficiência energética e reduzir o impacto ambiental dos data centers.

3.3 Considerações Finais

Este capítulo, dedicado aos trabalhos relacionados à área da computação em nuvem verde, proporciona entendimento amplo e contextualizado quanto às diversas abordagens e metodologias adotadas nessa área. A revisão de pesquisas representativas na área destacou a diversidade de estratégias existentes, tanto em termos de software quanto de hardware, voltadas para promover a sustentabilidade e eficiência em ambientes de computação em nuvem.

A análise abrangente de estudos focados em aspectos como eficiência energética, sustentabilidade operacional e uso de simuladores para pesquisa em ambientes de nuvem ressaltou a complexidade e a multifacetada natureza da computação em nuvem verde. Trabalhos que exploram o uso de inteligência artificial, algoritmos de otimização de recursos e a aplicação de fontes de energia renováveis, como detalhado por autores como Sriram, Setyaningrum, Anser e outros, sublinham a necessidade e os benefícios de práticas sustentáveis na TI.

A compilação e comparação de diferentes metodologias e ferramentas de simulação, como o CloudSim e iSPD, entre outras, ilustraram as variadas abordagens e técnicas usadas para tratar problemas de eficiência e sustentabilidade em data centers e serviços em nuvem. Essa análise comparativa, resumida na Tabela 1, ofereceu visão clara do estado atual da pesquisa na área e o direcionamento futuro que a computação em nuvem verde pode vir a tomar.

A revisão dos trabalhos relacionados ao tema desempenha uma etapa fundamental na estruturação de uma tese, pois fornece pano de fundo crítico com relação ao qual a pesquisa pode ser posicionada. As lacunas identificadas e o aprendizado a partir desses estudos constituiram um marco para o desenvolvimento desta pesquisa.

No próximo capítulo, a atenção se volta para a metodologia da pesquisa. Será apresentada a estrutura metodológica adotada para o modelo proposto, incluindo a seleção das ferramentas de simulação, a definição dos parâmetros do estudo e a concepção dos experimentos. A metodologia está alinhada aos insights obtidos a partir da revisão dos trabalhos relacionados, garantindo que o estudo contribua efetivamente para o campo da computação em nuvem verde, tanto em termos de pesquisa acadêmica quanto da prática.

4 Metodologia

Este capítulo aborda a metodologia empregada na pesquisa, cujo foco central é a análise de requisitos, o projeto e o desenvolvimento de modelo de relação entre Consumo de Energia, Redução Energética e Emissão de CO₂ equivalente, na computação em nuvem verde.

Inicialmente, descreve-se o modelo de forma ampla na Seção 4.1.1, oferecendo uma visão abrangente de todo o processo proposto no trabalho. Além disso, essa seção permite uma compreensão detalhada de cada etapa do diagrama e das atividades realizadas ao longo da pesquisa. Isto é fundamental para a compreensão não apenas do resultado final, mas também das etapas intermediárias que levaram à sua concepção e implementação.

Posteriormente, são discutidas diversas abordagens e algoritmos de eficiência energética submetidos ao ambiente de simulação (Seção 5.1). Esta etapa envolve a escolha do ambiente adequado de simulação de computação em nuvem verde, seguida pela seleção dos algoritmos mais promissores e sua implementação no ambiente da simulação. O objetivo é testar e comparar a eficácia de diferentes estratégias de escalonamento de recursos em termos do consumo de energia e eficiência operacional, de forma a refletir as condições reais.

O capítulo segue com a explicação do processo de construção da base de dados (Seções 4.2 e 4.3). Estas fases são fundamentais para a coleta e organização dos dados gerados pelas simulações. Os dados coletados são essenciais para a análise subsequente e avaliação dos algoritmos de escalonamento.

Além disso, é detalhada na Seção 4.4 a metodologia desenvolvida para analisar a abordagem mais eficiente por meio de uma proposta de cálculo de scores. Essa seção foca na construção de uma métrica quantitativa, que permite avaliar e comparar a eficiência energética das diferentes configurações e algoritmos testados.

Finalmente, é apresentado na Seção 4.5 o desenvolvimento de modelo de labels de eficiência energética. Este modelo faz uso da inteligência artificial para a classificação, oferecendo meio inovador e eficiente para categorizar data centers com base em seu desempenho energético. O capítulo conclui enfatizando a importância de cada uma destas etapas e como elas se interconectam para formar a base metodológica da pesquisa.

4.1 Metodologia Adotada

O estudo desenvolve abordagem inovadora para investigar e classificar a eficiência energética em data centers de computação em nuvem verde, com foco no cálculo dos scores de eficiência energética e na introdução de sistema de níveis energéticos, utilizando redes neurais para a classificação desses níveis.

Tal como exposto acima, a metodologia adotada tem por objetivo garantir a precisão, relevância e validade dos resultados obtidos. Em decorrência, é detalhada cada etapa do processo metodológico, incluindo a configuração do ambiente de simulação, seleção e implementação dos algoritmos de eficiência energética, construção da base de dados e o desenvolvimento do sistema de cálculo de scores e de classificação.

4.1.1 Modelo de Eficiência Energética

O diagrama a seguir, visualizado na figura 4, representa um mapa conceitual, no qual está delineada cada etapa do processo de pesquisa, desde a configuração inicial do ambiente de simulação até a análise final dos resultados. Oferece visão abrangente do fluxo de trabalho e das interações entre os diferentes componentes do estudo. A interpretação detalhada de cada etapa do diagrama fornece insights sobre como os dados foram coletados, processados e analisados, permitindo a compreensão clara da metodologia empregada. Também destaca a integração sistêmica entre as diferentes fases de análise da eficiência energética na computação em nuvem verde.




Figura 4 – Modelo de Eficiência Energética

Fonte: autor

O processo é iniciado com a etapa 1, seleção dos algoritmos de escalonamento,

seguida da etapa 2, de definição da infraestrutura do data center. Essa escolha pode basear-se em sua representatividade na literatura especializada, na contribuição potencial para a eficiência energética ou na arquitetura real do data center. Nessa etapa, também se faz necessário estabelecer a configuração de base, ou baseline, como parâmetro inicial de comparação, essencial para os cálculos subsequentes de eficiência. A etapa seguinte é a 3, de configuração do simulador. Neste estudo foi utilizado o CloudSim Plus, com as definições, estruturas e algoritmos explicitados anteriormente na Seção 2.4.

No âmbito deste estudo, a etapa 4, de execução de simulações detalhadas e a etapa 5, coleta de dados, concentram-se na execução de simulações detalhadas e no monitoramento rigoroso do desempenho do data center. Esta fase é responsável pela coleta de dados essenciais, como o consumo de energia, tempo de execução das aplicações, custos operacionais e emissões de CO₂ equivalente (CO_{2eq}). A análise desses dados é fundamental para quantificar e avaliar a eficiência energética dos algoritmos sob condições operacionais variadas.

Avançando para a segunda fase do modelo, a etapa 6, de cálculo dos scores, assume um papel central. Envolve a normalização dos dados coletados, seguida da aplicação de algoritmo previamente selecionado. O resultado é uma pontuação que reflete a eficiência energética de cada configuração analisada, com pesos atribuídos a critérios como tempo de execução, consumo de energia, emissões de CO₂ e custos. Esta abordagem fornece avaliação quantitativa do desempenho energético das configurações.

Seguindo o fluxo do modelo proposto, a etapa 7, de classificação em níveis energéticos, é realizada por meio de classificadores de inteligência artificial, especificamente redes neurais. Nesta etapa é utilizada abordagem inovadora e preditiva na classificação do desempenho energético dos algoritmos sob diferentes condições operacionais, o que permite a categorização eficiente dos níveis energéticos.

Finalmente, o modelo contempla a etapa 8, de identificação do nível energético do data center. O resultado fornece insights cruciais para a implementação de intervenções eficazes, facilitando a tomada de decisão quanto a operações otimizadas e sustentáveis.

4.2 Processo de Coleta de Dados

A coleta de dados constituiu componente essencial deste estudo, na qual resultados de todas as 800 simulações executadas foram meticulosamente coletados. Este processo incluiu a coleta de informações detalhadas sobre o desempenho de cada algoritmo de escalonamento em diferentes configurações e cenários de carga de trabalho (Seção 5.3).

Os dados coletados abrangeram uma gama de métricas relevantes, incluindo mas não limitadas a:

- **Tempo de Execução:** mede a eficiência operacional dos algoritmos em termos de rapidez no processamento das tarefas.
- **Custo de Execução:** baseado em custos reais de execução, conforme ([AMAZON, 2023b](#)), o Cloudsim produziu as informações dos custos diretamente a partir de cada execução das simulações.
- **Consumo de Energia:** objetiva fornecer insights sobre a sustentabilidade e eficiência energética dos algoritmos.
- **Emissões de CO₂:** o Cloudsim não provê informações sobre a emissão de CO₂ equivalente, contudo, a partir de informações fornecidas pela ([EPA, 2022](#)), foi possível realizar o cálculo das emissões, uma vez que os parâmetros utilizados foram os americanos.

Essas métricas foram consolidadas e apresentadas nas Tabelas correspondentes, tendo em vista sua análise mais aprofundada.

4.3 Análise dos Resultados

Após exame em profundidade dos dados coletados nas simulações, foi realizada análise dos resultados, com ênfase no cálculo de ganhos percentuais em eficiência e desempenho. A metodologia de análise utilizou abordagens estatísticas para comparar os resultados alcançados por cada algoritmo, possibilitando compreensão clara das vantagens e desvantagens de cada método em termos de eficiência energética e operacional. Ainda, permitiu identificar tendências gerais, padrões e insights que podem direcionar futuras investigações e desenvolvimentos na área da computação em nuvem verde (Cap. 5, Resultados e Discussão).

A análise dos resultados obtidos concentra-se principalmente na avaliação do desempenho dos algoritmos de escalonamento de máquinas virtuais sob diferentes configurações de carga de trabalho e sua implicação na eficiência energética dos data centers.

4.3.1 Estratégia de Análise

Inicialmente foi feita a consolidação dos dados referentes aos tempos de execução, consumo energético, custos operacionais e emissão de CO_{2eq}, categorizando-os conforme os diferentes algoritmos e configurações de máquinas virtuais. Esta foi efetuada por meio de tabelas comparativas, facilitando o reconhecimento de melhorias de desempenho e reduções de custos e emissões.

4.3.2 Interpretação dos Dados

Parte desta seção foi dedicada ao cálculo de ganhos percentuais em eficiência energética e operacional. Esses cálculos permitiram identificar quais algoritmos e configurações ofereceram os melhores resultados em termos de redução do consumo de energia e aumento da eficiência operacional.

4.3.3 Impacto Ambiental e Operacional

Foi dada especial atenção ao impacto ambiental dos algoritmos, tendo a emissão de CO_{2eq} servido como indicador-chave de sustentabilidade. Ao mesmo tempo, foram analisados os custos operacionais e o tempo de execução, de modo a assegurar que a eficiência energética não comprometesse a performance ou a viabilidade financeira dos data centers.

4.3.4 Metodologia de Análise

A análise dos resultados deste estudo foi realizada utilizando um desenho de experimento fatorial completo, onde os testes foram planejados para fornecer uma análise abrangente da performance dos sistemas computacionais em estudo. Cada teste foi executado dez vezes, de modo a assegurar a precisão e a confiabilidade dos resultados (MAINARDI; BIDOIA, 2020).

Entre os métodos estatísticos utilizados, encontra-se o cálculo da média dos resultados com intervalo de confiança de 95%. O intervalo de confiança foi determinado usando a distribuição t de Student (FERNANDES et al., 2021), adequada para amostras de tamanho menor e quando o desvio padrão da população é desconhecido. Este método permite afirmar que o verdadeiro valor médio do parâmetro de interesse está dentro do intervalo especificado. A análise incluiu a avaliação do tempo de execução, consumo de energia, custos operacionais e emissões de CO_{2eq}, proporcionando uma visão abrangente do desempenho de cada algoritmo.

4.3.5 Indicadores Avaliados

A análise incluiu o tempo de execução, eficiência energética, o consumo de energia, as emissões de CO₂ e custos de execução operacional. Os resultados são fundamentais para compreender como cada algoritmo influencia a sustentabilidade e eficiência de data centers na computação em nuvem verde.

4.4 Scores de Eficiência Energética

Esta etapa da metodologia é dedicada ao detalhamento do cálculo dos scores de eficiência energética, elemento essencial na avaliação do desempenho de data center na computação em nuvem verde, permitindo a avaliação objetiva e comparativa do desempenho dos diversos algoritmos de escalonamento em ambientes de computação em nuvem. Este processo é dividido em várias etapas (Seção 6.1).

4.4.1 Inicialização dos Dicionários e Métricas

O primeiro passo envolve a inicialização dos dicionários e a definição das métricas relevantes para o estudo. Essas métricas incluem fatores como consumo de energia, emissões de CO₂, tempo de execução e custos operacionais. A atribuição de pesos a essas métricas é baseada na sua importância relativa para a eficiência energética, de acordo com os resultados das simulações.

4.4.2 Normalização dos Dados

Devido às diferentes escalas utilizadas nas métricas, é essencial normalizá-las para garantir uma comparação equitativa. A normalização permite que as métricas sejam comparadas em um mesmo patamar, independentemente de suas unidades ou magnitudes originais.

4.4.3 Definição da Baseline

A definição de uma baseline é componente de suma importância no cálculo dos scores de eficiência energética. No contexto deste estudo, a baseline serve como ponto de referência padrão para avaliar e comparar o desempenho dos algoritmos de escalonamento.

O papel da baseline no cálculo dos scores é fornecer um ponto de comparação constante. Os scores de eficiência energética de outros algoritmos e configurações são calculados com base na diferença de desempenho em relação à baseline do RR. Este método permite uma avaliação objetiva da eficiência relativa dos algoritmos examinados.

Para este estudo, o algoritmo Round Robin (RR), com configuração de 50 máquinas virtuais (VMs), foi escolhido como baseline. Esta escolha se baseou na ampla utilização e reconhecimento do RR como método de escalonamento padrão e eficiente em muitos ambientes de computação em nuvem.

4.4.4 Cálculo dos Scores

Após a normalização, procede-se ao cálculo dos scores de eficiência para cada configuração e algoritmo. Este cálculo é realizado utilizando fórmula matemática que integra os pesos atribuídos às métricas. O resultado é um score que reflete a eficiência energética de cada configuração de algoritmo em comparação com a baseline estabelecida.

4.4.5 Classificação dos Algoritmos

Por fim, os algoritmos são classificados com base nos scores calculados. Esta classificação é feita do maior para o menor índice de eficiência, oferecendo uma visão hierárquica do desempenho dos algoritmos. Este ranking é utilizado para identificar as estratégias mais eficientes em termos de eficiência energética e sustentabilidade ambiental.

4.5 Modelo de Nível Energético

Nesta parte da metodologia, é apresentada a escala de nível energético, que representa o cerne da metodologia utilizada. Este modelo é projetado para quantificar a eficiência energética das diferentes configurações e algoritmos em ambiente de computação em nuvem. A escala é dividida em cinco níveis distintos, variando de A a E, cada um representando um grau diferente de eficiência energética (Seção 6.2).

4.5.1 Critérios de Classificação

Os níveis são atribuídos com base nos scores de eficiência energética calculados para as diversas configurações e algoritmos. O algoritmo Round Robin com 50 máquinas virtuais serve como ponto de referência, sendo classificado no nível E, o mais baixo da escala. Por outro lado, o nível A é atribuído para as configurações e algoritmos que alcancem os melhores scores, indicando a mais alta eficiência energética.

4.5.2 Escala Vertical

Os scores obtidos são organizados de forma hierárquica dentro da escala, com os níveis subsequentes (B, C, D e E) representando uma graduação decrescente de eficiência energética. Esta estrutura permite a comparação clara e objetiva entre diferentes métodos de escalonamento e suas respectivas eficácias energéticas.

4.5.3 Escala Horizontal

Um aspecto fundamental da escala horizontal é sua base na proporção entre o consumo e a produção energética de fontes renováveis. Esta abordagem promove a sustentabilidade ambiental ao incentivar o uso de energias renováveis, como solar e eólica, e alinhar o consumo de energia aos padrões de demanda. O modelo operacional busca maximizar a eficiência energética, reduzindo o impacto ambiental e favorecendo práticas sustentáveis.

4.5.4 Classificadores de Inteligência Artificial

Neste estudo, utilizou-se uma abordagem inovadora e não convencional para a clusterização e classificação dos scores de eficiência energética. Buscando explorar diferentes soluções e avaliar seu desempenho de maneira mais abrangente, optou-se pelo uso de redes neurais para categorizar os scores em diferentes níveis de eficiência energética.

4.5.5 Utilização de Redes Neurais

Comparada aos algoritmos tradicionais de aprendizado de máquina e classificação, a abordagem baseada em redes neurais se destaca por sua habilidade em lidar com relações complexas entre os escores e as classes de eficiência energética. Este método é particularmente vantajoso em cenários onde os dados apresentam complexidade elevada e são de grande volume.

A decisão de utilizar redes neurais para classificar os scores em diferentes níveis energéticos foi motivada por sua capacidade superior de interpretação de padrões complexos e categorização eficiente. Dessa forma, este modelo de classificação permite análise mais refinada e precisa dos resultados das simulações, contribuindo significativamente para a identificação de estratégias otimizadas de gestão energética em ambientes de computação em nuvem.

Em seu estudo, (LI et al., 2021) utilizaram os métodos Carpenter and Grossberg's Adaptive Resonance Neural Network ART2 e o de aprendizado Kohonen, que são redes neurais, para clusterizar ou classificar. O ART2 é uma rede neural adaptativa de ressonância que pode ser usada para reconhecimento de padrões e classificação, enquanto o método de aprendizado de Kohonen é uma técnica de aprendizado não supervisionado baseada em redes neurais para mapeamento topológico. Ambas são empregadas no estudo para realizar a clusterização e classificação de dados no contexto da análise de linguagem natural.

Quanto aos métodos utilizados em (KARIM et al., 2021; EZUGWU et al., 2022), estes foram baseados em abordagens de aprendizado profundo (deep learning), como

redes neurais profundas (DNN). Essas abordagens de aprendizado profundo superaram algoritmos de clustering baseados em aprendizado de máquina tradicional em diferentes situações de uso, abrangendo diferentes tipos de dados. Os autores, ainda afirmam que as redes neurais são utilizadas para clusterizar dados devido a sua capacidade de aprender representações complexas e não lineares de dados. Ao aplicar redes neurais para clustering, é possível extrair automaticamente características relevantes dos dados e agrupá-los com base nessas características aprendidas.

Além disso, as redes neurais profundas, em particular, têm mostrado ser eficazes na aprendizagem de representações de alto nível dos dados, o que pode facilitar a identificação de padrões e estruturas nos dados que podem não ser facilmente discerníveis por métodos tradicionais de clustering.

Ainda segundo (LI et al., 2021; KARIM et al., 2021; EZUGWU et al., 2022), as principais razões das redes neurais serem frequentemente utilizadas para clusterização são:

- **Capacidade de Aprendizado Não Supervisionado:** As redes neurais podem aprender padrões nos dados sem a necessidade de rótulos ou supervisão explícita. Isso é essencial para a clusterização, onde os agrupamentos não são conhecidos a priori.
- **Flexibilidade e Adaptabilidade:** As redes neurais são altamente flexíveis e podem se adaptar a diferentes tipos de dados e estruturas de agrupamento. Podem lidar com dados de alta dimensionalidade e não lineares.
- **Deteção de Padrões Complexos:** As redes neurais são capazes de identificar padrões complexos e não lineares nos dados, o que é crucial para a clusterização eficaz em conjuntos de dados heterogêneos.
- **Escalabilidade:** As redes neurais podem lidar com grandes volumes de dados e são escaláveis para conjuntos de dados de diferentes tamanhos.

4.6 Considerações Finais

A metodologia aplicada ao estudo da eficiência energética em computação em nuvem verde explanada neste capítulo, teve papel decisivo quanto ao desenvolvimento satisfatório da mesma. A abordagem metodológica adotada foi meticulosamente delineada, abrangendo desde a seleção e análise de algoritmos de escalonamento até o desenvolvimento de modelo inovador de pontuação energética e classificação de níveis energéticos. Esta abordagem multifacetada não só garantiu a profundidade e rigor na coleta e análise dos dados, mas descortinou caminhos que permitem orientar com maior

segurança futuras políticas e práticas sustentáveis no campo da responsabilidade ambiental em TI.

Através do uso do CloudSim Plus e da implementação de diferentes algoritmos de escalonamento, o estudo ofereceu insights valiosos quanto às implicações energéticas de várias estratégias de gestão de recursos em ambientes de nuvem. A análise detalhada dos resultados das simulações, focadas em métricas como tempo de execução, consumo de energia, emissões de CO₂ e custos operacionais, proporcionou compreensão abrangente do desempenho energético e ambiental dos algoritmos estudados.

A inovação trazida por este trabalho, em termos da sua abordagem metodológica reside, principalmente, na proposta de sistema de classificação mediante o uso de scores calculados a partir de parâmetros de eficiência energética e sua subsequente categorização utilizando redes neurais. Este modelo representa avanço significativo na quantificação e compreensão da eficiência energética de data centers, oferecendo ferramenta valiosa para a tomada de decisão na área da computação em nuvem verde.

O capítulo a seguir demonstra as implicações práticas dos métodos de escalonamento e do modelo de classificação proposto, oferecendo visão concreta do impacto dessas estratégias na operação real de data centers. Os resultados apresentados são cruciais para validar as hipóteses e conclusões deste estudo, além de fornecer direcionamentos claros quanto a futuras pesquisas e aplicações práticas na busca por soluções sustentáveis com relação à computação em nuvem verde.

5 Resultados e Discussão

Neste capítulo são apresentados os resultados e realizada discussão das simulações acerca das diferentes configurações de máquinas virtuais que utilizam vários algoritmos de escalonamento (Seções 5.1.1 e 5.3). A análise é focada em entender como tais diferentes configurações afetam o desempenho geral e a eficiência energética do sistema. Para garantir uma avaliação ampla, a análise é estruturada em diversos cenários, cada um explorando diferentes aspectos de desempenho dos sistemas em nuvem. Estes cenários incluem a análise de tempos de execução, consumo energético, custos operacionais e emissões de CO₂.

A contribuição apresentada neste capítulo quanto à computação em nuvem verde proporciona análise detalhada do impacto de várias estratégias de escalonamento sobre o desempenho e sustentabilidade de sistemas em nuvem, além da importante contribuição deste trabalho, à incorporação de um novo algoritmo, ACS, que passa a compor a gama de escalonadores estudados na literatura.

5.1 Ambiente de Simulação do Consumo Energético

O CloudSim Plus, extensão avançada e aprimorada do CloudSim (ZONG, 2020; SILVA, 2023; BARBIERATO et al., 2019; FILHO et al., 2017; FARAHNAKIAN et al., 2015; CLOUDSIM, 2016), foi a ferramenta escolhida para a simulação desenvolvida neste estudo. Este framework de simulação é amplamente reconhecido por sua flexibilidade e capacidade de modelar ambientes complexos de computação em nuvem. Ele permite a simulação detalhada de diferentes cenários, incluindo a alocação e gerenciamento de máquinas virtuais, oferecendo base realista e robusta para as análises. Além disso, por sua disseminação como ferramenta, torna possível a comparação entre trabalhos similares, conforme apresentado na seção 3.1.

5.1.1 Algoritmos de Escalonamento de Recursos

Os algoritmos selecionados para este estudo constituem diferentes estratégias de escalonamento em ambientes de computação em nuvem, cada um representando uma abordagem particular para o escalonamento de máquinas virtuais em ambientes de nuvem. São eles:

- **Round Robin (RR):** é um dos algoritmos mais simples e amplamente utilizado para escalonamento. Aloca tarefas de maneira sequencial, garantindo distribuição equitativa do trabalho entre todos os servidores. A simplicidade e a equidade do RR

o torna ponto de referência útil para comparação com métodos mais complexos (BALHARITH; ALHAIDARI, 2019).

- **Dynamic Voltage and Frequency Scaling (DVFS):** este algoritmo ajusta dinamicamente a tensão e a frequência dos processadores de acordo com a demanda de carga, reduzindo assim o consumo de energia quando a carga de trabalho é leve. O DVFS é escolhido por sua abordagem direta, focada na economia de energia, aspecto essencial em data centers que tenham a sustentabilidade como meta (JASMIN; PHILOMINA, 2019).
- **Otimização por Enxame de Partículas (PSO):** inspirado na natureza, o PSO é um algoritmo de otimização que simula o comportamento social de enxames. Busca soluções ótimas através da colaboração entre as partículas, tornando-o eficaz em encontrar configurações de alocação de recursos eficientes em termos energéticos (SHAMI et al., 2022).
- **Sistema de Colônia de Formigas (ACS):** este algoritmo imita o comportamento das formigas na busca por caminhos ótimos. É eficiente na resolução de problemas de otimização e foi escolhido por sua capacidade de encontrar soluções eficientes para alocação complexa de recursos em ambientes de nuvem (DORIGO; STÜTZLE, 2019).

5.1.2 Escolha dos Algoritmos

Os algoritmos selecionados para este estudo — Round Robin (RR), Dynamic Voltage and Frequency Scaling (DVFS), Particle Swarm Optimization (PSO) e Ant Colony System (ACS) — foram escolhidos com base em um equilíbrio entre técnicas tradicionais e inovadoras, permitindo uma análise abrangente das estratégias de alocação de recursos com foco na eficiência energética em data centers. Estes algoritmos foram integrados e adaptados ao CloudSim Plus para simulações realistas, com adaptações específicas garantindo a precisão dos parâmetros e das condições desta pesquisa (Cap. 3).

O Round Robin (RR), o Dynamic Voltage and Frequency Scaling (DVFS) e o Particle Swarm Optimization (PSO) são técnicas amplamente exploradas e validadas em pesquisas anteriores (Seção 3.1). No contexto do CloudSim, esses algoritmos já foram previamente implementados e testados neste simulador, embora adaptações específicas tenham sido realizadas para adequá-los à versão do CloudSim Plus e aos parâmetros utilizados nesta pesquisa (REIS; TEIXEIRA; NETO, 2023b; REIS et al., 2023).

O algoritmo Round Robin é reconhecido por sua simplicidade e baixa complexidade computacional, tornando-o uma base de comparação confiável. Sua natureza de "tempo compartilhado" permite que as tarefas sejam distribuídas de forma equitativa entre os

recursos, o que garante uma utilização balanceada e previsível do sistema. Embora o Round Robin não leve em conta diretamente variáveis como o consumo energético, sua ampla aplicabilidade e facilidade de implementação permitem avaliar como uma estratégia de alocação uniforme se compara com abordagens mais complexas e otimizadas, como o PSO e o ACS. Dessa forma, o Round Robin atua como uma referência de baseline, facilitando a mensuração dos ganhos de eficiência proporcionados pelos algoritmos otimizados (REIS; TEIXEIRA; NETO, 2023b; REIS et al., 2023).

O DVFS é amplamente utilizado em estudos de eficiência energética devido à sua abordagem baseada na redução dinâmica da frequência e da tensão dos processadores, o que impacta diretamente o consumo energético. Em ambientes de data centers, onde a carga de trabalho varia constantemente, o DVFS se destaca por sua habilidade em adaptar-se a essas mudanças, reduzindo o consumo de energia durante períodos de menor demanda. A eficácia do DVFS na computação em nuvem foi extensivamente validada em pesquisas relacionadas, e sua inclusão nesta pesquisa permite comparação direta com outras abordagens bioinspiradas. O DVFS é particularmente relevante para mostrar os benefícios de um ajuste dinâmico de parâmetros operacionais, o que representa pilar central da eficiência energética em TI (REIS; TEIXEIRA; NETO, 2023b; REIS et al., 2023).

O PSO é amplamente aplicado em problemas de otimização, por sua habilidade de balancear exploração e exploração no espaço de busca, características desejáveis na alocação de recursos em nuvem (Seção 2.6). Este algoritmo utiliza partículas para explorar soluções possíveis e convergir para aquelas que minimizam o consumo energético, uma característica que o torna altamente eficaz na alocação de máquinas virtuais e na otimização de carga de trabalho. Estudos demonstraram que o PSO melhora a eficiência operacional ao ajustar automaticamente a alocação de recursos para minimizar o desperdício energético. A presença do PSO no CloudSim Plus permite explorar como um método bioinspirado estabelecido pode ser otimizado e adaptado para novos cenários de simulação em computação verde, destacando sua aplicabilidade em otimização de recursos de forma rápida e eficaz (REIS; TEIXEIRA; NETO, 2023b; REIS et al., 2023).

A inclusão do ACS representa inovação significativa deste estudo, uma vez que é algoritmo menos explorado no contexto específico da alocação de recursos em data centers (Seção 2.6). O ACS, inspirado no comportamento coletivo das formigas na busca pelo caminho mais eficiente, oferece uma abordagem distinta ao resolver problemas de roteamento e alocação, que são análogos à distribuição de tarefas e recursos em ambientes de computação em nuvem. Ao contrário do PSO, que tende a convergir para a melhor solução global, o ACS é capaz de explorar múltiplos caminhos potenciais, o que pode reduzir a sobrecarga em certos nós e distribuir a carga de trabalho de forma mais

balanceada. Além disso, a aplicação do ACS permite avaliar seu potencial em melhorar a eficiência energética por meio da redução de congestionamento e do balanceamento dinâmico de carga, características fundamentais para o desempenho sustentável de data centers (REIS et al., 2024a).

Nesse contexto, o ACS foi implementado de forma completa na ferramenta de simulação. Este é o primeiro estudo de que se tem conhecimento em que o ACS é empregado na distribuição de recursos com vistas à computação em nuvem verde. Além disso, a incorporação do ACS ao CloudSim Plus e sua inclusão na literatura acadêmica são uma contribuição desta pesquisa, ao permitir simulação mais detalhada e realista das operações de um data center e explorar um algoritmo bioinspirado inovador e promissor para a computação em nuvem verde (REIS et al., 2024a).

A escolha dos algoritmos RR, DVFS, PSO e ACS proporciona análise aprofundada e diversificada do impacto de diferentes estratégias de escalonamento sobre a eficiência energética e operacional de ambientes de computação em nuvem. Esta diversidade permite verificar a eficácia dos métodos tradicionais bem como explorar e comparar as contribuições potenciais dos algoritmos bioinspirados, como o PSO e o ACS, que simulam processos naturais para a otimização. Ao colocar esses algoritmos em teste sob condições controladas no CloudSim Plus, este estudo busca não só validar abordagens estabelecidas, mas também revelar novas possibilidades para a área, contribuindo com insights para otimizações futuras em eficiência energética no contexto de data centers e computação verde (CLOUDSIM, 2016; MANDAL; DEHURI, 2019).

5.1.3 Definição da Infraestrutura

A infraestrutura para este estudo foi meticulosamente definida, de modo a garantir a precisão e relevância dos resultados (STERGIOU; PSANNIS; ISHIBASHI, 2020). As máquinas virtuais (VMs), que são elemento crítico na pesquisa, foram configuradas em cinco conjuntos distintos.

- Número de máquinas virtuais: 50, 100, 150, 200 e 250.
- Todas equipadas com memória RAM de 2GB e um núcleo de processamento.

A quantidade de tarefas (cloudlets) foi ajustada para avaliar o modelo sob diferentes cargas de trabalho.

- Número de cloudlets: 10, 100, 1000 e 2000.
- Os cloudlets possuem complexidade de 150.000 MIPS (milhões de instruções por segundo).

Este ajuste permitiu uma análise detalhada do impacto das variações de carga de trabalho na eficiência energética e no desempenho dos algoritmos de escalonamento, conforme demonstrado na Figura 5.




Figura 5 – Definição da Infraestrutura do Experimento

Fonte: Autor

Outras configurações da infraestrutura, como capacidade de armazenamento, largura de banda e outros aspectos, foram mantidas constantes em todos os cenários. Essa uniformidade tornou-se necessária para garantir que as variações observadas nos resultados fossem atribuíveis exclusivamente aos algoritmos de escalonamento aplicados e não a variações na infraestrutura subjacente.

A escolha dessas configurações reflete o compromisso do estudo em simular ambiente de computação em nuvem realista e complexo (STERGIOU; PSANNIS; ISHIBASHI, 2020). Ao manter certos parâmetros constantes, enquanto varia outros, o estudo foca na análise da eficiência energética dos algoritmos de escalonamento de máquinas virtuais sob diferentes condições operacionais, proporcionando insights valiosos para a otimização de data centers, conforme Seção 3.1.

Para o desenvolvimento deste estudo, foram realizadas um total de 800 iterações de simulação, abrangendo um extenso período de processamento, de aproximadamente 51.000 horas ou 2.163 dias. Estas simulações foram cruciais para avaliar a eficiência dos diferentes algoritmos de escalonamento, refletindo a complexidade e abrangência das configurações testadas.

5.2 Validação Funcional

O estudo emprega metodologia de análise estatística para validação funcional rigorosa, a exemplo da análise do comportamento do algoritmo Round Robin em diferentes configurações de máquinas virtuais, em duas dimensões críticas: o tempo de execução das tarefas e a emissão de dióxido de carbono (CO₂). Além disso, este enquadramento metodológico foi aplicado para avaliação de outros algoritmos e cenários, permitindo a identificação de padrões significativos e diferenças entre os algoritmos, contribuindo para o entendimento mais avançado das suas capacidades e limitações e reforçando a confiabilidade dos resultados obtidos.

A validação funcional, neste contexto, envolve a aplicação de técnicas estatísticas para analisar os dados coletados a partir de experimentos controlados. Isso inclui a utilização de medidas de tendência central e dispersão, como média, desvio padrão e intervalos de confiança, tendo em vista quantificar a variabilidade e prever o comportamento dos algoritmos sob teste.

Levando em consideração a análise estatística propriamente dita, a média e o desvio padrão são métricas estatísticas fundamentais utilizadas para descrever a distribuição e a variabilidade dos dados. Neste trabalho, a média foi calculada para fornecer uma medida central dos resultados dos diferentes algoritmos estudados, representando o valor médio das métricas de desempenho. Já o desvio padrão permitiu quantificar a variabilidade desses resultados em torno da média, indicando o grau de dispersão entre os diferentes valores.

Os intervalos de confiança foram empregados para avaliar a precisão das estimativas de média, fornecendo um intervalo no qual a média populacional verdadeira deve estar com um nível de confiança de 95%. Os intervalos de confiança serviram para ilustrar a confiabilidade dos resultados, assegurando que os resultados não foram influenciados por variações aleatórias ou vieses amostrais, fornecendo uma medida clara da precisão das conclusões e da eficácia dos algoritmos comparados. Isso conferiu maior robustez à análise, tornando as recomendações mais sólidas e baseadas em evidências.

O teste T de Student é uma ferramenta estatística particularmente útil para análises com amostras pequenas, já que permite comparar as médias de dois grupos e determinar se há diferença estatisticamente significativa entre eles. Diferentemente de outros testes, considera as variâncias dentro de cada grupo e a variabilidade entre as amostras ao calcular a estatística. Isso torna o teste adequado para amostras pequenas, como é o caso deste experimento, pois usa a distribuição T ao invés da normal para o cálculo (FERNANDES et al., 2021).

Adicionalmente ao critério do tamanho da amostra, optou-se pelo teste T de Student para comparar a eficácia de diferentes algoritmos devido as variáveis

apresentarem distribuição aproximadamente normal. Utilizou-se também o teste para determinar se existiam diferenças significativas nas médias dos grupos analisados. Este teste também foi empregado na validação estatística das diversas execuções de cada algoritmo e configuração.

Conforme demonstrado na Seção 4.3, o modelo fatorial completo foi utilizado como parte da validação estatística para analisar os efeitos de múltiplos fatores envolvidos nos algoritmos de otimização. Essa abordagem permitiu avaliar simultaneamente tanto os efeitos principais quanto as interações entre os diferentes fatores que influenciam a eficiência energética dos data centers. Cada fator foi considerado em múltiplos níveis, representando variações nas configurações dos algoritmos e condições operacionais. Ao combinar todos os níveis possíveis de cada fator, o experimento permitiu a visão completa dos impactos individuais e combinados dos parâmetros de otimização (ALIZADEH; ALLEN; MISTREE, 2020; MELO, 2017).

A escolha deste modelo foi essencial para identificar as interações significativas entre os fatores, fornecendo insights sobre como diferentes combinações de parâmetros afetam os resultados. As análises estatísticas realizadas a partir desse modelo permitiram determinar quais fatores e interações tinham efeitos significativos sobre o consumo de energia e o desempenho dos algoritmos testados. Essa análise aprofundada das interações ajudou a estabelecer diretrizes claras para a implementação do cálculo de scores proposto nesta tese.

5.2.1 Aplicação da Validação Funcional

Os resultados apresentados na Tabela 2 ilustram o comportamento do algoritmo Round Robin, que é o algoritmo base de comparação com os demais. Observa-se que o tempo mínimo de execução permanece constante (0,30 segundos) em todas as configurações, sugerindo que o algoritmo mantém uma eficiência básica em varias cargas de trabalho e modelos de distribuição. No entanto, esta constância também aponta para uma limitação na capacidade do algoritmo de adaptar-se e otimizar o desempenho em cenários mais complexos e com cargas de trabalho mais elevadas.

Tabela 2 – Estatística de validação do tempo de execução (s)

Qtd of VMs	MIN	MAX	MÉD	Desvio Padrão	Intervalo de Confiança	Variância
50	0.30	69.12	32.52	22.32	32.27 – 32.77	498,18
100	0.30	19.51	9.91	6.13	9.84 – 9.98	37,58
150	0.30	10.82	5.31	2.98	5.28 – 5.34	8,88
200	0.30	6.00	3.52	1.82	3.50 – 3.54	3,31
250	0.30	4.51	2.65	1.25	2.64 – 2.66	1,56

À medida que o número de VMs aumenta, o tempo máximo de execução diminui significativamente, de 69,12 segundos para 4,51 segundos quando passa de 50 VMs para

250. Este fenômeno pode ser atribuído ao aumento do escalonamento e ao modelo mais distribuído. No entanto, a redução do tempo máximo de execução atenua-se para maiores configurações de VMs, evidenciando limitações intrínsecas do algoritmo Round Robin em cenários altamente distribuídos.

Essa observação é confirmada pela análise da média e do desvio padrão dos tempos de execução corrobora a observação acima. A média de tempo segue a tendência do tempo máximo, diminuindo à medida que o número de VMs cresce, enquanto o desvio padrão decresce de forma notável, indicando uma menor variabilidade nos tempos de execução. Este último aspecto sugere uma estabilidade crescente do tempo de execução, devido ao aumento da distribuição de máquinas virtuais. O intervalo de confiança de 95% para os tempos de execução oferece uma perspectiva adicional sobre a previsibilidade do desempenho, reforçando a confiabilidade dos resultados obtidos.

A análise revela que o aumento do número de VMs está associado a uma redução na variância do tempo de execução, melhorando a eficiência e previsibilidade do sistema. Nas configurações iniciais, como a de 50 VMs, a alta variância revela dificuldades de consistência devido à alocação insuficiente de recursos. Com o aumento para 100, 150 e 200 VMs, a variância diminui, mostrando uma distribuição de carga mais equilibrada e tempos de execução mais previsíveis. Esse comportamento sugere que o sistema atinge um ponto de equilíbrio em torno de 200-250 VMs, onde a estabilidade é otimizada. Essas informações são valiosas para a tomada de decisão, ajudando a escolher o número de VMs ideal para um equilíbrio entre performance e custo-benefício.

Já a análise do impacto ambiental, especificamente quanto à emissão de CO₂, é resumizada na Tabela 3. Os dados indicam uma variação mínima nas emissões entre as diferentes configurações de VMs, variando levemente de 116 a 102, ao passar de 50 para 250 VMs. O desvio padrão, relativamente constante em todas as configurações, reforça a observação de que o algoritmo não oferece benefícios significativos em termos de eficiência energética ou redução do impacto ambiental, mesmo em ambientes mais distribuídos.

Tabela 3 – Estatística de validação da emissão de CO_{2eq}

Qtd of VMs	MIN	MAX	MÉD	Desvio Padrão	Intervalo de confiança	Variância
50	65	130	116	26,11	114,85 - 117,15	682,08
100	65	130	110	27,14	109,16 - 110,84	737,09
150	65	130	103	27,67	102,30 - 103,70	765,99
200	65	130	103	27,67	102,39 - 103,61	765,99
250	65	130	102	31,15	101,39 - 102,61	970,40

A análise da variância das emissões indica que, até a configuração de 200 VMs, a dispersão nos valores de emissão permanece relativamente estável, com variações graduais entre as configurações de 50 a 200 VMs. No entanto, ao atingir a

configuração de 250 VMs, há aumento expressivo na variância, possivelmente devido a limitações de recursos ou desafios de escalabilidade. Isso indica que, em termos de emissões, a configuração de 200 VMs pode ser um ponto ideal para estabilidade, enquanto configurações acima disso podem introduzir instabilidade adicional. Essa informação pode ser útil para equilibrar a alocação de recursos e a emissão de gás carbônico, principalmente se a estabilidade constituir objetivo importante para a operação.

A consistência das emissões de CO₂, juntamente com os intervalos de confiança de 95% e a variância apresentada, sugere que o algoritmo Round Robin mantém um perfil de emissão relativamente uniforme, independentemente da escala do ambiente de computação distribuída ou da carga de trabalho. Esta constatação reforça a necessidade de explorar alternativas mais eficientes do ponto de vista energético, especialmente considerando a crescente preocupação com a sustentabilidade em tecnologias de informação.

5.3 Análise dos Resultados

Os resultados obtidos ao longo desta pesquisa foram organizados e estão apresentados nesta seção com o propósito de fornecer uma visão clara e objetiva das contribuições deste trabalho. Durante a condução dos experimentos e análises, várias produções científicas foram publicadas, abordando aspectos como os resultados das simulações, com destaque para os artigos publicados em (REIS; TEIXEIRA; NETO, 2023b; REIS et al., 2024b; REIS et al., 2023; REIS; TEIXEIRA; NETO, 2023a). Enquanto que em (REIS; TEIXEIRA; NETO, 2023c; REIS et al., 2024a) o foco do trabalho esteve na validação da eficácia da metodologia utilizada.

Os resultados e análises consolidados a partir dessas publicações são detalhados a seguir, fornecendo uma visão aprofundada do impacto de diferentes estratégias e algoritmos na eficiência energética e operacional em data centers.

A discussão que se segue examina como as análises comparativas entre diferentes algoritmos fornecem insights valiosos sobre os padrões de sustentabilidade e eficiência energética. Os dados de entrada definidos atendem aos requisitos para condições de carga de trabalho leve e pesada. Os resultados obtidos relativos à simulação foram compilados e analisados para avaliar os critérios discutidos nas seções anteriores. Os resultados aqui consolidados demonstram as configurações utilizadas, os resultados alcançados para cada algoritmo e sua relação, evidenciando a porcentagem da melhoria alcançada.

Para tanto, são apresentados alguns cenários para exame e discussão:

- Cenário 1: Tempo de Execução das Aplicações

- Cenário 2: Consumo de Energia das Aplicações
- Cenário 3: Custo de Execução das Aplicações
- Cenário 4: Emissão de CO₂

5.3.1 Cenário 1: Tempo de Execução das Aplicações

A partir do exame das pesquisas relacionadas ao desempenho computacional, leva-se em consideração os tempos de execução das aplicações para avaliar a eficiência de determinada configuração. Ao observar os dados na Tabela 4, observa-se que não houve redução significativa ao longo do tempo. Isso demonstra que a utilização dos algoritmos de escalonamento neste cenário não prejudicou a capacidade de processamento do modelo ou o SLA (Acordo de Nível de Serviço), havendo apenas um discreto aumento quanto ao algoritmo DVFS.

Tabela 4 – Resultados do tempo de execução (s)

Qtd de VMs	Tempo Médio de Execução						
	RR	DVFS	PSO	ACS	Relação RR / DVFS	Relação RR / PSO	Relação RR / ACS
50	32.52	33.96	32.52	32.52	4.44%	0.00%	0.00%
100	9.91	9.93	9.91	9.91	0.16%	0.00%	0.00%
150	5.31	5.38	5.31	5.31	1.26%	0.00%	0.00%
200	3.52	3.12	3.52	3.52	-11.31%	0.00%	0.00%
250	2.65	2.66	2.65	2.65	0.38%	-0.21%	-0.21%

Pode-se destacar que a utilização de sistema computacional mais distribuído resultou em melhorias significativas, proporcionando redução média de 70% no tempo de processamento, ao mudar de 50 para 100 máquinas virtuais e de 83% ao migrar de 50 para 150 máquinas virtuais, mantendo a carga de trabalho, conforme demonstrado na Tabela 5.

Tabela 5 – Relação do tempo de execução

Qtd de VMs	Tempo Médio de Execução			
	RR	DVFS	PSO	ACS
50				
100	-69.53%	-69.48%	-69.53%	-69.53%
150	-83.67%	-83.47%	-83.67%	-83.67%
200	-89.18%	-90.40%	-89.18%	-89.18%
250	-91.84%	-91.82%	-91.85%	-91.86%

Ao escalonar as máquinas virtuais acima da 150 VMs, não produziu uma melhoria significativa, como é possível observar com o incremento de 150 a 200 e de 200 a

250, onde houve acréscimo, respectivamente, de somente 7 e 8 pontos percentuais. É importante frisar que a melhoria no desempenho depende de como a aplicação é construída para um modelo distribuído.

5.3.2 Cenário 2: Consumo de Energia das Aplicações

Ao considerar o contexto energético, houve redução de pelo menos 47% no consumo de energia para a mesma carga de trabalho, em comparação com o algoritmo RR, conforme evidenciado no modelo com 50 máquinas virtuais, é observada na Tabela 6 e representada na Figura 6. Além disso, a maior redução no consumo energético, em torno de 55,41%, foi constatada no modelo com 150 VMs usando o algoritmo ACS.

Tabela 6 – Consumo energético das simulações (w)

Qtd de VMs	Consumo Médio de Energia						
	RR	DVFS	PSO	ACS	Relação RR / DVFS	Relação RR / PSO	Relação RR / ACS
50	268.03	129.42	134.03	140.14	-51.71%	-50.00%	-47.71%
100	255.39	127.90	127.76	126.95	-49.92%	-49.97%	-50.29%
150	238.34	119.18	119.26	106.27	-49.99%	-49.96%	-55.41%
200	237.44	118.95	118.76	113.71	-49.90%	-49.99%	-52.11%
250	237.16	118.66	118.61	130.60	-49.97%	-49.99%	-44.93%




Figura 6 – Consumo Energético

Fonte: Autor

Já o consumo dos algoritmos DVFS e PSO mostra valores muito próximos, com

variações inferiores a 3% entre si, enquanto o algoritmo ACS obteve ganho energético 11% superior aos demais algoritmos.

Observa-se também que o algoritmo ACS alcançou desempenho inferior para um ambiente de nuvem menos distribuído, mas sendo superior nos ambientes mais escaláveis.

Ao analisar os dados de energia por conjunto de cloudlets, conforme a Tabela 7 e a Figura 7, foi observada diminuição significativa no consumo, variando entre 49,82% e 53,37%, através dos modelos de distribuição de máquinas virtuais e algoritmos. Esta variação é confirmada pelos dados apresentados de forma consolidada.

Tabela 7 – Consumo de energia por cloudlet (w)

Qtd de Cloudlets	Consumo de Energia por Cloudlet						
	RR	DVFS	PSO	ACS	Relação RR / DVFS	Relação RR / PSO	Relação RR / ACS
10	157.37	78.73	78.70	75.28	-49.97%	-49.99%	-52.16%
100	218.93	109.87	109.60	102.09	-49.82%	-49.94%	-53.37%
1000	293.73	147.00	146.87	146.80	-49.95%	-50.00%	-50.02%
2000	297.80	148.72	148.93	146.60	-50.06%	-49.99%	-50.77%




Figura 7 – Consumo de Energia por Cloudlet

Fonte: Autor

5.3.3 Cenário 3: Custo de Execução das Aplicações

O simulador calcula os custos com base nas configurações das máquinas virtuais, de acordo com os parâmetros mencionados na seção 5.1.3.

Observa-se na Tabela 8 e Figura 8 reduções significativas nos valores simulados, com diminuição de pelo menos 8% para os cenários mais simples e diminuição superior a 34% no cenário mais complexo, ao alocar máquinas virtuais, exceto para o algoritmo DVFS, que, embora com o mesmo padrão de alocação de máquinas virtuais do Round Robin, gerencia a energia dos processadores de forma mais eficiente. Em outras palavras, optando pelo algoritmo DVFS, em comparação com o RR, resulta um menor consumo energético mas sem economia nos custos da alocação das máquinas.

Ao comparar os modelos de arquitetura, a redução dos custos é significativamente maior no algoritmo ACS, sendo até 200% mais eficiente, devido à sua melhor eficiência em ambientes mais distribuídos. Essa tendência reforça a necessidade não apenas da construção de infraestrutura distribuída, mas também do desenvolvimento de aplicações que possam tirar proveito desse ambiente.

Tabela 8 – Custo dos ambientes em simulação (US\$)

Qtd de VMs	Custo de Alocação						
	RR	DVFS	PSO	ACS	Relação RR / DVFS	Relação RR / PSO	Relação RR / ACS
50	276.84	279.93	254.63	227.95	1.12%	-8.02%	-17.66%
100	118.29	118.33	108.78	97.95	0.04%	-8.04%	-17.19%
150	91.34	91.67	73.26	65.12	0.36%	-19.80%	-28.70%
200	75.49	75.47	63.78	57.24	-0.02%	-15.50%	-24.18%
250	70.26	70.28	59.24	46.19	0.03%	-15.68%	-34.26%




Figura 8 – Custo de Alocação

Fonte: Autor

5.3.4 Cenário 4: Emissão de CO₂

Em relação ao consumo energético do data center, é possível considerar as emissões de dióxido de carbono equivalente. Este estudo concentrou-se na análise do uso da energia dos equipamentos e, por conseguinte, demandou a avaliação e comparação do cálculo de equivalência de emissão de CO₂ com base nas referências americanas ([EPA, 2022](#)), já que os parâmetros utilizados foram provenientes da AWS, localizada nos Estados Unidos. Os gastos energéticos necessários para refrigeração, redes e outros dispositivos elétricos correlatos não são contemplados nesta análise.

Ao comparar as estratégias de alocação dos algoritmos, como demonstrado na Tabela 9 e Figura 9, fica evidente que a emissão de carbono equivalente nos três modelos de algoritmos é consideravelmente menor em comparação com o algoritmo Round Robin, levando em conta o consumo energético total para cada configuração.

Tabela 9 – Cálculo de emissão CO_{2eq}

Qtd de VMs	Emissão de CO _{2eq} (Tons)						
	RR	DVFS	PSO	ACS	Relação RR / DVFS	Relação RR / PSO	Relação RR / ACS
50	232	112	116	121	-51.72%	-50.00%	-47.84%
100	442	221	221	220	-50.00%	-50.00%	-50.23%
150	619	309	310	276	-50.08%	-49.92%	-55.41%
200	822	412	411	394	-49.88%	-50.00%	-52.07%
250	1026	513	513	452	-50.00%	-50.00%	-55.95%




Figura 9 – Emissão de CO_{2eq} para os Modelos

Fonte: Autor

5.3.5 Considerações Adicionais

Os resultados acima mostram que a aplicação do algoritmo Ant Colony System tem impacto significativo na diminuição das emissões de CO₂ equivalente em comparação com os demais, sendo cerca de 11% mais eficiente que o PSO, que é o segundo melhor em eficiência. Especificamente quanto às emissões de CO₂ equivalente, pode ser destacado que, ao ser utilizado o algoritmo ACS, estas variaram de 121 a 452 toneladas, correspondente a uma redução substancial comparada às 232 a 1.026 toneladas produzidas pelo Round Robin. É importante ressaltar que essas emissões são para todo o processamento realizado durante aproximadamente 2.163 dias da simulação.

Uma observação relevante é que a maior emissão decorrente do ACS (ocorrida com 250 máquinas) é próxima da menor emissão do Round Robin (com 100 máquinas). Além disso, o aumento das emissões é mais pronunciado no algoritmo Round Robin do que nos outros, indicando uma eficiência energética mais otimizada com o uso do ACS.

Ao comparar todos os modelos, observa-se, quanto às emissões de CO₂, reduções de no mínimo 49,88% e no máximo 51,72% para o DVFS, de 49,92% e 50% para o PSO, enquanto para o ACS tem-se o intervalo de 47,84% a 55,95%.

Em síntese, este estudo vem destacar a viabilidade de reduzir de forma significativa o impacto ambiental relacionado à computação em nuvem, ao implementar técnicas e estratégias eficientes de gestão de recursos. Conforme demonstrado pelos cenários simulados, é possível alcançar redução mínima de 50% no impacto ambiental sem comprometer a capacidade computacional.

Ficou evidenciado que a aplicação dessas estratégias não acarreta despesas diretas e pode até resultar em economias significativas de infraestrutura, tanto para os provedores de serviços de nuvem quanto para os usuários. Assim, trata-se de situação vantajosa para todos, na qual a qualidade e capacidade computacional são preservadas, o impacto ambiental é minimizado e há redução nos custos associados.

No que concerne aos quatro modelos simulados, o modelo com 150 máquinas virtuais apresenta a melhor relação custo-benefício. Com a implementação do algoritmo ACS neste cenário, é viável obter diminuição de 55,41% no impacto ambiental e na emissão de CO₂, e redução de 28,70% nos gastos diretos de alocação de máquinas virtuais. Ademais, em comparação ao modelo com 50 VMs, houve redução de aproximadamente 84% no tempo de resposta.

Os resultados e conclusões trazidos por esta pesquisa ressaltam a eficácia e importância da computação em nuvem sustentável e enfatizam a necessidade de maior adoção de práticas ambientalmente responsáveis na indústria de tecnologia da informação.

5.4 Considerações Finais

O capítulo apresentou uma análise aprofundada e sistemática dos resultados obtidos, a partir das extensivas simulações realizadas em ambiente de computação em nuvem verde. A metodologia aplicada, baseada em diferentes algoritmos de escalonamento e configurações de máquinas virtuais, foi cuidadosamente desenhada para avaliar a eficiência energética, os custos operacionais, tempo de execução das aplicações e emissões de CO₂.

Através da análise detalhada dos cenários propostos, foi possível identificar a eficácia de diferentes estratégias de alocação de recursos em reduzir o impacto

ambiental, enquanto mantida ou melhorada a performance computacional. Os resultados demonstraram que estratégias como o uso do algoritmo Ant Colony System (ACS) com um número otimizado de máquinas virtuais podem levar a reduções significativas no consumo energético e nas emissões de CO₂, sem comprometer o desempenho das aplicações.

O próximo capítulo, dedicado às contribuições da pesquisa, consolida os insights obtidos, reflete sobre as implicações práticas e teóricas destes resultados, além de discutir as contribuições dadas pela investigação realizada para o campo da computação em nuvem verde e propor direções futuras para pesquisa e prática na área da sustentabilidade em TI.

6 Contribuições da Pesquisa e Expansão do Escopo

As contribuições desta pesquisa e expansão de seu escopo apresentadas neste capítulo quanto à computação em nuvem verde são quádruplas. Em primeiro lugar, é introduzido modelo de pontuação energética (Seção 6.1), baseado na atribuição de pesos a diferentes métricas-chave, como o consumo de energia, emissões de CO₂, tempo de execução e custos operacionais. Através deste método, cada configuração de máquinas virtuais e algoritmo de escalonamento recebe um score que reflete sua eficiência relativa. Em segundo lugar, vem a escala de nível energético (Seção 6.2), que constitui ferramenta estratégica para avaliar e categorizar a eficiência energética em ambientes de computação em nuvem. Esta escala é baseada nos scores obtidos, utilizando inteligência artificial, e permite uma visão hierarquizada e clara do desempenho energético das diversas configurações e algoritmos de escalonamento testados.

A terceira contribuição (Seção 6.3) diz respeito à previsão da eficiência energética, especificamente em termos do desenvolvimento de métodos para estimar o índice e o nível de eficiência energética. A previsão desse índice baseada em variáveis críticas, como o consumo de energia, tempo de processamento e custos associados à alocação de recursos. Em vez de se concentrar na previsão da demanda energética, esta etapa enfoca uma abordagem mais granular e específica, buscando otimizar as possibilidades de otimização energética em ambientes computacionais intensivos.

Na última seção (Seção 6.4), como trabalhos futuros, é explorada a quantização como técnica promissora para aprimorar a eficiência energética e reduzir o consumo de energia em ambientes de computação em nuvem. A aplicação da quantização não apenas otimiza a carga computacional e a utilização de recursos, mas também pode acelerar a inferência de modelos que utilizam IA, contribuindo significativamente para a eficiência energética dos data centers.

6.1 Cálculo dos Scores

Como abordagem para que a análise dos resultados seja realizada de forma mais objetiva, excluindo-se critérios subjetivos, neste trabalho são utilizados scores para as diversas configurações de VMs e algoritmos utilizados. O uso desses scores permite identificar as diversas pontuações que podem ser obtidas em cada cenário, bem como determinar em qual estrato de consumo de energia o data center se encontra.

Para tanto, é utilizado modelo baseado em algoritmos frequentemente usados em

otimização multiobjetivo e decisão multicritério, usando pesos e resultados normalizados, tendo por objetivo a criação de um ranking (ALVAREZ; ISHIZAKA; MARTÍNEZ, 2021; ZHENG; WANG, 2022; KUMAR et al., 2021).

6.1.1 Definição dos Pesos

Além dos desafios impostos pelo uso de ponderação é a definição dos pesos para cada métrica, sendo que essa importância pode ser relativizada dependendo dos objetivos de cada data center. Para este estudo, é adotado o uso de pesos para as métricas, uma vez que o algoritmo desenvolvido pode ser customizado a partir desses parâmetros, de modo a flexibilizar o uso desta solução.

Sendo assim, o objetivo do algoritmo criado para o cálculo de scores é definir uma pontuação de eficiência para cada conjunto de configurações e algoritmo, tendo por base os resultados obtidos e atribuindo pesos aos mesmos. Ou seja, a cada fator, como emissão de CO₂, consumo de energia, tempo de execução e custos, é atribuído um peso.

A determinação dos pesos apropriados para as métricas em cenário de data center é influenciada por uma variedade de fatores, incluindo a natureza específica do data center, seus objetivos operacionais e prioridades organizacionais, dentre outros.

Emissão de CO₂: o foco global em sustentabilidade e a preocupação com as mudanças climáticas levam muitas empresas a priorizarem a redução de suas emissões de carbono. Se o data center tem metas rigorosas de sustentabilidade ou está localizado em área onde a regulamentação de emissão é estrita, além de haver demanda crescente dos consumidores por práticas mais verdes, este peso pode ser mais alto.

Consumo de Energia: o consumo de energia é diretamente relacionado ao custo operacional e eficiência do data center. Além dos custos, o consumo excessivo de energia pode ter implicações ambientais, e muitos data centers estão buscando formas de operar de maneira mais eficiente em termos energéticos. Assim, esta métrica, por estar diretamente relacionada à emissão de CO₂, também recebeu peso substancial.

Dado que estas duas métricas guardam relação direta, é possível considerá-las como uma única métrica combinada. Uma alternativa seria mantê-las separadas, atribuindo pesos semelhantes para reconhecer sua interdependência. No entanto, juntas, elas ainda devem representar uma proporção significativa do peso total.

Tempo de Execução: o desempenho é fator primordial para a maioria dos data centers, já que um tempo de execução mais longo pode afetar negativamente a experiência do usuário e a eficiência operacional. Se os clientes ou aplicações do data center são sensíveis ao tempo de resposta, este peso será mais alto.

Sendo assim, recomenda-se que o peso desta métrica seja semelhante ao peso somado das duas anteriores, de modo a equilibrar o SLA e o impacto ambiental.

Mas caso o desempenho computacional não seja um objetivo prioritário, pode-se reduzir este peso para focar o consumo energético e a emissão de gás carbônico.

Custos: a maioria das organizações está atenta aos custos, mas a prioridade pode variar. Sendo que estes podem ser indiretamente representados nas métricas de emissão de CO₂ e consumo de energia, já que ambas têm implicações de custo associadas. No entanto, o custo operacional direto ainda se diferencia e é importante, por isso foi-lhe atribuído peso específico.

A soma dos pesos deve ser igual a 1, de modo a garantir que a combinação ponderada de todas as métricas resulte em um valor de score que reflita uma proporção ou porcentagem total dos critérios de avaliação. Quando os pesos somam 1 (ou 100%), isso proporciona várias vantagens, quais sejam:

Normalização: ao garantir que o total seja 1, está-se normalizando os critérios. Isto permite que os resultados sejam interpretados de forma intuitiva e comparados facilmente entre diferentes cenários ou alternativas.

Interpretação Clara: quando os pesos somam 1, a contribuição relativa de cada métrica ao score total é claramente compreendida. Por exemplo, se uma métrica tem peso de 0.3, isso indica claramente que essa métrica representa 30%.

Facilita a Comparação: Ao se comparar diferentes alternativas ou cenários usando o mesmo conjunto de critérios, ter pesos que somam 1 em todos os cenários garante que se está fazendo comparações equitativas e consistentes.

Consistência em Métodos Multicritério: muitos métodos de decisão multicritério, como o Método de Análise Hierárquica (AHP) e outros, utilizam a convenção de que os pesos somam 1. Isso garante consistência e comparabilidade entre diferentes abordagens e aplicações.

Conforme referido anteriormente, como configuração de referência (baseline) é utilizado o algoritmo Round Robin com 50 VMs de referência. A pontuação de eficiência é calculada com base na diferença entre o resultado do RR e os demais algoritmos e configurações, ponderada pela importância de cada métrica.

6.1.2 Algoritmo de Cálculo dos Scores

A seguir é apresentada a síntese do funcionamento do algoritmo, representada no Algoritmo 1.

A primeira etapa é a de inicialização dos dicionários e métricas, além da atribuição dos pesos. A etapa seguinte é a da normalização, de forma a garantir comparação equitativa, principalmente devido às métricas possuírem diferentes escalas.

A seguir é realizado o cálculo propriamente dito dos scores para cada algoritmo e

configuração preparados anteriormente. E por fim, é realizada a classificação em termos de eficiência, do maior ao menor índice, oferecendo uma visão hierárquica do desempenho.

Algorithm 1 Cálculo da Pontuação de Eficiência

```

1: procedure CALCULATEEFFICIENCYSCORE(metrics, weights, rr_algorithm)
2:   scores  $\leftarrow$  {}
                                     ▷ Step 1: Initializing dictionaries

3:   for all alg  $\in$  metrics do
4:     scores[alg]  $\leftarrow$  {}
5:     for all (vm, value)  $\in$  metrics[alg] do
6:       scores[alg][vm]  $\leftarrow$  0
                                     ▷ Step 2: Normalization

7:   for all (metric, weight)  $\in$  weights do
8:     maximum  $\leftarrow$  max(val[metric] | alg  $\in$  metrics, (vm, val)  $\in$  metrics[alg])
9:     minimum  $\leftarrow$  min(val[metric] | alg  $\in$  metrics, (vm, val)  $\in$  metrics[alg])
10:    for all alg  $\in$  metrics do
11:      for all vm  $\in$  metrics[alg] do
12:        metrics[alg][vm][metric]  $\leftarrow$  (metrics[alg][vm][metric] -
        minimum) / (maximum - minimum)
                                     ▷ Step 3: Calculating efficiency score

13:   for all (alg, data)  $\in$  metrics do
14:     if alg  $\neq$  rr_algorithm then
15:       for all (vm, metric_values)  $\in$  data do
16:         for all (metric, value)  $\in$  metric_values do
17:           difference  $\leftarrow$  value - metrics[rr_algorithm][vm][metric]
18:           score  $\leftarrow$  difference  $\times$  weights[metric]
19:           scores[alg][vm] += score
                                     ▷ Step 4: Ranking

20:   ranking  $\leftarrow$  sorted(scores.keys(), key =  $\lambda alg : \sum (scores[alg].values())$ , reverse = True)
   return ranking
  
```

A pontuação de eficiência calculada para o Algoritmo 1 acima pode ser expressa como uma fórmula matemática, conforme apresentado na equação 6.1:

$$[H]Score = \sum_{i=1}^n w_i * \left(1 - \frac{x_{i,j}}{x_{i,RR}}\right) \quad (6.1)$$

Onde:

- n é o número total de métricas (neste caso, são 4: emissão de CO₂, consumo energético, tempo de execução e custo).
- w_j é o peso da i -ésima métrica, com base na prioridade dessa métrica.

- $x_{i,j}$ é o valor da i -ésima métrica para a j -ésima configuração de VMs relativo ao determinado algoritmo.
- $x_{i,RR}$ é o valor da i -ésima métrica para a j -ésima configuração de VMs para o algoritmo RR.

O resultado desta fórmula, representando o score, é a pontuação de eficiência para a j -ésima configuração de VMs para um determinado algoritmo. Quanto maior a pontuação, melhor é a configuração em termos de minimização da emissão de CO₂, energia consumida, tempo de processamento e custos.

6.1.3 Resultados dos Scores

Ao executar o algoritmo proposto, é possível atribuir uma pontuação de eficiência para cada configuração de máquinas virtuais e para cada algoritmo específico, conforme explanado anteriormente. Dessa forma, optou-se por realizar duas parametrizações para identificar o seu comportamento e avaliar diferentes aspectos relacionados às configurações de pesos.

Inicialmente é atribuído peso igual para todos os critérios, de modo a avaliar o seu resultado e confrontar com as análises realizadas anteriormente, nesse caso 0,25 para cada métrica.

O resultado apresentado na Tabela 10 revela que o algoritmo ACS, com 150 máquinas, é considerado a alternativa mais vantajosa em termos de custo-benefício, conforme exposto anteriormente na Seção 5.3, através da análise empírica dos resultados.

Tabela 10 – Resultados dos scores com pesos iguais

Algoritmo	VMs	Score
ACS	150	0.3898
ACS	250	0.3826
ACS	200	0.3610
PSO	150	0.3393
ACS	100	0.3379
PSO	200	0.3323
PSO	250	0.3318
DVFS	200	0.3227
ACS	50	0.3222
PSO	100	0.3172
PSO	50	0.3159
DVFS	50	0.3060
DVFS	100	0.2998
DVFS	250	0.2996
DVFS	150	0.2975

A segunda parametrização do algoritmo de cálculo de score considera que o

consumo energético e a emissão de CO₂ estão diretamente relacionados e, para manter pelo menos o SLA do modelo inicial, sugere-se atribuir os seguintes pesos: 0,2 para o consumo energético, 0,2 para a emissão de CO₂, 0,4 para o tempo de processamento e 0,2 para os custos.

A Tabela 11 demonstra que, ao atribuir pesos diferentes às métricas, o modelo de algoritmo de ACS com 250 VMs torna-se mais eficiente. Nesta análise, fica evidente a possibilidade de determinar as prioridades das métricas de acordo com os objetivos da organização.

Tabela 11 – Resultados dos scores com pesos diferentes

Algoritmo	VMs	Score
ACS	250	0.2923
ACS	150	0.2788
ACS	200	0.2564
DVFS	200	0.2450
PSO	150	0.2393
ACS	100	0.2367
PSO	200	0.2319
PSO	250	0.2313
ACS	50	0.2267
PSO	100	0.2168
PSO	50	0.2159
DVFS	50	0.1995
DVFS	100	0.1990
DVFS	250	0.1984
DVFS	150	0.1948

Esta abordagem proporciona a transição da percepção subjetiva para uma visão objetiva e ponderada na análise das informações, demonstrando que uma análise mais aprofundada e criteriosa é requerida. Assim, com a definição clara dos pesos e prioridades das métricas utilizadas, pode-se ter um impacto significativo na identificação da configuração de máquinas virtuais mais eficiente em termos de minimização da emissão de CO₂, consumo energético, tempo de processamento e custos.

6.2 Escala de Nível Energético

Levando em consideração os resultados obtidos de acordo com o capítulo anterior, é viável apresentar uma escala de nível energético precisa, que possa ser facilmente aplicada em um data center específico e que esteja alinhada com a necessidade de monitorar e gerenciar o consumo de energia.

Esta escala é dividida em cinco níveis diferentes, de A a E, atribuídos os scores obtidos pelas diversas configurações e algoritmos apresentados. O algoritmo Round Robin com 50 máquinas virtuais é usado como referência, sendo classificado como nível

E.

O nível A é caracterizado pelo melhor score de configuração e algoritmos, enquanto os níveis subsequentes classificam os demais scores. A escala permite um diagnóstico estratégico, possibilitando a identificação de áreas com potencial de otimização e a implementação de soluções voltadas para a eficiência energética.

A implementação desta escala de nível energético em determinado data center não somente permite a monitorização precisa do consumo energético, como também promove a gestão mais sustentável dos recursos energéticos, além de atender às crescentes demandas por sustentabilidade e responsabilidade ambiental. Além disso, a aplicação prática deste modelo pode contribuir significativamente para a criação de um framework de gestão energética em ambientes de TI, o que poderá proporcionar avanços em pesquisa e desenvolvimento no campo da eficiência energética.

Um dos principais desafios nesta etapa é realizar a adequada distribuição dos scores obtidos na seção anterior nas diferentes categorias propostas de clusterização e classificação. Essa tarefa pode ser realizada utilizando abordagens distintas, dependendo das características dos dados e do objetivo da categorização. Uma estratégia de uso frequente para agrupar valores numéricos em cinco níveis é empregar técnicas estatísticas e algoritmos de aprendizado de máquina (ZHANG et al., 2021a; LIN et al., 2021c; ESPADOTO; HIRATA; TELEA, 2021).

Essas técnicas visam agrupar os valores numéricos em clusters que possuam características semelhantes. É possível utilizar diversas estratégias, dependendo das informações e do propósito da categorização.

Ao escolher uma técnica, é essencial considerar a adequação ao conjunto de dados disponíveis e os objetivos da segmentação. Embora a divisão com base em percentis possa ser adequada para algumas aplicações, em contextos mais complexos pode-se optar por técnicas avançadas para identificar padrões subjacentes.

Para realizar esta tarefa, é possível utilizar o algoritmo k-means, amplamente referido na literatura. Esse método de clusterização não supervisionada agrupa os valores numéricos em k clusters, onde k representa o número desejado de grupos. O procedimento do algoritmo consiste em dividir os valores numéricos em grupos com variância mínima dentro de cada grupo e variância máxima entre os diferentes grupos. Esta abordagem reduz a distância total intra-cluster através da minimização dessa medida, considerando todos os clusters formados.

Embora os dados trabalhados sejam relativamente simples e reduzidos, o uso de técnicas de clusterização e classificação ainda é fundamental para a segmentação em cinco níveis. É necessário considerar a dimensão e a natureza dos dados, bem como os recursos computacionais disponíveis. É relevante destacar que outras simulações podem

produzir dados mais numerosos e complexos nos resultados obtidos.

Neste estudo, optou-se por utilizar uma abordagem não tradicional para a clusterização, visando explorar diferentes soluções e avaliar seu desempenho, por meio da validação cruzada ou por um conjunto separado de testes. Com o objetivo de maximizar a precisão e a eficácia da categorização, decidiu-se empregar redes neurais para classificar os scores em diferentes níveis. Com o avanço do aprendizado profundo, as redes neurais têm se mostrado uma opção viável para categorizar valores numéricos em níveis específicos. Apesar de ser uma abordagem mais complexa em comparação com algoritmos tradicionais de aprendizado de máquina e classificação, as redes neurais podem oferecer bons resultados, especialmente quando há uma grande quantidade de dados ou quando a relação entre os scores e as classes é complexa.

De forma simplificada, usando redes neurais são realizadas as seguintes etapas para clusterização e classificação de valores numéricos em cinco níveis:

1. Normalização dos dados, pois as redes neurais são sensíveis à escala dos dados de entrada;
2. Construção do modelo de rede neural;
3. Treinamento do modelo;
4. Predição.

Após a predição, os valores numéricos são atribuídos aos níveis com base nas categorias pré-estabelecidas. Após a submissão dos dados coletados na etapa anterior, por meio do modelo de inteligência artificial que utiliza redes neurais recorrentes foi possível obter a seguinte distribuição das classes e intervalos definidos para os scores, conforme detalhado adiante na Tabela 12.

É importante observar que os scores podem ser negativos, ou seja, quando os resultados forem inferiores à configuração base, representada com valor 0 neste trabalho:

- Level A: 0.2788 to 0.2923
- Level B: 0.2367 to 0.2564
- Level C: 0.2159 to 0.2319
- Level D: 0.1948 to 0.1995
- Level E: -0.8525 to 0.0305

Tabela 12 – Classificação dos scores por nível

Nível	Algoritmo	Qtd de VMs	Score
A	ACS	250	0.2923
A	ACS	150	0.2788
B	ACS	200	0.2564
B	DVFS	200	0.2450
B	PSO	150	0.2393
B	ACS	100	0.2367
C	PSO	200	0.2319
C	PSO	250	0.2313
C	ACS	50	0.2267
C	PSO	100	0.2168
C	PSO	50	0.2159
D	DVFS	50	0.1995
D	DVFS	100	0.1990
D	DVFS	250	0.1984
D	DVFS	150	0.1948
E	RR	100	0.0305
E	RR	50	0.0
E	RR	150	-0.1984
E	RR	200	-0.5148
E	RR	250	-0.8525

Com base nesta análise, propõe-se a introdução de até quatro subníveis dentro de cada classe, denotados pelo símbolo '+'. Cada subnível representa um acréscimo de 25% no uso de energia renovável no nível ou pontuação respectiva. Este aprimoramento proposto no sistema de classificação oferece aos administradores de data centers um leque mais amplo de opções ao tomar decisões a respeito de despesas operacionais e da integração de fontes de energia renováveis.

Os subníveis são baseados em soluções heurísticas multicritério pré-estabelecidas, as quais orientam decisões em situações de consumo consciente de energia, sem prejudicar a operação dos data centers. Os métodos foram inspirados nos artigos (KOCOT; CZARNUL; PROFICZ, 2023; SHEIKH; PASHA, 2021) e estão representados de forma detalhada na Tabela 13:

Tabela 13 – Resumo dos scores com pesos diferentes

Nível	Algoritmos / VMs	Escala
A	ACS 250 e ACS 150	{++++}
B	ACS 200; DVFS 200; PSO 150; ACS 100	{++++}
C	PSO 200; PSO 250; ACS 50, PSO 100; PSO 50	{++++}
D	DVFS 50; DVFS 100; DVFS 250; DVFS 150	{++++}
E	RR 100; RR 50; RR 150; RR 200; RR 250	{++++}

A introdução de métodos de inteligência artificial para a rotulação, combinada com a incorporação de subníveis energéticos, cria um sistema robusto e adaptável. Isso não apenas facilita a tomada de decisões operacionais e estratégicas, mas também promove

a eficiência energética e a adoção de fontes renováveis de energia. Este modelo, portanto, não só otimiza os recursos energéticos de um data center como também orienta as organizações quanto a práticas mais sustentáveis e ecologicamente responsáveis (ZHANG et al., 2021a; CHICHE; YITAGESU, 2022; LIN et al., 2021c; LIN et al., 2021b; ESPADOTO; HIRATA; TELEA, 2021).

Por outro lado, a utilização de subníveis fundamentados no consumo de energia renovável se faz necessária. Mesmo um data center que adquira toda sua energia de fontes renováveis não é, por definição, energeticamente eficiente. Com base nas metodologias apresentadas neste estudo, é possível reduzir ainda mais o consumo energético, direcionando a energia economizada para outras áreas críticas.

Isto torna possível melhorar o uso de energia renovável e diminuir os danos ambientais de forma eficiente. Essas estratégias são fundamentais tanto em termos econômicos quanto para atender às necessidades de sustentabilidade e responsabilidade ambiental.

Devido à singularidade de cada data center em termos de carga e demanda energética, a elaboração de uma tabela de nível energético personalizada é vital para a análise adequada da eficiência energética. Esta escala permite avaliar o grau de otimização energética do data center, proporcionando visão clara dos níveis de eficiência, desde os mais elevados até os menos favoráveis, tendo em conta as particularidades da carga operacional.

Um dos principais objetivos deste modelo é indicar a eficiência energética do data center naquele momento e sua evolução potencial em termos de gestão de energia, de modo a demonstrar os reais benefícios dessas implementações. Isto envolve avaliar seu status e selecionar algoritmos que possam elevar o data center a um nível superior de eficiência energética. Destaca-se que estes valores de pontuação não são absolutos, pois variarão de acordo com as configurações e equipamentos de cada data center, uma vez que representam a relação entre vários níveis de energia.

Isto significa que, em termos práticos, este modelo permite estabelecer metas realistas para a implementação de eficiência energética, além de planejar a evolução e a redução do impacto ambiental. Permite também a redução direta e indireta de custos, por meio da adoção não apenas de algoritmos de alocação de recursos mais eficientes, mas também do uso de energia renovável. Realiza dessa forma diagnóstico do ambiente atual, bem como prevê os resultados das intervenções.

Um exemplo hipotético de data center é utilizado para ilustrar a estratégia de escalonamento, qual consome 155w para uma carga de trabalho específica e está classificado no Nível C. A escala utilizada para este exemplo, representada na Tabela 12 apresentada anteriormente, que é o resultado deste trabalho e os consumos energéticos,

são baseados nos valores de cada nível, onde 40w desse consumo são provenientes de fontes de energia renovável.

Nesse contexto, o data center hipotético utilizado é classificado como C+, já que os 40w representam cerca de 25,8% do consumo total proveniente de fontes renováveis. A pesquisa ressalta a importância não apenas da eficiência energética geral, mas também da proporção de energia renovável utilizada, representada na Tabela 14:

Tabela 14 – Escala de Nível Energético – Data Center Hipotético

Nível	Algoritmos / VMs	Consumo (w)
A	ACS 150 machines	106
B	DVFS 50 machines	149
C	PSO 50 machines	184
D	ACS 50 machines	205
E	RR 50 machines	268

Embora o uso exclusivo de energia renovável em um data center não seja suficiente para garantir plenamente a eficiência energética e a redução do impacto ambiental, é essencial adotar estratégias inteligentes para otimizar os recursos e promover a utilização racional da energia. Isto requer a busca por fontes limpas de energia, bem como soluções tecnológicas e organizacionais que favoreçam a gestão responsável e eficiente dos recursos no ambiente computacional.

A partir dessa categorização, é possível ter insights valiosos sobre o consumo de energia e a adoção de fontes renováveis, contribuindo assim para o desenvolvimento de práticas mais sustentáveis e responsáveis no setor de TI. As empresas podem utilizar essas informações para estabelecer metas de melhorias específicas, a exemplo de aumentar a proporção de energia renovável utilizada ou reduzir o consumo total de energia.

As propostas podem incluir melhorias na otimização da eficiência energética, seja através do aprimoramento dos algoritmos em uma escala vertical ou horizontal, seja por meio da substituição das fontes de energia convencionais por fontes renováveis.

Em suma, a incorporação de fontes renováveis de energia na infraestrutura do data center está representada pelos níveis horizontais apresentados nesta escala, conforme a Tabela 13. Cada adição é uma extensão do mesmo nível hierárquico, permitindo flexibilidade para se adaptar às oportunidades de crescimento energético de fontes renováveis. No entanto, a implementação horizontal requer investimentos financeiros e logísticos, além de gerenciamento cuidadoso para manter a eficiência operacional e energética à medida que o consumo de energia muda devido ao aumento da demanda computacional.

A variação da escala horizontal pode ser resultante de aumento ou redução

significativa na capacidade de processamento e armazenamento. Isto ocorre porque o modelo operacional baseia-se na proporção entre o consumo e a produção energética de fontes renováveis. Esta abordagem possibilita que os data centers atinjam a excelência operacional, mantendo simultaneamente gestão energética otimizada e consciente, de modo a garantir a sustentabilidade ambiental.

A utilização da escala vertical resulta em otimização do desempenho dos elementos já existentes, promovendo assim maior eficiência na alocação de energia e outros recursos. Por ser um modelo lógico, que visa maximizar a utilização dos recursos disponíveis, sua implementação pode ocorrer de maneira ágil e com menor investimento financeiro, o que também contribui para redução nos custos operacionais.

A integração estratégica das dimensões horizontal e vertical fornece uma abordagem inovadora quanto a maximizar a eficiência e sustentabilidade dos data centers. A harmonização dessas dimensões permite adaptar soluções que respondam eficazmente às demandas variáveis, buscando equilibrar a necessidade de expansão com a otimização dos recursos disponíveis.

Uma das vantagens dessa integração é a otimização dos benefícios de cada abordagem, o que resulta em sistema flexível e adaptável, que se ajusta proativamente às mudanças no ambiente operacional e nas demandas de mercado. O impacto desses elementos na eficiência energética e sustentabilidade pode ser significativo, oferecendo novos estímulos para inovação e melhorias na gestão dos data centers.

6.3 Predição dos Scores e do Nível Energético

Nesta seção, é explorada a predição dos scores e dos níveis energéticos utilizando técnicas de inteligência artificial. A predição eficiente desses scores permite melhor alocação de recursos e otimização do consumo energético, resultando em operações mais eficientes.

Utilizando redes neurais recorrentes (RNNs), que são adequadas para a modelagem de sequências temporais e padrões complexos, é proposto modelo que prevê o desempenho energético com base em dados históricos e variáveis operacionais. A aplicação de RNNs possibilita a análise mais precisa e dinâmica dos padrões de consumo de energia, adaptando-se a mudanças em tempo real e oferecendo subsídios valiosos para a gestão de data centers.

A predição dos scores e níveis energéticos não apenas aprimora a eficiência das operações, mas também contribui para a sustentabilidade ambiental, reduzindo o desperdício de energia e as emissões de CO₂. Além disso, essas predições facilitam a implementação de estratégias de gerenciamento proativas, permitindo intervenções antecipadas e ajustes na infraestrutura de TI.

A seguir é apresentada a metodologia utilizada para desenvolver e validar o modelo de predição, conforme ilustrado na Figura 10, construído com camada de entrada, várias camadas ocultas com unidades LSTM e camada de saída, de modo a prever o score de pontuação e o nível energético.




Figura 10 – Modelo de Predição do Nível Energético

Fonte: Autor

O treinamento do modelo foi realizado utilizando dados normalizados e categorizados, de acordo com os seguintes passos:

1. **Coleta e preparação de dados:** inicialmente, os dados foram obtidos a partir de simulações de ambiente em nuvem, resultantes desta pesquisa, considerando diferentes configurações de máquinas virtuais e algoritmos de escalonamento. As métricas coletadas incluíram consumo energético, tempo de processamento e custos de alocação. Visando garantir a comparabilidade dos dados, estes foram devidamente preparados e organizados para serem utilizados no treinamento do modelo de Redes Neurais Recorrentes.
2. **Implementação da LSTM:** A Rede Neural Recorrente de Memória de Longo Prazo (LSTM) foi selecionada como o modelo de RNN a ser utilizado, devido à sua capacidade de capturar dependências em séries temporais de longo prazo. A

implementação da LSTM envolveu a definição da arquitetura do modelo, incluindo o número de camadas, unidades e parâmetros ajustados durante o treinamento:

- Camada de Entrada: Recebe os dados normalizados de consumo energético, emissão de CO₂, tempo e custo.
 - Camadas Ocultas: Múltiplas camadas de neurônios LSTM para processamento sequencial.
 - Camada de Saída: Produz a previsão do score energético categorizado em níveis (A, B, C, D, E).
3. **Treinamento do modelo:** O modelo LSTM foi treinado com os dados históricos gerados na pesquisa. Durante o processo de treinamento, os parâmetros do modelo foram ajustados iterativamente para minimizar a discrepância entre as previsões do modelo e os valores reais observados.
 4. **Avaliação e validação:** após a etapa de treinamento, o modelo foi avaliado e validado com base em métricas de desempenho adequadas, alcançando uma taxa de acurácia aproximada de 90%.
 5. **Predição com RNN:** A predição foi realizada utilizando a função de previsão do modelo treinado. Novos dados de consumo energético foram normalizados e então fornecidos ao modelo como entrada, que então realizou a previsão da classe do índice de eficiência energética.

A acurácia do modelo é um indicador importante de seu desempenho, representando a proporção de previsões corretas em relação ao total de previsões. No treinamento inicial do modelo de Redes Neurais Recorrentes atingiu-se uma precisão de 90%. Embora essa precisão seja significativa, é possível sua melhora em trabalhos futuros. Podem ser adicionadas, por exemplo, técnicas como dropout para evitar o overfitting, aumentar a complexidade do modelo com camadas ocultas adicionais e implementar validação cruzada para garantir que o modelo generalize bem para novos dados.

Essas melhorias visam não apenas aumentar a acurácia, mas também garantir que o modelo seja robusto e confiável em diferentes cenários operacionais. A análise contínua da precisão, em conjunto com outras métricas de desempenho, é essencial para otimizar o modelo e assegurar que ele forneça previsões precisas e úteis.

Os resultados deste estudo revelaram que o modelo de Rede Neural Recorrente demonstrou capacidade de prever com precisão os índices de eficiência energética dos data centers, classificando-os em diferentes níveis (A, B, C, D, E). A análise indicou que as RNNs são eficazes na captura de padrões temporais e na modelagem das complexidades envolvidas no consumo de energia, tempo de processamento e custos

operacionais dos ambientes de computação em nuvem. Em comparação a métodos tradicionais, o uso de RNNs proporcionou melhoria significativa na precisão das previsões, facilitando a identificação de estratégias para a otimização da eficiência energética.

6.4 Quantização como Proposta para Eficiência Energética

O objetivo em relação a trabalhos futuros é explorar a possibilidade de utilizar a quantização como abordagem eficaz para reduzir o consumo de energia na computação em nuvem verde. A quantização pode otimizar o uso de recursos de hardware, permitindo uma execução mais eficiente e rápida das tarefas. Modelos quantizados ocupam menos espaço, o que pode diminuir os acessos à memória e o tráfego de rede, reduzindo, conseqüentemente, o consumo de energia associado à transferência de dados, à operação dos servidores e aos sistemas de refrigeração. Essa otimização de recursos é fundamental para a computação em nuvem verde, onde a eficiência energética e a sustentabilidade são prioridades.

A quantização é um conceito fundamental em diversas áreas científicas e tecnológicas, tais como processamento de sinais, telecomunicações e visão computacional. Com o aumento do volume de dados e da demanda por processamento, a quantização se destaca como campo promissor para a otimização e eficiência computacional.

Essa técnica envolve a redução da precisão dos dados de modo a otimizar o uso de recursos computacionais, apresentando-se como técnica promissora para a melhora da eficiência energética em data centers. No contexto deste trabalho, a quantização pôde ser explorada como abordagem eficaz para reduzir o consumo de energia sem comprometer significativamente a precisão dos resultados ([LATOTZKE; GEMMEKE, 2021](#)).

Futuros estudos podem investigar a aplicação de diferentes técnicas de quantização, como a quantização linear, logarítmica e binária, e avaliar seu impacto na eficiência energética, no caso, em ambientes de computação em nuvem verde. A aplicação de modelos quantizados pode otimizar o uso de recursos, diminuindo o consumo de energia associado à operação dos servidores e sistemas de refrigeração. A combinação de quantização com estratégias de gerenciamento de recursos e práticas de computação verde pode resultar em data centers mais eficientes e sustentáveis ([LIN et al., 2021a](#); [LE; LI, 2023](#)).

A quantização, apesar de trazer benefícios significativos em termos de eficiência e desempenho, enfrenta diversos desafios que podem impactar a qualidade e a utilidade dos dados e modelos. Ou seja, é importante considerar o trade-off entre precisão e eficiência, buscando estratégias que equilibrem a redução da precisão com a manutenção da acurácia do modelo ([LATOTZKE; GEMMEKE, 2021](#); [GHOLAMI et al., 2022](#)).

Sugere-se que a metodologia para esses estudos possa envolver a realização de simulações e experimentos em ambientes controlados para avaliar a eficiência energética e precisão dos modelos quantizados. A combinação da quantização com estratégias de gerenciamento de recursos e práticas de computação verde pode resultar em data centers mais eficientes e sustentáveis. Também é possível avaliar a adoção de processamento distribuído, permitindo que tarefas sejam executadas localmente em dispositivos de borda, antes de serem enviadas para a nuvem, minimizando a necessidade de transmissão constante de grandes volumes de dados e reduzindo o consumo de energia (ROKH; AZARPEYVAND; KHANTEYMOORI, 2022; DU; GONG; CHU, 2024):.

Tais aspectos ressaltam a necessidade de investigações adicionais para desenvolver e implementar técnicas de quantização que maximizem a eficiência energética e a sustentabilidade em data centers, contribuindo portanto para a computação em nuvem verde.

6.5 Considerações Finais

Dentre as contribuições desta pesquisa, este capítulo apresentou método de pontuação energética inovador, baseado em pesos atribuídos a várias métricas, permitindo a avaliação mais objetiva e quantitativa das configurações e algoritmos de escalonamento. Este sistema fornece ferramenta útil para avaliar e comparar a eficiência energética em diferentes configurações de data centers, oferecendo base sólida para decisões estratégicas e operacionais.

Além disso, o modelo de nível energético que categoriza os data centers em diferentes níveis de eficiência energética, utilizando inteligência artificial, ressalta o compromisso com práticas sustentáveis e responsáveis. Este modelo não só facilita a identificação das áreas que necessitam de melhorias, mas também oferece caminho claro para práticas de gestão de energia mais eficientes e sustentáveis.

Por outro lado, este capítulo examinou a previsão dos níveis de eficiência energética por meio do uso de Redes Neurais Recorrentes, demonstrando ser esta uma abordagem robusta. Através da normalização e categorização dos dados, bem como da aplicação de modelos LSTM, foi possível realizar previsões precisas dos níveis de eficiência energética, auxiliando na implementação de práticas sustentáveis e eficientes. Esta combinação de técnicas avançadas reforça o potencial de melhorar significativamente a gestão de energia em data centers, promovendo a exploração de possibilidades de intervenções mais sustentáveis, alinhada com as demandas ambientais atuais.

A quantização foi apresentada como proposta promissora para trabalhos futuros, com o potencial de não apenas otimizar o uso de recursos computacionais mas também

minimizar o consumo de energia, oferecendo caminho viável para a operação eficiente e sustentável de data centers. A implementação de modelos quantizados pode equilibrar a necessidade de processamento de alto desempenho com a urgência de práticas de conservação de energia. Além disso, estudos futuros podem investigar como a integração eficaz de estratégias de gerenciamento de recursos e práticas de computação verde, aliada à quantização, pode resultar em operações de TI mais econômicas e ambientalmente responsáveis.

O próximo capítulo, dedicado às conclusões desta pesquisa, sintetiza os principais achados e reflete sobre as implicações práticas e teóricas dos resultados obtidos. Além de destacar as contribuições para o avanço da computação em nuvem verde, avalia o papel dessas soluções no contexto de sustentabilidade em TI, oferecendo uma análise crítica dos desafios enfrentados e também propõe caminhos futuros para pesquisas e inovações que possam fortalecer a adoção de práticas mais sustentáveis na área.

7 Conclusão

7.1 Conclusões da Tese

A computação sustentável em nuvem é tema cada vez mais debatido, tanto no setor empresarial quanto na área acadêmica. As empresas estão gradualmente adotando este modelo, como resposta ao aumento do armazenamento de dados e das demandas de computação, o que leva à expansão da infraestrutura dos provedores de serviços em nuvem. Esta expansão traz implicações econômicas e socioambientais significativas, incluindo o consumo de energia, a utilização de recursos hídricos e as emissões de CO₂. Diante dessa crescente necessidade, torna-se imprescindível desenvolver data centers com maior eficiência energética e utilização de fontes renováveis de energia, como reflexo da crescente responsabilidade ambiental das empresas.

No âmbito acadêmico, a computação em nuvem verde emerge como catalisador da pesquisa inovadora, ao mesmo tempo em que promove a reestruturação da infraestrutura tecnológica das organizações. Além disso, estabelece novos paradigmas quanto à pesquisa e ao desenvolvimento acadêmico, sublinhando o papel indispensável das instituições de ensino quanto ao avanço de práticas sustentáveis na área da computação.

Este estudo teve como um dos seus propósitos identificar as principais métricas utilizadas bem como as possíveis áreas e categorias para a sustentabilidade na computação em nuvem. Além disso, objetivou avaliar a redução do consumo de energia sem prejudicar o tempo de processamento e sua eficiência.

Inicialmente, realizou-se revisão bibliográfica sobre tópicos relevantes para a área de sustentabilidade na computação em nuvem. Ainda, explorou-se os conceitos fundamentais de energia e computação em nuvem, com ênfase especial na computação em nuvem verde, apresentando princípios de sustentabilidade aplicados à TI, à eficiência energética e ao uso sustentável de recursos.

No que diz respeito aos trabalhos relacionados, proporcionou visão abrangente do estado da arte, identificando lacunas que esta pesquisa se propôs a preencher.

Foi descrita detalhadamente a metodologia utilizada neste estudo, na qual são destaques o rigor e a inovação, empregando abordagem quantitativa para avaliar o desempenho de algoritmos de alocação de recursos em ambientes de nuvem.

Por meio do uso do simulador CloudSim Plus, pôde simular cenários complexos e analisar o comportamento dos algoritmos frente a diferentes demandas de processamento e padrões de consumo de energia. Além disso, o estudo realizou uma análise crítica das

implicações das estratégias propostas, fundamentando os resultados obtidos e garantindo a replicabilidade dos experimentos.

Os resultados das simulações apresentaram redução significativa no consumo de energia e nas emissões de CO₂, além de melhorias na eficiência do custo de alocação de máquinas virtuais.

Desse modo, as contribuições deste trabalho destacam a importância da adoção de estratégias inovadoras e a implementação de modelos quantitativos de avaliação energética para otimizar a eficiência da computação em nuvem. Além disso, a proposta de novos métodos para a computação em nuvem verde abre novas perspectivas para futuras pesquisas e desenvolvimento de tecnologias ainda mais eficientes em termos energéticos.

7.2 Principais Resultados e Contribuições

Os principais resultados desta pesquisa são apresentados a seguir, com destaque para as contribuições relevantes que trazem para a temática:

1. **Revisão Bibliográfica:** Foi realizada revisão crítica da bibliografia existente, com o objetivo de contextualizar o presente trabalho e relatar os avanços mais recentes na área de computação em nuvem verde. Destaca-se especialmente o levantamento feito sobre as métricas de eficiência energética e as estratégias de sustentabilidade aplicadas em data centers. Este levantamento representa contribuição significativa para a sistematização do conhecimento sobre o tema.
2. **Desenvolvimento Sustentável:** O desenvolvimento sustentável envolve a gestão equilibrada de recursos naturais e a redução dos impactos ambientais, ao mesmo tempo em que se busca o progresso econômico e social. No âmbito da computação em nuvem, a implementação de práticas sustentáveis é essencial, que vem ocorrendo devido ao aumento do consumo de energia e à expansão da infraestrutura de data centers. Este estudo realça a relevância da eficiência energética e do uso de fontes de energia renováveis como fundamentos essenciais do desenvolvimento sustentável na computação. As estratégias sugeridas não só visam diminuir o consumo de energia e as emissões de CO₂, mas também promover abordagem integrada que combine sustentabilidade e inovação tecnológica, contribuindo para a preservação do meio ambiente e a responsabilidade social corporativa.
3. **Computação Verde no Meio Acadêmico:** A computação verde no meio acadêmico tem se destacado como campo de pesquisa emergente e essencial para a modernização da infraestrutura tecnológica. Este estudo explora a adoção de práticas de computação verde, com ênfase na eficiência energética e na sustentabilidade ambiental.

A pesquisa é fundamental para fornecer diretrizes e modelos aplicáveis tanto na área acadêmica quanto na indústria. Por meio do desenvolvimento e avaliação de novos algoritmos e metodologias, a academia contribui significativamente para a disseminação de conhecimentos e práticas sustentáveis, respaldando as futuras gerações para enfrentar os desafios ambientais com soluções inovadoras e eficazes.

4. **Uso do ACS para Alocação de Tarefas:** O Sistema de Colônia de Formigas (ACS), técnica de otimização baseada no comportamento coletivo das formigas, foi aplicado de forma pioneira neste estudo para a alocação de tarefas em ambientes de computação em nuvem verde. A implementação do ACS visa melhorar a eficiência na alocação de recursos, reduzindo o consumo de energia e aumentando o desempenho operacional dos data centers.

No contexto deste estudo, o ACS foi implementado no âmbito do simulador CloudSim Plus para gerir a alocação de tarefas e foi configurado para considerar várias métricas de desempenho, incluindo o consumo de energia, o tempo de resposta, custos de alocação e a eficiência no uso de recursos.

A implementação do ACS na distribuição de tarefas demonstrou ser extremamente eficaz na diminuição do consumo de energia e no aumento da eficiência operacional dos data centers. Em comparação com outros algoritmos, como Round Robin (RR), Dynamic Voltage and Frequency Scaling (DVFS) e Particle Swarm Optimization (PSO), o ACS mostrou desempenho superior em diversos cenários de simulação.

Os principais benefícios observados com o uso do ACS foram:

- **Redução no Consumo de Energia em 55%:** Através da implementação de algoritmos mais eficientes na alocação de recursos, mostrou-se que é possível alcançar significativa redução no uso de energia, de aproximadamente 55%, sem prejudicar o tempo de processamento. Essa diminuição no consumo energético não só auxilia na redução do impacto ambiental, mas também pode gerar economias operacionais expressivas.
- **Redução nos Custos de Alocação em 28%:** A pesquisa também constatou diminuição significativa nos gastos relacionados à distribuição de máquinas virtuais, podendo chegar a aproximadamente 28%. Isto evidencia que adotar práticas mais eficientes de computação em nuvem verde não apenas é vantajoso para o ambiente no aspecto energético, mas também apresenta benefícios econômicos relevantes.
- **Redução na Emissão de CO₂ em 55.95%:** Com a implementação deste modelo foi possível observar redução significativa no impacto ambiental,

resultando em diminuição total de 513 toneladas de CO₂ liberadas no ambiente, equivalendo a 55.95% na diminuição da emissão de dióxido de carbono.

5. **Método de Avaliação Inovador:** A pesquisa introduziu método inovador de avaliação para medir a eficiência energética de algoritmos de alocação de recursos em ambientes de computação em nuvem verde. Com o uso do simulador CloudSim Plus, foram criados cenários complexos para examinar o comportamento dos algoritmos sob diversas demandas de processamento. O método incluiu a aplicação de técnicas estatísticas rigorosas para validar os resultados, assegurando a precisão e a replicabilidade dos experimentos. Esta abordagem inovadora permitiu avaliação objetiva e detalhada das estratégias de alocação, fornecendo insights valiosos para a otimização do consumo energético e a melhoria do desempenho dos data centers.
6. **Otimização do Consumo Energético:** A otimização do consumo de energia foi um dos principais objetivos deste estudo, com o intuito de diminuir consideravelmente o impacto ambiental dos data centers. Foram investigadas várias estratégias de escalonamento e alocação de recursos, destacando-se os algoritmos Round Robin (RR), Dynamic Voltage and Frequency Scaling (DVFS), Particle Swarm Optimization (PSO) e Ant Colony System (ACS). Os resultados das simulações mostram redução significativa no consumo de energia e nas emissões de CO₂, além de melhoria na eficiência de custos. A pesquisa evidenciou que a implementação de estratégias de otimização inovadoras pode resultar em ganhos substanciais quanto à sustentabilidade e eficiência operacional.

É fundamental ressaltar que, para obter melhores resultados, é necessário utilizar várias abordagens em conjunto. A exemplo da utilização da arquitetura sugerida combinada com o desenvolvimento de software distribuído.

7. **Cálculo de Pontuação:** O método de pontuação apresentado neste estudo, como uma das suas contribuições inovadoras relevantes, serve como ferramenta objetiva e quantificável para avaliar comparativamente os algoritmos de alocação de recursos com relação à eficiência energética e ao desempenho operacional. A criação de um sistema de pontuação foi motivada pela constatação de que, apesar da existência de diversas técnicas de otimização e escalonamento, a ausência de métrica padronizada tornava difícil a avaliação comparativa e a tomada de decisões bem fundamentadas.

Este método permitiu medir com precisão os ganhos em sustentabilidade, auxiliando na tomada de decisões sobre as estratégias mais adequadas para a computação em nuvem verde. A pontuação foi determinada com base em métricas específicas, utilizando modelo de otimização multiobjetivo e decisão multicritério, permitindo comparação direta entre diferentes soluções, com destaque para aquelas que

apresentam melhores resultados em termos de consumo de energia e redução de emissões de CO₂.

A implementação do sistema de pontuação constituiu avanço importante na investigação da eficiência energética na computação em nuvem. Este método não apenas permite a comparação objetiva entre diversos algoritmos mas também fornece ferramenta útil para administradores de data centers e desenvolvedores de algoritmos. Com essa ferramenta, é possível determinar rapidamente quais estratégias proporcionam os melhores resultados em termos de sustentabilidade e eficiência operacional.

Ademais, a avaliação pode ser ajustada e ampliada para abranger novos critérios à medida que a tecnologia e as necessidades operacionais se desenvolvam. Dessa forma, o cálculo da pontuação não só atende às demandas atuais, mas também se estabelece como base flexível para inovações futuras na gestão sustentável de data centers.

8. **Modelo de Classificação da Eficiência Energética:** O modelo de classificação da eficiência energética criado nesta pesquisa, também como uma das suas contribuições de destaque, possibilita o monitoramento e a avaliação do desempenho dos data centers em termos de consumo de energia e uso de fontes renováveis. Este modelo oferece escala clara e objetiva para classificar os níveis de eficiência energética, contribuindo para a adoção de práticas mais sustentáveis.

Para tanto, o modelo de classificação da eficiência energética utiliza duas abordagens distintas: a escala vertical e a escala horizontal, onde a vertical otimiza o desempenho dos elementos já existentes e promove maior eficiência na alocação de energia e outros recursos disponíveis. Enquanto a horizontal baseia-se na proporção entre o consumo e a produção energética de fontes renováveis, incorporando a sustentabilidade ambiental e incentivando o uso de energias renováveis,

O modelo de classificação da eficiência energética tem implicações significativas tanto para a academia quanto para a indústria de TI, considerando:

- **Transparência e Clareza:** Fornece visão clara do desempenho energético dos data centers, facilitando a identificação de áreas que necessitam de melhorias.
- **Incentivo à Sustentabilidade:** Ao destacar o uso de energias renováveis e a eficiência de resfriamento, o modelo incentiva práticas mais sustentáveis e ambientalmente responsáveis.
- **Redução de Custos:** Ajuda a identificar ineficiências e a implementar estratégias para reduzir o consumo de energia, resultando em economias significativas de custos operacionais.

- **Melhoria Contínua:** O feedback contínuo fornecido pelo modelo permite ajustes constantes e implementação de práticas de melhoria contínua.
- **Benchmarking:** Oferece referência para empresas compararem o desempenho energético de seus data centers com os padrões da indústria, incentivando a competição saudável e a melhoria contínua.
- **Certificação:** Pode servir como base para programas de certificação de eficiência energética, reconhecendo e destacando data centers que alcancem altos níveis de eficiência.
- **Desenvolvimento de Políticas:** Subsidia a formulação de políticas e regulamentações que promovam a eficiência energética e a sustentabilidade nos data centers.

9. **Utilização de Classificadores Baseados em Redes Neurais:** De maneira igualmente inovadora, visando aprimorar a capacidade de adaptação do modelo, foram incorporadas nesta pesquisa, técnicas de inteligência artificial, como redes neurais e algoritmos de aprendizado de máquina, para distribuição e classificação dos níveis, o que contribuiu para a melhoria da precisão na categorização dos scores de eficiência energética.
10. **Predição de Nível Energético:** a aplicação de Redes Neurais Recorrentes revelou-se abordagem eficaz e robusta para a previsão do nível de eficiência energética em data centers. Essa metodologia mostrou-se capaz de lidar com a complexidade inerente à análise de grandes volumes de dados, identificando padrões sutis e não lineares. As RNNs demonstraram aptidão em capturar as dependências temporais e modelar as relações complexas entre consumo energético, emissão de CO₂, tempo de processamento e custos de alocação de recursos. A utilização dessas técnicas resultou em previsões precisas do desempenho energético, com aproximadamente 90% de acurácia, evidenciando a solidez do modelo quanto a projetar os níveis de eficiência energética com base em dados históricos.

A capacidade de prever com precisão o desempenho energético permite que ajustes proativos sejam realizados nas operações dos data centers, resultando na redução do consumo de energia e dos custos operacionais. Essa previsão facilita a identificação de áreas com potencial para melhoria significativa na eficiência energética, proporcionando base sólida para a implementação de práticas operacionais mais sustentáveis.

Por outro lado, a proposta de sistema preditivo do índice de eficiência energética baseado em Redes Neurais Recorrentes proporciona ferramenta objetiva para avaliar e comparar diferentes configurações e algoritmos de escalonamento,

facilitando a tomada de decisões estratégicas e operacionais em ambientes de data centers. Este modelo, que abrangeu a coleta e preparação dos dados, a implementação de camadas LSTM bem como o treinamento e avaliação do modelo, representa contribuição significativa para aplicações práticas na área.

Em suma, pode-se concluir que esta tese atingiu plenamente os objetivos a que se propôs, quanto ao estudo da eficiência energética e a sustentabilidade em data centers de computação em nuvem. O modelo de pontuação de scores e classificação da eficiência energética desenvolvidos engloba os principais aspectos da sustentabilidade e os transporta para o ambiente de data centers de forma flexível e independente de arquitetura. Os resultados obtidos comprovam que o modelo é efetivamente capaz de avaliar e categorizar a eficiência energética de diferentes infraestruturas, estimulando práticas mais sustentáveis.

A tese ainda destaca a importância e necessidade de uma abordagem integrada, que empregue simultaneamente infraestrutura eficiente, software otimizado e políticas sustentáveis, de modo a fomentar um futuro tecnológico mais verde. As inovações aqui apresentadas servem como chamado às instituições acadêmicas e empresas de TI, incentivando-as quanto à transição para práticas mais sustentáveis, e assim contribuindo de modo importante para a computação em nuvem verde e para a construção de ambiente de TI mais sustentável e eficiente.

Por sua vez, até o momento as seguintes publicações foram produzidas com base nos resultados alcançados ao longo do desenvolvimento desta tese:

- REIS, T. N. F. d.; TEIXEIRA, M. M.; NETO, C. d. S. S. Relações do consumo energético nas execuções de tarefas em computação em nuvem verde. *Revista de Sistemas e Computação-RSC*, v.12, n.3, 2023.
- REIS, T. N. F. D.; TEIXEIRA, M. M.; NETO, C. D. S. S. Relation of energy consumption in green cloud computing with big data. In: *IEEE. 2023 IEEE Green Technologies Conference (GreenTech)*. [S.l.], 2023. p.280–284.
- REIS, T. N. F. dos; TEIXEIRA, M. M.; NETO, C. d. S. S. Uma abordagem de redução de energia na computação em nuvem verde. *Research, Society and Development*, v. 12, n.7, p.e1812742407–e1812742407, 2023.
- REIS, T. N. F. dos; TEIXEIRA, M. M.; NETO, C. d. S. S.; REIS, A. M. S. dos. Algoritmo dvfs como alternativa para redução de energia na computação em nuvem verde com big data. *OBSERVATÓRIO DE LA ECONOMÍA LATINOAMERICANA*, v. 21, n. 11, p. 23302–23320, 2023.

- REIS, T. N. F. dos; TEIXEIRA, M. M.; NETO, C. d. S. S.; OLIVEIRA, A.; SOUSA, A. M. A tier labeling proposal for energy efficiency in green cloud. *Journal of Sustainability Research*, *Journal of Sustainability Research*, v.6, n.1, 2024.
- REIS, T. N. F. dos; TEIXEIRA, M. M.; NETO, C. d. S. S.; SOUSA, A. M. Uma proposta de classificação para rotular a eficiência energética na computação em nuvem verde. *Boletim de Conjuntura (BOCA)*, v.17, n.49, p.761–793, 2024.

7.3 Trabalhos Futuros

Quanto aos trabalhos futuros, abrem-se novos e promissores direcionamentos. Os conhecimentos adquiridos a partir dos resultados atuais revelam um vasto campo para exploração adicional e aprimoramento na área da computação em nuvem verde.

Cabe explorar a quantização, proposta na pesquisa como metodologia inovadora e eficaz para a computação em nuvem verde, visando à redução do consumo energético em data centers. Esta técnica permite a otimização de recursos computacionais ao converter os dados e operações em formatos mais compactos, sem comprometer significativamente a precisão e melhorando o desempenho das aplicações. Ao reduzir a complexidade computacional, a quantização resulta em menor consumo de energia e, conseqüentemente, menor emissão de CO₂, alinhando-se aos princípios da sustentabilidade.

Outra contribuição relevante desta abordagem é a possibilidade de processamento distribuído, com tarefas sendo executadas localmente em dispositivos de borda antes de serem enviadas para a nuvem. Esta estratégia permite minimizar a necessidade de transferência constante de grandes volumes de dados, reduzindo o consumo de energia associado à transmissão dos dados e ao processamento centralizado em data centers.

Além dos benefícios já observados com a técnica de quantização, seu uso pode abrir novas perspectivas para o desenvolvimento de tecnologias ainda mais eficientes em termos energéticos, observando que a proposta de utilizar a quantização como metodologia para a computação em nuvem verde ainda carece de maior investigação, incluindo o desenvolvimento de benchmarks específicos para avaliação da eficiência energética.

Referências

AGARWAL, S.; RANI, N.; VAJPAYEE, A. Bioinspired algorithms: Opportunities and challenges. **Bio-Inspired Optimization for Medical Data Mining**, Wiley Online Library, p. 1–30, 2024. Citado na página 53.

AGRAWAL, M. N.; SAINI, M. J. K.; WANKHEDE, P. Review on green cloud computing: A step towards saving global environment. 2020. Citado 2 vezes nas páginas 36 e 37.

Agência Nacional de Energia Elétrica (ANEEL). **Resolução Normativa Nº 1000, de 07 de dezembro de 2021**. 2021. Acesso em: 13 mai. 2024. Disponível em: <<https://www2.aneel.gov.br/cedoc/ren20211000.pdf>>. Citado 2 vezes nas páginas 24 e 25.

Agência Nacional de Energia Elétrica (ANEEL). **Manual de Procedimentos de Distribuição (PRODIST) - Módulo 5**. [S.l.], 2022. Acesso em: 13 mai. 2024. Disponível em: <https://www2.aneel.gov.br/cedoc/aren2021956_2.pdf>. Citado 2 vezes nas páginas 24 e 25.

Agência Nacional de Energia Elétrica (ANEEL). **Manual de Procedimentos de Distribuição (PRODIST) - Módulo 5**. [S.l.], 2022. Acesso em: 13 mai. 2024. Disponível em: <https://www2.aneel.gov.br/cedoc/aren2021956_2_4.pdf>. Citado 2 vezes nas páginas 24 e 25.

Agência Nacional de Energia Elétrica (ANEEL). **Regras e Procedimentos de Distribuição (Prodinst)**. 2022. Acesso em: 13 mai. 2024. Disponível em: <<https://www.gov.br/aneel/pt-br/centrais-de-conteudos/procedimentos-regulatorios/prodist>>. Citado 2 vezes nas páginas 24 e 25.

ALIZADEH, R.; ALLEN, J. K.; MISTREE, F. Managing computational complexity using surrogate models: a critical review. **Research in Engineering Design**, Springer, v. 31, n. 3, p. 275–298, 2020. Citado na página 81.

ALVAREZ, P. A.; ISHIZAKA, A.; MARTÍNEZ, L. Multiple-criteria decision-making sorting methods: A survey. **Expert Systems with Applications**, Elsevier, v. 183, p. 115368, 2021. Citado na página 93.

AMAZON. **Amazon WorkSpaces Family pricing**. 2023. Disponível em: <<https://sustainability.google/>>. Acesso em: Agosto 2023. Citado na página 32.

AMAZON. **Amazon WorkSpaces Family pricing**. 2023. Disponível em: <<https://aws.amazon.com/workspaces/pricing/>>. Acesso em: Junho 2023. Citado na página 68.

ANSER, M. K.; AHMAD, M.; KHAN, M. A.; ZAMAN, K.; NASSANI, A. A.; ASKAR, S. E.; ABRO, M. M. Q.; KABBANI, A. The role of information and communication technologies in mitigating carbon emissions: evidence from panel quantile regression. **Environmental Science and Pollution Research**, Springer, v. 28, p. 21065–21084, 2021. Citado 2 vezes nas páginas 57 e 61.

ARAÚJO, R. S. de; SOUSA, F. L. N. de; VANDERLEY, P. S.; BENTES, S. O. da S.; GOMES, L. M.; FERREIRA, F. C. L. Fontes de energias renováveis: pesquisas, tendências e perspectivas sobre as práticas sustentáveis. **Research, Society and Development**, v. 11, n. 11, p. e468111133893–e468111133893, 2022. Citado 2 vezes nas páginas 60 e 63.

BALHARITH, T.; ALHAIDARI, F. Round robin scheduling algorithm in cpu and cloud computing: a review. In: IEEE. **2019 2nd International Conference on Computer Applications & Information Security (ICCAIS)**. [S.l.], 2019. p. 1–7. Citado na página 76.

BARBIERATO, E.; GRIBAUDO, M.; IACONO, M.; JAKÓBIK, A. Exploiting cloudsims in a multiformalism modeling approach for cloud based systems. **Simulation Modelling Practice and Theory**, Elsevier, v. 93, p. 133–147, 2019. Citado 3 vezes nas páginas 19, 47 e 75.

BASH, C.; CADER, T.; CHEN, Y.; GMACH, D.; KAUFMAN, R.; MILOJICIC, D.; SHAH, A.; SHARMA, P. Cloud sustainability dashboard, dynamically assessing sustainability of data centers and clouds. **Proceedings of the Fifth Open Cirrus Summit, Hewlett Packard, CA, USA**, Citeseer, v. 13, 2011. Citado na página 37.

BCS, T. C. I. f. I. **Green IT: Managing Your Carbon Footprint**. British Informatics Society Limited, 2012. (ITPro collection). ISBN 9781780171340. Disponível em: <https://books.google.com.br/books?id=Gz2_fUJIZtYC>. Citado na página 34.

BHARANY, S.; SHARMA, S.; KHALAF, O. I.; ABDULSAHIB, G. M.; HUMAIMEEDY, A. S. A.; ALDHYANI, T. H.; MAASHI, M.; ALKAHTANI, H. A systematic survey on energy-efficient techniques in sustainable cloud computing. **Sustainability**, MDPI, v. 14, n. 10, p. 6256, 2022. Citado 4 vezes nas páginas 41, 45, 58 e 61.

BISWAS, N. K.; BANERJEE, S.; BISWAS, U.; GHOSH, U. An approach towards development of new linear regression prediction model for reduced energy consumption and sla violation in the domain of green cloud computing. **Sustainable Energy Technologies and Assessments**, Elsevier, v. 45, p. 101087, 2021. Citado 2 vezes nas páginas 58 e 62.

BREBNER, P. C. Is your cloud elastic enough?: Performance modelling the elasticity of infrastructure as a service (iaas) cloud applications. In: **Proceedings of the 3rd ACM/SPEC International Conference on Performance Engineering**. New York, NY, USA: ACM, 2012. (ICPE '12), p. 263–266. ISBN 978-1-4503-1202-8. Disponível em: <<http://doi.acm.org/10.1145/2188286.2188334>>. Citado na página 30.

CHENG, H.; LIU, B.; LIN, W.; MA, Z.; LI, K.; HSU, C.-H. A survey of energy-saving technologies in cloud data centers. **The Journal of Supercomputing**, Springer, v. 77, n. 11, p. 13385–13420, 2021. Citado 2 vezes nas páginas 32 e 33.

CHICHE, A.; YITAGESU, B. Part of speech tagging: a systematic review of deep learning and machine learning approaches. **Journal of Big Data**, SpringerOpen, v. 9, n. 1, p. 1–25, 2022. Citado na página 101.

CHOPRA, J.; RANGARAJAN, V.; SEN, R. Sustainable energy technologies and assessments. 2021. Citado 3 vezes nas páginas 46, 58 e 61.

CLOUDSIM. **Full-featured and fully documented cloud simulation framework**. 2016. Disponível em: <<http://cloudsimplus.org/>>. Citado 3 vezes nas páginas 47, 75 e 78.

CUNHA, C. R.; MORAIS, E. P.; SOUSA, J. P.; GOMES, J. P. The role of cloud computing in the development of information systems for smes. **IBIMA Publishing**, p. 1–7, 2017. ISSN 2326-6538. Disponível em: <<http://hdl.handle.net/10198/14061>>. Citado 2 vezes nas páginas 28 e 29.

DORIGO, M.; STÜTZLE, T. **Ant colony optimization: overview and recent advances**. [S.l.]: Springer, 2019. Citado na página 76.

DU, D.; GONG, G.; CHU, X. Model quantization and hardware acceleration for vision transformers: A comprehensive survey. **arXiv preprint arXiv:2405.00314**, 2024. Citado na página 107.

EPA, U. S. E. P. A. **Greenhouse Gas Equivalencies Calculator**. 2022. Disponível em: <<https://www.epa.gov/energy/greenhouse-gas-equivalencies-calculator>>. Citado 3 vezes nas páginas 40, 68 e 88.

ESPADOTO, M.; HIRATA, N. S. T.; TELEA, A. C. Self-supervised dimensionality reduction with neural networks and pseudo-labeling. In: **Proceedings**. [S.l.: s.n.], 2021. Citado 2 vezes nas páginas 98 e 101.

EZUGWU, A. E.; IKOTUN, A. M.; OYELADE, O. O.; ABUALIGAH, L.; AGUSHAKA, J. O.; EKE, C. I.; AKINYELU, A. A. A comprehensive survey of clustering algorithms: State-of-the-art machine learning applications, taxonomy, challenges, and future research prospects. **Engineering Applications of Artificial Intelligence**, Elsevier, v. 110, p. 104743, 2022. Citado 2 vezes nas páginas 72 e 73.

FAN, X.; SAYERS, W.; ZHANG, S.; HAN, Z.; REN, L.; CHIZARI, H. Review and classification of bio-inspired algorithms and their applications. **Journal of Bionic Engineering**, Springer, v. 17, p. 611–631, 2020. Citado na página 52.

FARAHNAKIAN, F.; ASHRAF, A.; PAHIKKALA, T.; LILJEBERG, P.; PLOSILA, J.; PORRES, I.; TENHUNEN, H. Using ant colony system to consolidate vms for green cloud computing. **IEEE Transactions on Services Computing**, v. 8, n. 2, p. 187–198, 2015. Citado na página 75.

FERNANDES, A. H. dos S.; BRAGA, A. da S.; FRADE, D. D. R.; NASCIMENTO, J. dos S.; OLIVEIRA, J. A. M. de; MEDEIROS, D. J. O. de. An overview of the development of a new probability distribution: Odd log-logistic skew t-student. **Brazilian Journal of Development**, v. 7, n. 3, p. 30536–30555, 2021. Citado 2 vezes nas páginas 69 e 80.

FILHO, M. C. S.; OLIVEIRA, R. L.; MONTEIRO, C. C.; INÁCIO, P. R.; FREIRE, M. M. Cloudsim plus: A cloud computing simulation framework pursuing software engineering principles for improved modularity, extensibility and correctness. In: IEEE. **2017 IFIP/IEEE symposium on integrated network and service management (IM)**. [S.l.], 2017. p. 400–406. Citado 3 vezes nas páginas 19, 47 e 75.

FRANÇA, C. G.; FACEROLI, S. T.; NASCIMENTO, P. S. C.; KLIGERMAN, A. S. et al. Análise comparativa de modelos de previsão de geração de energia eólica baseados em machine learning. **Revista de Sistemas e Computação-RSC**, v. 9, n. 2, 2020. Citado 2 vezes nas páginas 60 e 63.

- GADE, A. Survey on energy efficient cloud: A novel approach towards green computing. **HELIX**, 2018. Citado 2 vezes nas páginas 17 e 39.
- GARG, S. K.; YEO, C. S.; BUYYA, R. Green cloud framework for improving carbon efficiency of clouds. In: SPRINGER. **European Conference on Parallel Processing**. [S.l.], 2011. p. 491–502. Citado 2 vezes nas páginas 36 e 37.
- GHOLAMI, A.; KIM, S.; DONG, Z.; YAO, Z.; MAHONEY, M. W.; KEUTZER, K. A survey of quantization methods for efficient neural network inference. In: **Low-Power Computer Vision**. [S.l.]: Chapman and Hall/CRC, 2022. p. 291–326. Citado na página 106.
- GOYAL, V.; GARG, S. Green cloud computing for sustainable environment: A review. 2022. Citado 2 vezes nas páginas 31 e 45.
- HAMMOOD, W. A.; ZAMIL, K. Z.; ALI, A. M. A review of bio-inspired algorithm. In: **Conference:(SOFTEC Asia 2017), at Kuala Lumpur Convention Centre**. [S.l.: s.n.], 2017. v. 12, p. 303–334. Citado na página 52.
- HERBST, N. R.; KOUNEV, S.; REUSSNER, R. Elasticity in cloud computing: What it is, and what it is not. In: **Proceedings of the 10th International Conference on Autonomic Computing (ICAC 13)**. San Jose, CA: USENIX, 2013. p. 23–27. ISBN 978-1-931971-02-7. Disponível em: <<https://www.usenix.org/conference/icac13/technical-sessions/presentation/herbst>>. Citado 2 vezes nas páginas 26 e 29.
- HUANG, P.; COPERTARO, B.; ZHANG, X.; SHEN, J.; LÖFGREN, I.; RÖNNELID, M.; FAHLEN, J.; ANDERSSON, D.; SVANFELDT, M. A review of data centers as prosumers in district energy systems: Renewable energy integration and waste heat reuse for district heating. **Applied energy**, Elsevier, v. 258, p. 114109, 2020. Citado na página 44.
- JASMIN, M.; PHILOMINA, S. Runtime adaptive dynamic voltage frequency scaling technique for reducing the power consumption in multi processor system on chip. 2019. Citado na página 76.
- JENA, S. R.; SHANMUGAM, R.; SAINI, K.; KUMAR, S. Cloud computing tools: inside views and analysis. **Procedia Computer Science**, Elsevier, v. 173, p. 382–391, 2020. Citado 2 vezes nas páginas 58 e 62.
- JOHNSON, D. V. D. L. Auto-scaling and cloud bursting service for eucalyptus. **IBIMA Publishing**, 2011. Disponível em: <<https://people.cs.uct.ac.za/~djohnson/Files/autoscale.pdf>>. Citado na página 29.
- JOHNVICTOR, A. C.; DURGAMAHANTHI, V.; VENKATA, R. M. P.; JETHI, N. Critical review of bio-inspired optimization techniques. **Wiley Interdisciplinary Reviews: Computational Statistics**, Wiley Online Library, v. 14, n. 1, p. e1528, 2022. Citado na página 52.
- JUMDE, M.; DONGRE, S. Analysis on energy efficient green cloud computing. In: IOP PUBLISHING. **Journal of Physics: Conference Series**. [S.l.], 2021. v. 1913, n. 1, p. 012100. Citado na página 31.
- JUNIOR, T. J. T.; BRUSCHI, S. Epcsc-extensible platform for cloud scheduling algorithm comparison. In: SBC. **Anais Estendidos do XXI Simpósio em Sistemas Computacionais de Alto Desempenho**. [S.l.], 2020. p. 46–53. Citado na página 19.

JUNIOR, T. J. T.; BRUSCHI, S. Epcsac-extensible platform for cloud scheduling algorithm comparison. In: SBC. **Anais Estendidos do XXI Simpósio em Sistemas Computacionais de Alto Desempenho**. [S.l.], 2020. p. 46–53. Citado na página 47.

KARIM, M. R.; BEYAN, O.; ZAPPA, A.; COSTA, I. G.; REBHOLZ-SCHUHMANN, D.; COCHEZ, M.; DECKER, S. Deep learning-based clustering approaches for bioinformatics. **Briefings in bioinformatics**, Oxford University Press, v. 22, n. 1, p. 393–415, 2021. Citado 2 vezes nas páginas 72 e 73.

KATAL, A.; DAHIYA, S.; CHOUDHURY, T. Energy efficiency in cloud computing data centers: a survey on software technologies. **Cluster Computing**, Springer, v. 26, n. 3, p. 1845–1875, 2023. Citado 5 vezes nas páginas 31, 32, 33, 34 e 45.

KHAN, M. A. An efficient energy-aware approach for dynamic vm consolidation on cloud platforms. **Cluster Computing**, Springer, v. 24, n. 4, p. 3293–3310, 2021. Citado 2 vezes nas páginas 59 e 62.

KHAN, R.; KHAN, S. U. Achieving energy saving through proxying applications on behalf of idle devices. **Procedia Computer Science**, Elsevier, v. 83, p. 187–194, 2016. Citado na página 37.

KHAN, T.; TIAN, W.; ILAGER, S.; BUYYA, R. Workload forecasting and energy state estimation in cloud data centres: ML-centric approach. **Future Generation Computer Systems**, Elsevier, v. 128, p. 320–332, 2022. Citado na página 59.

KOCOT, B.; CZARNUL, P.; PROFICZ, J. Energy-aware scheduling for high-performance computing systems: A survey. **Energies**, MDPI, v. 16, n. 2, p. 890, 2023. Citado na página 100.

KUMAR, R.; SINGH, S.; BILGA, P. S.; SINGH, J.; SINGH, S.; SCUTARU, M.-L.; PRUNCU, C. I. et al. Revealing the benefits of entropy weights method for multi-objective optimization in machining operations: A critical review. **Journal of materials research and technology**, Elsevier, v. 10, p. 1471–1492, 2021. Citado na página 93.

KUPFERMAN JEFF SILVERMAN, P. J. J. Scaling into the cloud. **ADVANCED OPERATING SYSTEMS**, p. 1–8, 2016. Citado na página 26.

LATOTZKE, C.; GEMMEKE, T. Efficiency versus accuracy: a review of design techniques for dnn hardware accelerators. **IEEE Access**, IEEE, v. 9, p. 9785–9799, 2021. Citado na página 106.

LE, P.-H. C.; LI, X. Binaryvit: pushing binary vision transformers towards convolutional models. In: **Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 2023. p. 4664–4673. Citado na página 106.

LI, G.; LIU, F.; SHARMA, A.; KHALAF, O. I.; ALOTAIBI, Y.; ALSUFYANI, A.; ALGHAMDI, S. Research on the natural language recognition method based on cluster analysis using neural network. **Mathematical Problems in Engineering**, Hindawi Limited, v. 2021, p. 1–13, 2021. Citado 2 vezes nas páginas 72 e 73.

LIN, H.; LOU, J.; XIONG, L.; SHAHABI, C. Integer-arithmetic-only certified robustness for quantized neural networks. In: **Proceedings of the IEEE/CVF International Conference on Computer Vision**. [S.l.: s.n.], 2021. p. 7828–7837. Citado na página 106.

- LIN, J. C.-W.; SHAO, Y.; DJENOURI, Y.; YUN, U. Asrnn: A recurrent neural network with an attention model for sequence labeling. **Knowledge-Based Systems**, Elsevier, v. 212, p. 106548, 2021. Citado na página 101.
- LIN, Z.; CUI, Y.; LIU, J.; SUN, Z.; MA, S.; ZHANG, X.; WANG, X.-y. Automated segmentation of kidney and renal mass and automated detection of renal mass in ct urography using 3d u-net-based deep convolutional neural network. **European Radiology**, v. 31, 01 2021. Citado 2 vezes nas páginas 98 e 101.
- LIU, Y.; WEI, X.; XIAO, J.; LIU, Z.; XU, Y.; TIAN, Y. Energy consumption and emission mitigation prediction based on data center traffic and pue for global data centers. **Global Energy Interconnection**, Elsevier, v. 3, n. 3, p. 272–282, 2020. Citado na página 16.
- LORIDO-BOTRAN, T.; MIGUEL-ALONSO, J.; LOZANO, J. A. A review of auto-scaling techniques for elastic applications in cloud environments. **Journal of Grid Computing**, v. 12, n. 4, p. 559–592, 2014. ISSN 1572-9184. Disponível em: <<http://dx.doi.org/10.1007/s10723-014-9314-7>>. Citado 3 vezes nas páginas 26, 29 e 30.
- MAINARDI, P. H.; BIDOIA, E. D. Modelos estatísticos fatoriais: conceitos e aplicações. **Exatas Online**, Jequié BA: Universidade Estadual do Sudoeste da Bahia Departamento de ..., 2020. Citado na página 69.
- MAKARATZIS, A. T.; GIANNOUTAKIS, K. M.; TZOVARAS, D. Energy modeling in cloud simulation frameworks. **Future Generation Computer Systems**, Elsevier, v. 79, p. 715–725, 2018. Citado 3 vezes nas páginas 46, 58 e 62.
- MANDAL, A. K.; DEHURI, S. A survey on ant colony optimization for solving some of the selected np-hard problem. In: SPRINGER. **International Conference on Biologically Inspired Techniques in Many-Criteria Decision Making**. [S.l.], 2019. p. 85–100. Citado na página 78.
- MANGANELLI, M.; SOLDATI, A.; MARTIRANO, L.; RAMAKRISHNA, S. Strategies for improving the sustainability of data centers via energy mix, energy conservation, and circular energy. **Sustainability**, v. 13, n. 11, 2021. ISSN 2071-1050. Disponível em: <<https://www.mdpi.com/2071-1050/13/11/6114>>. Citado na página 40.
- MANSOURI, N.; GHAFARI, R.; ZADE, B. M. H. Cloud computing simulators: A comprehensive review. **Simulation Modelling Practice and Theory**, Elsevier, v. 104, p. 102144, 2020. Citado na página 31.
- MARKUS, A.; KERTESZ, A. A survey and taxonomy of simulation environments modelling fog computing. **Simulation Modelling Practice and Theory**, Elsevier, v. 101, p. 102042, 2020. Citado 2 vezes nas páginas 48 e 49.
- MASANET, E.; SHEHABI, A.; LEI, N.; SMITH, S.; KOOMEY, J. Recalibrating global data center energy-use estimates. **Science**, American Association for the Advancement of Science, v. 367, n. 6481, p. 984–986, 2020. Citado na página 33.
- MASDARI, M.; ZANGAKANI, M. Green cloud computing using proactive virtual machine placement: challenges and issues. **Journal of Grid Computing**, Springer, v. 18, n. 4, p. 727–759, 2020. Citado 3 vezes nas páginas 16, 37 e 41.

MELL, P.; GRANCE, T. The nist definition of cloud computing. national institute of standards and technology special publication 800-145. **Gaithersburg: US Department of Commerce. Google Scholar**, 2011. Citado na página 26.

MELO, R. M. d. Análise de sensibilidade aplicada à identificação de pontos que requerem melhoria na disponibilidade em infraestrutura de cloud. Universidade Federal de Pernambuco, 2017. Citado na página 81.

MEYER, V.; KRINDGES, R.; FERRETO, T. C.; ROSE, C. A. D.; HESSEL, F. Simulators usage analysis to estimate power consumption in cloud computing environments. In: IEEE. **2018 Symposium on High Performance Computing Systems (WSCAD)**. [S.l.], 2018. p. 70–76. Citado 3 vezes nas páginas 46, 58 e 61.

MOHAMMADZADEH, A.; MASDARI, M.; GHAREHCHOPOGH, F. S.; JAFARIAN, A. Improved chaotic binary grey wolf optimization algorithm for workflow scheduling in green cloud computing. **Evolutionary Intelligence**, Springer, v. 14, p. 1997–2025, 2021. Citado 2 vezes nas páginas 58 e 62.

MONDAL, S.; FARUK, F. B.; RAJBONGSHI, D.; EFAZ, M. M. K.; ISLAM, M. M. Geeco: Green data centers for energy optimization and carbon footprint reduction. **Sustainability**, MDPI, v. 15, n. 21, p. 15249, 2023. Citado na página 40.

MUKHERJEE, R.; GANGULY, P.; DAHIYA, R. Bioinspired distributed energy in robotics and enabling technologies. **Advanced Intelligent Systems**, Wiley Online Library, v. 5, n. 4, p. 2100036, 2023. Citado na página 59.

MURINO, T.; MONACO, R.; NIELSEN, P. S.; LIU, X.; ESPOSITO, G.; SCOGNAMIGLIO, C. Sustainable energy data centres: A holistic conceptual framework for design and operations. **Energies**, v. 16, n. 15, 2023. ISSN 1996-1073. Disponível em: <<https://www.mdpi.com/1996-1073/16/15/5764>>. Citado na página 40.

NARANG, S.; GOSWAMI, P.; JAIN, A. A comprehensive review of load balancing techniques in cloud computing and their simulation with cloudsim plus. **Recent Advances in Computer Science and Communications (Formerly: Recent Patents on Computer Science)**, Bentham Science Publishers, v. 14, n. 6, p. 1684–1694, 2021. Citado 2 vezes nas páginas 48 e 49.

NAYAK, S. K.; PANDA, S. K.; DAS, S. Renewable energy-based resource management in cloud computing: a review. **Advances in Distributed Computing and Machine Learning: Proceedings of ICADCML 2020**, Springer, p. 45–56, 2020. Citado 3 vezes nas páginas 33, 35 e 36.

NAYAK, S. K.; PANDA, S. K.; DAS, S. Renewable energy-based resource management in cloud computing: a review. **Advances in Distributed Computing and Machine Learning: Proceedings of ICADCML 2020**, Springer, p. 45–56, 2021. Citado na página 44.

NEU, D. A.; LAHANN, J.; FETTKE, P. A systematic literature review on state-of-the-art deep learning methods for process prediction. **Artificial Intelligence Review**, Springer, v. 55, n. 2, p. 801–827, 2022. Citado na página 50.

NGUYEN, T.-H.; NGUYEN, L. V.; JUNG, J. J.; AGBEHADJI, I. E.; FRIMPONG, S. O.; MILLHAM, R. C. Bio-inspired approaches for smart energy management: State of the art

and challenges. **Sustainability**, MDPI, v. 12, n. 20, p. 8495, 2020. Citado 2 vezes nas páginas 52 e 59.

NIKBAKHTI, R.; WANG, X.; HUSSEIN, A. K.; IRANMANESH, A. Absorption cooling systems—review of various techniques for energy performance enhancement. **Alexandria Engineering Journal**, Elsevier, v. 59, n. 2, p. 707–738, 2020. Citado na página 41.

PANWAR, S. S.; RAUTHAN, M. M. S.; BARTHWAL, V. A systematic review on effective energy utilization management strategies in cloud data centers. **Journal of Cloud Computing**, Springer, v. 11, n. 1, p. 95, 2022. Citado 2 vezes nas páginas 59 e 62.

PARDO, M. H. d. S. **Projeto e avaliação de um broker como agente de intermediação e QoS em uma nuvem computacional híbrida**. Tese (Doutorado) — Universidade de São Paulo, 2016. Citado na página 17.

PARIKH, S. M. A survey on cloud computing resource allocation techniques. In: IEEE. **Engineering (NUICONE), 2013 Nirma University International Conference on**. [S.l.], 2013. p. 1–5. Citado 2 vezes nas páginas 26 e 28.

PATIL, A.; PATIL, D. R. An analysis report on green cloud computing current trends and future research challenges. In: **Proceedings of International Conference on Sustainable Computing in Science, Technology and Management (SUSCOM)**, Amity University Rajasthan, Jaipur-India. [S.l.: s.n.], 2019. Citado na página 40.

POP, C. B.; CIOARA, T.; ANGHEL, I.; ANTAL, M.; CHIFU, V. R.; ANTAL, C.; SALOMIE, I. Review of bio-inspired optimization applications in renewable-powered smart grids: Emerging population-based metaheuristics. **Energy Reports**, Elsevier, v. 8, p. 11769–11798, 2022. Citado na página 59.

RADU, L.-D. Green cloud computing: A literature survey. **Symmetry**, Multidisciplinary Digital Publishing Institute, v. 9, n. 12, p. 295, 2017. Citado 2 vezes nas páginas 36 e 37.

REIS, T. N.; TEIXEIRA, M. M.; ALMEIDA, J. D. S. d.; PAIVA, A. C. d. et al. Um recomendador de alocação de recursos em computação em nuvem usando algoritmos genéticos e svr. Universidade Federal do Maranhão, 2018. Citado 3 vezes nas páginas 26, 30 e 31.

REIS, T. N. F. d.; TEIXEIRA, M. M.; NETO, C. d. S. S. Relações do consumo energético nas execuções de tarefas em computação em nuvem verde. **Revista de Sistemas e Computação-RSC**, v. 12, n. 3, 2023. Citado na página 83.

REIS, T. N. F. D.; TEIXEIRA, M. M.; NETO, C. D. S. S. Relation of energy consumption in green cloud computing with big data. In: IEEE. **2023 IEEE Green Technologies Conference (GreenTech)**. [S.l.], 2023. p. 280–284. Citado 3 vezes nas páginas 76, 77 e 83.

REIS, T. N. F. dos; TEIXEIRA, M. M.; NETO, C. d. S. S. Uma abordagem de redução de energia na computação em nuvem verde. **Research, Society and Development**, v. 12, n. 7, p. e1812742407–e1812742407, 2023. Citado na página 83.

REIS, T. N. F. dos; TEIXEIRA, M. M.; NETO, C. d. S. S.; REIS, A. M. S. dos. Algoritmo dvfs como alternativa para redução de energia na computação em nuvem verde com big data. **OBSERVATÓRIO DE LA ECONOMÍA LATINOAMERICANA**, v. 21, n. 11, p. 23302–23320, 2023. Citado 3 vezes nas páginas 76, 77 e 83.

REIS, T. N. F. dos; TEIXEIRA, M. M.; NETO, C. d. S. S.; OLIVEIRA, A.; SOUSA, A. M. A tier labeling proposal for energy efficiency in green cloud. **Journal of Sustainability Research**, Journal of Sustainability Research, v. 6, n. 1, 2024. Citado 2 vezes nas páginas 78 e 83.

REIS, T. N. F. dos; TEIXEIRA, M. M.; NETO, C. d. S. S.; SOUSA, A. M. Uma proposta de classificação para rotular a eficiência energética na computação em nuvem verde. **Boletim de Conjuntura (BOCA)**, v. 17, n. 49, p. 761–793, 2024. Citado na página 83.

ROKH, B.; AZARPEYVAND, A.; KHANTEYMOORI, A. A comprehensive survey on model quantization for deep neural networks. **arXiv preprint arXiv:2205.07877**, 2022. Citado na página 107.

ROSTIROLLA, G.; GRANGE, L.; MINH-THUYEN, T.; STOLF, P.; PIERSON, J.-M.; COSTA, G. D.; BAUDIC, G.; HADDAD, M.; KASSAB, A.; NICOD, J.-M. et al. A survey of challenges and solutions for the integration of renewable energy in datacenters. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 155, p. 111787, 2022. Citado na página 44.

SABOOR, A.; MAHMOOD, A. K.; OMAR, A. H.; HASSAN, M. F.; SHAH, S. N. M.; AHMADIAN, A. Enabling rank-based distribution of microservices among containers for green cloud computing environment. **Peer-to-Peer Networking and Applications**, Springer, v. 15, n. 1, p. 77–91, 2022. Citado 2 vezes nas páginas 59 e 62.

SAHA, B. Green computing: current research trends. **International Journal of Computer Sciences and Engineering**, v. 6, n. 3, p. 467–469, 2018. Citado 2 vezes nas páginas 17 e 39.

SAYADNAVARD, M. H.; HAGHIGHAT, A. T.; RAHMANI, A. M. A multi-objective approach for energy-efficient and reliable dynamic vm consolidation in cloud data centers. **Engineering science and technology, an International Journal**, Elsevier, v. 26, p. 100995, 2022. Citado 2 vezes nas páginas 59 e 63.

SEGURANCA de A Segurança em Computação nas Nuvens. 2016. Disponível em: <<http://www.de-seguranca.com.br/a-seguranca-em-computacao-nas-nuvens/>>. Acesso em: Junho 2016. Citado 2 vezes nas páginas 27 e 29.

SETYANINGRUM, R. P.; KHOLID, M. N.; SUSILO, P. Sustainable smes performance and green competitive advantage: The role of green creativity, business independence and green it empowerment. **Sustainability**, MDPI, v. 15, n. 15, p. 12096, 2023. Citado 2 vezes nas páginas 57 e 60.

SHAHABUDDIN, M.; UDDIN, M. N.; CHOWDHURY, J.; AHMED, S.; UDDIN, M.; MOFIJUR, M.; UDDIN, M. A review of the recent development, challenges, and opportunities of electronic waste (e-waste). **International Journal of Environmental Science and Technology**, Springer, v. 20, n. 4, p. 4513–4520, 2023. Citado na página 35.

SHAMI, T. M.; EL-SALEH, A. A.; ALSWAITTI, M.; AL-TASHI, Q.; SUMMAKIEH, M. A.; MIRJALILI, S. Particle swarm optimization: A comprehensive survey. **IEEE Access**, IEEE, v. 10, p. 10031–10061, 2022. Citado na página 76.

SHARMA, M.; GUPTA, R.; ACHARYA, P. Analysing the adoption of cloud computing service: A systematic literature review. **Global Knowledge, Memory and Communication**, Emerald Publishing Limited, v. 70, n. 1/2, p. 114–153, 2021. Citado na página 45.

SHEIKH, S. Z.; PASHA, M. A. Energy-efficient cache-aware scheduling on heterogeneous multicore systems. **IEEE Transactions on Parallel and Distributed Systems**, IEEE, v. 33, n. 1, p. 206–217, 2021. Citado na página 100.

SHU, W.; CAI, K.; XIONG, N. N. Research on strong agile response task scheduling optimization enhancement with optimal resource usage in green cloud computing. **Future Generation Computer Systems**, Elsevier, v. 124, p. 12–20, 2021. Citado 2 vezes nas páginas 58 e 62.

SILVA, D. T. da; RODRIGUES, J. A.; MANACERO, A.; LOBATO, R. S.; SPOLON, R.; CAVENAGHI, M. A. Modeling and simulation of cloud computing with ispd. In: SBC. **Anais do XXIII Simpósio em Sistemas Computacionais de Alto Desempenho**. [S.l.], 2022. p. 217–228. Citado 2 vezes nas páginas 58 e 61.

SILVA, G. G. d. Cloud computing e sua contribuição para a sustentabilidade das organizações. Universidade Federal de São Paulo, 2023. Citado 3 vezes nas páginas 34, 45 e 75.

SINGH, G.; CHATURVEDI, A. K.; RATHORE, N. S. Task scheduling algorithms in the cloud computing environment: A comprehensive review. **Solid State Technology**, v. 63, n. 6, p. 17012–17030, 2020. Citado 2 vezes nas páginas 48 e 49.

SOARES, L. L.; TORK, V. M.; GOMES, W. G. P.; SOUZA, A. M. F. de; NASCIMENTO, P. S. F.; OLIVEIRA, R. C. L. de. Algoritmos bioinspirados—uma revisão sistemática da literatura no brasil. **Anais da I Escola Regional de Alto Desempenho Norte 2 e I Escola Regional de Aprendizado de Máquina e Inteligência Artificial Norte 2**, SBC, p. 1–4, 2021. Citado na página 52.

SONG, J.; ZHU, P.; ZHANG, Y.; YU, G. Versatility or validity: A comprehensive review on simulation of datacenters powered by renewable energy mix. **Future Generation Computer Systems**, Elsevier, v. 136, p. 326–341, 2022. Citado na página 44.

SOUSA, E.; LINS, F.; TAVARES, E.; MACIEL, P. Cloud infrastructure planning considering different redundancy mechanisms. In: **Computing**. [S.l.: s.n.], 2016. Citado na página 29.

SRIRAM, G. Green cloud computing: an approach towards sustainability. **International Research Journal of Modernization in Engineering Technology and Science**, v. 4, n. 1, p. 1263–1268, 2022. Citado 2 vezes nas páginas 57 e 60.

STERGIOU, C. L.; PSANNIS, K. E.; ISHIBASHI, Y. Green cloud communication system for big data management. In: IEEE. **2020 3rd World Symposium on Communication Engineering (WSCE)**. [S.l.], 2020. p. 69–73. Citado 4 vezes nas páginas 59, 62, 78 e 79.

VASQUES, T. L.; MOURA, P.; ALMEIDA, A. de. A review on energy efficiency and demand response with focus on small and medium data centers. **Energy Efficiency**, Springer, v. 12, p. 1399–1428, 2019. Citado na página 40.

VENDRAMINI, H. J.; SALDIAS, C. E. P.; TAVARES, A. A. Análise de dados para predição de cenários da matriz elétrica nacional para 2050. **Revista Vincici-Periódico Científico do UniSATC**, v. 8, n. 1, p. 117–146, 2023. Citado 2 vezes nas páginas 50 e 51.

VIJAY, V.; NANDA, R. A systematic review and comparative analysis of cloud simulation tools. **no. February**, 2021. Citado 2 vezes nas páginas 48 e 49.

VILAÇA, N. L. et al. Predição de demanda de energia elétrica para o dia seguinte aplicando redes neurais convolutivas e redes recorrentes. Universidade Federal do Amazonas, 2022. Citado 2 vezes nas páginas 50 e 51.

WADHWA, M.; GOEL, A.; CHOUDHURY, T.; MISHRA, V. P. Green cloud computing-a greener approach to it. In: IEEE. **2019 international conference on computational intelligence and knowledge economy (ICCIKE)**. [S.l.], 2019. p. 760–764. Citado 3 vezes nas páginas 47, 58 e 61.

XU, M.; BUYYA, R. Managing renewable energy and carbon footprint in multi-cloud computing environments. **Journal of Parallel and Distributed Computing**, Elsevier, v. 135, p. 191–202, 2020. Citado na página 45.

YANG, J.; XIAO, W.; JIANG, C.; HOSSAIN, M. S.; MUHAMMAD, G.; AMIN, S. U. Ai-powered green cloud and data center. **IEEE Access**, IEEE, v. 7, p. 4195–4203, 2018. Citado 3 vezes nas páginas 47, 58 e 61.

ZHANG, M.; LI, P.; XIA, Y.; WANG, K.; JIN, L. Labeling trick: A theory of using graph neural networks for multi-node representation learning. **Advances in Neural Information Processing Systems**, v. 34, p. 9061–9073, 2021. Citado 2 vezes nas páginas 98 e 101.

ZHANG, Q.; MENG, Z.; HONG, X.; ZHAN, Y.; LIU, J.; DONG, J.; BAI, T.; NIU, J.; DEEN, M. J. A survey on data center cooling systems: Technology, power consumption modeling and control strategy optimization. **Journal of Systems Architecture**, Elsevier, v. 119, p. 102253, 2021. Citado na página 41.

ZHENG, Y.; WANG, D. Multi-criteria ranking: Next generation of multi-criteria recommendation framework. **IEEE Access**, IEEE, v. 10, p. 90715–90725, 2022. Citado na página 93.

ZHOU, Y.; DONG, H.; SADDIK, A. E. Deep learning in next-frame prediction: A benchmark review. **IEEE Access**, IEEE, v. 8, p. 69273–69283, 2020. Citado na página 50.

ZHOU, Y.; DONG, H.; SADDIK, A. E. Deep learning in next-frame prediction: A benchmark review. **IEEE Access**, v. 8, p. 69273–69283, 2020. Citado na página 50.

ZONG, Z. An improvement of task scheduling algorithms for green cloud computing. In: IEEE. **2020 15th International Conference on Computer Science & Education (ICCSE)**. [S.l.], 2020. p. 654–657. Citado 4 vezes nas páginas 46, 58, 61 e 75.