

O Paradoxo da IA para Sustentabilidade e a Sustentabilidade da IA

Gabriel B. Breder¹, Douglas F. Brum¹, Lucas Dirk¹, Mariza Ferro¹

¹Instituto de Computação – Universidade Federal Fluminense (UFF)
Av. Gal. Milton Tavares de Souza, S/Nº, São Domingos – Niterói – RJ – Brasil.

{gabrielbertobreder, douglasbrum, lucasdirk, mariza-ferro}@id.uff.br

Resumo. A popularização da inteligência artificial (IA) nos últimos anos tem gerado um impacto cada vez maior em diversos setores, fazendo com que seja necessária a análise das consequências de sua utilização frente a questões éticas e ambientais. Na área ambiental, pesquisas estão sendo realizadas no sentido de mensurar o impacto da utilização de algoritmos de IA em termos de consumo de energia e conseqüente emissão de dióxido de carbono equivalente (CO₂e). Neste artigo, será abordado sobre o paradoxo envolvendo IA e sustentabilidade, com ênfase na importância de relatar o consumo de energia nas pesquisas envolvendo aprendizado de máquina (AM) e a viabilidade do uso de ferramentas online para realizar a medição da quantidade de CO₂e emitida.

Abstract. In recent years, the popularization of Artificial Intelligence (AI) has generated an increasing impact on several sectors, making it necessary to analyze the consequences of its use in relation to ethical and environmental issues. In the environmental area, research is being carried out to measure the impact of AI algorithms in terms of energy consumption and equivalent Carbon Dioxide emissions (CO₂e). In this paper, the paradox involving AI and sustainability will be addressed, with an emphasis on the environmental issue and the importance of reporting energy consumption in research involving Machine Learning and the feasibility of using online tools to measure the amount of CO₂e.

1. Introdução

Em 2015, a Organização das Nações Unidas (ONU) organizou a Agenda 2030 para o desenvolvimento sustentável. Neste plano, foram estabelecidos 17 Objetivos de Desenvolvimento Sustentável (ODS) e as 169 metas que deverão estimular a ação até 2030 em áreas de grande importância para a humanidade e o planeta, envolvendo metas ambientais, sociais e econômicas. A Inteligência Artificial (IA) vem sendo considerada fundamental para fazer face a estes grandes desafios, com potencial de auxiliar positivamente na solução da maiorias deles. Porém, diante do impacto cada vez mais discutido da IA em diversos setores, alguns estudos têm sido feitos com o intuito de avaliar possíveis impactos negativos da IA sobre o desenvolvimento sustentável, especialmente sob a perspectiva dos ODS [Vinuesa et al. 2020b].

Tendo como base os ODS, [Vinuesa et al. 2020b] indica que no geral a IA pode atuar como facilitadora em 79% dos objetivos, no entanto, também pode ter um impacto negativo em 35% deles. Um exemplo dessa dualidade é o fato da IA poder apoiar a compreensão de mudanças climáticas e a modelagem de seus impactos tendo um resultado

muito positivo sobre as metas relacionados ao meio ambiente. Porém, ao mesmo tempo pode haver impacto sobre o meio ambiente em termos de consumo energético e, consequentemente, taxas de emissão de CO₂e [Vinueza et al. 2020b]. Há trabalhos que relatam que o desenvolvimento completo de uma solução com IA para grandes modelos de linguagem, como o GPT utilizado pelo ChatGPT, podem produzir tanto CO₂e quanto cinco carros durante toda a sua vida útil [Strubell et al. 2019]. Ainda do ponto de vista ambiental, além do consumo excessivo de energia, também há preocupações crescentes sobre o aumento do volume de resíduos eletrônicos e a pressão sobre o uso de elementos raros, cuja necessidade surge da indústria da computação [UNESCO 2019]. Recentemente, também o problema do consumo de água potável vem sendo apontado como indicador negativo desta relação [Li et al. 2023]. É estimado que para o treinamento do GPT-3 (nos EUA), o consumo total de água seja de 3.500.000 litros; na inferência, uma conversa de cerca de 50 perguntas e respostas usando o ChatGPT, precisaria de 500ml de água.

Os autores que definem o termo IA Verde (*Green Artificial Intelligence*) [Schwartz et al. 2020] vêm advogando pela necessidade de se reportar o consumo de energia relacionadas às publicações com grandes experimentos na área de IA como forma de mudar este atual paradigma de desenvolvimento, com impactos ambientais e econômicos. A OCDE também vêm preconizando que estes números deveriam ser transparentes ¹. O mesmo é apoiado em trabalhos experimentais [Ferro et al. 2023, Yokoyama et al. 2023] de coautores deste artigo, onde medir e reportar os números de CO₂e foi altamente complexo e desafiador. Em relação à isto, algumas ferramentas vêm sendo propostas justamente com o objetivo de tornar estes números mais acessíveis aos desenvolvedores de soluções com IA [Lannelongue et al. 2020, Lacoste et al. 2019].

O objetivo deste trabalho é contribuir para este debate, do impacto da IA na sociedade, trazendo elementos para a reflexão do que tem sido apontado como um paradoxo: uso da IA para a sustentabilidade em oposição à sustentabilidade da IA. Em especial, será dado enfoque ao aspecto ambiental da IA e à proposta dos autores da área de IA Verde que apontam o caminho da transparência do uso de recursos como forma de mudar este paradigma, o que é apoiado pelos autores deste artigo. Para isso propomos analisar duas questões (Q): Q1: O uso de soluções com IA para mitigar as consequências das mudanças climáticas é algo contraditório, devido aos seus impactos negativos ao meio ambiente, e por isso não deveria ser adotada? Q2: Reportar os custos ambientais do desenvolvimento e uso de soluções com IA pode ser um caminho para mitigar usos excessivos e conscientizar sobre seus impactos? Q2.1: Esta proposta é viável aos desenvolvedores de IA?

Ao explorar essas questões, dentro das limitações de espaço deste artigo, o nosso trabalho contribui ao apresentar os elementos técnicos computacionais que levam à este paradoxo e permitem explorar qual a origem dos custos negativos ambientais, jogando luz ao tema da sustentabilidade da IA na Seção 2. Além disso, apresenta uma reflexão sobre os impactos positivos na mitigação dos efeitos das mudanças climáticas ao predizer chuvas extremas (IA para sustentabilidade) na Seção 3. Ainda, avaliamos quão acessível a estimativa de consumo de energia e CO₂e pode ser para o desenvolvedor de soluções com IA na Seção 4 ao testar algumas ferramentas disponíveis. Finalmente, na Seção 5 são discutidas as questões Q1, Q2 e Q2.1 com base no conteúdo das Seções anteriores.

¹<https://oecd.ai/en/wonk/how-much-water-does-ai-consume> acesso em 26/02/2023.

2. A Sustentabilidade da IA

O trabalho [Schwartz et al. 2020] define o conceito de IA Verde como uma IA mais ecologicamente amigável e inclusiva; contrapondo isso, os autores também definem o termo IA Vermelha como uma IA que busca apenas melhorar sua precisão usando poder computacional massivo enquanto desconsidera o custo econômico e ambiental. Com base nestas definições, nesta seção será abordado o que leva a IA a impactar negativamente na sustentabilidade, com enfoque especial no aspecto ambiental.

Alguns aspectos podem levar a que um modelo de IA, durante o seu treinamento, emitam CO₂e associada². Alguns destes aspectos são relacionados ao software, ou seja, os modelos de IA em si em conjunto com as linguagens de programação utilizadas para implementá-los; e aspectos de hardware, relacionado à arquitetura computacional do computador onde os modelos de IA serão treinados. Além disso, há a diferença ao se utilizar diferentes fontes de energia onde estes computadores estão localizados.

2.1. Impacto Multifatorial do Consumo de Energia em IA

Alguns trabalhos demonstram que há um impacto na escolha da **arquitetura computacional** no consumo de energia. Segundo [Hennessy and Patterson 2011], entre 2003 e 2010 o crescimento no desempenho dos processadores foi de 22% ao ano e o aumento no desempenho dos processadores também acarreta diretamente no aumento do consumo de energia. [Hennessy and Patterson 2011] também apresentam a comparação na evolução das SDRAMs e como ao passar de DDR2 para DDR3 reduz-se significativamente o consumo de energia. Além do uso de CPUs e SDRAMs, a IA vem utilizando principalmente as GPUs, devido a sua alta capacidade de processamento e do paralelismo que torna os treinamentos muito mais rápidos. De acordo com [Mór et al. 2015], melhorias na computação paralela podem ser muito eficazes no contexto de aumentar a eficiência energética. Porém, se a capacidade de paralelismo das GPUs não for realmente bem explorada esta arquitetura pode não ser tão eficiente, como demonstramos em experimentos em [Yokoyama et al. 2023].

No **aspecto relacionado ao software**, as **linguagens de programação** escolhidas também podem impactar no consumo. Com base nos resultados de [Pereira et al. 2017] as linguagens que consomem menos energia são C, Rust e C++, enquanto Ruby, Python e Perl são as que consomem mais energia. Também, demonstramos em [Yokoyama et al. 2023] por meio experimental o quanto essas escolhas podem ter impactos significativos no consumo final para treinar um modelo. Ainda relacionado ao **software**, existem alguns modelos de AM que são computacionalmente caros por design, como é o caso das redes neurais, em especial de aprendizado profundo (AP) [Thompson et al. 2020]. Os modelos atuais, como o GPT-3, com 175 bilhões de parâmetros [Othman 2023] e o BERT-large, com 340 milhões de parâmetros, treinados em 4 dias em 64 TPUs [Devlin et al. 2019], são exemplos da IA Vermelha, dado seu alto foco em precisão sem transparência com questões de uso computacional e sustentabilidade. Tais modelos se baseiam na arquitetura Transformer [Vaswani et al. 2017], que tem contribuído significativamente para o aumento da pegada de carbono devido ao

²Computadores não emitem CO₂, mas como necessitam de uma fonte de energia elétrica para se manterem ligados e também os seus sistemas de refrigeração, diz-se que há um CO₂ equivalente, que está relacionado a fonte de energia na qual este computador está ligado.

seu intenso consumo de energia para treinamento e inferência. É importante notar que ser o estado da arte em Processamento de Linguagem Natural não implica em superioridade em outras áreas. Atualmente, existem adaptações da arquitetura Transformer para visão computacional [Liu et al. 2021] e previsão de séries temporais, por exemplo. No entanto, especialmente em séries temporais, percebemos que os modelos baseados em Transformer podem não ter o melhor desempenho [Zeng et al. 2022] além de exigirem mais parâmetros e recursos computacionais. Existem abordagens de software que procuram reduzir os custos dos modelos. Conforme proposto por [Mehlin et al. 2023], algumas técnicas e abordagens podem ser aplicadas nas fases do ciclo de vida do AP para reduzir o consumo de energia destes modelos. Isso inclui a implementação de práticas como treinamento de precisão mista, poda [Yang et al. 2017], destilação de conhecimento e otimização de arquiteturas de rede, que podem acelerar o tempo de treinamento e de inferência, além de reduzir o consumo de energia. Além disso, diminuir a complexidade da rede pode levar à redução pela metade do consumo energético durante o treinamento. Estratégias como a otimização Bayesiana também se mostraram superiores em eficiência energética, alcançando configurações ótimas com menos iterações quando comparadas às buscas aleatórias [Yarally et al. 2023]. Essas técnicas mostram que é possível um ganho em eficiência energética, mantendo ou diminuindo o consumo energético, promovendo uma IA mais sustentável.

Finalmente, a fonte de energia tem grande impacto sobre o cálculo da emissão de CO₂e e do consumo de água [Li et al. 2023]. O trabalho [Ritchie and Rosado 2020] demonstra que mais de um terço da energia elétrica mundial vem de fontes renováveis (hidroelétricas, eólicas) e nuclear, porém a maior parte de toda energia ainda é gerada a partir de fontes não renováveis (combustíveis fósseis, predominantemente carvão e gás). [Ritchie and Rosado 2020] também fala sobre a intensidade carbônica da eletricidade que é a quantidade de CO₂ produzido por unidade de energia em quilowatts hora (kWh), sendo que países que produzem mais energia de fontes renováveis e nuclear também terão uma menor quantidade de CO₂e emitida. Assim, o local onde o supercomputador está instalado e a fonte de energia deste local tem impacto significativo neste cálculo. Em trabalho anterior [Yokoyama et al. 2023] medimos e comparamos como um mesmo treinamento de IA realizado em um computador instalado no Brasil (fonte de energia majoritariamente renovável), pode ter números de CO₂e até três vezes menores do que se instalados nos Estados Unidos ou quatro vezes se na China.

3. IA para Sustentabilidade - Mitigação de Impactos Climáticos

Ao se pensar no paradoxo da IA para a sustentabilidade e sua relevância na agenda de desenvolvimento sustentável, especialmente nos objetivos 11 e 13, é evidente que a IA pode desempenhar um papel significativo para realização desses objetivos. No Brasil, os eventos climáticos extremos, como precipitação intensa, causam inúmeros problemas, principalmente nas comunidades mais vulneráveis, ocasionando mortes e perdas materiais. Com isso, a previsão precisa desses eventos é crucial para diminuição dos efeitos colaterais ocasionados por esses fenômenos. Entretanto, a assertividade das previsões nem sempre é alta, especialmente para eventos de precipitação em *nowcasting*, que consiste na previsão de eventos com algumas horas de antecedência. Assim, pesquisas recentes vêm explorando as oportunidades de aplicação de modelos de IA na previsão desses eventos climáticos extremos [Porto et al. 2022], não só podem melhorar a precisão das previsões,

mas também auxiliar na compreensão da sua causalidade.

Para compreendermos o impacto desses eventos, e a falta de predições precisas, pode-se olhar para um dos eventos ocorridos no Brasil. Em fevereiro de 2022, a cidade de Petrópolis, situada na região serrana do Estado do Rio de Janeiro, foi atingida por uma chuva extrema, com precipitação superior a 220 mm em um período de 4 horas [Assunção et al. 2023]. Como consequência, a morte de 235 pessoas [Machado et al. 2023] e um prejuízo econômico estimado em cerca de R\$ 665 milhões, o que equivalia a cerca de 2% do Produto Interno Bruto (PIB) da região [Souza 2022]. Apenas no mês de dezembro de 2022, no Brasil 386 pessoas morreram e cerca de 232.530 pessoas foram afetadas por enchentes e deslizamentos com as destruições causadas pela chuva³. Segundo o Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN), em 2023 o Brasil bateu recorde de ocorrências de desastres hidrológicos e geo-hidrológicos, com pelo menos 132 mortes, mais de 9 mil feridos, 74,7 mil desabrigados e 525 mil desalojados, afetando principalmente pessoas com menos recursos e em áreas de risco⁴. Segundo o órgão, desde sua criação os alertas de risco geo-hidrológicos para estados e municípios, conseguiu reduzir em 80% o número de mortes em desastres naturais no país, desde 2011, ano em que foi criado⁵. Entretanto, os alertas para chuvas extremas, especialmente em relação a precisão dos locais que serão afetados, ainda é um grande desafio para os métodos numéricos atuais, sendo a IA uma grande expectativa para esta melhoria.

Assim, observa-se que o uso da IA pode contribuir para o objetivo de tornar as cidades e os assentamentos humanos inclusivos, seguros, resilientes e sustentáveis, conforme estabelecido no objetivo 11. Já que o uso dessa técnica, não apenas prevê os fenômenos, mas também auxilia no entendimento da sua causalidade, possibilitando a tomada de decisões de políticas públicas mais precisas. Da mesma forma, o objetivo 13, que fala sobre a urgência de combater a mudança climática e seus impactos, pode ser apoiado pelo uso da IA. Um exemplo é o trabalho de [Kaikkonen et al. 2021] que faz uma revisão bibliográfica sobre o uso das Redes Bayesianas na avaliação de riscos ambientais por meio de estimativa de probabilidade e das consequências dos efeitos adversos das atividades humanas, e de outros fatores de estresse no meio ambiente, mostrando-se uma técnica poderosa para auxiliar na tomada de decisões de medidas para o combate das mudanças climáticas.

Portanto, embora a IA possa ter um impacto na emissão de CO₂, ela surge como uma ferramenta que pode ajudar na tomada de decisões contra as mudanças climáticas e promover a segurança da população nas cidades. Isso evidencia o paradoxo da IA e sustentabilidade, visto que ela pode contribuir positivamente, apesar de gerar degradações devido às emissões de CO₂e. Porém, neste caso, parece que o resultado é positivo à favor da IA se estimarmos que para o desenvolvimento de uma aplicação de *nowcasting* fosse emitida a mesma quantidade de CO₂ que para o desenvolvimento do GPT3 [Strubell et al. 2019], por exemplo, mas que poderia salvar tantas vidas.

³<https://noticias.r7.com/cidades/prejuizo-do-brasil-com-chuvas-em-um-mes-e-suficiente-para-construir-17-piscinoes-aponta-estudo-09012023>

⁴<https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/noticias/2024/01/em-2023-cemaden-registrou-maior-numero-de-ocorrencias-de-desastres-no-brasil>

⁵<http://portal.sbpcnet.org.br/noticias/trabalho-do-cemaden-reduziu-em-80-numero-de-mortes-em-desastres-naturais-no-pais/>

Não é fácil definir quantos impactos positivos e negativos a IA pode trazer para as pessoas e para o planeta. Diante deste desafio outros trabalhos [Vinueza et al. 2020a, UNESCO 2021, Sætra 2021, Cowls et al. 2021, Mazzi and Floridi 2023, Floridi 2023] também dedicam-se a analisar e avaliar esses efeitos com base nos benefícios e malefícios que a IA produz para os 17 ODS.

4. Estimando o Impacto da IA com Ferramentas Acessíveis

Alguns trabalhos [Schwartz et al. 2020, Bender et al. 2021, Luccioni et al. 2022, Luccioni and Hernandez-Garcia 2023] têm enfatizado que é fundamental considerar o consumo de energia como uma métrica de igual importância à precisão e reduzir tarefas ou usos de energia irrelevantes. Em trabalho experimental de coautores deste trabalho [Yokoyama et al. 2023] foram medidos consumo de energia e estimadas quantidade de CO₂e para diversos algoritmos de AM, em diferentes arquiteturas computacionais e para diferentes fontes energéticas. A tarefa foi extremamente custosa e difícil de ser realizada, mesmo com o apoio de especialistas em HPC, o que inviabilizava tornar esta abordagem mais popular, pelo menos para a maioria dos desenvolvedores de IA. Porém, mais recentemente diversas ferramentas foram propostas para tornar essas estimativas mais acessíveis. No trabalho de [Bouza et al. 2023] são analisadas sete ferramentas online para o cálculo estimado da quantidade de CO₂e emitida por treinamentos realizados com IA. O foco do trabalho de [Bouza et al. 2023] foi analisar a precisão destas ferramentas online em relação ao uso de medidores externos ou abordagens de medição interna por meio de contadores de hardware. Apesar das estimativas não serem tão precisas quando a medição direta, os resultados foram próximos. Estas mesmas ferramentas são analisadas nesta seção buscando responder a Q2.1, apresentando os resultados dos testes e quão acessíveis são para o usuário não especializado em HPC as seguintes ferramentas: Green-Algorithms [Lanelongue et al. 2020], MLCO₂ [Lacoste et al. 2019], CodeCarbon [Lottick et al. 2019], Eco2AI [Budenny et al. 2022], CarbonTracker [Anthony et al. 2020], Experiment-Impact-Tracker (EIT) [Henderson et al. 2020] e Cumulator [Tristan Trebaol and Ghadikolaei 2020].

A ferramenta **Green-Algorithms**⁶ foi desenvolvida com o objetivo de ser uma plataforma online simples e intuitiva para que os usuários em poucos minutos consigam estimar a quantidade de CO₂e que foi emitida por seu algoritmo e sejam capazes de reportar os resultados em suas publicações. Para utilizar a calculadora, o usuário deve inserir informações sobre o tipo de hardware utilizado e a região onde o algoritmo foi treinado. Com isso é realizado o cálculo da pegada de carbono de forma instantânea, retornando um relatório e gerando automaticamente uma mensagem de reporte para publicações científicas com o resultado obtido e a devida referência, tornando a ferramenta extremamente fácil e prática de se utilizar.

A ferramenta **MLCO₂**⁷ também é uma plataforma online, porém um pouco mais simplificada, apresentando apenas possibilidade de cálculo para algoritmos processados em GPU e menos entradas para dados. A plataforma é mais fácil de se utilizar em caso de algoritmos que foram processados em nuvem, contendo três provedores a mais que a ferramenta Green-Algorithms. Porém para software processados em infraestrutura privada foi constatado que é mais simples utilizar as ferramentas que serão citadas a seguir.

⁶Green-Algorithms - <https://www.green-algorithms.org/>

⁷MLCO₂ - <https://mlco2.github.io/impact/>

A **CodeCarbon**⁸ é um pacote Python que pode ser integrada diretamente no *script* da IA. Possui uma documentação bem completa, fácil de instalar e utilizar. Após a instalação do pacote e adição de apenas 5 linhas no código do algoritmo da IA o programador é capaz de saber a quantidade de energia utilizada no treino, sendo a energia total e a energia separada por componentes do sistema. Além disso, com a execução de um arquivo gerado pela ferramenta em sua instalação, o usuário recebe uma estimativa em tempo real da quantidade de energia que toda sua máquina está consumindo.

A ferramenta **Eco2AI**⁹ também é um pacote Python que pode ser instalado e integrado no *script* de treinamento da IA. Sua instalação é um pouco mais lenta em comparação com a CodeCarbon, porém, o código é tão simples de ser integrado quanto. Após o treinamento a ferramenta retorna uma tabela com a energia consumida e a quantidade de CO₂e.

A última atualização das ferramentas **EIT** e **Cumulator** ocorreu há mais de dois anos e não são tão intuitivas de serem utilizadas quanto a CodeCarbon e a Eco2AI. Já a **CarbonTracker** possuía suporte até o dia da publicação desse artigo, porém, só pode ser utilizada em GPUs NVIDIA ou CPUs Intel com acesso à superusuário.

Portanto, respondendo à Q2.1, é simples para um desenvolvedor de soluções com IA realizar um reporte da quantidade de CO₂e emitido utilizando a maioria das ferramentas analisadas. Ao utilizar a ferramenta Green-Algorithms ou MLCO₂ o usuário consegue de forma eficiente em uma aplicação web inserir as características do hardware do sistema e a quantidade de tempo utilizada para o teste de algoritmo, resultando em um texto breve para ser inserido ao final de seu relatório de pesquisa. Além disso, existe a opção de instrumentar o código da IA com as ferramentas CodeCarbon ou Eco2AI, por meio de uma simples instalação e poucas linhas adicionadas.

5. Considerações Finais

Ao longo deste trabalho foram apresentados elementos técnicos que contribuem para o debate sobre os impactos da IA na sociedade e para a reflexão sobre o que tem sido apontado como um paradoxo: uso da IA para a sustentabilidade em oposição à sustentabilidade da IA, em especial, no aspecto ambiental.

Ao buscar respostas para a Q1: *O uso de soluções com IA para mitigar as consequências das mudanças climáticas é algo contraditório, devido aos seus impactos negativos ao meio ambiente, e por isso não deveria ser adotada?* foram apresentados os elementos técnicos computacionais que permitem explorar qual a origem dos custos negativos ambientais da IA. É possível observar que diversos são os fatores que podem elevar ou reduzir estes números, tais como o hardware utilizado, o modelo de IA escolhido para a tarefa e a fonte energética do local. Números alarmantes em emissão de CO₂e de água foram apresentados. Porém, um dos aspectos que merece destaque nesta discussão é o aumento do uso de poder computacional, conforme destacado por [Schwartz et al. 2020, Yusuf et al. 2022], num paradigma de desenvolvimento de quanto mais melhor (mais parâmetros, mais dados de treinamento, mais recursos computacionais), mesmo que para alcançar alguns décimos de precisão, intensificando os problemas ambientais. À medida que esses modelos de IA tornam-se

⁸CodeCarbon - <http://codecarbon.io/>

⁹Eco2AI - <http://codecarbon.io/>

maiores e mais complexos, eles exigem mais energia, aumentando assim as emissões de CO₂ [Strubell et al. 2019, Bender et al. 2021, Yusuf et al. 2022, Luccioni et al. 2022, Luccioni and Hernandez-Garcia 2023]. Paralelamente, a necessidade de recursos computacionais avançados para desenvolver esses modelos acarreta desigualdades no campo da IA, limitando a liderança da inovação a organizações com acesso significativo a recursos computacionais, econômicos e dados de treinamento. Por exemplo, o modelo GPT-3 custou milhões de dólares para ser treinado [Brown et al. 2020]. Porém, ao analisarmos uma proposta da aplicação da IA, também para a área ambiental, ao procurar desenvolver previsões precisas para o alerta de eventos de chuva extrema e imaginar que mais de 200 vidas poderiam ter sido salvas em um único dia, além de centenas de edificações e custos da ordem de milhões, parece que o impacto negativo da IA é inferior aos positivos, olhando para este exemplo específico.

Nas Q2 e Q2.1: *Reportar os custos ambientais do desenvolvimento e uso de soluções com IA pode ser um caminho para mitigar usos excessivos e conscientizar sobre seus impactos? e se Esta proposta é viável aos desenvolvedores de IA?*

A proposta dos autores da área de IA Verde apontam que o caminho da transparência do uso de recursos computacionais e econômicos deveria ser um compromisso dos desenvolvedores de IA, como forma de mudar o atual paradigma de “quanto mais melhor”, o que é apoiado pelos autores deste artigo. É possível que ao assumir este compromisso, reforçando o caminho da ciência aberta e da reprodutibilidade dos resultados, os desenvolvedores passariam a ter mais consciência dos custos atrelados às suas escolhas. Não é a questão de deixar de desenvolver IA, mas de fazer escolhas melhores. Mas este caminho só é possível por meio do conhecimento de onde os custos vêm e quais são eles, o que as atuais propostas de ferramentas online têm tornado mais acessível, como visto na análise das ferramentas. Além disso, este caminho também exigiria mais transparência das *big techs* sobre os seus impactos ambientais e sociais e o direcionamento de regulações e políticas públicas que exijam a mitigação destes impactos.

Enquanto nas abordagens acadêmicas, os riscos seguem em destaque e a preocupação ética assume um sentido eminentemente negativo e os possíveis benefícios das IA, muito mais realistas, são subfocalizados [Vilaça et al. 2024], este trabalho, ao explorar essas questões, contribuiu para a reflexão do tema do impacto da IA na sociedade com uma abordagem realista.

Em trabalhos futuros será analisado os impactos positivos e negativos para o desenvolvimento de outras aplicações, com enfoque em outros ODS, procurando trazer novos elementos à esta análise de quantos impactos positivos e negativos a IA pode trazer para as pessoas e para o planeta mantendo esta abordagem ética realista. Além disso, será realizada uma revisão sistemática da literatura sobre este tema.

Agradecimentos

Este trabalho recebeu apoio do Instituto Serrapilheira (N. do processo Serra – 2211-41897), SERRAPILHEIRA/FAPERJ - 2023 (Proc. E-26/210.242/2024), FAPERJ - Auxílio Básico à Pesquisa - APQ1 E-13/2023 (Proc.N:210.723/20240) e do Programa Institucional de Bolsas de Iniciação Científica da UFF (PIBIC-CNPQ).

Referências

- Anthony, L. F. W., Kanding, B., and Selvan, R. (2020). Carbontracker: Tracking and predicting the carbon footprint of training deep learning models. ICML Workshop on Challenges in Deploying and monitoring Machine Learning Systems. arXiv:2007.03051.
- Assunção, V. D., Haniya, M. V., de Oliveira Fonseca, A. C., Jacob, A. C. P., Junior, J. T. A., de Magalhães, P. C., de Oliveira, A. K. B., and de Sousa, M. M. (2023). Análise dos desastres naturais em petrópolis ocorridos em fevereiro de 2022. *ENCONTRO NACIONAL DE DESASTRES*, 3.
- Bender, E. M., Gebru, T., McMillan-Major, A., and Shmitchell, S. (2021). On the dangers of stochastic parrots: Can language models be too big? In *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency*, FAccT '21, page 610–623, New York, NY, USA. Association for Computing Machinery.
- Bouza, L., Bugeau, A., and Lannelongue, L. (2023). How to estimate carbon footprint when training deep learning models? a guide and review. *Environmental Research Communications*, 5.
- Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., et al. (2020). Language models are few-shot learners. *arXiv preprint arXiv:2005.14165*.
- Budenny, S. A., Lazarev, V. D., Zakharenko, N. N., Korovin, A. N., Plosskaya, O. A., Dimitrov, D. V., Akhrikin, V. S., Pavlov, I. V., Oseledets, I. V., Barsola, I. S., Egorov, I. V., Kosterina, A. A., and Zhukov, L. E. (2022). eco2ai: Carbon emissions tracking of machine learning models as the first step towards sustainable ai. *Doklady Mathematics*, 106(1):S118–S128.
- Cowls, J., Tsamados, A., Taddeo, M., and Floridi, L. (2021). The ai gambit: leveraging artificial intelligence to combat climate change—opportunities, challenges, and recommendations. *Ai & Society*, pages 1 – 25.
- Devlin, J., Chang, M.-W., Lee, K., and Toutanova, K. (2019). Bert: Pre-training of deep bidirectional transformers for language understanding. In *Proceedings of the North American Chapter of the Association for Computational Linguistics (NAACL)*.
- Ferro, M., Silva, G. D., de Paula, F. B., Vieira, V., and Schulze, B. (2023). Towards a sustainable artificial intelligence: A case study of energy efficiency in decision tree algorithms. *Concurrency and Computation: Practice and Experience*, 35(17):e6815.
- Floridi, L. (2023). 209References. In *The Ethics of Artificial Intelligence: Principles, Challenges, and Opportunities*. Oxford University Press.
- Henderson, P., Hu, J., Romoff, J., Brunskill, E., Jurafsky, D., and Pineau, J. (2020). Towards the systematic reporting of the energy and carbon footprints of machine learning.
- Hennessy, J. L. and Patterson, D. A. (2011). *Computer Architecture, Fifth Edition: A Quantitative Approach*. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, 5th edition.

- Kaikkonen, L., Parviainen, T., Rahikainen, M., Uusitalo, L., and Lehtikainen, A. (2021). Bayesian networks in environmental risk assessment: A review. *Integrated environmental assessment and management*, 17(1):62–78.
- Lacoste, A., Luccioni, A., Schmidt, V., and Dandres, T. (2019). Quantifying the carbon emissions of machine learning. *arXiv preprint arXiv:1910.09700*.
- Lannelongue, L., Grealey, J., and Inouye, M. (2020). Green algorithms: Quantifying the carbon footprint of computation.
- Li, P., Yang, J., Islam, M. A., and Ren, S. (2023). Making ai less "thirsty": Uncovering and addressing the secret water footprint of ai models.
- Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Lin, S., and Baining, G. (2021). Swin transformer: Hierarchical vision transformer using shifted windows. *arXiv preprint arXiv:2103.14030*.
- Lottick, K., Susai, S., Friedler, S. A., and Wilson, J. P. (2019). Energy usage reports: Environmental awareness as part of algorithmic accountability.
- Luccioni, A. S. and Hernandez-Garcia, A. (2023). Counting carbon: A survey of factors influencing the emissions of machine learning.
- Luccioni, A. S., Viguier, S., and Ligozat, A.-L. (2022). Estimating the carbon footprint of bloom, a 176b parameter language model.
- Machado, L., Gomes, M., Alves, J., and Freitas, F. (2023). Em 2022, mesmo depois da maior tragédia climática da história, petrópolis gastou apenas 15% do valor autorizado em habitação.
- Mazzi, F. and Floridi, L., editors (2023). *The Ethics of Artificial Intelligence for the Sustainable Development Goals*. Springer Verlag.
- Mehlin, V., Schacht, S., and Lanquillon, C. (2023). Towards energy-efficient deep learning: An overview of energy-efficient approaches along the deep learning lifecycle.
- Mór, S., Alves, M., Lima, J., Maillard, N., and Navaux, P. (2015). Eficiência energética em computação de alto desempenho: Uma abordagem em arquitetura e programação para green computing.
- Othman, A. (2023). Demystifying gpt and gpt-3: How they can support innovators to develop new digital accessibility solutions and assistive technologies? *Nafath*.
- Pereira, R., Couto, M., Ribeiro, F., Rua, R., Cunha, J., Fernandes, J., and Saraiva, J. (2017). Energy efficiency across programming languages: how do energy, time, and memory relate? pages 256–267.
- Porto, F., Ferro, M., Ogasawara, E., Moeda, T., Tenorio de Barros, C. D., Chaves Silva, A., Zorrilla, R., Silva Pereira, R., Nascimento Castro, R., Silva, J. V., Salles, R., Fonseca, A. J., Hermsdorff, J., Magalhães, M., Sá, V., Simões, A. A., Cardoso, C., and Bezerra, E. (2022). Machine learning approaches to extreme weather events forecast in urban areas: Challenges and initial results. *Supercomputing Frontiers and Innovations*, 9(1):49–73.
- Ritchie, H. and Rosado, P. (2020). Electricity mix. *Our World in Data*. <https://ourworldindata.org/electricity-mix>.

- Schwartz, R., Dodge, J., Smith, N. A., and Etzioni, O. (2020). Green ai. *Communications of the ACM*, 63(12):54–63.
- Souza, B. (2022). Petrópolis tem prejuízo de r\$ 665 milhões e perde cerca de 2% do pib por consequência das chuvas.
- Strubell, E., Ganesh, A., and McCallum, A. (2019). Energy and policy considerations for deep learning in nlp. In *Proceedings of the Conference on Empirical Methods in Natural Language Processing (EMNLP)*.
- Sætra, H. S. (2021). Ai in context and the sustainable development goals: Factoring in the unsustainability of the sociotechnical system. *Sustainability*, 13(4).
- Thompson, N. C., Greenewald, K., Lee, K., and Manso, G. F. (2020). The computational limits of deep learning.
- Tristan Trebaol, Mary-Anne Hartley, M. J. and Ghadikolaei, H. S. (2020). A tool to quantify and report the carbon footprint of machine learning computations and communication in academia and healthcare. *Infoscience EPFL: record 278189*.
- UNESCO (2019). Preliminary study on the ethics of artificial intelligence.
- UNESCO, D.-G. (2021). Preliminary report on the first draft of the recommendation on the ethics of artificial intelligence.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., and Polosukhin, I. (2017). Attention is all you need. In *Advances in Neural Information Processing Systems*. NIPS.
- Vilaça, M. M., Pederneira, I. L., and Ferro, M. (2024). AI beyond a new academic hype: an interdisciplinary theoretical analytical experiment (computational, linguistic and ethical) of an AI tool. *Unisinos Journal of Philosophy*, 25:e25112.
- Vinuesa, R., Azizpour, H., Leite, I., Balaam, M., Dignum, V., Domisch, S., Felländer, A., Langhans, S., Tegmark, M., and Nerini, F. F. (2020a). The role of AI in achieving the Sustainable Development Goals. *Nature Communications*, 11(233).
- Vinuesa, R., Azizpour, H., Leite, I., Balaam, M., Dignum, V., Domisch, S., Felländer, A., Langhans, S. D., Tegmark, M., and Fuso Nerini, F. (2020b). The role of artificial intelligence in achieving the sustainable development goals. *Nature Communications*, 11(1):233.
- Yang, T.-J., Chen, Y.-H., and Sze, V. (2017). Designing energy-efficient convolutional neural networks using energy-aware pruning. In *arXiv preprint arXiv:1704.05155*. Massachusetts Institute of Technology.
- Yarally, T., Cruz, L., Feitosa, D., Sallou, J., and Van Deursen, A. (2023). Uncovering energy-efficient practices in deep learning training. In *2023 IEEE/ACM 2nd International Conference on AI Engineering – Software Engineering for AI (CAIN)*, pages 25–36. IEEE.
- Yokoyama, A., Ferro, M., Paula, F., Vieira, V., and Schulze, B. (2023). Investigating hardware and software aspects in the energy consumption of machine learning: A green ai-centric analysis. *Concurrency and Computation: Practice and Experience*, 35.

Yusuf, M., Surana, P., Gupta, G., and Ramesh, K. (2022). Curb your carbon emissions: Benchmarking carbon emissions in machine translation. *Preprint*.

Zeng, A., Chen, M., Zhang, L., and Xu, Q. (2022). Are transformers effective for time series forecasting? In *The Thirty-Seventh AAAI Conference on Artificial Intelligence (AAAI-23)*. AAAI Press.