

Zero-Carbon Cloud: Mensuração do Consumo Energético Associado à Virtualização de Solução Baseada em Redes Neurais Recorrentes LSTM

Davi Lopes Lemos¹, Naylor Bastiani Perez², Leonardo Bidese de Pinho¹

¹Universidade Federal do Pampa (UNIPAMPA) - Campus Bagé
96.413-172 – Bagé – RS – Brasil

²Embrapa Pecuária Sul
96.401-970 – Bagé – RS – Brasil

{davilemos.aluno, leonardopinho}@unipampa.edu.br

naylor.perez@embrapa.br

Abstract. *The growing use of Cloud Computing for Artificial Intelligence applications has heightened concerns regarding energy expenditure and the environmental impact of such systems. This study examines the execution of an RNN-LSTM model in a virtual machine under zero-carbon cloud principles, showing that virtualization adds approximately 15% to energy consumption and has an even more pronounced effect on execution time. Furthermore, the findings demonstrate that both location and time of execution strongly influence GHG emissions, indicating that running the workload in countries with cleaner electricity mixes reduces the solution's carbon footprint.*

Resumo. *O uso crescente de Cloud Computing para aplicações de Inteligência Artificial tem ampliado a preocupação com o gasto de energia e o impacto ambiental desses sistemas. Este estudo analisa a execução de um modelo RNN LSTM em máquina virtual considerando os princípios de zero-carbon cloud, mostrando que a virtualização acrescenta cerca de 15% ao consumo energético e impacta de forma mais expressiva o tempo de execução. Além disso, demonstra-se que o local e horário influenciam fortemente as emissões de GEE, evidenciando que a execução em países com matrizes elétricas mais limpas reduz a pegada de carbono da solução.*

1. Introdução

Em seus primórdios, a Inteligência Artificial (IA) surgiu para caracterizar todos aqueles algoritmos capazes realizar tarefas que, até então, demandassem atuação humana [Rich et al. 2009]. Atualmente, no cenário mundial, observa-se ampla adoção destas técnicas no cotidiano e em diversos setores, como na indústria, saúde e agricultura, compondo, por exemplo, neste último caso, sistemas de apoio à decisão e trazendo ganhos significativos aos produtores rurais.

Entretanto, tendo em vista a complexidade de algoritmos de IA, deve-se levar em consideração sua demanda por recursos computacionais que, à esta altura, cresce de forma acelerada tendo em vista a popularização de aplicações deste tipo. Aumenta-se,

portanto, a procura por meios de se executá-los mais rapidamente, uma vez que, normalmente, máquinas convencionais possuem capacidade limitada, tornando o processo consideravelmente mais lento.

Neste contexto de maior demanda, ocorre o triunfo dos serviços de Computação em Nuvem (*Cloud Computing*), que, em linhas gerais, disponibilizam recursos computacionais alocados em *data centers*, necessitando de um artifício para gerenciamento e isolamento das diferentes cargas de trabalho, podendo serem realizados por máquinas virtuais (VM) ou pelos contêineres, por exemplo. Considerando-se a execução nestas grandes infraestruturas, o impacto ambiental e social é eminente, uma vez que possuem grande consumo energético, elevando a emissão de Gases do Efeito Estufa (GEE), e que sua instalação afeta diretamente seu entorno.

Dessa maneira, estudam-se técnicas voltadas à mitigação desse efeito, como o conceito de *zero-carbon cloud*, que propõe aproximar a computação das próprias fontes de energia renovável, aproveitando períodos e locais com sobra de energia limpa [Large-Scale Sustainable Systems Group 2025]. Essa abordagem se justifica porque transmitir eletricidade por longas distâncias envolve custos elevados e perdas significativas, tornando mais eficiente levar os serviços de nuvem até a fonte de energia [DeSantis et al. 2021]. Nesse contexto, diferentes formas de virtualização permitem maior flexibilidade na alocação das cargas de trabalho e apresentam diferentes implicações energéticas [Morabito 2015].

Neste trabalho, pretende-se analisar o consumo energético de um modelo preditivo de IA aplicado à agricultura digital para estimar a quantidade de massa de forragem disponível em determinada área de manejo animal, quando executado em ambiente de computação em nuvem sobre VM. A partir da mensuração do consumo dessa aplicação, são discutidas estratégias de distribuição e implantação das cargas de trabalho, considerando decisões de localização e alocação de instâncias, com o objetivo de tornar sua execução mais eficiente energeticamente e reduzir o impacto ambiental da infraestrutura.

2. Trabalhos Relacionados

A literatura recente dedicada à sustentabilidade computacional consolidou duas linhas centrais de investigação: o estudo do impacto ambiental dos modelos de IA e a análise das infraestruturas responsáveis por executá-los. O termo Green AI foi inicialmente proposto com o objetivo de destacar que o avanço dos modelos deve considerar não apenas métricas de acurácia, mas também o custo energético associado às fases de treinamento e inferência [Schwartz et al. 2020]. Esse movimento motivou o crescimento contínuo de estudos voltados à eficiência energética, como evidenciado por uma revisão sistemática publicada em 2023 que identifica práticas recorrentes nesse campo, incluindo a preferência por modelos menores, o uso de abordagens de treino mais enxutas, a escolha de *hardwares* mais econômicos e o fortalecimento de métodos de monitoramento de energia para tornar as análises mais comparáveis e transparentes [Verdecchia et al. 2023].

Além disso, há esforços para melhorar o gerenciamento de *data centers* e tornar a computação em nuvem mais sustentável. Uma abordagem recente, por exemplo, propõe eficiência energética e redução do impacto ambiental por meio de gestão integrada de recursos, englobando servidores, redes, sistemas de resfriamento, energia renovável e cargas de trabalho, combinada com algoritmos de aprendizado de máquina e aprendizado

por reforço, capazes de otimizar automaticamente a alocação de tarefas, evitar *hotspots* e reduzir o consumo de energia sem comprometer os níveis de serviço [Buyya et al. 2023]. Essa perspectiva dialoga diretamente com o presente trabalho, que busca caracterizar o custo energético da execução de modelos de IA em VM e compreender como esse comportamento pode informar estratégias de implantação mais eficientes para sistemas de computação em nuvem.

3. Material e Métodos

Realizou-se uma pesquisa exploratória de caráter experimental com o objetivo de analisar o consumo energético de uma aplicação baseada em um modelo preditivo de IA voltado à estimativa da massa de forragem disponível em áreas de manejo animal, quando executada em um ambiente de computação em nuvem utilizando VM. O modelo utiliza dados de entrada compostos por variáveis meteorológicas e ambientais coletadas entre 2014 e 2018, processados por uma Rede Neural Recorrente (RNN) do tipo *Long Short-Term Memory* (LSTM), que produz como saída a estimativa de massa de forragem expressa em kg/ha, cuja acurácia é avaliada por meio do Erro Médio Quadrático (RMSE) [Schulte 2019].

Os experimentos foram conduzidos em um ambiente GNU/Linux (Ubuntu 22.04.5 LTS) utilizando o VMware Workstation 17 para execução da VM. A implementação da máquina convidada se dá sobre uma máquina *host* que dispõe de um processador AMD Ryzen 7 5700U, com 8 núcleos e 16 *threads*, frequência de até 4,3 GHz, GPU integrada AMD Radeon Graphics 8 e 12 GB de memória DDR4, que serve também como ambiente de contraste para os experimentos. A VM foi configurada com quatro núcleos de Unidade Central de Processamento (CPU), 4 GB de RAM, suporte a AMD-V/RVI e contadores de desempenho habilitados.

No que tange à mensuração do consumo energético, adotou-se um procedimento baseado no utilitário `perf`, empregando o comando `perf stat -e power/energy-pkg/` para acessar os contadores RAPL disponibilizados pelo processador, seguindo a sintaxe recomendada e permitindo estimar a energia consumida pela CPU sem a necessidade de instrumentos externos [Tomm et al. 2025]. A fim de levantar-se um parâmetro para comparação, também experimenta-se na máquina *host*, sem influência da virtualização, para a execução do modelo e captura do consumo energético.

Os experimentos foram executados dez vezes e organizados conforme as limitações impostas pelo hipervisor do ambiente virtualizado. Como o uso de VM implica a virtualização do acesso aos eventos de *hardware* e aos sensores RAPL, não é possível obter diretamente essa métrica a partir da própria instância. Considerando que a execução do modelo leva, em média, cerca de 390 s nessa configuração de VM [Lemos et al. 2025], adotou-se uma abordagem alternativa baseada na mensuração do consumo total da máquina *host*, ilustrada na Figura 1. Para isso, registrou-se o consumo energético do *host* em dois cenários: em estado ocioso (*baseline*) e com a alocação da VM executando o modelo, monitorando-se a carga no `perf` por meio do comando `sleep 4000`, respectivo ao tempo estimado para a execução do modelo dez vezes ($390\text{ s} \times 10$), acrescido de uma margem para eventual variabilidade. O tempo efetivo de processamento foi obtido a partir da própria VM, utilizando o comando `time`. A monitoração direta do processo correspondente à instância não foi viável, já que o hipervisor também bloqueia o acesso às métricas relativas ao PID da VM.

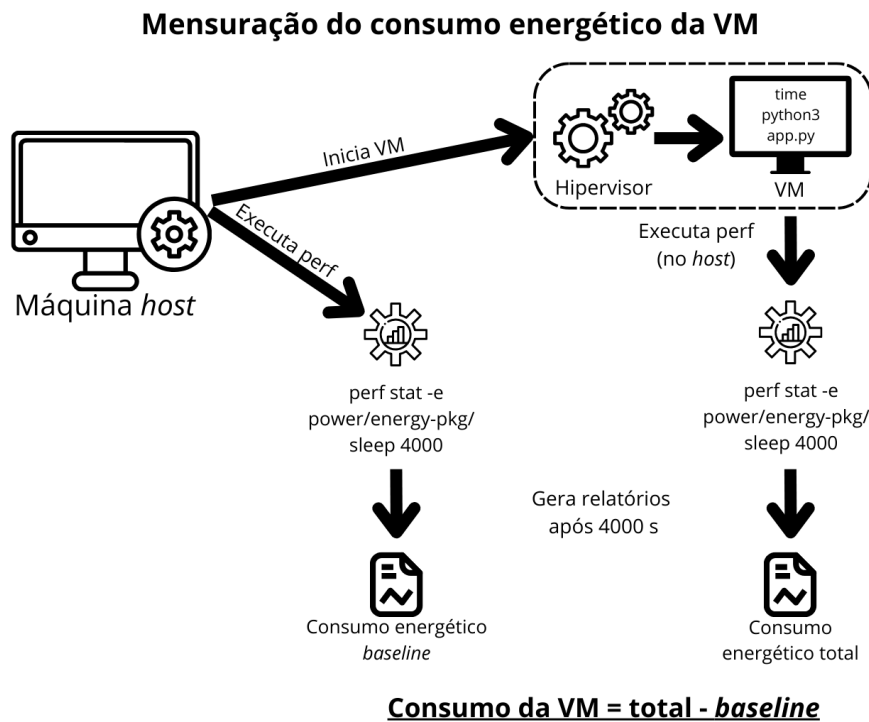


Figura 1. Experimento para mensuração do consumo energético da VM.

Com o objetivo de relacionar a execução do modelo às variações na intensidade de carbono da geração elétrica, definiu-se um recorte que contempla dez países entre aqueles com maior concentração de servidores segundo a plataforma Statista. O conjunto inclui Estados Unidos, Alemanha, Reino Unido, China, Canadá, França, Austrália, Países Baixos, Japão e Brasil, sendo este analisado também por suas regiões Sul, Centro, Norte e Nordeste. Para obter a estimativa das emissões associadas ao consumo energético, recorreu-se aos dados da Electricity Maps, considerando uma média calculada a partir de um intervalo de 72 horas e expressa em gCO_2eq/kWh . Como a aplicação processa novas entradas quatro vezes ao dia, as avaliações foram organizadas tomando os horários de 12:00 AM, 06:00 AM, 12:00 PM e 06:00 PM como pontos de referência, permitindo observar como a escolha do horário de execução pode influenciar o impacto ambiental.


4. Resultados e Discussões

Considerando o objetivo deste trabalho, que envolve analisar como a execução do modelo preditivo em VM pode se aproximar dos princípios de *zero-carbon cloud*, este estudo organiza inicialmente os valores médios de intensidade de carbono (gCO_2eq/kWh) das regiões capazes de hospedar a aplicação. A consolidação desses dados concentra na Tabela 1 os contrastes entre matrizes elétricas nacionais e regionais, criando um panorama que fundamenta as discussões subsequentes. Essa estruturação é essencial porque permite avaliar em que medida o local e o momento de execução da VM influenciam o impacto ambiental de uma mesma carga computacional, especialmente quando se considera a rotina de quatro execuções diárias do modelo. A partir dessa base comparativa, tornam-se possíveis estimativas mais precisas das emissões associadas e a identificação do potencial de redução proporcionado por uma estratégia alinhada ao *zero-carbon cloud*.

Tabela 1. gCO_2eq/kWh emitidas nos diferentes países/regiões e horários.

País	Horário			
	12:00 AM	06:00 AM	12:00 PM	06:00 PM
Estados Unidos	403,67	389,67	331,33	377,33
Alemanha	477,00	349,33	456,67	476,00
Reino Unido	231,00	267,33	269,67	312,67
China	400,00	476,00	481,33	456,67
Canadá	146,00	139,33	140,00	144,33
França	30,33	33,00	35,00	47,00
Austrália	238,33	533,67	520,33	361,67
Países Baixos	473,33	272,33	387,33	472,67
Japão	359,33	520,33	501,67	494,33
Brasil - Norte	223,33	224,00	199,67	185,33
Brasil - Central	124,33	138,67	120,33	110,00
Brasil - Sul	72,00	78,67	79,00	67,00
Brasil - Nordeste	70,00	71,00	86,00	76,00

As medições energéticas que sustentam esta análise partem do levantamento de *baseline* com a máquina *host* totalmente ociosa, resultando em um consumo de 6.419,8 J ao longo de 4.000 s, equivalente a uma potência média de aproximadamente 1,60 W. Esse valor serve como referência indispensável para isolar o efeito real da carga computacional imposta pela VM e a execução do modelo. Com a VM ativada e o modelo sendo executado, o consumo bruto registrado atinge 47.900,30 J no mesmo intervalo (aproximadamente 11,97 W de potência). A diferença obtida pela subtração da *baseline* corresponde a 41.480,5 J, resultando em uma potência adicional de cerca de 10,37 W, que representa diretamente o impacto energético efetivo atribuível à virtualização e ao processamento do modelo preditivo. Esse incremento constitui a métrica central utilizada nas discussões subsequentes, especialmente na estimativa de emissão de GEE associada a cada execução.

**Figura 2.** Comparação do tempo e potência para os diferentes ambientes.

A execução do modelo na máquina *host*, sem virtualização, teve um consumo de 9,05 W ao longo de 113,65 s. A Figura 2 apresenta a relação entre o tempo de execução e a potência média nos dois ambientes analisados. Observa-se que a VM executa o modelo cerca de 222% mais lentamente que o *host*, porém seu consumo instantâneo é apenas 14,6% maior, revelando que o impacto energético adicional decorre sobretudo do tempo prolongado de processamento. Mesmo assim, o tempo obtido na VM ficou abaixo do esperado para essa configuração (que era em torno de 390 s), indicando desempenho ligeiramente mais eficiente do que o previsto.

Em termos de emissão de GEE, com os valores da Tabela 1 e considerando o consumo equivalente a 0,01037 kWh por execução na VM, observa-se que os melhores cenários globais ocorrem em países com matrizes limpas, especialmente a França, cujas intensidades de carbono (30-47 gCO_2eq/kWh) resultam em emissões extremamente baixas por execução. Por outro lado, os piores cenários globais aparecem em regiões como Austrália, Japão e China, que frequentemente ultrapassam 450 CO_2eq/kWh e, portanto, ampliam substancialmente o impacto climático da mesma carga de trabalho. No contexto nacional, os melhores cenários são encontrados no Sul e no Nordeste, com valores entre 67 e 86 CO_2eq/kWh , enquanto os piores se concentram no Norte, que apresenta intensidades entre 185 e 224 CO_2eq/kWh , ainda assim inferiores às de diversos países de alta intensidade de carbono, evidenciando que situar a execução em regiões brasileiras mais limpas pode reduzir de maneira significativa a pegada de carbono associada ao processamento.

5. Considerações Finais e Trabalhos Futuros

A partir da proposta de analisar o consumo energético de um modelo preditivo baseado em RNN LSTM executado em ambiente de VM, este estudo demonstrou que o ambiente de execução influencia diretamente o impacto ambiental da carga computacional. A execução na VM possui cerca de 10,37 W como consumo médio, cerca de 15% a mais do que o consumo registrado para a mesma carga de trabalho na máquina *host* sem virtualização, efeito decorrente do hipervisor e do maior tempo de processamento. Mesmo assim, o desempenho obtido, em termos de tempo de execução, foi ligeiramente melhor que o esperado para a configuração utilizada.

A análise das emissões revelou que a intensidade de carbono das matrizes elétricas é decisiva para o impacto final. Países com matrizes limpas, como a França, apresentam emissões muito baixas por execução, enquanto regiões fortemente dependentes de combustíveis fósseis, como Austrália, Japão e China, aumentam significativamente a pegada ambiental de uma mesma tarefa computacional. No Brasil, a variação regional mostrou que a escolha da localidade pode reduzir consideravelmente as emissões, com Sul e Nordeste oferecendo os cenários mais favoráveis.

Esses resultados reforçam que decisões relacionadas à localização da carga, ao momento de execução e ao ambiente computacional empregado são fundamentais para aproximar aplicações de IA dos princípios descritos pelo conceito de *zero-carbon cloud*. Mesmo modelos relativamente leves demonstram variações expressivas de impacto quando esses fatores são considerados, o que evidencia a importância de estratégias de alocação mais sensíveis ao perfil energético disponível.

Como trabalhos futuros, propõe-se ampliar a experimentação para múltiplas instâncias de VM, permitindo observar o comportamento energético em cenários de maior escala. Também se pretende investigar a execução em contêineres, a fim de comparar seu custo energético com o ambiente virtualizado adotado neste estudo e aprofundar a compreensão das diferentes formas de virtualização no contexto da *zero-carbon cloud*. Além disso, planeja-se avaliar outras aplicações de IA, tanto modelos mais simples quanto arquiteturas mais avançadas, com o objetivo de verificar se padrões semelhantes de consumo se mantêm em diferentes cargas de trabalho, aproveitando a metodologia já estruturada para permitir comparações diretas entre algoritmos.

Agradecimentos

Reconhece-se o apoio da CAPES - Código de Financiamento 001, como parte das ações integradas do Programa de Pós-Graduação em Computação Aplicada (PPGCAP) com Ensino, Pesquisa e Extensão de Engenharia de Computação na graduação, além do Programa Institucional de Bolsas de Iniciação Científica PRO-IC/UNIPAMPA, no contexto do Núcleo de Pesquisa em Pecuária de Precisão (NP3).

Referências

- Buyya, R., Ilager, S., and Arroba, P. (2023). Energy-efficiency and sustainability in new generation cloud computing: A vision and directions for integrated management of data centre resources and workloads.
- DeSantis, D., James, B. D., Houchins, C., Saur, G., and Lyubovsky, M. (2021). Cost of long-distance energy transmission by different carriers. *iScience*, 24(12):103495.
- Large-Scale Sustainable Systems Group (2025). Zero-carbon cloud (zccloud) and sustainable cloud computing. <https://people.cs.uchicago.edu/~aachien/lssg/research/zccloud/>.
- Lemos, D. L., Perez, N. B., and Pinho, L. (2025). Impacto do uso de virtualização na execução de modelos preditivos com ia para agricultura digital. *Anais do Salão Inovação, Ensino, Pesquisa e Extensão*, 2(17).
- Morabito, R. (2015). Power consumption of virtualization technologies: an empirical investigation. In *8th IEEE/ACM International Conference on Utility and Cloud Computing (UCC)*.
- Rich, E., Knight, K., and Nair, S. B. (2009). *Artificial Intelligence*. McGraw Hill Education.
- Schulte, L. G. (2019). Suporte à decisão em pastagens: Análise espaço-temporal e aprendizado de máquina para predição da disponibilidade de forragem no contexto de smart farming. Master's thesis, PPGCAP – UNIPAMPA.
- Schwartz, R., Dodge, J., Smith, N. A., and Etzioni, O. (2020). Green ai. *Communications of the ACM*, 63(12):54–63.
- Tomm, D. F., Lemos, D. L., Perez, N. B., and Pinho, L. (2025). Avaliação de método baseado em software para medição do consumo energético de redes neurais recorrentes. *Anais do Salão Inovação, Ensino, Pesquisa e Extensão*, 2(17).
- Verdecchia, R., Sallou, J., and Cruz, L. (2023). A systematic review of green ai. *WIREs Data Mining and Knowledge Discovery*, 13(4):e1507.