

O Boletim de Conjuntura (BOCA) publica ensaios, artigos de revisão, artigos teóricos e empíricos, resenhas e vídeos relacionados às temáticas de políticas públicas.

O periódico tem como escopo a publicação de trabalhos inéditos e originais, nacionais ou internacionais que versem sobre Políticas Públicas, resultantes de pesquisas científicas e reflexões teóricas e empíricas.

Esta revista oferece acesso livre imediato ao seu conteúdo, seguindo o princípio de que disponibilizar gratuitamente o conhecimento científico ao público proporciona maior democratização mundial do conhecimento.



BOLETIM DE CONJUNTURA

BOCA

Ano VI | Volume 17 | Nº 49 | Boa Vista | 2024

<http://www.ioles.com.br/boca>

ISSN: 2675-1488



UMA PROPOSTA DE CLASSIFICAÇÃO PARA ROTULAR A EFICIÊNCIA ENERGÉTICA NA COMPUTAÇÃO EM NUVEM VERDE

Thiago Nelson Faria dos Reis¹

Mario Antônio Meireles Teixeira²

Carlos de Salles Soares Neto³

Apoena Mendes Sousa⁴

Resumo

Este artigo 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 uma iniciativa importante para reduzir o consumo de energia e as emissões de CO₂ associadas à computação em nuvem, sem comprometer sua funcionalidade e desempenho. O foco principal deste trabalho é avaliar a eficácia de algoritmos de escalonamento de recursos em data centers de computação em nuvem e desenvolver uma metodologia inovadora para calcular scores de eficiência energética e classificar o desempenho energético. Utilizando 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 as 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 um 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 uma redução significativa no consumo de energia e emissões de CO₂ - aproximadamente 55% - e uma melhoria na eficiência de custo de alocação de máquinas virtuais, em torno de 28%. O estudo demonstra que a adoção de estratégias de escalonamento inovadoras e a implementação de um modelo quantitativo de avaliação energética podem otimizar significativamente a eficiência da computação em nuvem. Além disso, a proposta de um novo cálculo de scores e a criação de uma escala de nível energético oferecem ferramentas valiosas para a otimização e sustentabilidade em data center.

Palavras-chave: Computação em Nuvem Verde; Eficiência Energética; Estratégias de Otimização Energética; Impacto Ambiental; Tecnologias de Redução de Consumo Energético.

761

Abstract

This article 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 computing, 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) - were 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: Energy Consumption Reduction Technologies; Energy Efficiency; Energy Optimization Strategies; Environmental Impact; Green Cloud Computing.

¹ Doutorando em Ciência da Computação pela Universidade Federal do Maranhão (UFMA). E-mail: thiagonelson@gmail.com

² Professor da Universidade Federal do Maranhão (UFMA). Doutor em Ciência da Computação. E-mail: mario.meireles@ufma.br

³ Professor da Universidade Federal do Maranhão (UFMA). Doutor em Informática. E-mail: carlos.salles@ufma.br

⁴ Professora do Centro Universitário Santa Terezinha (CEST). Mestre em Engenharia da Computação. E-mail: apoenamendess@gmail.com



INTRODUÇÃO

A adoção da computação em nuvem oferece vantagens significativas em diversas áreas, incluindo a área de computação. Entre esses benefícios, destaca-se a redução dos gastos das empresas com energia e refrigeração.

No entanto, é importante observar que essa redução não deve ser considerada 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 a responsabilidade compartilhada quanto ao impacto ambiental, tanto direta quanto indiretamente.

Em sua pesquisa, Liu *et al.* (2020) afirmam que cerca de 4,5% do consumo global de energia é atribuído aos data centers até 2025. Isso os torna os principais consumidores de energia em todo o mundo e 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 entre a computação convencional e a computação verde, é crucial entender suas diferenças fundamentais. A computação verde visa reduzir o consumo de energia, incentivar o uso de fontes renováveis de energia e otimizar a eficiência na utilização dos recursos disponíveis.

A fim de alcançar esse objetivo, é fundamental possuir conhecimento acerca das técnicas, frameworks, metodologias e classificações da computação verde. Tais conhecimentos embasam a análise, o desenvolvimento e as implementações nesse campo específico. Vale ressaltar que existem diversas abordagens em termos de software, hardware e virtualização que visam otimizar o uso dos recursos e reduzir tanto a emissão de CO₂ quanto o impacto ambiental.

Os critérios para selecionar a infraestrutura de nuvem estão evoluindo. Além dos aspectos computacionais e financeiros, torna-se cada vez mais importante considerar a eficiência energética do data center e o uso de recursos renováveis ao tomar essa decisão.

Desse modo, 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.

Este estudo orienta-se pelo seguinte questionamento: é possível obter melhores resultados em desempenho, juntamente com a redução energética do data center e conseqüente redução do impacto



ambiental, mais especificamente, na emissão de CO₂ equivalente (CO_{2eq}) a partir da alocação dos recursos de forma mais eficiente?

Nesse sentido, o objetivo central deste trabalho é realizar uma análise do modelo de relação entre Consumo Energético, Redução Energética e Emissão de CO_{2eq}, de forma a criar um cálculo de pontuação e escala de nível energético que categorize o data center em relação a sua eficiência na computação em nuvem verde.

A metodologia adotada para a realização da pesquisa foi baseada em um ambiente de simulação CloudSim Plus para realizar a análise comparativa de quatro algoritmos: Round Robin, Particle Swarm Optimization, Dynamic Voltage and Frequency Scaling e Ant Colony System, sendo este último incluído como uma possível solução inédita entre as diversas opções já estudadas. A metodologia envolveu a realização de 800 simulações e uma análise estatística aprofundada utilizando a tabela T-Student. Adicionalmente, são sugeridos dois modelos de cálculo de scores, com base nos pesos atribuídos às medidas, e a criação de um índice de eficiência energética a partir dos resultados alcançados. A inteligência artificial, por meio de algoritmos de classificação baseados em redes neurais, foi utilizada para aprimorar a classificação dos níveis energéticos.

A pesquisa apresenta uma seção de estudos relacionados à computação em nuvem verde e sustentabilidade energética. A seção seguinte aborda as principais categorias e estratégias para redução de energia na área da computação em nuvem verde. Já na seguinte, são discutidos os métodos utilizados nesta pesquisa.

A seção de Resultados e Discussão demonstra, por meio de uma abordagem quantitativa, que é possível reduzir o consumo de energia sem comprometer significativamente os indicadores de qualidade do serviço.

Na seção seguinte desse artigo, são apresentadas duas propostas. 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.

Ou seja, é possível afirmar que a computação em nuvem sustentável e a minimização do desperdício computacional são áreas de grande relevância na busca por uma maior eficiência energética e sustentabilidade, o que pode ser alcançado através da adoção de algoritmos eficazes e estratégias inteligentes.



TRABALHOS RELACIONADOS

O campo da computação em nuvem verde emerge como uma área promissora para pesquisas científicas, dada a ampla variedade de estratégias, tanto físicas quanto de software, e as possibilidades para múltiplas aplicações. Isso impulsiona o desenvolvimento de métodos computacionais que visam a utilização eficiente dos recursos e a redução dos custos operacionais, resultando em vantagens tanto para os provedores de serviços quanto para os consumidores finais.

As pesquisas realizadas por Sriram (2022), Anser (2021) e Setyaningrum (2023) apresentam 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. Exploram também as relações dinâmicas entre fatores tecnológicos e emissões de carbono e as características-chave da computação em nuvem verde, identificam as barreiras para sua adoção e destacam seu potencial para mitigar o impacto ambiental dos data centers.

Adicionalmente, Bharany (2022) realizou uma 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 de 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. Em prosseguimento, são explorados diversos 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). A análise dos resultados visa comparar esses algoritmos, considerando tempos de execução e consumo energético.

Porém, a pesquisa realizada por Silva *et al.* (2022) descreve uma comparação entre os 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 e Tzovaras (2018) e 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.



Ainda como estratégias utilizando algoritmos de alocação, tem-se os estudos de Shu (2021), Biswas (2021) e Mohammadzadeh (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.

Sobre a abordagem da eficiência energética por meio da consolidação dinâmica de máquinas virtuais (VMs) realizada por Khan (2021) e Sayadnavard (2022), onde o objetivo principal é reduzir o consumo de energia através da alocação dinâmica das VMs. Os resultados demonstram melhorias significativas na eficiência energética, redução de violações de SLA e aumento da confiabilidade do sistema, destacando a relevância da abordagem proposta para aprimorar a gestão de recursos em ambientes de computação em nuvem.

O estudo de Stergiou, Psannis e Ishibashi (2020) explora a computação em nuvem sustentável no contexto da aplicação de Big Data. Em suas análises, confrontam os desfechos usando o indicador DCIE, observando uma 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 em relação às métricas relacionadas à emissão de CO₂.

Em relação a abordagens utilizando inteligência artificial, tem-se os estudos de (PANWAR, 2022; KHAN, 2022), que além da revisão sistemática, tem como objetivo apresentar diferentes estratégias de gerenciamento de energia em data centers de 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.

No caso da abordagem da eficiência energética por meio da consolidação dinâmica de máquinas virtuais (VMs) realizada por Khan (2021) e Sayadnavard (2022), cujo objetivo principal é reduzir o consumo de energia através da alocação dinâmica das VMs. Os resultados demonstram melhorias significativas na eficiência energética, redução de SLA e aumento da confiabilidade do sistema, destacando a relevância da abordagem proposta para aprimorar a gestão de recursos em ambientes de computação em nuvem.

Tratando-se de 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.



Quanto 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.

Deste modo, a contribuição desta pesquisa em relação aos algoritmos é ampliar o conjunto de algoritmos utilizados nesses modelos, incluindo especificamente Particle Swarm Optimization (PSO), Dynamic Voltage and Frequency Scaling (DVFS) e Ant Colony System (ACS), além dos já avaliados para cargas de trabalho com Big Data. Essa escolha segue a metodologia adotada em estudos relacionados.

PRINCIPAIS ABORDAGENS SOBRE EFICIÊNCIA ENERGÉTICA

Existem várias abordagens que podem ser aplicadas para maximizar a eficiência energética, resultando em maior lucratividade e menor impacto ambiental. No entanto, é importante garantir uma correlação entre essas abordagens, de modo a obter benefícios otimizados em diferentes categorias, como destacado por Radu (2017), Bash *et al.*, (2011), Agrawal, Saini e Wankhede (2020), Garg, Yeo e Buyya (2011), Khan (2021) e Masdari e Zangakani (2020) e outros.

Uma gestão mais eficiente das máquinas virtuais pode ser obtida através de métodos como a consolidação dessas máquinas em servidores físicos, diminuição da velocidade dos processadores, realocação de tarefas, utilização de engenharia especializada distribuída e alocação em data centers que são energeticamente mais eficientes.

São também possíveis abordagens que se baseiam no hardware, incluindo a redução do calor dissipado, o planejamento energético de placas e processadores para transmissão independente de energia e o uso de armazenamento mais eficiente.

Outras abordagens compreendem o uso de energias renováveis e a reciclagem de recursos energéticos, como energia proveniente do vento, solar e do uso da água para refrigeração.

No âmbito desta pesquisa, será adotada uma metodologia centrada no gerenciamento de máquinas virtuais (VMs) hospedadas em servidores físicos. A abordagem selecionada envolve a consolidação das ativas e o desligamento daquelas que estão ociosas. Tal estratégia é vantajosa por não demandar alterações em hardware existente nem requerer investimentos adicionais em infraestrutura, o que facilita sua implementação como parte das políticas de gestão em qualquer configuração de ambiente em nuvem.

Como resultado deste trabalho, surgem dois resultados relevantes: (1) definição de um cálculo de scores de eficiência energética baseado nas várias metodologias e estratégias estudadas, e (2) proposta de



uma classificação dos scores calculados, resultando em um selo de consumo energético (como aqueles utilizados em eletrodomésticos) que determina a qual classe o data center pertence e o quão ele poderá se tornar eficiente energeticamente.

METODOLOGIA

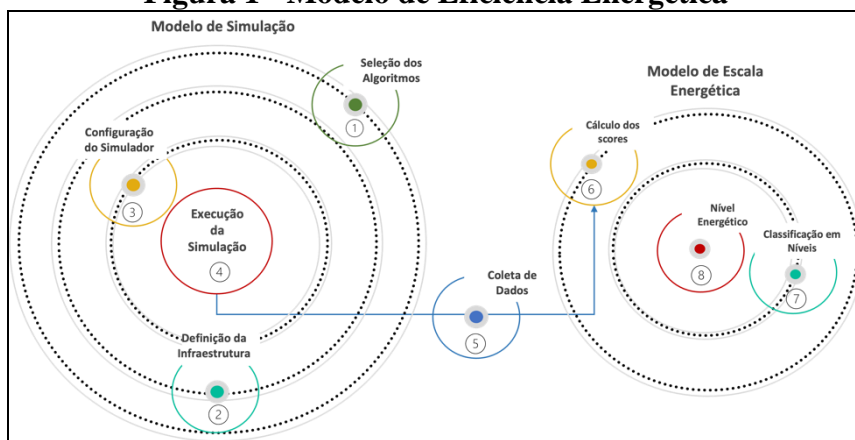
Este estudo apresenta uma abordagem inovadora para investigar e classificar a eficiência energética em data centers de computação em nuvem verde, com foco no cálculo dos scores de eficiência energética e na introdução de um sistema de níveis energéticos, utilizando redes neurais para a classificação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

Diagrama do modelo de eficiência energética

O mapa conceitual apresentado na Figura 1 delimita cada etapa do processo de pesquisa, desde a configuração inicial do ambiente de simulação até a análise final dos resultados. Este modelo oferece uma visão abrangente do fluxo de trabalho e das interações entre os diferentes componentes do estudo, fornecendo uma descrição detalhada de cada etapa do diagrama que permite uma compreensão clara da metodologia utilizada. Além disso, destaca a integração sistêmica entre as diferentes fases da análise de eficiência energética na computação em nuvem verde, permitindo uma compreensão mais profunda do processo de pesquisa e dos dados coletados, processados e analisados.

767

Figura 1 - Modelo de Eficiência Energética



Fonte: Elaboração própria.

O processo começa com a seleção dos algoritmos de escalonamento e a definição da infraestrutura do data center. Essa escolha pode basear-se em sua representatividade na literatura



especializada, potencial contribuição para a eficiência energética ou na arquitetura real do data center. Nessa etapa, também é 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 configuração do simulador, neste estudo o CloudSim Plus, com as definições, estruturas e algoritmos mencionados anteriormente.

No âmbito deste estudo, as etapas quarta e quinta concentram-se na execução de simulações detalhadas e no monitoramento rigoroso do desempenho dos data centers. Esta fase é crucial para a coleta de dados essenciais, como o consumo de energia, o tempo de execução das aplicações, custos operacionais e emissões de CO₂.

Avançando para a segunda fase do modelo, a etapa de cálculo dos scores assume um papel central. Ela envolve a normalização dos dados coletados seguida da aplicação de um 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.

Seguindo o fluxo do modelo proposto, a classificação do nível energético é realizada por meio de classificadores de inteligência artificial, em particular, redes neurais. Esta etapa representa uma abordagem inovadora e preditiva na classificação do desempenho energético dos algoritmos em diferentes condições operacionais.

Finalmente, na etapa oito, o modelo permite a identificação do nível energético atual do data center. Este resultado fornece insights cruciais para a implementação de intervenções eficazes, facilitando a tomada de decisão em direção a operações otimizadas e sustentáveis.

Ambiente de simulação

O CloudSim Plus, uma extensão avançada e aprimorada do CloudSim (BARBIERATO, 2019; SILVA FILHO, 2017; CLOUDSIM, 2021; ZONG, 2020; SILVA *et al.*, 2022), é a ferramenta escolhida para a simulação 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 oferecendo uma base realista e robusta para as análises.

Selecionamos quatro algoritmos-chave para o nosso estudo, cada um representando uma abordagem particular para o escalonamento de máquinas virtuais em ambientes de nuvem:

Round Robin (RR): Este é um dos algoritmos mais simples e amplamente utilizados para escalonamento. Ele aloca tarefas de maneira sequencial, garantindo uma distribuição equitativa do



trabalho entre todos os servidores. A simplicidade e a equidade do RR o tornam um 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 carga, reduzindo o consumo de energia quando a carga demandada é leve. O DVFS é escolhido por sua abordagem direta de economia de energia, o que é crucial 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. Ele 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. Ele é eficiente na resolução de problemas de otimização, sendo escolhido pela sua capacidade de encontrar soluções eficientes para alocação complexa de recursos em ambientes de nuvem (DORIGO; STÜTZLE, 2019).

Esses algoritmos representam um equilíbrio entre métodos comprovados e inovações emergentes, permitindo uma análise compreensiva de diferentes estratégias no contexto de sustentabilidade e eficiência energética. Adicionalmente, a implementação desses algoritmos no CloudSim Plus permite uma simulação detalhada e realista das operações de um data center.

Definição da infraestrutura


O Objetivo desse experimento é validar a viabilidade de redução de consumo energético sem comprometer a capacidade computacional do ambiente em nuvem. Com esse propósito, serão empregados quatro algoritmos para realizar o escalonamento das máquinas virtuais: Round Robin (RR), Dynamic Voltage and Frequency Scaling (DVFS), Otimização por Enxame de Partículas (PSO) e o Sistema de Colônia de Formigas (ACS). Foram utilizados os mesmos parâmetros de (STERGIOU; PSANNIS; ISHIBASHI, 2020), com o número de hosts variando de 50 a 250 máquinas, com 2 núcleos de 2,2 GHz/núcleo e 4 GB de memória, conforme demonstrado na Figura 2.

A proposta neste trabalho é na utilização com Big Data e a utilização de um único data center, cenário comum em diversas empresas, o que diverge da proposta referenciado realizada por (STERGIOU; PSANNIS; ISHIBASHI, 2020). Além disso, realizamos o estudo da eficiência energética e comparativo com outros trabalhos apresentados. Todos os testes foram planejados utilizando um desenho completo de experimento fatorial, baseado em uma análise sistemática de performance para



sistemas computacionais (JAIN, 2010), com 10 execuções cada. Os resultados obtidos possuem um nível de confiança de 95%, conforme a tabela T-student.

Figura 2 – Modelo do Experimento



Fonte: Elaboração própria.

Os parâmetros estabelecidos são as máquinas virtuais, que neste caso incluem 4 conjuntos de configurações: Número de máquinas virtuais: 50, 100, 150, 200 e 250; Todas equipadas com memória RAM de 2GB e um núcleo de processamento.

Foi realizado o ajuste da quantidade de tarefas (cloudlets) executadas no ambiente, a fim de avaliar o modelo em diferentes cargas de trabalho: Número de cloudlets: 10, 100, 1000 e 2000; Os cloudlets possuem 150.000 MIPS (Milhões de Instruções Por Segundo).

Todas as outras configurações, incluindo capacidade de armazenamento, largura de banda e outros aspectos semelhantes, permaneceram iguais em todas as situações. Além disso, foi estabelecido que o consumo de energia é de 150W quando inativo (0% de uso) e 300W quando operando a plena capacidade (100% de uso). Esses parâmetros são utilizados para avaliar a premissa de que a relação custo-benefício ideal ocorre ao implantar um maior número de máquinas virtuais com uma menor quantidade de processadores ou um menor número delas com mais processadores.

Os procedimentos para a execução das simulações foram definidos com o intuito de avaliar os tempos de resposta, o consumo energético e os custos envolvidos. É relevante destacar que as quantias monetárias estão em dólares americanos e foram obtidas a partir das configurações da AWS americana, assim como os consumos energéticos dos processadores (AMAZON, 2023). Devemos ressaltar ainda que está sendo levado em conta somente o consumo energético dos processadores.

Para cada iteração, coletamos os resultados de tempo das aplicações, custos e consumo de energia, juntamente com outras informações. O tempo total simulado foi de 51.909 horas, cerca de 2.163 dias, realizando um total de 800 simulações.



Processo de coleta de dados

A coleta de dados foi um componente essencial deste estudo, onde os resultados de todas as 800 simulações executadas foram meticulosamente coletados. Este processo incluiu informações detalhadas sobre o desempenho de cada algoritmo de escalonamento em diferentes configurações e cenários de carga de trabalho.

Os dados coletados abrangeram uma gama de métricas cruciais, incluindo, mas não limitando a:

Tempos de Execução: Medindo a eficiência operacional dos algoritmos em termos de velocidade no processamento das tarefas.

Custo de Execução: Baseados em custos reais de execução (AMAZON, 2023), o cloudsim produziu as informações dos custos direto de cada execução das simulações.

Consumo de Energia: Fornecendo insights sobre a sustentabilidade e eficiência energética dos algoritmos.

Emissões de CO₂: O cloudsim não fornece informações sobre a emissão de CO₂ equivalente, mas a partir de informações fornecido pela EPA (2022) foi possível realizar o cálculo, uma vez que, os parâmetros utilizados foram os americanos.

Análise dos resultados

A etapa de análise dos resultados obtidos a partir das simulações no CloudSim Plus e das análises subsequentes enfoca principalmente na avaliação do desempenho dos algoritmos de escalonamento de máquinas virtuais sob diferentes configurações de carga de trabalho e suas implicações na eficiência energética dos data centers.

Análise Estatística e Comparativa: Foram utilizados métodos estatísticos para analisar os dados coletados, comparando os resultados dos diferentes algoritmos de escalonamento. Esta análise incluiu a avaliação do tempo de execução, consumo de energia, custos operacionais e emissões de CO_{2eq}, fornecendo uma visão abrangente do desempenho de cada algoritmo.

Cálculo dos Ganhos Percentuais em Eficiência: Uma parte crucial desta seção foi dedicada ao cálculo de ganhos percentuais em eficiência energética e operacional. Estes cálculos permitiram identificar quais algoritmos e configurações ofereceram os melhores desempenhos em termos de redução do consumo de energia e aumento da eficiência operacional.

Identificação de Tendências e Padrões: Ainda através da sumarização dos dados, identificamos tendências e padrões significativos que podem influenciar decisões futuras em termos de



escolha de algoritmos e estratégias de escalonamento para otimização de data centers em ambientes de computação em nuvem verde.

Scores de eficiência energética

Essa etapa da metodologia é dedicada ao processo detalhado de cálculo dos scores de eficiência energética, um aspecto crucial na avaliação do desempenho dos data centers na computação em nuvem verde.

Inicialização dos Dicionários e Métricas: Esta etapa envolveu a definição e inicialização dos dicionários de dados, onde as métricas relevantes para a eficiência energética foram estabelecidas. As métricas incluíram consumo de energia, emissões de CO₂, tempo de execução e custos operacionais. Cada métrica foi ponderada de acordo com sua importância relativa, refletindo a complexidade multifacetada da eficiência energética em data centers.

Normalização dos Dados: Devido às diferentes escalas utilizadas nas métricas, a normalização dos dados foi essencial para garantir uma comparação justa e equitativa. Este processo permitiu que os dados fossem avaliados em uma base comum, facilitando a análise comparativa entre diferentes algoritmos e configurações de data center.

Definição do Baseline para Comparação: Um baseline foi estabelecido para proporcionar um ponto de referência padrão na avaliação do desempenho dos algoritmos de escalonamento. Este baseline foi crucial para a análise subsequente, ao permitir a comparação relativa da eficiência dos diferentes algoritmos em relação a um padrão estabelecido.

Cálculo dos Scores de Eficiência Energética: Após a normalização, procedeu-se ao cálculo dos scores de eficiência para cada configuração e algoritmo. Este cálculo utilizou uma fórmula matemática que integrou os pesos atribuídos às métricas, resultando em um score que reflete a eficiência energética de cada configuração de algoritmo em comparação com o baseline.

Classificação dos Algoritmos com Base nos Scores: Finalmente, os algoritmos foram classificados com base nos scores calculados. Esta classificação foi realizada do mais eficiente ao menos eficiente, oferecendo uma visão hierárquica do desempenho dos algoritmos em termos de eficiência energética e sustentabilidade ambiental.



Modelo de nível energético

O objetivo é apresentar e discutir o modelo de nível energético desenvolvido como parte crucial da nossa metodologia para avaliar a eficiência energética em computação em nuvem verde. Para tanto, as seguintes etapas foram definidas.

Desenvolvimento da Escala de Nível Energético: Nesta parte, descrevemos a criação de uma escala de nível energético inovadora para a computação, que é o cerne do nosso modelo de avaliação. Esta escala é dividida em cinco níveis distintos, de A a E, com cada nível representando um grau diferente de eficiência energética. O desenvolvimento dessa escala foi fundamentado nos scores de eficiência energética calculados anteriormente, proporcionando uma métrica quantitativa para classificar os data centers.

Critérios de Classificação: Os critérios para a atribuição dos níveis energéticos são detalhadamente explicados na seção Definição de infraestrutura. O algoritmo Round Robin com 50 máquinas virtuais é usado como ponto de referência e classificado no nível E, o mais baixo da escala. Em contraste, o nível A é reservado para configurações e algoritmos que alcançam os melhores scores, indicando a mais alta eficiência energética.

Escala Vertical e Horizontal: A escala de nível energético é descrita tanto em termos verticais quanto horizontais. Verticalmente, os níveis são organizados hierarquicamente, com níveis subsequentes (B, C, D e E) representando uma graduação decrescente de eficiência. Horizontalmente, a escala incorpora uma dimensão de sustentabilidade, enfatizando a importância da geração e do uso de energia renovável.

Uso de Classificadores de Inteligência Artificial: Abordamos a aplicação de classificadores de inteligência artificial, particularmente redes neurais, para categorizar os scores calculados em diferentes níveis de eficiência energética. Esta abordagem inovadora é destacada por sua capacidade de analisar eficientemente os scores complexos e multidimensionais de eficiência energética.

RESULTADOS E DISCUSSÃO

Nesta seção são apresentados os resultados das simulações. Os dados definidos em 4.3 satisfazem as exigências de carga leve e pesada.

Os resultados da simulação foram coletados e analisados para avaliar os critérios discutidos anteriormente. As informações apresentadas nas Tabelas 1 e 2 a seguir foram consolidadas com as



configurações utilizadas, os resultados alcançados para cada algoritmo e suas relações, com o objetivo de exemplificar o percentual de ganho obtido.

Tabela 1 – Tempos de execução (s)

Qty of VMs	Average Execution Time						
	RR	DVFS	PSO	ACS	Relation RR / DVFS	Relation RR / PSO	Relation 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	2.64	0.38%	-0.21%	-0.21%

Fonte: Elaboração própria.

Tabela 2 – Consumo energético das simulações (w)

Qty of VMs	Average Energy Consumption						
	RR	DVFS	PSO	ACS	Relation RR / DVFS	Relation RR / PSO	Relation 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%

Fonte: Elaboração própria.

Tabela 3 – Consumo de energia por cloudlets (w)

Qty of Cloudlets	Energy consumption per cloudlet						
	RR	DVFS	PSO	ACS	Relation RR / DVFS	Relation RR / PSO	Relation 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%

Fonte: Elaboração própria.

Tabela 4 – Resultados consolidados dos custos (US) dos ambientes em simulações

Qty of VMs	Allocation Costs						
	RR	DVFS	PSO	ACS	Relation RR / DVFS	Relation RR / PSO	Relation 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%

Fonte: Elaboração própria.



Tabela 5 – Cálculo de emissão CO_{2eq}

Qty of VMs	CO _{2eq} emission (Tons)						
	RR	DVFS	PSO	ACS	Relation RR / DVFS	Relation RR / PSO	Relation 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%	-55.00%

Fonte: Elaboração própria.

Cenário 1: Tempo de execução das aplicações

Ao examinar as pesquisas relacionadas ao desempenho computacional, considera-se os tempos de execução das aplicações para avaliar a eficiência de uma determinada configuração. Ao observar os dados na Tabela 1, observa-se que não houve redução significativa no 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 para o algoritmo DVFS.

É crucial enfatizar que a utilização de um sistema computacional mais distribuído resultou em melhorias significativas, proporcionando uma 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 1.

Ao escalonar as máquinas virtuais acima dessa quantidade, para esse modelo, não produziu uma melhoria significativa, com incremento de 7%, entre 150 e 200, e 8%, entre 200 e 250, pontos percentuais. É importante frisar que a melhoria no desempenho depende de como a aplicação é construída para um modelo distribuído, conforme pode ser visualizado na Tabela 6.

Tabela 6 – Relação dos tempos de execuções

Qty of VMs	Average Execution Time						
	RR	DVFS	PSO	ACS	Relation RR / DVFS	Relation RR / PSO	Relation RR / ACS
50					-51.72%	-50.00%	-47.84%
100	-69.53%	-69.48%	-69.53%	-69.53%	-50.00%	-50.00%	-50.23%
150	-83.67%	-83.47%	-83.67%	-83.67%	-50.08%	-49.92%	-55.41%
200	-89.18%	-90.40%	-89.18%	-89.18%	-49.88%	-50.00%	-52.07%
250	-91.84%	-91.82%	-91.85%	-91.86%	-50.00%	-50.00%	-55.95%


Fonte: Elaboração própria.



Cenário 2: Consumo de energia das aplicações

Ao considerar o contexto energético, uma redução de pelo menos 47% no consumo de energia para a mesma carga de trabalho é observada na Tabela 2 e representado no Gráfico 1 em comparação com o algoritmo RR, conforme evidenciado no modelo com 50 máquinas virtuais. Além disso, a maior redução no consumo energético, em torno de 55,41%, foi constatada no modelo com 150 VMs usando o algoritmo ACS.

Gráfico 1 – Consumo energético



Fonte: Elaboração própria.

Já os consumos dos algoritmos DVFS e PSO mostraram valores muito próximos, com variações inferiores a 3% entre si, enquanto o algoritmo ACS obteve um ganho energético 11% superior aos demais algoritmos.

Observa-se também que, o algoritmo ACS teve um 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 3, foi observada uma diminuição significativa no consumo, variando entre 49,82% e 53,37% através dos modelos de distribuição de máquinas virtuais e algoritmos. Isso confirma os dados apresentados de forma consolidada.

Cenário 3: Custos da execução das aplicações

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



Observa-se na Tabela 4 reduções significativas nos valores simulados, com diminuição de pelo menos 8% para os cenários mais simples e uma diminuição superior a 34% no cenário mais complexo ao alocar máquinas virtuais, exceto para o algoritmo DVFS que tem o mesmo padrão de alocação das máquinas virtuais do Round Robin, porém gerencia a energia dos processadores de forma mais eficiente. Em outras palavras, optando pelo algoritmo DVFS em comparação com o RR resulta em 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, devido à sua melhor eficiência em ambientes mais distribuídos. Essa tendência reforça a necessidade não apenas da construção de uma infraestrutura distribuída, mas também do desenvolvimento de aplicações que possam tirar proveito desse ambiente.


Cenário 4: Emissão de CO₂

Em relação ao consumo energético do data center, é crucial considerar as emissões de dióxido de carbono equivalentes. Este estudo concentrou-se na análise do uso da energia dos equipamentos e, por conseguinte, demandou a avaliação e comparação de 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 estão sendo contemplados nesta análise.

Ao comparar as estratégias de alocação dos algoritmos, como demonstrado na Tabela 5 e Gráfico 2, 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 todo o consumo energético para cada configuração.

777

Gráfico 2 – Emissão de CO₂ para os modelos



Fonte: Elaboração própria.



Os resultados mostram que a aplicação do algoritmo Ant Colony System tem um impacto significativo na diminuição das emissões de CO₂ equivalente em comparação com os outros, sendo cerca de 11% mais eficiente que o PSO, que é o segundo melhor em eficiência. Especificamente, as emissões de CO₂ equivalentes ao utilizar o algoritmo ACS variaram de 121 a 452 toneladas, uma redução substancial comparada às 232 a 1.026 toneladas produzidas pelo Round Robin.

Uma observação relevante é que a maior emissão de 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, em relação à 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 e para o ACS têm-se o intervalo de 47,84% e 55,95% em comparação ao Round Robin.

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

É evidente 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 uma situação vantajosa para todos, na qual a qualidade e capacidade computacional são preservadas, o impacto ambiental é minimizado e há uma redução nos custos associados.

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

Essas descobertas evidenciam a eficácia e importância da computação em nuvem sustentável, enfatizando a necessidade de uma maior adoção de práticas ambientalmente responsáveis na indústria de tecnologia da informação.

Proposta de cálculo de *scores*

Como abordagem para que a análise dos resultados seja realizada de forma mais objetiva, excluindo critérios subjetivos, este trabalho propõe a definição de Scores para as diversas configurações



de VMs e algoritmos utilizados. O objetivo desses scores é permitir 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, será utilizado um modelo baseado em algoritmos frequentemente usado em otimização multiobjetivo e decisão multicritério, utilizando pesos e resultados normalizados, tendo como objetivo a criação de um ranking (ALVAREZ *et al.*, 2021; ZHENG; WANG, 2022; KUMAR, 2021).

Definição dos pesos

Alguns desafios impostos pelo uso da 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, será adotado o uso dos pesos para as métricas, contudo o algoritmo desenvolvido pode ser customizado a partir desses parâmetros para flexibilizar o uso desta solução.

Sendo assim, o objetivo do algoritmo proposto 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 a cada métrica.

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

Emissão de CO₂: O foco global em sustentabilidade e as preocupações 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 uma área onde as regulamentações de emissão são estritas, além de uma crescente demanda 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 de um 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, essa métrica, por estar diretamente relacionada à emissão de CO₂, também recebeu um peso substancial.

Dado que essas duas métricas possuem uma relação proporcional, 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 crucial 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, para equilibrar o SLA e o impacto ambiental. Mas caso o desempenho computacional não seja um objetivo crucial, pode-se reduzir esse peso para focar no fator sustentabilidade.

Custos: A maioria das organizações está atenta aos custos, mas a prioridade pode variar. Sendo que ele pode ser indiretamente representado 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 é distinto e importante, por isso foi-lhe dado um peso.

A soma dos pesos deve ser igual a 1 para 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:

Normalização: Ao garantir que o total seja 1, está-se normalizando os critérios. Isso 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 um peso de 0,3, isso indica claramente que essa métrica representa 30%.

Facilita a Comparação: Se você estiver comparando diferentes alternativas ou cenários usando o mesmo conjunto de critérios, ter pesos que somam 1 em todos os cenários garantem que se está fazendo comparações justas 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.

Como uma configuração de referência (baseline), será 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 pelo peso de cada métrica.

Algoritmo de cálculo de scores

A seguir, é apresentada uma síntese do funcionamento do algoritmo, representada no Algoritmo 1. Sendo a primeira etapa a de inicialização dos dicionários e métricas, bem como a atribuição dos



pesos. A próxima etapa é a da normalização de forma a garantir uma comparação equitativa, principalmente devido às métricas possuírem diferentes escalas.

Em seguida é realizado o cálculo propriamente dito dos scores para cada algoritmo e configuração preparados anteriormente. E por fim, a classificação em termos de eficiência, do maior ao menor índice, oferecendo uma visão hierárquica do desempenho.

Figura 1 - Algoritmo 1: Cálculo de Pontuação de Eficiência

```

1: procedure CalculateEfficiencyScore(metrics, weights, rr_algorithm)
2:   scores ← {}
3:   ▷ Step 1: Initializing dictionaries
4:     for all alg ∈ metrics do
5:       scores[alg] ← {}
6:       for all (vm, value) ∈ metrics[alg] do
7:         scores[alg][vm] ← 0
8:       end for
9:     end for
10:  ▷ Step 2: Normalization
11:    for all (metric, weight) ∈ weights do
12:      maximum ← max(val[metric] | alg ∈ metrics, (vm, val) ∈ metrics[alg])
13:      minimum ← min(val[metric] | alg ∈ metrics, (vm, val) ∈ metrics[alg])
14:      for all alg ∈ metrics do
15:        for all vm ∈ metrics[alg] do
16:          metrics[alg][vm][metric] ← (metrics[alg][vm][metric] - minimum) / (maximum - minimum)
17:        end for
18:      end for
19:  ▷ Step 3: Calculating efficiency score
20:    for all (alg, data) ∈ metrics do
21:      if alg ≠ rr_algorithm then
22:        for all (vm, metric, values) ∈ data do
23:          for all (metric, value) ∈ metric_values do
24:            difference ← value - metrics[rr_algorithm][vm][metric]
25:            score ← difference × weights[metric]
26:            scores[alg][vm] += score
27:          end for
28:        end for
29:      end if
30:    end for
31:  ▷ Step 4: Ranking
32:  ranking ← sorted(scores.keys(), key = λalg : P(scores[alg].values()), reverse = True) return ranking
33: end procedure

```

Fonte: Elaboração própria.

A pontuação de eficiência calculada no algoritmo acima pode ser expressa como uma fórmula matemática, como apresentado a seguir:

$$\text{Score} = \sum_{i=1}^n w_i * \left(1 - \frac{x_{i,j}}{x_{i,RR}} \right)$$

Onde:



- n é o número total de métricas (neste caso, 4: emissão de CO₂, consumo energético, tempo de execução e custo);
- w_j é o peso da i -ésima métrica, baseado na prioridade dessa métrica;
- $x_{i,j}$ é o valor da i -ésima métrica para a j -ésima configuração de VMs para um algoritmo específico; e
- $x_{i,RR}$ é o valor da i -ésima métrica para a j -ésima configuração de VMs para o algoritmo RR.

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

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 já discutido anteriormente. Dessa forma, optou-se por realizar duas parametrizações para identificar o seu comportamento e avaliar diferentes aspectos relacionados às configurações de pesos.

Inicialmente será atribuído o peso igual para todos os critérios, para avaliar o seu resultado e confrontar com as análises realizadas nas seções anteriores, nesse caso 0,25 para cada métrica.

O resultado apresentado na tabela 7 revela que o algoritmo ACS com 150 máquinas é considerado a alternativa mais vantajosa em termos de custo-benefício, como exposto anteriormente na seção 5.

Tabela 7 – Resultados dos Scores com pesos iguais

Algoritmo	VMs	Score
ACS	150	0.38980022733134967
ACS	250	0.3826935174565252
ACS	200	0.3610430060959349
PSO	150	0.3393988886719097
ACS	100	0.3379077819656378
PSO	200	0.33236928163390456
PSO	250	0.33180833605992033
DVFS	200	0.3227479267700133
ACS	50	0.3222416776686283
PSO	100	0.3172433662121699
PSO	50	0.3159420289855073
DVFS	50	0.3060310223254843
DVFS	100	0.29989058097554877
DVFS	250	0.29962504765021686
DVFS	150	0.29752501604860526

Fonte: Elaboração própria.



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

Tabela 8 – Resultados dos Scores com pesos diferentes

Algoritmo	VMs	Score
ACS	250	0.29239815880673614
ACS	150	0.2788758575834505
ACS	200	0.25640165588496444
DVFS	200	0.245053258569016
PSO	150	0.2393988886719097
ACS	100	0.2367313113774025
PSO	200	0.23194734070563455
PSO	250	0.23138639513165032
ACS	50	0.22671928960892687
PSO	100	0.2168512093494248
PSO	50	0.21594202898550727
DVFS	50	0.19959365198163165
DVFS	100	0.19909479141855546
DVFS	250	0.1984483897408147
DVFS	150	0.19488848120868055

Fonte: Elaboração própria.

Essa abordagem proporcionou uma 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 uma 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.

Proposta de nível energético

Considerando em conta os resultados obtidos na seção anterior, é viável apresentar uma Escala de Nível Energético precisa que possa ser facilmente aplicada em um data center específico e que está alinhada com a necessidade de monitorar e gerenciar o consumo de energia em data centers.



Essa 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 organizam os demais scores. Essa escala fornece um diagnóstico estratégico, permitindo 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 data centers específicos não somente permite a monitorização precisa do consumo energético, como também promove uma 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 frequente para agrupar valores numéricos em cinco níveis é empregar técnicas estatísticas e algoritmos de aprendizado de máquina (ZHANG, 2021; LIN *et al.*, 2021; ESPADOTO, 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 descobrir padrões subjacentes.

Para realizar essa tarefa, é possível utilizar o algoritmo k-means, amplamente adotado 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. Essa abordagem reduz a distância total intra-cluster através da minimização dessa medida considerando todos os clusters formados.



Embora os dados trabalhados atualmente sejam relativamente simples e reduzidos, o uso de técnicas de clusterização e classificação ainda é fundamental para a segmentação em cinco níveis. É crucial considerar o tamanho 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 um conjunto separado de testes.

Dessa forma, foi decidido utilizar redes neurais para classificar os escores em diferentes níveis. Com o avanço do aprendizado profundo, as redes neurais têm se mostrado como uma opção viável para categorizar valores numéricos em níveis específicos. Apesar de ser uma abordagem mais complexa quando comparada aos algoritmos tradicionais de aprendizado de máquina e classificação, pode oferecer bons resultados, especialmente quando há uma grande quantidade de dados ou quando a relação entre os escores e as classes é complexa.

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

1. Normalizar os dados, pois as redes neurais são sensíveis à escala dos dados de entrada;
2. Construção do Modelo de Rede Neural;
3. Treinamento do Modelo; e
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 seção anterior, no modelo de inteligência artificial que utiliza redes neurais recorrentes, foi possível obter a seguinte distribuição das classes e intervalos definidos para os scores, detalhados na tabela 9.

É importante observar que os scores podem ser negativos, ou seja, informando que os resultados foram inferiores à configuração base, representada com valor 0 neste trabalho.

- Level A: 0.2788758575834505 to 0.29239815880673614
- Level B: 0.2367313113774025 to 0.25640165588496444
- Level C: 0.21594202898550727 to 0.23194734070563455
- Level D: 0.19488848120868055 to 0.19959365198163165
- Level E: -0.8525042147924222 to 0.03059390266864702



Tabela 9 – Classificação dos scores por nível

Level	Algorithm	Qty of VM	Score
A	ACS	250	0.29239815880673614
A	ACS	150	0.2788758575834505
B	ACS	200	0.25640165588496444
B	DVFS	200	0.245053258569016
B	PSO	150	0.2393988886719097
B	ACS	100	0.2367313113774025
C	PSO	200	0.23194734070563455
C	PSO	250	0.23138639513165032
C	ACS	50	0.22671928960892687
C	PSO	100	0.2168512093494248
C	PSO	50	0.21594202898550727
D	DVFS	50	0.19959365198163165
D	DVFS	100	0.19909479141855546
D	DVFS	250	0.1984483897408147
D	DVFS	150	0.19488848120868055
E	RR	100	0.03059390266864702
E	RR	50	0.0
E	RR	150	-0.19845846132944986
E	RR	200	-0.5148470382586974
E	RR	250	-0.8525042147924222

Fonte: Elaboração própria.

Propõe-se ainda a inclusão de até quatro subníveis em cada classe, representados pelo símbolo ‘+’, onde cada um correspondendo a 25% do uso de energia renovável no nível ou score correspondente. Esse refinamento na escala permitirá que os gestores de data centers tenham um leque mais amplo de opções ao tomar decisões referentes à adoção de energias 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 e estão representados de forma detalhada na Tabela 10.

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 energias renováveis. Este modelo, portanto, não só otimiza os recursos energéticos de um data center, mas também orienta as organizações rumo a práticas mais sustentáveis e ecologicamente responsáveis (ZHANG, 2021; CHICHE, 2022; LIN *et al.*, 2021; ESPADOTO, 2021).

A utilização de subníveis fundamentados no consumo de energia renovável se faz crucial. Mesmo um data center que adquira toda a sua energia de fontes renováveis não é, por definição, eficiente energeticamente. Com base nas metodologias apresentadas neste estudo, é possível reduzir ainda mais o consumo energético, direcionando a energia economizada para outros setores críticos.



Tabela 10 – Resumo dos scores com pesos diferentes

Scale	Level	Scale
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	{++++}

Fonte: Elaboração própria.

Isso torna possível melhorar o uso da 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 uma análise adequada da eficiência energética. Esta escala permite avaliar o grau de otimização energética do data center, proporcionando uma visão clara dos níveis de eficiência, desde os mais elevados até os menos favoráveis, tendo em conta as particularidades da carga operacional.

O Data center XYZ é um exemplo hipotético utilizado para ilustrar a estratégia de escalonamento, onde consome 155W para uma carga de trabalho específica e está classificado no Nível C. A escala utilizada para este exemplo, representado na Tabela 8, é o resultado deste trabalho, e os consumos energéticos são baseados nos valores de cada nível. É relevante ressaltar que 40W desse consumo são provenientes de fontes de energia renovável.

Nesse sentido, o Data center XYZ é classificado como C+, já que os 40w representam cerca de 25,8% do consumo total proveniente de fontes renováveis. A pesquisa resalta a importância não apenas da eficiência energética geral, mas também da proporção de energia renovável utilizada, representado na tabela 11.

Tabela 11 – Escala de Nível Energético – Data center XYZ

Scale	Level	Scale
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

Fonte: Elaboração própria.

Embora o uso exclusivo de energia renovável em um data center não seja suficiente para garantir a eficiência energética e redução do impacto ambiental, é essencial adotar estratégias inteligentes para



otimizar os recursos e promover uma utilização racional da energia. Isso requer a busca por fontes limpas de energia, bem como soluções tecnológicas e organizacionais que favoreçam uma gestão responsável e eficiente dos recursos no ambiente computacional.

A partir dessa categorização, é possível extrair percepções valiosas 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, como 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 através da substituição das fontes de energia convencionais por fontes renováveis.

Em suma, as incorporações das fontes de energia renovável na infraestrutura do data center estão representadas pelos níveis horizontais apresentadas nesta proposta. Cada adição é uma extensão no mesmo nível hierárquico, permitindo flexibilidade para se adaptar às oportunidades de crescimento energético. No entanto, a implementação horizontal requer investimentos financeiros e logísticos, além de um 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 resultado de um aumento ou redução significativa na capacidade de processamento e armazenamento. Isso ocorre porque o modelo operacional baseia-se na proporção entre o consumo e a produção energética de fontes renováveis. Essa abordagem possibilita que os data centers atinjam a excelência operacional, mantendo simultaneamente uma gestão energética otimizada e consciente para garantir a sustentabilidade ambiental.

A utilização da escala vertical resulta em uma 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 a utilização dos recursos disponíveis, sua implementação pode ocorrer de maneira ágil e com menor investimento, que também contribui para redução nos custos operacionais.

A integração estratégica das dimensões horizontal e vertical fornece uma abordagem inovadora para maximizar a eficiência e sustentabilidade dos data centers. A harmonização dessas dimensões permite adaptar soluções que respondem 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 um sistema flexível e adaptável que se ajusta proativamente às mudanças no ambiente



operacional. O impacto desses elementos na eficiência energética e sustentabilidade pode ser significativo, oferecendo novos estímulos para inovação e melhorias na gestão dos data centers.

CONCLUSÃO

A computação sustentável em nuvem é um assunto cada vez mais debatido tanto no setor empresarial quanto no campo acadêmico. As empresas estão gradualmente adotando esse 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. Essa 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.

Este estudo teve como propósito identificar as métricas principais utilizadas, bem como as possíveis áreas e categorias de mudança para a sustentabilidade da computação em nuvem. Além disso, objetivou-se avaliar a suposição de que é possível reduzir o consumo de energia sem prejudicar os tempos de processamento.

Os achados deste estudo são relevantes e mostram o potencial de técnicas eficientes para administrar recursos na nuvem. Ao utilizar o simulador CloudSim Plus, foi viável criar e analisar várias estratégias e algoritmos com o intuito de diminuir o consumo de energia e aprimorar os indicadores de qualidade do serviço.

Através da implementação de algoritmos mais eficientes na alocação de recursos, foi viável alcançar uma significativa redução no uso de energia, aproximadamente 55%, sem prejudicar os tempos de processamento. Essa diminuição no consumo energético não só auxilia na redução do impacto ambiental, mas também pode gerar economias expressivas em termos operacionais.

Além disso, a pesquisa também constatou uma diminuição significativa nos gastos relacionados à distribuição de máquinas virtuais, podendo chegar a aproximadamente 28%. Isso evidencia que adotar práticas mais eficientes de computação em nuvem no aspecto energético não apenas é vantajoso para o ambiente, mas também apresenta benefícios econômicos.

Com a implementação desse modelo, por meio do uso de algoritmos ACS, é possível observar uma redução significativa no impacto ambiental, chegando a 55.95% na diminuição das emissões de dióxido de carbono. Isso resulta em uma diminuição total de 513 toneladas de CO₂ liberadas no ambiente.



Visando simplificar a escolha da melhor solução, propôs-se utilizar um cálculo de pontuação para avaliar os resultados dos algoritmos. Isso possibilita uma comparação objetiva entre eles e facilita a decisão quanto à implementação da estratégia mais adequada para computação em nuvem verde.

Para além desta proposta, também foi incluída uma estrutura de classificação da eficiência energética para avaliar os data centers quanto ao seu consumo e uso de fontes renováveis. Isso possibilita o acompanhamento do progresso na eficiência energética ao longo do tempo e permite a implementação de medidas adequadas para melhorá-la.

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

Dessa forma, a utilização desse método de alocação de máquinas virtuais possui uma influência benéfica nos gastos operacionais da infraestrutura, além de diminuir o tempo de execução, possibilitando que pesquisadores e gestores dos centros de dados aproveitem melhor seus recursos tecnológicos, tanto em um ambiente público quanto privado.

Para um futuro trabalho, é possível realizar estudos mais avançados em simuladores e algoritmos para definir os parâmetros mais adequados para avaliar a eficiência computacional e energética de data centers. Além disso, será possível analisar os benefícios das diferentes abordagens implementadas nessa área, contribuindo assim para uma adoção ainda mais eficiente computação em nuvem verde.

REFERÊNCIAS

AGRAWAL, M. N.; SAINI, M. J. K.; WANKHEDE, P. “Review on green cloud computing: a step towards saving global environment”. **International Journal of Engineering Research and Technology**, vol. 8, n. 5, 2020.

ALVAREZ, P. A. *et al.* Multiple-criteria decision-making sorting methods: A survey. **Expert Systems with Applications**, vol. 183, 2021.

AMAZON. “Amazon WorkSpaces Family pricing”. **Amazon** [2023]. Disponível em: <www.amazon.com>. Acesso em: 01/08/2023.

ANSER, M. K. *et al.* “The role of information and communication technologies in mitigating carbon emissions: evidence from panel quantile regression”. **Environmental Science and Pollution Research**, vol. 28, 2021.

ARAÚJO, R. S. de *et al.* “Fontes de energias renováveis: pesquisas, tendências e perspectivas sobre as práticas sustentáveis”. **Research, Society and Development**, vol. 11, n. 11, 2022.

BARBIERATO, E. *et al.* Exploiting cloudsims in a multiformalism modeling approach for cloud based systems. **Simulation Modelling Practice and Theory**, vol. 93, 2019.



BASH, C. *et al.* “Cloud sustainability dashboard, dynamically assessing sustainability of data centers and clouds”. **Proceedings of the Fifth Open Cirrus Summit, Hewlett Packard**, vol. 13, 2011.

BHARANY, S. *et al.* “A systematic survey on energy-efficient techniques in sustainable cloud computing”. **Sustainability**, vol. 14, n. 10, 2022.

BISWAS, N. K. *et al.* “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**, vol. 45, 2021.

CHICHE, A.; YITAGESU, B. “Part of speech tagging: a systematic review of deep learning and machine learning approaches”. **Journal of Big Data**, vol. 9, n. 1, 2022.

CLOUDSIM. “Full-featured and fully documented cloud simulation framework”. **Clouddim Plus** [2016]. Disponível em: <www.cloudsimplus.org>. Acesso em: 10/12/2023.

EPA - Environmental Protection Agency. “Greenhouse Gas Equivalencies Calculator”. **EPA** [2022]. Disponível em: <www.epa.gov>. Acesso em: 10/12/2023.

ESPADOTO, M.; HIRATA, N. S. T.; TELEA, A. C. **Self-supervised dimensionality reduction with neural networks and pseudo-labeling**. Lisboa: SciTePress, 2021.

FRANÇA, C. G. *et al.* “Análise comparativa de modelos de previsão de geração de energia eólica baseados em machine learning”. **Revista de Sistemas e Computação**, vol. 9, n. 2, 2020.

GARG, S. K.; YEO, C. S.; BUYYA, R. “Green cloud framework for improving carbon efficiency of clouds”. **European Conference on Parallel Processing**. France: Springer, 2011.

JAIN, R. **Computer systems performance analysis**. London: Wiley, 2010.

JENA, S. R. *et al.* “Cloud computing tools: inside views and analysis”. **Procedia Computer Science**, vol. 1731, 2020.

KHAN, M. A. “An efficient energy-aware approach for dynamic VM consolidation on cloud platforms”. **Cluster Computing**, vol. 24, n. 4, 2021.

KHAN, T. *et al.* “Workload forecasting and energy state estimation in cloud data centres: ML-centric approach”. **Future Generation Computer Systems**, vol. 128, 2022.

KUMAR, R. *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**, vol. 10, 2021.

LIN, J. C. W. *et al.* “ASRNN: A recurrent neural network with an attention model for sequence labeling”. **Knowledge-Based Systems**, vol. 212, 2021.

LIU, Y. *et al.* “Energy consumption and emission mitigation prediction based on data center traffic and PUE for global data centers”. **Global Energy Interconnection**, vol. 3, n. 3, 2020.

MAKARATZIS, A. T.; GIANNOUTAKIS, K. M.; TZOVARAS, D. “Energy modeling in cloud simulation frameworks”. **Future Generation Computer Systems, Elsevier**, vol. 79, 2018.



MANDAL, A. K.; DEHURI, S. “A survey on ant colony optimization for solving some of the selected np-hard problem”. **International Conference on Biologically Inspired Techniques in Many-Criteria Decision Making**. London: Springer, 2019.

MASDARI, M.; ZANGAKANI, M. “Green cloud computing using proactive virtual machine placement: challenges and issues”. **Journal of Grid Computing, Springer**, vol. 18, n. 4, 2020.

MEYER, V. *et al.* “Simulators usage analysis to estimate power consumption in cloud computing environments”. **Symposium on High Performance Computing Systems**. Washington: WSCAD, 2018.

MOHAMMADZADEH, A. *et al.* “Improved chaotic binary grey wolf optimization algorithm for workflow scheduling in green cloud computing”. **Evolutionary Intelligence**, vol. 14, 2021.

NESMACHNOW, S. *et al.* “Energy-aware scheduling on multicore heterogeneous grid computing systems”. **Journal of grid computing**, vol. 11, 2021

PANWAR, S. S. *et al.* “A systematic review on effective energy utilization management strategies in cloud data centers”. **Journal of Cloud Computing**, vol. 11, n. 1, 2022.

RADU, L. D. “Green cloud computing: A literature survey”. **Symmetry, Multidisciplinary Digital Publishing Institute**, vol. 9, n. 12, 2017.

SABOOR, A. *et al.* “Enabling rank-based distribution of microservices among containers for green cloud computing environment”. **Peer-to-Peer Networking and Applications**, vol. 15, n. 1, 2022.

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**, vol. 26, 2022.

SETYANINGRUM, R.; KHOLID, M. N.; SUSILO, P. “Sustainable SMEs Performance and Green Competitive Advantage: The Role of Green Creativity, Business Independence and Green IT Empowerment”. **Sustainability**, vol. 15, n. 15, 2023.

SHU, W. *et al.* “Research on strong agile response task scheduling optimization enhancement with optimal resource usage in green cloud computing”. **Future Generation Computer Systems**, vol. 124, 2021.

SILVA FILHO, M. C. *et al.* “Cloudsim plus: A cloud computing simulation framework pursuing software engineering principles for improved modularity, extensibility and correctness”. **Symposium on Integrated Network And Service Management**. London: Springer, 2017.

SILVA, D. T. da *et al.* “Modeling and simulation of cloud computing with ispd”. **Anais do XXIII Simpósio em Sistemas Computacionais de Alto Desempenho**. São Paulo: SBC, 2022.

SRIRAM, G. S. “Green cloud computing: an approach towards sustainability”. **International Research Journal of Modernization in Engineering Technology and Science**, vol. 4, n. 1, 2022.

STERGIOU, C. L.; PSANNIS, K. E.; ISHIBASHI, Y. “Green cloud communication system for big data management”. **3rd World Symposium on Communication Engineering**. Washington: WSCE, 2020.



TOLEDO JUNIOR, T. J.; BRUSCHI, S. “Epcsac-extensible platform for cloud scheduling algorithm comparison”. **Anais Estendidos do XXI Simpósio em Sistemas Computacionais de Alto Desempenho**. São Paulo: SBC, 2020.

WADHWA, M. *et al.* “Green cloud computing-a greener approach to it”. **International conference on computational intelligence and knowledge economy**. Cham: Springer, 2019.

YANG, J. *et al.* “Ai-powered green cloud and data center”. **IEEE**, vol. 7, 2018.

ZHANG, M. *et al.* “Labeling trick: A theory of using graph neural networks for multi-node representation learning”. **Advances in Neural Information Processing Systems**, vol. 34, 2021.

ZHENG, Y.; WANG, D. “Multi-criteria ranking: Next generation of multi-criteria recommendation framework”. **IEEE**, vol. 10, 2022.

ZONG, Z. “An improvement of task scheduling algorithms for green cloud computing”. **15th International Conference on Computer Science and Education**. Washington: ICCSE, 2020.



BOLETIM DE CONJUNTURA (BOCA)

Ano VI | Volume 17 | Nº 49 | Boa Vista | 2024

<http://www.ioles.com.br/boca>

Editor chefe:

Elói Martins Senhoras

Conselho Editorial

Antonio Ozai da Silva, Universidade Estadual de Maringá

Vitor Stuart Gabriel de Pieri, Universidade do Estado do Rio de Janeiro

Charles Pennaforte, Universidade Federal de Pelotas

Elói Martins Senhoras, Universidade Federal de Roraima

Julio Burdman, Universidad de Buenos Aires, Argentina

Patrícia Nasser de Carvalho, Universidade Federal de Minas Gerais

Conselho Científico

Claudete de Castro Silva Vitte, Universidade Estadual de Campinas

Fabiano de Araújo Moreira, Universidade de São Paulo

Flávia Carolina de Resende Fagundes, Universidade Feevale

Hudson do Vale de Oliveira, Instituto Federal de Roraima

Laodicéia Amorim Weersma, Universidade de Fortaleza

Marcos Antônio Fávaro Martins, Universidade Paulista

Marcos Leandro Mondardo, Universidade Federal da Grande Dourados

Reinaldo Miranda de Sá Teles, Universidade de São Paulo

Rozane Pereira Ignácio, Universidade Estadual de Roraima