

Relações do Consumo Energético nas Execuções de Tarefas em Computação em Nuvem Verde

Thiago Nelson Faria dos Reis
DCCMAPI/UFMA/UFPI /
Universidade Federal do Maranhão e
Universidade Federal do Piauí
Av. dos Portugueses, 1966 -
Vila Bacanga, São Luís - MA,
65080-805
Ministro Petrônio Portella, s/n -
Ininga, Teresina - PI,
64049-550 – Brazil
thiago.nelson@discente.ufma.br

Mário Meireles Teixeira
DCCMAPI/UFMA/UFPI /
Universidade Federal do Maranhão e
Universidade Federal do Piauí
Av. dos Portugueses, 1966 -
Vila Bacanga, São Luís - MA,
65080-805
Ministro Petrônio Portella, s/n -
Ininga, Teresina - PI,
64049-550 – Brazil
mario.meireles@ufma.br

Carlos de Salles Soares Neto
DCCMAPI/UFMA/UFPI /
Universidade Federal do Maranhão e
Universidade Federal do Piauí
Av. dos Portugueses, 1966 -
Vila Bacanga, São Luís - MA,
65080-805
Ministro Petrônio Portella, s/n -
Ininga, Teresina - PI,
64049-550 – Brazil
carlos.salles@ufma.br

ABSTRACT

Cloud computing is already part of the daily lives of people and companies, as well as environmental concerns. The union of these two realities provides an opportunity for the emergence of Green Cloud Computing with new proposals, approaches and metrics in order to make datacenters more efficient, mainly in terms of energy, in order to reduce CO₂ emissions and the environmental impact. Knowing the metrics that can be used to measure the energy cost and environmental impact of datacenters as well as the main categories and areas of action are fundamental bases in Green Computing. This article presents a study of the relationships between energy consumption and execution times, architecture and cloud environment costs with the adoption of algorithms for complex problems, in the scheduling of Virtual Machines. Through the use of simulators, it was possible to prove the improvement of energy efficiency above 60% and reduction in processing times by at least 29%. In addition to reducing costs by at least 10% and reducing the environmental impact by 65% in the emission of CO₂.

Keywords

Green Cloud Computing; Cloud Simulation; Energy Efficiency

RESUMO

A computação em nuvem já faz parte do cotidiano das pessoas e empresas, bem como a preocupação com a questão ambiental. A união dessas duas realidades oportuniza o

surgimento da Computação em Nuvem Verde com novas propostas, abordagens e métricas, no sentido de tornar os datacenters mais eficientes, principalmente em termos energéticos, de forma a reduzir a emissão de CO₂ e o impacto ambiental. Conhecer as métricas que podem ser utilizadas para medir o custo energético e o impacto ambiental de um datacenter bem como as principais categorias e áreas de ação são pontos fundamentais na Computação Verde. Este artigo apresenta um estudo das relações entre o consumo energético com os tempos de execução, arquitetura e custos de ambiente em nuvem com a adoção de algoritmos para problemas complexos, no escalonamento de Máquinas Virtuais. Por meio da utilização de simuladores foi possível comprovar a melhoria da eficiência energética acima de 60% e redução nos tempos de processamento em no mínimo 29%. Além da redução dos custos de no mínimo 10% e redução do impacto ambiental de 65% na emissão de CO₂.

Palavras-chaves

Computação em Nuvem Verde; Simulador de Nuvem; Eficiência Energética

1. INTRODUÇÃO

Migrar para a computação em nuvem tem uma série de vantagens, tanto computacionais quanto em outros aspectos. É possível citar a redução de custos de energia e refrigeração para a empresa, mas essa redução não pode ser considerada como uma medida de preocupação ambiental, uma vez que somente se está transferindo esses custos e impactos. Quem contrata serviços de computação em nuvem também é responsável direta ou indiretamente pelo impacto ambiental.

De acordo com [15], cerca de 10% de toda energia consumida globalmente é para dispositivos eletrônicos e computacionais, sendo que 50% é diretamente para a computação (29 GW para datacenters, 25 GW para equipamentos de rede e 30 GW para computadores). Os outros 50% são divididos para TV's (44 GW) e para outros dispositivos (40 GW), conforme visualizado na Figura 1. E segundo [18], 50% da energia consumida em um *datacenter* é utilizada para a dis-

sipação do calor, ou seja, refrigeração.

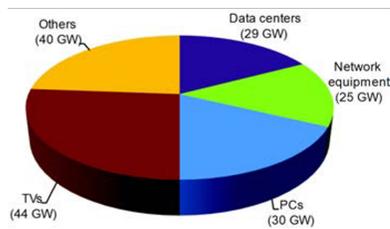


Figure 1: Consumo energético mundial. Fonte: [15]

Em outras palavras, ter um parque computacional mais eficiente e com menor impacto ambiental é de responsabilidade de todos. Quando se fala em computação e computação verde deve-se levar em consideração o que difere uma da outra. Em síntese, na computação verde tem-se o foco na redução do consumo de energia, no uso de recursos renováveis e uso mais eficiente dos recursos.

Para tanto, é necessário ter conhecimento de técnicas, *frameworks*, metodologias e classificações da Computação Verde, de forma a embasar a análise, desenvolvimento e implementações nessa área, pois existem várias abordagens, tanto a nível de software, hardware e virtualização de modo a otimizar o uso dos recursos e consequente diminuição da emissão de CO₂ e impacto no ambiente [11].

Segundo [22], a escolha da infraestrutura em nuvem começa a mudar, pois os critérios deixam de ser somente computacionais e de custos, mas entra na equação a questão da eficiência energética do *datacenter* e o uso de recursos renováveis.

Computação verde não compreende somente a questão do uso de energia, mas também de água, da utilização de recursos renováveis e redução do desperdício computacional, ou seja, utilizar os recursos computacionais necessários somente.

Esta pesquisa apresenta, primeiramente, as métricas computacionais mais utilizadas relacionadas à eficiência energética que permitem avaliar a eficiência de um *datacenter*, bem como as principais abordagens utilizadas na redução do consumo de energia e garantia da qualidade da prestação dos serviços.

O objetivo é demonstrar que é possível reduzir o consumo energético sem perdas significativas de indicadores de qualidade de serviço, ou seja, mantendo os mesmos tempos de respostas e volumes de processamento, com a adoção de algoritmos mais eficientes de alocação de máquinas virtuais. Neste caso em particular entre os algoritmos de Round Robin e Ant Colony System (ACS), incluindo assim, esse algoritmo nas possíveis soluções a serem adotadas dentro dos diversos trabalhos relacionados.

As avaliações são realizadas utilizando vários cenários de configuração com 600 simulações, totalizando cerca de 10.000 horas de processamento. Para finalizar, são apresentados os resultados encontrados e suas conclusões.

2. TRABALHOS RELACIONADOS

Devido a grande variedade de abordagens, tanto físicas quanto lógicas, e a possibilidade dos mais diversos usos propicia uma área fértil de pesquisa na temática de computação em nuvem verde, gerando assim o desenvolvimento de métodos computacionais para o uso eficiente dos recursos com-

putacionais bem como a redução de custos, tanto no Provedor de Serviços quanto para o usuário.

Dentre as formas de se analisar e estimar o uso dos recursos, tem se destacado o uso simuladores de computação em nuvem, uma vez que, se torna impossível ter um ambiente complexo de nuvem para a realização de experimentos. Na sequência, serão apresentados alguns trabalhos que utilizam abordagens e simuladores com esta finalidade em ambientes em nuvem.

Em [19, 16, 13] realizam experimentos utilizando vários simuladores de nuvem e algoritmos como *First-Fit-Approach* e *Round Robin* e fazem análise dos comparativos dos resultados dos simuladores, comparando-os entre si.

Enquanto que [27, 26, 28, 5] utilizam o CloudSim como simulador e realizam os experimentos com algoritmos DPSO, DENS, RoundRobin e Green Scheduler e GA. A análise dos resultados tem por objetivo o comparativo entre os algoritmos, levando em consideração os tempos de execução e os consumos energéticos.

Outras abordagens, como [23] que utiliza algoritmos baseados no modelo SARO onde avalia através da predição o impacto levando em consideração a relação de fatores como a fila de requisições, carga dos servidores e o congestionamento da rede em servidores Hadoop, enquanto que [4] utiliza a regressão para predizer o tempo de resposta, de forma a garantir o SLZ, e consequentemente realizar as migrações das máquinas virtuais.

A abordagem de [7] introduz um comparativo entre os simuladores CloudSim e o iSPD, onde demonstra a eficiência do uso desse simulador, disponibilizando assim, uma outra opção para ser utilizada pelos pesquisadores.

Em contrapartida, o estudo de [25] faz análise da computação em nuvem verde com uso de Big Data. Onde nos seus experimentos, faz o comparativo utilizando as métricas DCIE, com resultados significativos de redução energética de no mínimo 47%. Enquanto que [21] realiza sua pesquisa usando algoritmos com Distribuição baseada em classificação além de realizar o comparativo dos resultados em métricas de emissão de CO₂.

Em relação as abordagens sobre geração de energia renovável, o trabalho de [10] trata da utilização de algoritmos de redes neurais para a predição da energia eólica, de forma a estimar aos grandes *datacenters* a viabilidade do uso deste tipo de modelo.

Este estudo tem por objetivo ampliar os algoritmos utilizados nesses modelos, no caso, incluindo o *Ant Colony System* (ACS) na gama dos algoritmos já avaliados. Para tanto, utilizou-se como base de comparação o *Round Robin* e o CloudSim, seguindo os outros trabalhos relacionados.

2.1 Categorias e Áreas da Computação em Nu- vem Verde

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

A seguir tem-se algumas das diversas categorias, apresentadas na comunidade acadêmica, que são usadas na 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 [20, 1, 12].

Modelos e Métodos: Nesta categoria encontram-se as 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 fala 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 [12], que define um broker que recebe as solicitações e a partir de serviços de monitoramento de recursos e de *datacenters*, sugere 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 as 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.

2.2 Principais Abordagens para Eficiência Energética

Dentre as categorias discutidas na seção 2.1, existem as diversas abordagens que podem ser utilizadas de forma a implementar ou otimizar a redução energética e dos custos, além de reduzir o impacto ambiental. De forma semelhante, as abordagens também devem ser associadas entre si, garantindo um melhor benefício nas mais diversas categorias, podendo ser citadas [20, 3, 1, 12, 15, 18]:

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 das velocidades dos processadores das VM: Dessa forma há redução do consumo de energia e da refrigeração para dissipar o calor, mas garantindo 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 reativando somente quando existe uma demanda necessária.
- (d) Alocação para *datacenter* com melhor eficiência energética: Realizar a alocação dos recursos dos serviços que possuem uma melhor eficiência energética, e desativando nos centros que não possuem.

2. Gerenciamento de energia mais eficiente

- (a) Por meio do controle da voltagem e frequência dos processadores é possível reduzir tanto a energia quanto a temperatura, utilizando-se nesse caso de recursos da própria arquitetura do processador.
- (b) De modo similar ao controle de voltagem e frequência do modelo anterior, mas 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 de acordo com o fluxo ou demanda, desativando assim equipamentos de rede para economizar energia.

3. Abordagens dependentes do hardware

- (a) Redução de dissipação do calor por meio de adoção de processadores que não precisem de dissipadores, como chips de dispositivos móveis.
- (b) Planejamento de energia das placas e processadores que permitem a transmissão separada de energia para os diversos processadores, gerenciando melhor o consumo de acordo com a demanda.
- (c) De modo similar ao gerenciamento da velocidade, a 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, como energia eólica, solar e de água, dentre outras.
- (b) Reaproveitamento dos recursos já utilizadas, como por exemplo o aproveitamento da água utilizada para refrigeração na geração de energia.

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, essas abordagens não necessitam de modificações 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.

3. MATERIAIS E MÉTODOS

3.1 Métricas Computacionais

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

Para se avaliar a eficácia da mudança para a computação em nuvem e, posteriormente, para a computação em nuvem verde, se faz 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 [11, 22]:

- **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 *datacenter*. O melhor resultado do PUE (Energia total do *datacenter* / 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 uma métrica inversa ao PUE, ambas sendo mais utilizadas para comparações entre *datacenters*. É a relação de $1 / \text{PUE}$, ou energia de uma aplicação ou equipamento / Energia total do *datacenter*.
- **Performance per Watt:** É uma medida de eficácia de um processador ou equipamento. É a taxa de desempenho por watt de consumo.
- **GEC:** É uma medida de energia verde, ou seja, é uma medida da quantidade de energia que é consumida pelo *datacenter* 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 *datacenter*. É uma relação entre a emissão de CO_2 e a quantidade de energia consumida. Diz respeito às fontes de energia utilizadas pelo *datacenter*.
- **Data Center Productivity:** Métrica que relaciona o trabalho efetivamente realizado com o total de recursos utilizados para a realização dele. Semelhante ao DCP, mas leva 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 CO_2 :** Apesar do uso computacional não emitir CO_2 diretamente, existe uma relação do seu consumo de energia e o impacto ambiental. Sendo que neste trabalho utilizaremos o cálculo disponível em [8].

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

3.2 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 uma grande quantidade de informações, além do tempo necessário de processamento para atingir parâmetros realistas.

Para tanto, de acordo com [2, 14, 24, 6], para este trabalho foi utilizado o CloudSim Plus, que é um ambiente de simulação Java 8 que permite a modelagem e simulação de diferentes serviços de computação em nuvem, desde as camadas de infraestrutura como serviço (IaaS) até camadas de software como serviço (SaaS). Este ambiente possibilita a implementação de cenários de simulação para experimentação, avaliação e validação de algoritmos para diferentes objetivos.

O *framework* permite que sejam especificadas as características do provedor em nuvem, como:

- Recursos físicos como datacenters, 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 para 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.

3.3 Execução do CloudSim Plus

O CloudSim Plus monitora os tempos de execuções, o uso das CPU's, bem como a energia consumida nos *hosts* e nas VMs para cada cloudlet. Ainda é possível calcular o custo monetário, pay-per-use das máquinas virtuais.

Também estão sendo monitorados os tempos de execução da simulação e o tempo simulado do ambiente, bem como o uso da CPU, memória RAM e o *Max Heap* do ambiente.

Ao final da execução, após a análise dos dados coletados citados anteriormente, os resultados são avaliados levando em consideração dois algoritmos de alocação, o Round Robin (RR), já existente no CloudSim, e Ant Colony System (ACS), adaptado para ser executado nestes experimentos [9]. No caso a primeira, algoritmo muito popular que faz a seleção da máquina virtual através de rodízio entre os *hosts*, distribuindo de forma equilibrada as quantidades de máquinas. Enquanto a segunda, é uma meta-heurística que consiste em um aperfeiçoamento do Ant System, e possui um desempenho notadamente superior e aplicabilidade a problemas de tamanhos mais consideráveis, pois envolve uma parte determinística, ou exploratória, e uma parte probabilística, ou desbravadora [6, 17].

3.4 Experimento

O objetivo deste experimento é validar a possibilidade da redução energética sem prejuízo da capacidade computacional do ambiente em nuvem. Para tanto, serão utilizados dois algoritmos de escalonamento de máquinas virtuais, o Round Robin (RR) e Ant Colony System (ACS), discutidos na seção 3.3. A Figura 2 representa os parâmetros utilizados nas simulações.

Qtd de VM's	40	80
Qtd de Núcleos	4	2
Qtd de Cloudlets	100, 200, 400, 600, 1000	100, 200, 400, 600, 1.000
Tam. dos Cloudlets	1.000.000, 5.000.000	1.000.000, 5.000.000
Políticas de Alocação de VM	Round Robin, ACS	Round Robin, ACS

Figure 2: Parâmetros da Simulação

Os parâmetros definidos são as máquinas virtuais, que neste caso compreendem dois conjuntos de configurações:

- Cenário 1: 40 máquinas virtuais com 4 núcleos de processamento cada.
- Cenário 2: 80 máquinas virtuais com 2 núcleos de processamento cada.

As demais configurações de memória, armazenamento, largura de banda, etc são mantidas idênticas nos dois cenários. Esses parâmetros são para analisar a premissa de que o melhor custo benefício está entre instanciar mais máquinas virtuais com menor quantidade de processadores ou menor quantidade de máquinas com mais processadores.

As aplicações que serão executadas, ou seja, os *cloudlets*, foram divididas em dois conjuntos de parâmetros:

- Quantidade de *cloudlets*: foram divididos em 5 grupos, a saber: 100, 200, 400, 600 ou 1000 *cloudlets*.
- Tamanho dos *cloudlets*: foram divididos em 2 categorias, onde o tamanho é definido por quantidade de instruções a serem executadas: 1.000.000 e 5.000.000 de instruções.

Estes cenários foram definidos de forma a avaliar o comportamento em situações de baixa carga no ambiente e também de sobrecarga. Além de analisar a premissa de que o

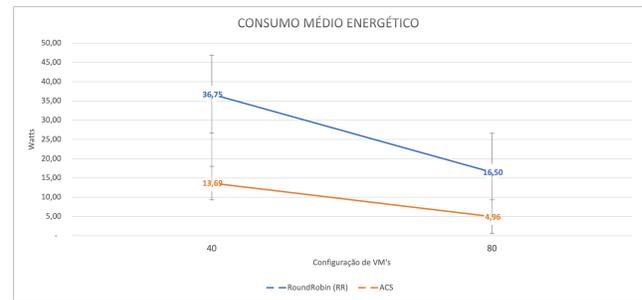


Figure 3: Consumo energético.

melhor custo benefício está entre instanciar mais máquinas virtuais com menor quantidade de processadores ou menor quantidade de máquinas com mais processadores, além de confrontá-los com outros trabalhos realizados.

E por fim, as políticas de alocação, conforme citado, para a execução das simulações de forma a avaliar os tempos de respostas, consumo energético e custos das execuções. Vale lembrar que os valores monetários são expressos em dólares americanos e foram extraídos das bases e configurações da AWS americana, bem como os consumos energéticos dos processadores. Importante também frisar que nestes experimentos está sendo levado em consideração somente o consumo energético dos processadores, tanto dos Hosts quando das VM's.

Foram capturados para cada execução os resultados de tempo de processamento das aplicações, custos e consumo energético dentre outra informações. O tempo total simulado de processamento foi de 643.284 mins (10.721 horas, equivalente a 446 dias) com cerca de 600 simulações executadas.

4. ANÁLISE DOS RESULTADOS

Esta seção apresenta os resultados experimentais e os examina em profundidade. Os dados de entrada foram fornecidos na seção 3.4 de forma a atender aos requisitos de carga de trabalho pesada.

Os resultados de simulação capturados foram agrupados e analisados com o objetivo de avaliar os critérios discutidos nas seções anteriores. Os dados apresentados nas Tabelas 1 e 2 a seguir foram consolidados para apresentação deste artigo, onde são apresentadas as configurações utilizadas, os resultados obtidos para cada algoritmo e relação entre eles com o objetivo de visualizar o percentual de ganho.

Para tanto foram criados alguns cenários para discussão:

- Cenário 1: Tempos de execuções das aplicações;
- Cenário 2: Consumos energéticos das aplicações;
- Cenário 3: Custos de execução das aplicações;
- Cenário 4: Avaliação das métricas computacionais;
- Cenário 5: Avaliação da emissão de gás carbônico.

4.1 Cenário 1: Tempos de execuções das aplicações

Os principais trabalhos relacionados a desempenho computacional levam em consideração os tempos de execuções das aplicação para medir a eficácia de um determinado cenário.

Table 1: Resultados consolidados dos tempos de execução (s) e consumo energético das simulações (w)

2*Configurações	Tempo Médio de Execução			Consumo Médio Energético		
	RoundRobin (RR)	ACS	Relação RR e ACS	RoundRobin (RR)	ACS	Relação RR e ACS
40 VMs e 4 Núcleos	696,47	490,17	-29,62%	36,75	13,69	-62,76%
80 VM's e 2 Núcleos	81,07	45,60	-43,75%	16,50	4,96	-69,96%

Table 2: Resultados consolidados dos custos (US\$) dos ambientes nas simulações

2*Configurações	Algoritmo de Alocação		
	RoundRobin (RR)	ACS	Relação RR e ACS
40 VMs e 4 Núcleos	8.340,13	7.465,53	-10,49%
80 VM's e 2 Núcleos	1.305,24	549,28	-57,92%

Levando em consideração a Tabela 1, verificou-se reduções do tempo de processamento de cerca de 29% e de 43%, de acordo com o modelo de configuração, na adoção do algoritmo ACS em relação ao de RR. Ou seja, a adoção de algoritmos para modelos mais complexos reduz o tempo de execução de forma significativa, consequentemente os custos também.

É importante salientar, que o uso de um modelo computacional mais distribuído produziu ganhos significativos, a citar uma redução do tempo de processamento médio de 88% na mudança de 40 para 80 máquinas virtuais, considerando a mesma carga de trabalho para o Round Robin. E para o algoritmo ACS o ganho chega a ser superior a 91% na redução do tempo médio de execução.

4.2 Cenário 2: Consumos energéticos das aplicações

Levando em consideração o cenário energético, tem-se a partir da análise consolidada da Tabela 1 e visualizados na Figura 3, uma redução superior a 60% no consumo energético para a mesma carga de trabalho, além da redução no tempo de execução das aplicações de no mínimo 29%, citado anteriormente no cenário 1. Consequentemente, a redução energética também é impactada pela redução do tempo de processamento, mas gerando reduções significativas de energia e resfriamento, diminuindo assim o impacto ambiental.

Analisando os dados energéticos por conjunto de *cloudlets*, conforme a Tabela 3, observa-se reduções significativas dos consumos, variando de 61% a 65% independentemente do tamanho das aplicações ou do modelo de distribuição das máquinas virtuais e na adoção dos algoritmos de escalonamento, de forma a corroborar com os dados apresentados de forma consolidada.

Nota-se também, conforme visualizado na Figura 4, que o consumo energético para o algoritmo de RoundRobin, independente das configurações adotadas, houve variação próxima dos 12% (25,63w e 37,50w), enquanto que no ACS, a variação ficou próxima dos 5% (8,82w e 14,26w). Essa variação demonstra, que além de melhorar o consumo energético com o algoritmo selecionado, também é possível melhorar o desempenho energético sem afetar o tempo de processamento, neste caso, fazendo associação com os dados analisados no Cenário apresentado na Seção 4.1.

Neste caso em específico, levando somente em consider-

Table 3: Resultados detalhados por cloudlets dos consumos energéticos (w)

Aplicações (<i>cloudlets</i>)		Algoritmo		
Qtd	Tamanho	Round Robin	ACS	Diferença
100	1.000.000	25,63	9,24	-63,95%
100	5.000.000	25,63	8,82	-65,59%
200	1.000.000	36,75	14,26	-61,21%
200	5.000.000	36,75	13,44	-63,43%
400	1.000.000	37,50	13,43	-64,19%
400	5.000.000	37,50	13,93	-62,86%
600	1.000.000	37,25	13,94	-62,58%
600	5.000.000	37,25	13,67	-63,31%
1.000	1.000.000	37,50	14,18	-62,18%
1.000	5.000.000	37,50	13,81	-63,17%

ação os dois fatores já apresentados, tempo de processamento e consumo energético, o melhor custo benefício seria o modelo de 80 máquinas virtuais.

Ainda comparando apenas os modelos de arquitetura entre a adoção de 40 VMs e 80 VMs tem-se a redução do consumo energético em torno de 44% (36,75w e 16,50w) para o RR e 36% (13,69w e 4,96w) para o ACS, independentemente da adoção de políticas de escalonamento mais eficientes.

4.3 Cenário 3: Custos de execução das aplicações

O simulador faz o cálculo dos custos baseado nas configurações das máquinas virtuais, conforme parâmetros citados na seção 3.4, não levando em consideração o tipo de uso ou mesmo a sobrecarga de utilização da mesma. Sendo assim, para cenário mais simples, a redução média de custos foi superior a 10% e para cenário mais complexo, superou os 50% na alocação das máquinas virtuais, conforme demonstrado na Tabela 2 e visualizado na Figura 5.

Entretanto, se compararmos os modelos de arquitetura, o de 40 VMs e de 80 VMs, apesar de possuírem os mesmos recursos computacionais, a redução dos custos se torna maior no algoritmo ACS devido à melhor eficiência para ambientes mais distribuídos. Essa tendência reforça que não somente a construção de uma infraestrutura distribuída se faz necessária, mas também o desenvolvimento de aplicações que possam usufruir desse ambiente. Neste caso, já seria utilizando outra abordagem para a computação em nuvem verde, discutida na seção 2.2.

4.4 Cenário 4: Avaliação das métricas computacionais

A partir dos dados extraídos nas simulações e aplicados nas métricas da seção 3.1 foi construída a Tabela 4 abaixo e representado na Figura 6, onde com relação à PUE e DCIE, quanto mais próximo de 1 melhor o índice energético. Nesse caso se destaca o algoritmo ACS a medida que o ambiente

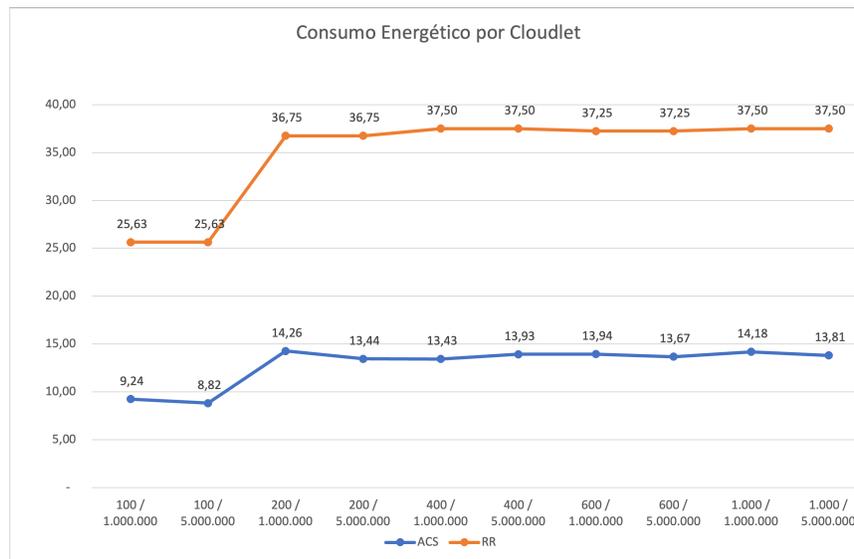


Figure 4: Consumo energético dos cloudlets.



Figure 5: Custos de Execução dos modelos.

se torna mais complexo.

É importante salientar que neste trabalho utilizou-se apenas algoritmos de alocação de máquinas virtuais, sendo possível ainda outras técnicas que podem ser utilizadas, como de escalonamento de tarefas e migração de máquinas virtuais. Também foi considerado somente o consumo energético dos equipamentos, não sendo levado em consideração o necessário para refrigeração do modelo.

A partir dessas duas medidas é possível mensurar e comparar a eficiência energética não somente entre diversos algoritmos mas também entre *datacenters*.

4.5 Cenário 5: Avaliação da emissão de gás carbônico

O consumo de energia do data center está diretamente relacionado às emissões de dióxido de carbono equivalentes à energia. Como este estudo se concentrou na utilização de energia dos equipamentos somente, foi necessário calcular e comparar as emissões de dióxido de carbono, utilizando a referência americana, em [8], já que, usou-se parâmetros da

AWS localizada nos Estados Unidos. Não estão sendo levadas em consideração os consumos energéticos necessários à refrigeração, redes, demais equipamentos elétricos relacionados.

A comparação de ambas as estratégias de alocação dos algoritmos, conforme demonstrado na Tabela 5 e visualizado na Figura 7, totalizando o consumo para toda a carga de trabalho para cada configuração, indicam claramente que a emissão de carbono equivalente no algoritmo ACS é significativamente menor quando comparada com ao algoritmo de RoundRobin para alocação de máquinas virtuais.

A menor quantidade para o RoundRobin foi de 18 Tons de CO₂ equivalente. É dito equivalente, uma vez que, a produção da energia elétrica não necessariamente emite gás carbônico. Esses valores atingem cerca 19,5 Toneladas. É importante salientar que essas emissões são para todo o processamento realizado, que na simulação foi cerca de 446 dias.

Enquanto que no uso do algoritmo ACS, a variação ocorreu de 4,8 tons à 7,2 tons. Sendo possível fazer a analogia, de que, a maior quantidade de emissão do ACS é cerca de 60% menor que a do Round Robin. Percebe-se também o crescimento mais acentuado no algoritmo RR do que no ACS.

Comparando os dois algoritmos entre si para cada modelo, percebe-se reduções de emissão de CO₂ mínima de 61,67% e máxima de 75,38% para as mesmas cargas de trabalho, sendo que a média de redução da emissão foi de 65,30%.

Em resumo, ao adotar os vários parâmetros avaliados nos 5 cenários apresentados, é possível diminuir o impacto ambiental em pelo menos 60%, sem detrimento da capacidade computacional na adoção de medidas que não geram custos diretos. Além de manter a qualidade e capacidade computacional, reduzir o impacto ambiental, ainda é gerada uma economia de custos com a infraestrutura, tanto para o provedor, quanto para o usuário final da computação em nuvem.

Sendo que para esses modelos simulados, o melhor custo benefício é a adoção do modelo de 80 máquinas virtuais, onde têm-se a redução do impacto ambiental em 65% e redução dos custos de pelo menos 10% na utilização do algo-

Table 4: Cálculos das métricas computacionais

Aplicações (<i>cloudlets</i>)		PUE		DCIE	
Qtd	Tamanho	Round Robin	ACS	Round Robin	ACS
100	1.000.000	0,94	0,73	106,29%	136,35%
100	5.000.000	0,94	0,70	106,29%	142,85%
200	1.000.000	1,35	1,13	74,12%	88,35%
200	5.000.000	1,35	1,07	74,12%	93,71%
400	1.000.000	1,38	1,07	72,63%	93,78%
400	5.000.000	1,38	1,11	72,63%	90,43%
600	1.000.000	1,37	1,11	73,12%	90,36%
600	5.000.000	1,37	1,09	73,12%	92,15%
1.000	1.000.000	1,38	1,13	72,63%	88,80%
1.000	5.000.000	1,38	1,10	72,63%	91,20%

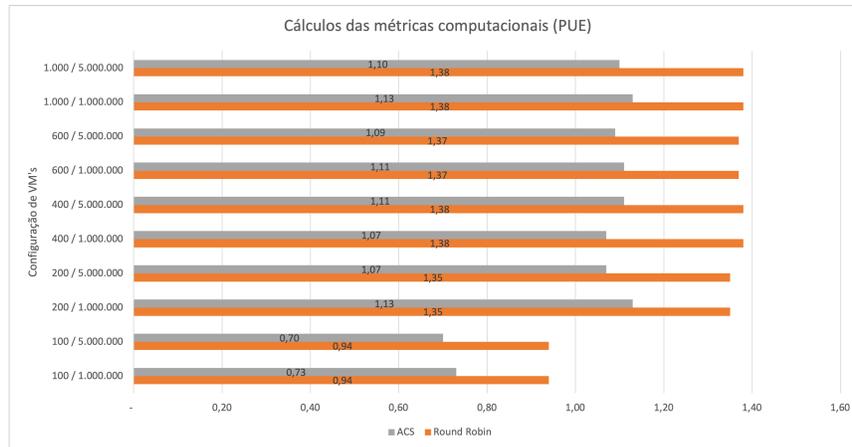


Figure 6: Gráfico dos valores de PUE para os modelos.

Table 5: Cálculos de emissão de CO_{2eq}

Cloudlets	Emissão de CO ₂ (Tons)			Relação RR e ACS
	Round Robin (RR)	ACS		
100	18	6,9	-61,67%	
200	19,1	7,2	-62,30%	
400	19,5	7,1	-63,59%	
600	19,3	7,1	-63,21%	
1000	19,5	4,8	-75,38%	
Total	95,4	33,1	-65,30%	

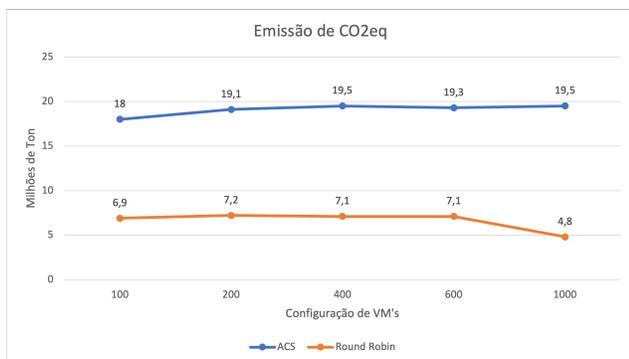


Figure 7: Gráfico de emissão de CO₂ para os modelos.

ritmo ACS, além de diminuir em 90% o tempo de resposta em relação ao modelo de 40 máquinas virtuais.

5. CONCLUSÃO

A computação em nuvem verde está se tornando um tópico amplamente discutido na indústria e na academia. Cada dia mais as empresas estão migrando para esse modelo devido ao aumento do armazenamento de dados e demandas computacionais, havendo por consequência o crescimento da infraestrutura dos provedores em nuvem. Esse crescimento possui um grande impacto econômico e socioambiental. Devido à demanda energética, de água ou emissão de CO₂. A partir desta demanda, cresce também a necessidade de *datacenters* energeticamente mais eficientes e com utilização de recursos renováveis.

Este estudo teve por objetivo a identificação das principais métricas utilizadas, bem como as possíveis áreas e categorias de transformação para a Computação em Nuvem Verde. Além disso, pretendeu-se avaliar a premissa de que é possível obter uma redução energética de consumo sem diminuição dos tempos de processamento.

Os resultados foram coletados utilizando o CloudSim Plus, um simulador desenvolvido para ambientes complexos em nuvem, que permite implementar diferentes estratégias de redução de energia ou melhorias em indicadores de qualidade de serviço.

A partir deste experimento é possível afirmar que com o uso de algoritmos mais eficientes de alocação ou de abordagens diferenciadas obtém-se reduções significativas no con-

sumo energético, variando entre 62% e 69%, com impacto também na redução dos tempos de processamento, cerca de 29%, ou seja, melhorando o SLA. Além da redução indireta de custos relacionadas ao tempo de processamento e eficiência energética, identificou-se também a redução de custos diretos na alocação das máquinas virtuais, de no mínimo 10%, podendo chegar a 57%.

O impacto ambiental, com a adoção desse modelo e utilização de algoritmos mais eficientes, que neste caso o ACS, é reduzido de forma significativa, chegando até 65% na redução de emissão de gás carbônico, ou seja, 62 toneladas a menos de CO₂ para esse modelo simulado.

Ainda percebeu-se que a adoção de um modelo de infraestrutura mais distribuído, considerando a mesma carga de trabalho apresentada, uma redução de 90% no tempo de execução das tarefas e redução de custos em cerca de 92% ao se utilizar uma maior quantidade de máquinas virtuais e uso do algoritmo ACS, mas que, nesse caso, é necessário outras abordagens para poder aproveitar esse arquitetura.

A adoção desse modelo de alocação de máquinas virtuais possui um impacto positivo no custo operacional da infraestrutura, além da redução do tempo de execução, permitindo assim, aos pesquisadores e gerentes de *datacenters*, o melhor aproveitamento do seu parque tecnológico com menor custo, seja para nuvem pública ou privada.

Com estudos mais avançados dos simuladores e algoritmos, como trabalhos futuros será possível definir quais os melhores parâmetros de medição da eficiência computacional e energética de um *datacenter*, bem como medir a eficiência das diversas abordagens implementadas, contribuindo assim para a adoção da Computação em Nuvem Verde de forma mais eficiente.

6. REFERENCES

- [1] M. N. Agrawal, M. J. K. Saini, and P. Wankhede. Review on green cloud computing: A step towards saving global environment. 2020.
- [2] E. Barbierato, M. Gribaudo, M. Iacono, and A. Jakóbbik. Exploiting cloudsims in a multiformalism modeling approach for cloud based systems. *Simulation Modelling Practice and Theory*, 93:133–147, 2019.
- [3] C. Bash, T. Cader, Y. Chen, D. Gmach, R. Kaufman, D. Milojevic, A. Shah, and P. Sharma. Cloud sustainability dashboard, dynamically assessing sustainability of data centers and clouds. *Proceedings of the Fifth Open Cirrus Summit, Hewlett Packard, CA, USA*, 13, 2011.
- [4] N. K. Biswas, S. Banerjee, U. Biswas, and U. Ghosh. 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*, 45:101087, 2021.
- [5] J. Chopra, V. Rangarajan, and R. Sen. Sustainable energy technologies and assessments. 2021.
- [6] CLOUDSIM. Full-featured and fully documented cloud simulation framework, 2016.
- [7] D. T. da Silva, J. A. Rodrigues, A. Manacero, R. S. Lobato, R. Spolon, and M. A. Cavenaghi. Modeling and simulation of cloud computing with ispd. In *Anais do XXIII Simpósio em Sistemas Computacionais de Alto Desempenho*, pages 217–228. SBC, 2022.
- [8] U. S. E. P. A. EPA. Greenhouse gas equivalencies calculator, 2022.
- [9] F. Farahnakian, A. Ashraf, T. Pahikkala, P. Liljeberg, J. Plosila, I. Porres, and H. Tenhunen. Using ant colony system to consolidate vms for green cloud computing. *IEEE Transactions on Services Computing*, 8(2):187–198, 2015.
- [10] C. G. França, S. T. Faceroli, P. S. C. Nascimento, A. S. Kligerman, et al. Análise comparativa de modelos de previsão de geração de energia eólica baseados em machine learning. *Revista de Sistemas e Computação-RSC*, 9(2), 2020.
- [11] A. Gade. Survey on energy efficient cloud: A novel approach towards green computing. *HELIX*, 2018.
- [12] S. K. Garg, C. S. Yeo, and R. Buyya. Green cloud framework for improving carbon efficiency of clouds. In *European Conference on Parallel Processing*, pages 491–502. Springer, 2011.
- [13] S. R. Jena, R. Shanmugam, K. Saini, and S. Kumar. Cloud computing tools: inside views and analysis. *Procedia Computer Science*, 173:382–391, 2020.
- [14] T. J. T. Junior and S. Bruschi. Epcscac-extensible platform for cloud scheduling algorithm comparison. In *Anais Estendidos do XXI Simpósio em Sistemas Computacionais de Alto Desempenho*, pages 46–53. SBC, 2020.
- [15] R. Khan and S. U. Khan. Achieving energy saving through proxying applications on behalf of idle devices. *Procedia Computer Science*, 83:187–194, 2016.
- [16] A. T. Makaratzis, K. M. Giannoutakis, and D. Tzovaras. Energy modeling in cloud simulation frameworks. *Future Generation Computer Systems*, 79:715–725, 2018.
- [17] A. K. Mandal and S. Dehuri. A survey on ant colony optimization for solving some of the selected np-hard problem. In *International Conference on Biologically Inspired Techniques in Many-Criteria Decision Making*, pages 85–100. Springer, 2019.
- [18] M. Masdari and M. Zangakani. Green cloud computing using proactive virtual machine placement: challenges and issues. *Journal of Grid Computing*, 18(4):727–759, 2020.
- [19] V. Meyer, R. Krindges, T. C. Ferreto, C. A. De Rose, and F. Hessel. Simulators usage analysis to estimate power consumption in cloud computing environments. In *2018 Symposium on High Performance Computing Systems (WSCAD)*, pages 70–76. IEEE, 2018.
- [20] L.-D. Radu. Green cloud computing: A literature survey. *Symmetry*, 9(12):295, 2017.
- [21] A. Saboor, A. K. Mahmood, A. H. Omar, M. F. Hassan, S. N. M. Shah, and A. Ahmadian. Enabling rank-based distribution of microservices among containers for green cloud computing environment. *Peer-to-Peer Networking and Applications*, 15(1):77–91, 2022.
- [22] B. Saha. Green computing: current research trends. *International Journal of Computer Sciences and Engineering*, 6(3):467–469, 2018.
- [23] W. Shu, K. Cai, and N. N. Xiong. Research on strong agile response task scheduling optimization

- enhancement with optimal resource usage in green cloud computing. *Future Generation Computer Systems*, 124:12–20, 2021.
- [24] M. C. Silva Filho, R. L. Oliveira, C. C. Monteiro, P. R. Inácio, and M. M. Freire. Cloudsim plus: A cloud computing simulation framework pursuing software engineering principles for improved modularity, extensibility and correctness. In *2017 IFIP/IEEE symposium on integrated network and service management (IM)*, pages 400–406. IEEE, 2017.
- [25] C. L. Stergiou, K. E. Psannis, and Y. Ishibashi. Green cloud communication system for big data management. In *2020 3rd World Symposium on Communication Engineering (WSCE)*, pages 69–73. IEEE, 2020.
- [26] M. Wadhwa, A. Goel, T. Choudhury, and V. P. Mishra. Green cloud computing-a greener approach to it. In *2019 international conference on computational intelligence and knowledge economy (ICCIKE)*, pages 760–764. IEEE, 2019.
- [27] J. Yang, W. Xiao, C. Jiang, M. S. Hossain, G. Muhammad, and S. U. Amin. Ai-powered green cloud and data center. *IEEE Access*, 7:4195–4203, 2018.
- [28] Z. Zong. An improvement of task scheduling algorithms for green cloud computing. In *2020 15th International Conference on Computer Science & Education (ICCSE)*, pages 654–657. IEEE, 2020.