IA para políticas públicas

Escola de verão Climate Change AI 2026

Carlos Rodriguez-Pardo, PhD

Politecnico di Milano / EIEE / CMCC

Pergunta de aquecimento:

Na sua opinião, qual é a aplicação mais promissora da IA na política climática?

https://partici.fi/32182658

Escola de verão Climate Change AI 2026

Carlos Rodriguez-Pardo, PhD

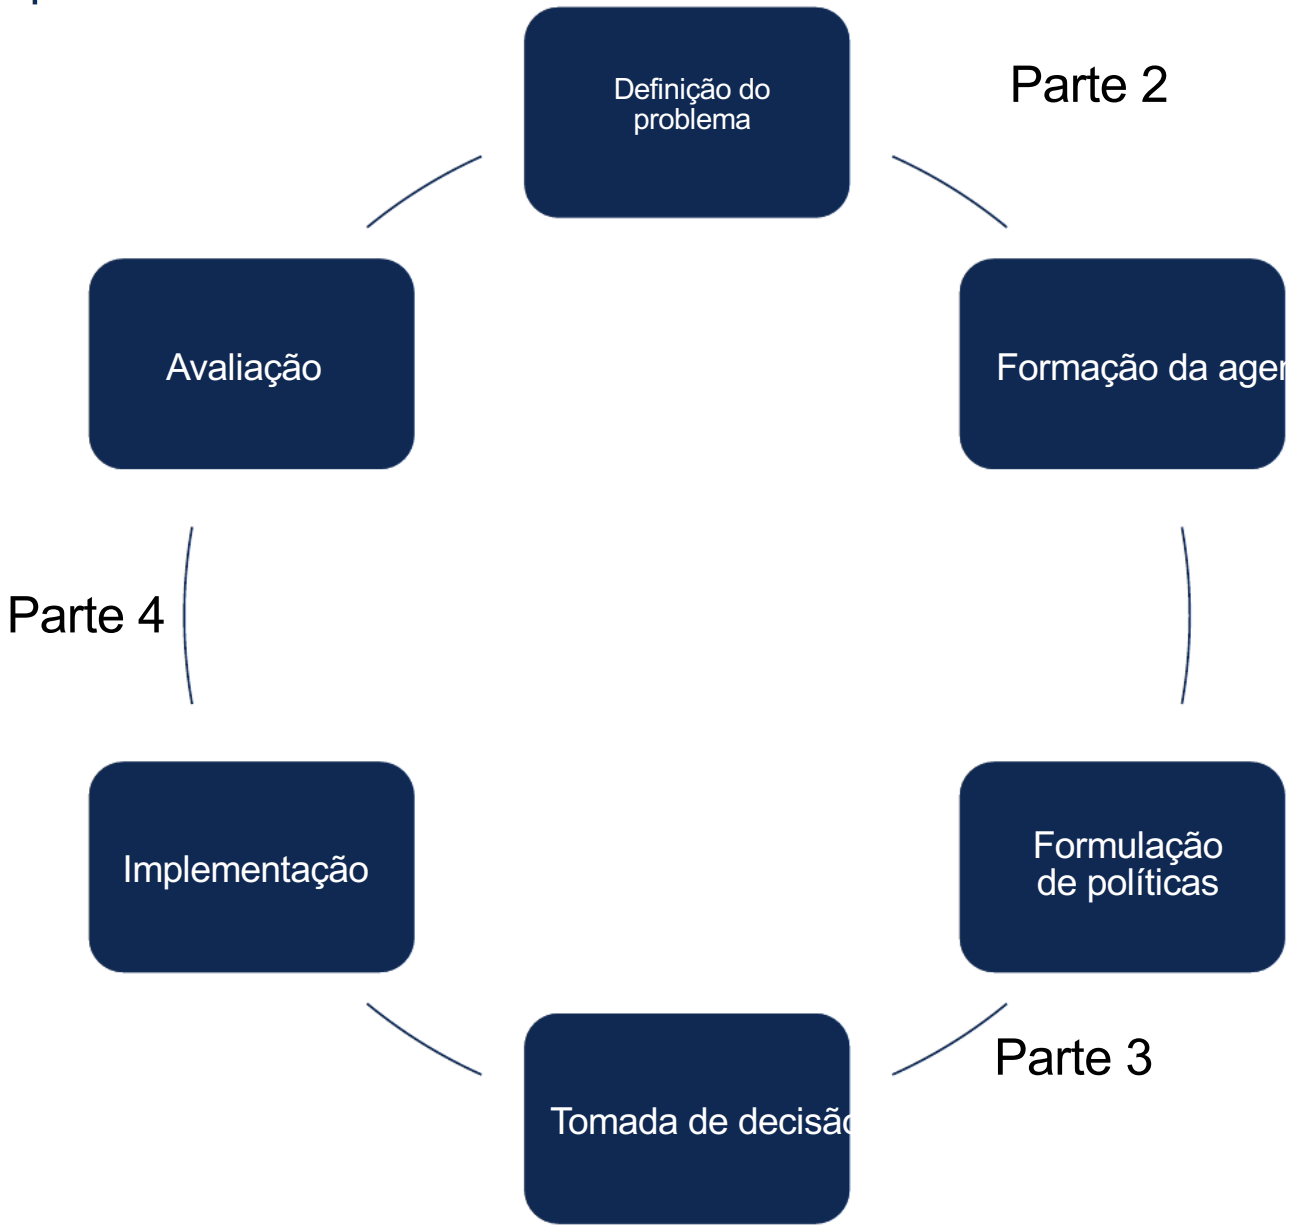
Politecnico di Milano / EIEE / CMCC

Agenda de hoje

	A pergunta	O papel da IA
Parte 1: fundamentos	Quais são os objetivos da análise de políticas climáticas?	Nenhum ainda, só uma introdução
Parte 2: medir	O que está acontecendo, o que já foi tentado, quem está exposto?	PLN em corpora de políticas · visão computacional e sensoriamento remoto · modelos de base geoespaciais / do sistema Terra
Parte 3: modelar futuros	O que pode acontecer com diferentes políticas e atores?	Emuladores de IAM · solvers neurais de EDP · AR e AR multiagente
Parte 4: avaliação e implantação	Uma política funcionou? Será aceita? É confiável?	AM causal · LLMs · modelos baseados em agentes

O ciclo das políticas públicas

Onde a IA pode ajudar a política climática?



Quais instituições participam da tomada de decisão?

Internacionais: UNFCCC, IPCC, UE

Governos nacionais e regionais

Governos locais

Atores setoriais: distribuidoras de energia, agências de transporte

Atores privados: seguradoras, empresas, bancos, certificadoras etc.

- Atores diferentes, com problemas e prioridades diferentes
- Escalas de tempo diferentes (políticas de décadas vs. resultados trimestrais)
- Alavancas diferentes: impostos sobre carbono, participação de renováveis, % de veículos elétricos no transporte público
- Resoluções espaciais diferentes (políticas continentais, planejamento urbano, reformas de edifícios…)

A IA pode ajudar a formulação de políticas em todas essas es



O que a análise de políticas climáticas busca alcançar?

Estimar danos e riscos

Qual a gravidade, onde, para quem e quando?

Comparar opções, avaliar trade-offs

Mitigação, adaptação ou aceitação de perdas.

Desenhar instrumentos

Impostos, normas, subsídios, planos, mercados.

Avaliar o que funcionou

Nossas políticas mudaram algo, e em que condições?

Decidir sob incerteza

Escolhas robustas apesar de grandes incógnitas.

Respostas políticas à mudança climática



Mitigação

Objetivo: evitar ou reduzir a concentração de GEE na atmosfera

Exemplos:

- Normas para renováveis
- Mandatos de veículos elétricos
- Captura e armazenamento de carbono
- Impostos sobre carbono
- Eletrificação



Adaptação

Objetivo: reduzir os danos inevitáveis do aquecimento

Exemplos:

- Defesas contra enchentes
- Isolamento de edifícios
- Sistemas de alerta precoce
- Infraestrutura



Perdas e danos

Objetivo: compensar o que não pode ser evitado nem adaptado

Exemplos:

- Financiamento climático
- Atribuição

A análise de políticas precisa comparar as três e entender seu custo, seus trade-offs e sua viabilidade. Para isso, precisamos de instrumentos como o custo social do carbono e estimativas de danos.

A caixa de ferramentas dos instrumentos de política

Precificação de carbono

Impostos e comércio de emissões

Regulação e normas

Proibições, códigos, regras de eficiência

Subsídios e investimentos

P&D público, renováveis, reformas

Política industrial

Estratégia industrial verde

Planejamento da adaptação

Redução de riscos e resiliência

Financiamento climático

Quem paga, quem é compensado

Mercados de carbono e compensações

Créditos, MRV, integridade

Essas políticas podem competir pelos mesmos orçamentos

O custo social do carbono

O custo social do carbono é o dano econômico causado por uma tonelada adicional de CO2 emitida, expresso em dinheiro de hoje.

+1 tonelada de CO2 emitida hoje

↓

Causa aquecimento global adicional por séculos

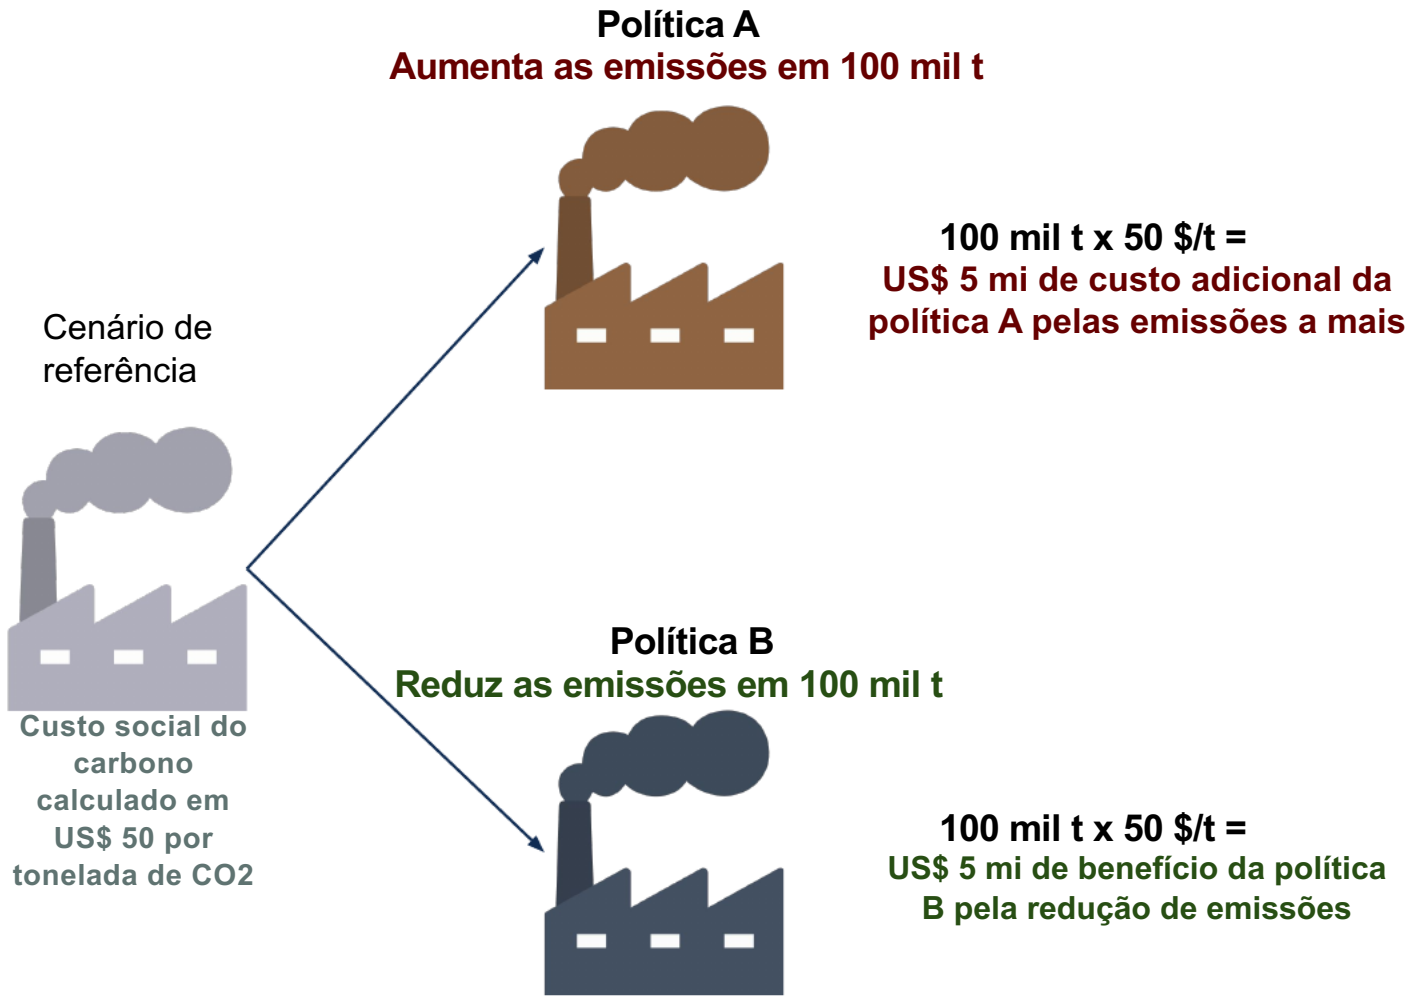
↓

Que causa danos futuros: saúde, lavouras, capital…

↓

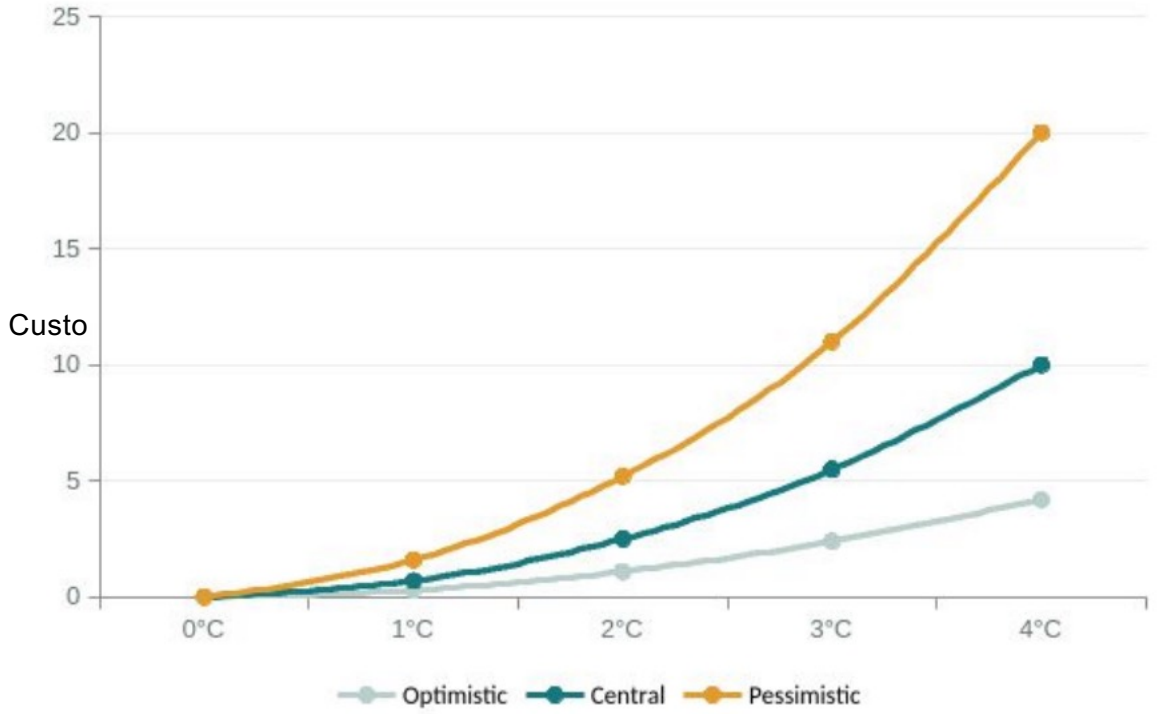
Descontar esses danos a valor presente: $ / CO2

Todas essas setas escondem modelos, premissas e incertezas



Funções de dano

- Convertem o aquecimento global em perdas econômicas
- Estimadas com dados históricos e extrapoladas muito além deles
- Essas funções são muito usadas em modelos de avaliação integrada e outros instrumentos de análise de políticas
- Forma funcional, pontos de inflexão e premissas de adaptação são todos contestados
- Sua incerteza também tem implicações para as políticas



Onde a IA entra em tudo isso?

Dados

Processar fontes de dados complexas e extrair conhecimento: imagens de satélite, documentos de políticas, redes, sensores, dados econômicos…

PARTE 2: MEDIR

Modelos

Ajudar a modelar sistemas socioeconômicos e climáticos complexos:

- Modelos de base
- Modelos de avaliação integrada
- Aprendizado por reforço

PARTE 3: MODELAR FUTUROS

Decisões

- Estimar a possível eficácia de diferentes políticas
- Entender se políticas passadas foram eficazes e em que condições
- Otimizar a alocação de recursos

PARTE 4: AVALIAR E IMPLANTAR

Referências úteis:

- Rolnick et al., Tackling Climate Change with Machine Learning
- Kaack et al. 2022, Aligning AI with climate change mitigation ·
- Ou et al. 2026, AI to support cross-disciplinary climate change research (Nature Climate Change)

https://partici.fi/32182658

Quiz nº 1:

De que informações você precisa para estimar o custo social do carbono?

Trajetórias de emissões

Para onde o mundo vai? Cenários, incertezas

Resposta climática (TCRE)

Quanto aquecimento por tonelada adicional de CO2?

Função de dano

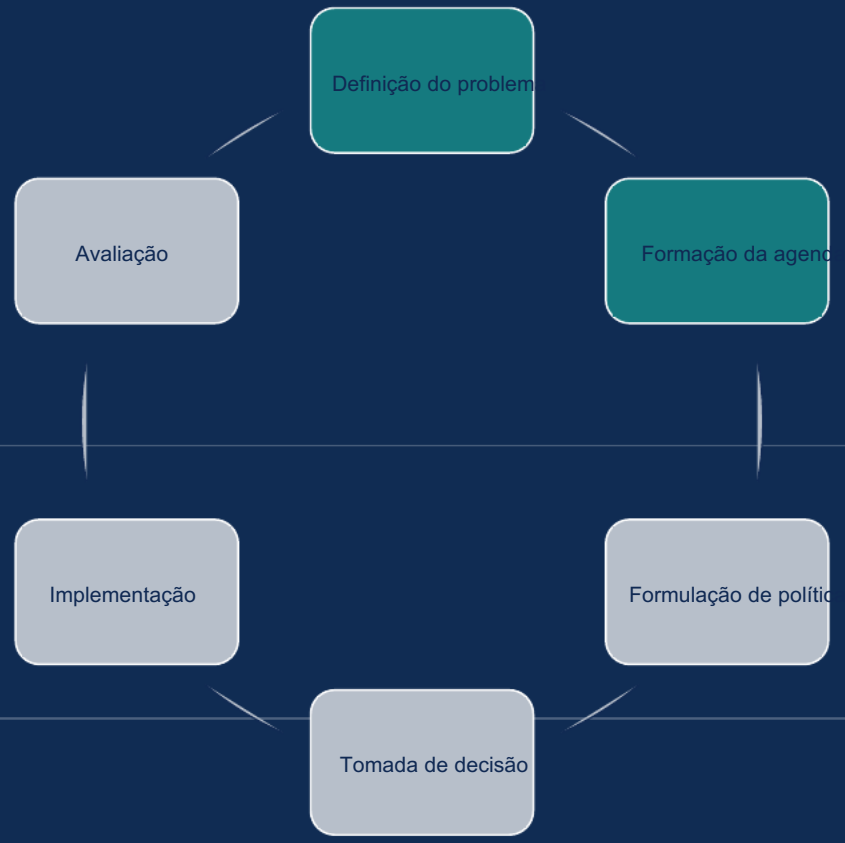
Qual é o custo de cada unidade adicional de aquecimento?

Desconto

Quanto nos importa o futuro em comparação com o presente?

Parte 2: medindo o mundo das políticas e os impactos climáticos

- Que políticas existem?
- O que está acontecendo no mundo?
- Quem está exposto?



O que precisamos saber para desenhar políticas eficazes?

Que políticas existem hoje?

- Bases de políticas
- Monitores de políticas

Onde as emissões acontecem?

- Inventários
- Estimativas

Quem está exposto? Quem são os atores-chave?

Mapeamento de vulnerabilidade

O que diz a literatura?

Mapas de evidências, revisões,

Onde estão as lacunas de evidência?

Onde estão as incertezas? Que evidências faltam?

Como saber o que já foi tentado e estudado?

Harmonização de bases de dados de políticas

Entrada:

- Documentos nacionais fragmentados
- Bases globais, regionais e setoriais

Métodos

- Processamento de linguagem natural,
- conhecimento especializado, aprendizado por regras
- Aprendizado semissupervisionado

Resultado:

- Painéis de políticas comparáveis entre países
- Quem adotou qual política e quando
- Formato comum, alinhado ao IPCC

Wu et al. 2024
https://www.nature.com/articles/s41597-024-03411-z

Mapeamento da literatura científica

Entrada:

- Centenas de milhares de artigos sobre política climática
  - Impossível de ler e analisar por uma pessoa ou grupo de pesquisa

Métodos

- Processamento de linguagem natural
- Classificação de textos
- Mapeamento de temas

Resultado:

- Mapas de evidências
- Lacunas na literatura, evidência escassa

Callagan et al. 2025
https://www.nature.com/articles/s44168-024-00196-0

Medindo o que acontece, em resolução útil para as políticas

Medição em alta resolução e qualidade do ar

- Estimativas por AM de emissões urbanas de GEE subnacionais
  - Yu et al. https://www.nature.com/articles/s41597-026-06691-9
- Classificação por AM de estações de qualidade do ar
  - Renna et al (https://www.nature.com/articles/s41597-026-06797-0.pdf)

Ler e entender documentos de políticas

- PLN para classificar programas partidários (Sanford et al. doi:10.1017/S0007123425100719)

O desafio da integração

- Como ligar políticas, setores, emissões, territórios, populações e resultados? Como
- transformar dados e modalidades dispersos em evidências úteis para as políticas?

Referências:

- Reichstein et al. https://www.nature.com/articles/s41467-025-57640-w
- Rodriguez-Pardo et al.: https://eartharxiv.org/repository/view/13019/

A cadeia de modelagem de impactos



A IA já acelera esses elos

Pouco ou nenhum impacto da IA

Dados fracos, maior lacuna científica

As aulas de IA para o tempo e IA para as ciências do clima da escola CCAI26 abordarão esses temas a fundo. Aqui focamos nos impactos climáticos e em como eles entram nas decisões políticas

Por que a resolução importa

Célula global

~100-1000km

- Um país está no caminho certo?
- Quais são os padrões climáticos desta região?

Regiões

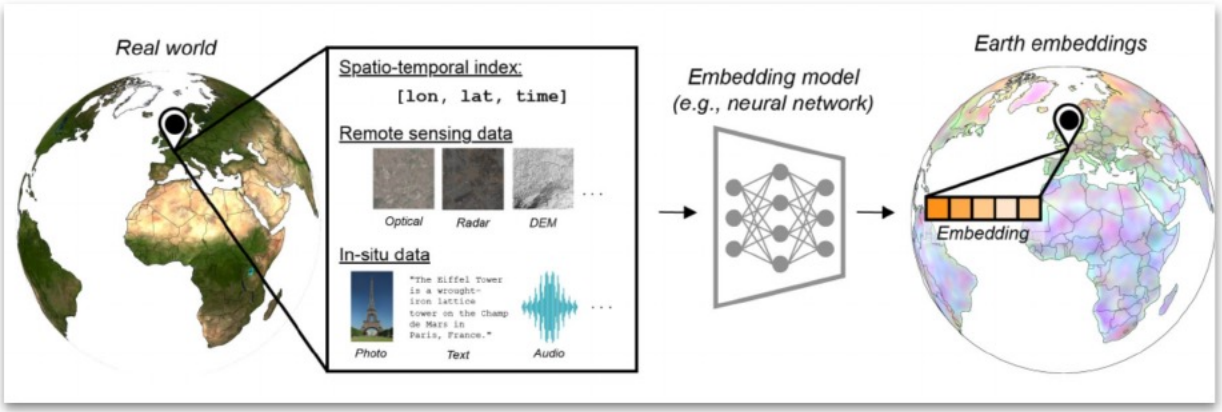
~10-100km

- Para onde devem ir os fundos de adaptação?
- Quais cidades são mais vulneráveis a extremos?
- Quais populações são mais vulneráveis?

Quarteirões

~10m-10km

- Quais bairros precisam de proteção contra enchentes?
- De onde vêm as emissões?
- Onde plantar árvores?



Embeddings geoespaciais e modelos de base do sistema Terra conectam bem as resoluções: aprende-se a representação uma vez e ela é reutilizada em várias tarefas de análise de impactos, reconstrução e exposição.

Exemplos: SatCLIP, GeoCLIP, Range, Clay, Tessera, AlphaEarth

Figura de: Earth Embeddings: Towards AI-centric Representations of our Planet (Klemmer et al. https://eartharxiv.org/repository/view/11083/)

Dados melhores mudam decisões reais

Direcionamento da adaptação

Quem é protegido primeiro, e a que custo?

Financiamento climático e perdas e danos

Estimativas de danos mais precisas melhoram as decisões financeiras

Ecossistemas e natureza

Quais os impactos climáticos na biodiversidade, e onde? Quais espécies são mais afetadas?

Seguros

Melhorias na precificação, segurabilidade, cobertura e gestão de riscos

Planejamento de infraestrutura

O que construir e como? Qual a chance de grandes enchentes, ondas de calor, nevascas extremas?

Avaliação distributiva

Quem será mais afetado pela mudança climática? Quais os impactos na igualdade e na saúde?

Exemplo: alocação de fundos de adaptação

Com dados grosseiros e de baixa qualidade:

- Os fundos podem seguir tendências, vieses, lobby
- Os fundos podem não chegar às populações que mais precisam
- O dinheiro público é alocado de forma subótima

Com dados de impacto localizados em alta resolução

- Os fundos seguem a exposição e a vulnerabilidade
- Os fundos são alocados de forma robusta e defensável
- Os decisores entendem melhor os trade-offs e as limitações

A medição não é neutra

Falsa precisão

- Resultados de alta resolução parecem exatos, mas muitas vezes não são
- Muitos conjuntos de dados comuns (p. ex. ERA5) escondem premissas e escolhas de modelagem, e modelos
- As incertezas se somam de forma invisível

A disponibilidade de dados não é uniforme

- A cobertura de dados tende a ser menor justamente onde a vulnerabilidade é maior
- Por isso, os modelos extrapolam e são menos precisos nas regiões mais vulneráveis
- P. ex.: Fairness and representation in satellite-based poverty maps: Evidence of urban-rural disparities and their impacts on downstream policy (Aiken et al https://arxiv.org/abs/2305.01783)

Documentado não significa eficaz

- As bases de políticas registram o que está escrito, não necessariamente o que foi eficaz

Perdas ocultas

- Algumas variáveis são mais difíceis de medir que outras. As funções de dano podem ignorar
  - Danos não monetários
  - A distribuição dos danos
  - Perdas culturais
  - Danos ecológicos

Quiz nº 2

Por que uma função de dano global ou dados de emissões em alta resolução podem não bastar para decidir para onde devem ir os fundos de adaptação?

Precisão ≠ relevância

Modelos e dados podem ser menos precisos onde a precisão mais importa

Vulnerabilidades ignoradas

O mesmo extremo climático pode ser um desastre para uma comunidade e um mero incômodo para outra

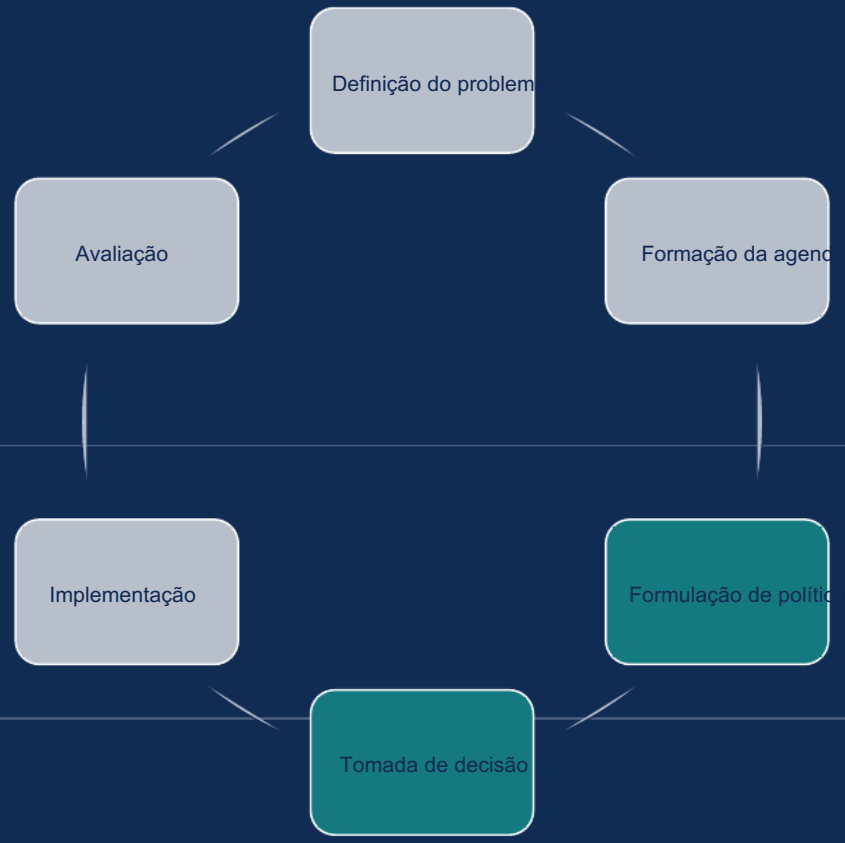
Escolhas normativas

Quem priorizar? A maioria, os mais vulneráveis? Eficiência ou equidade?

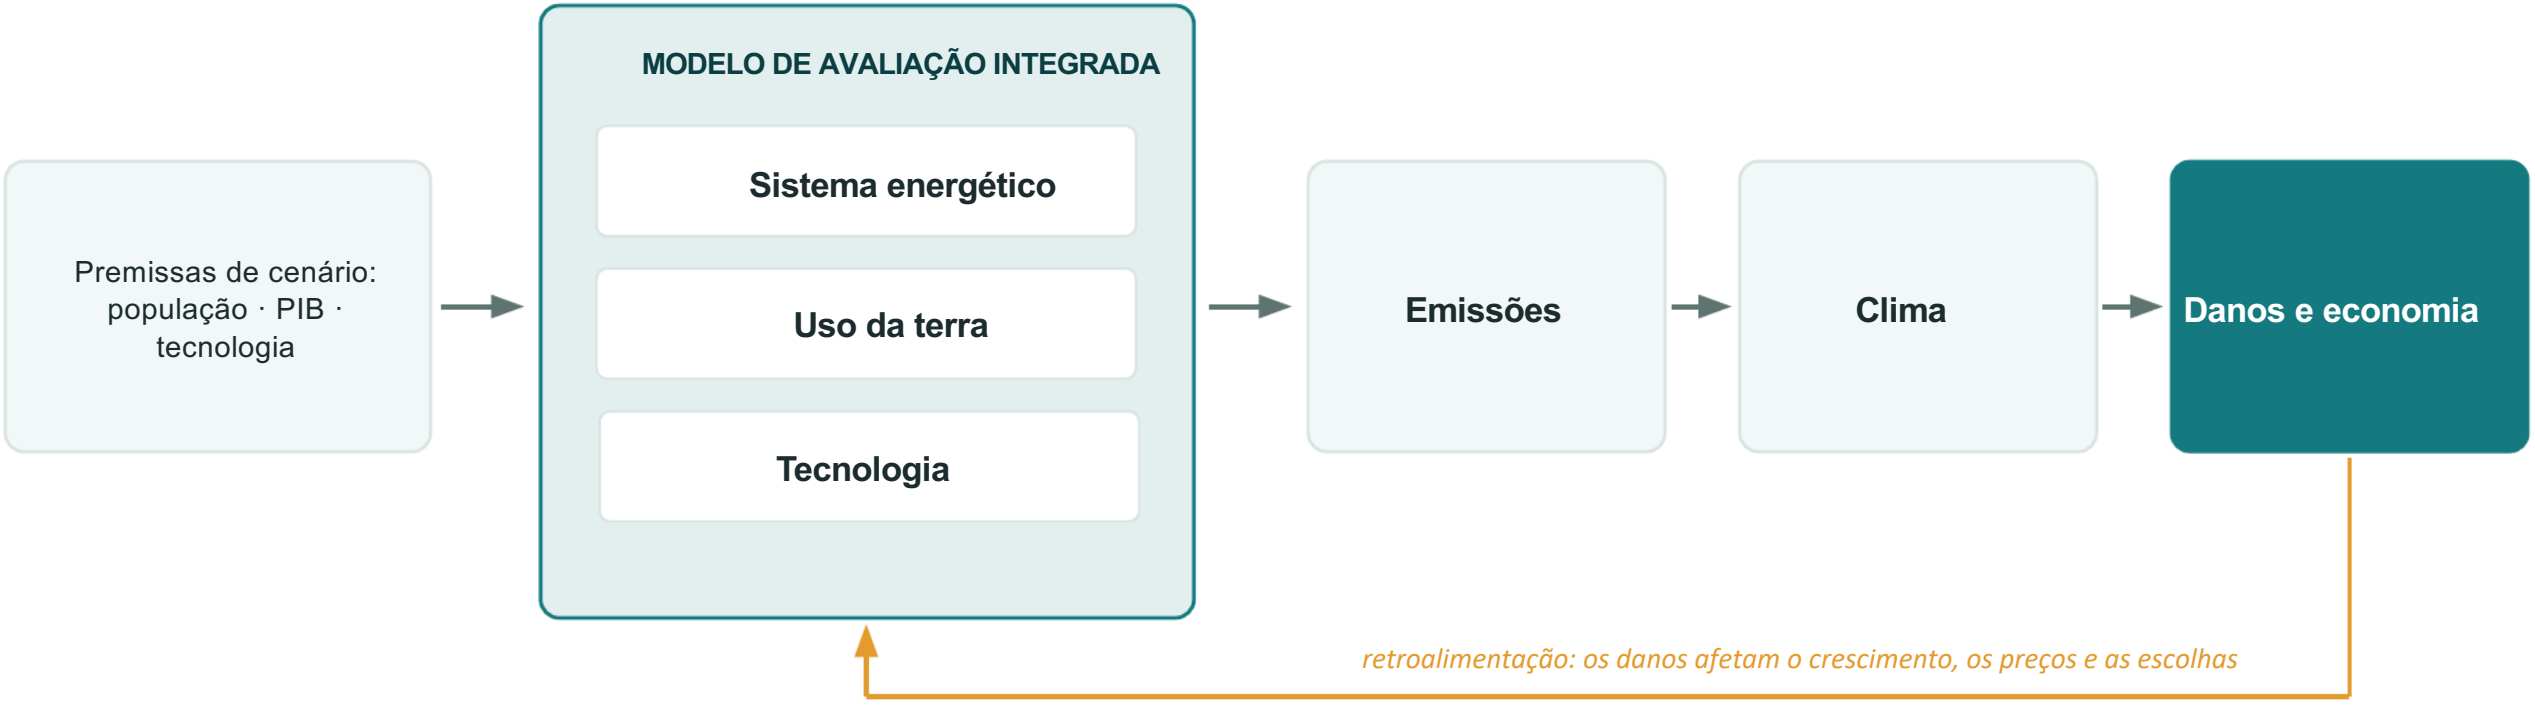
Dados melhores são necessários, mas não suficientes:
ajudam a estreitar os debates, mas não decidem quais perguntas são relevantes para as políticas

Parte 3: modelando futuros e desenhando opções de política

- Como modelar o clima e a economia do futuro?
- Como modelar os vários atores da política climática?
- Como garantir que nossos modelos sejam confiáveis?



Modelos de avaliação integrada (IAMs)



- Os IAMs modelam mundos estilizados: úteis para perguntas “e se?”, não para fazer previsões
- Há diferentes famílias de IAMs:
  - IAMs de custo-benefício (DICE)
  - IAMs detalhados por processo (REMIND, WITCH)

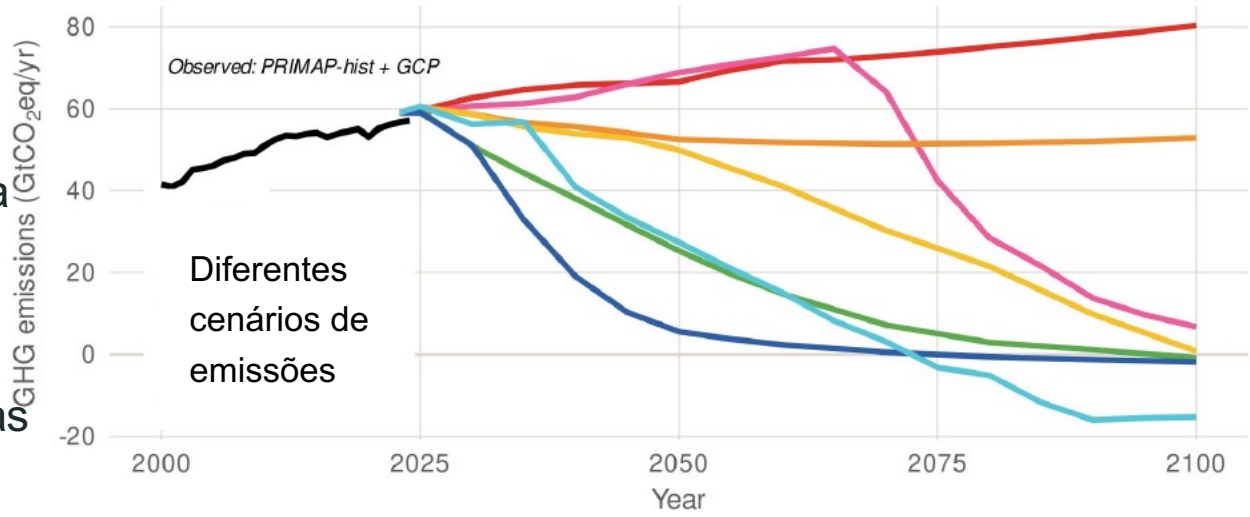
O que os IAMs informam

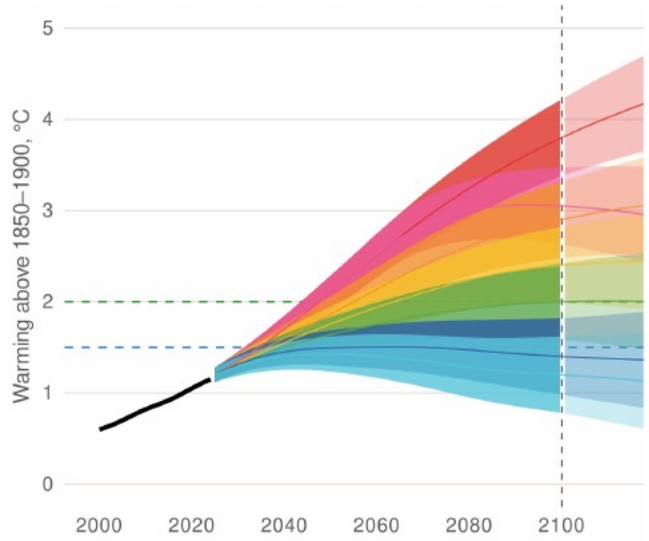
- Trajetórias de menor custo rumo às metas de temperatura
- Portfólios tecnológicos: quanto de eólica, CCS, nuclear, quando e a que custo
- Trajetórias de preço do carbono compatíveis com as metas
- Divisão regional do esforço e sua (in)equidade
- Bases de cenários do IPCC

IAMC
Integrated Assessment Modeling Consortium
Founded 2007

ipcc
INTERGOVERNMENTAL PANEL ON climate change

Trajetórias de emissões estilizadas ($GtCO_2$/ano)





IA para emular IAMs

- Os IAMs são úteis, mas muito caros computacionalmente
- Conjuntos de modelos para medir a incerteza podem se tornar inviáveis
- Emuladores de AM podem ajudar:
  - Eles aprendem a relacionar entradas e saídas de um IAM
  - Depois de treinados, respondem instantaneamente
- O ML-IAM permite explorar cenários de forma interativa
  - P. ex. Shin et al., ML-IAM v1.0 · Li et al. 2025, aprendizado profundo para variáveis de cenários globais de mitigação (https://egusphere.copernicus.org/preprints/2026/egusphere-2025-5305/)

1

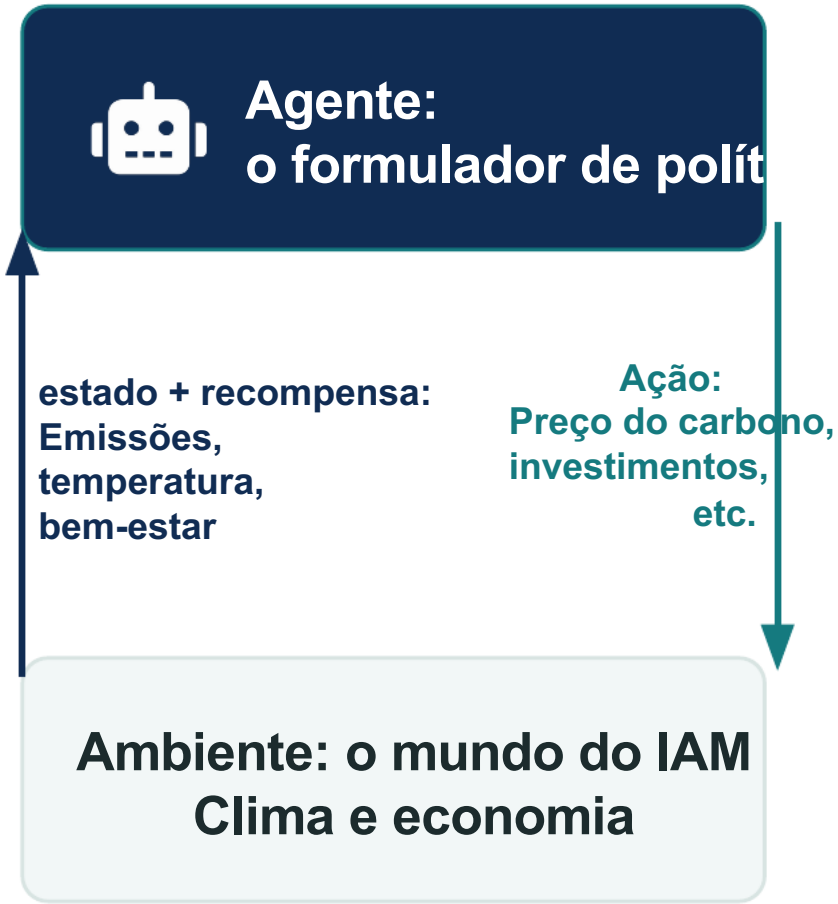
Cenário de IAM
de horas a dias de processamento

10.000+

avaliações do emulador no mesmo tempo

(ilustrativo)

Aprendizado por reforço: políticas como sequências de decisões



- A política climática é sequencial: agir, observar, ajustar, por décadas
- O AR explora trajetórias de políticas, não configurações isoladas
- Acoplado aos IAMs, o AR pode alcançar regiões do espaço de soluções que os solvers clássicos nunca visitam
- **Resultado útil: estratégias candidatas surpreendentes, nunca exploradas**

Agentes em competição e cooperação

- Muitos atores, com objetivos e prioridades diferentes e mutáveis (países, empresas, reguladores)
- Eles cooperam, competem, pegam carona ou se ignoram
- O AR multiagente torna visíveis e quantificáveis os incentivos desalinhados e as falhas de coordenação

	B reduz	**B pega carona**
A reduz	Todos pagam, o planeta ganha	A paga, B se beneficia
A pega carona	B paga, A se beneficia	**Ninguém paga: todos perdem**

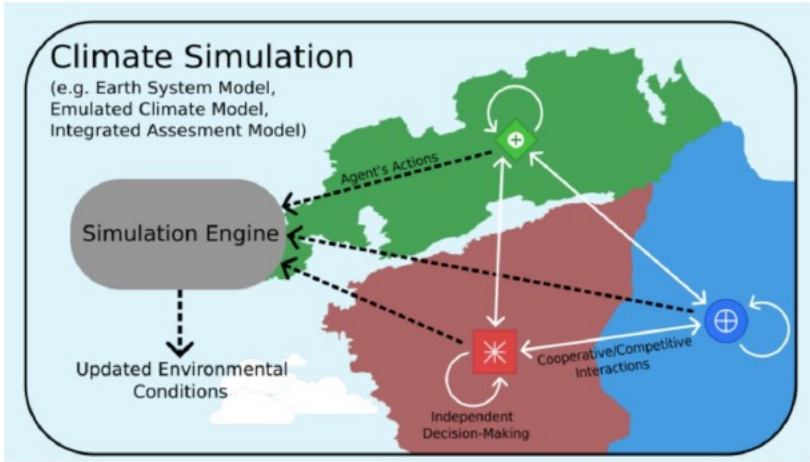
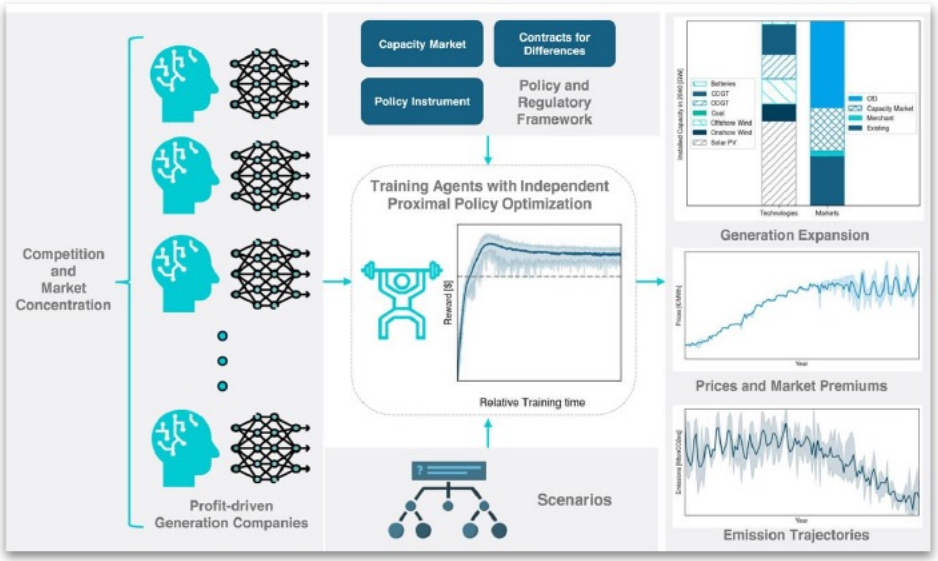


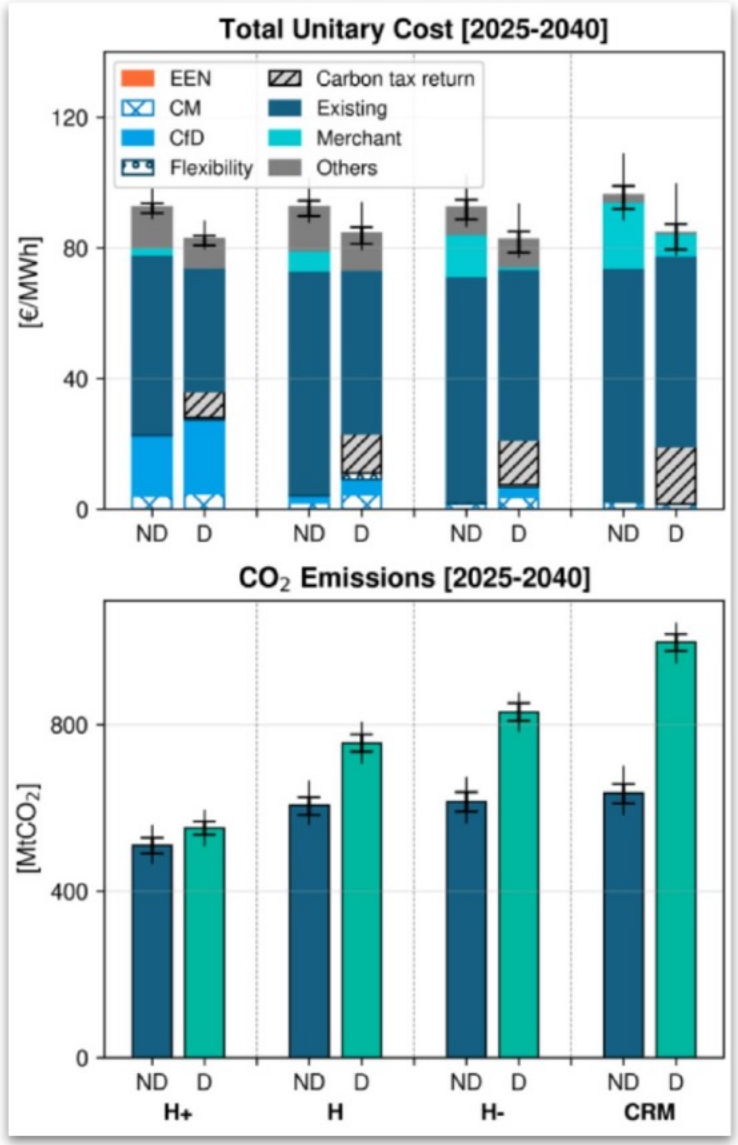
Figura de Multi-Agent Reinforcement Learning Simulation for Environmental Policy Synthesis (Rudd-Jones et al.)

AR multiagente para desenhar a política do mercado elétrico de longo prazo

- **Pergunta: quais desenhos de mercado levam a uma descarbonização profunda a preços aceitáveis?**
- **Abordagem: geradores como agentes que aprendem, dão lances e investem sob regras de mercado alternativas**
- Os agentes revelam comportamentos estratégicos que a análise de equilíbrio não vê
- As escolhas de desenho mudam visivelmente os preços e a descarbonização



González-Ruiz et. al. Assessing Long-Term Electricity Market Design for Ambitious Decarbonization Targets using Multi-Agent Reinforcement Learning



González-Ruiz et. al. EU-ETS under attack? The impact of carbon price suppression on the decarbonization of the power sector

O que o AR não pode decidir



Valores não se aprendem

- O AR otimiza dentro de um problema formalizado. O que a sociedade deve valorizar não é algo que o AR possa ou deva otimizar



Uma única recompensa não consegue modelar objetivos complexos, interligados e multidimensionais

- As funções de valor dos ambientes de AR podem achatar objetivos plurais e em disputa.



Viés de visibilidade

- Os espaços de estados e ações codificam apenas o que é facilmente mensurável e acionável. O resto é ignorado por construção



Muitas restrições não podem ser totalmente modeladas

- Normas legais, culturais e sociais, restrições políticas e limites institucionais são decisivos para a viabilidade das políticas

https://partici.fi/32182658

Quiz nº 3

Uma política de AR funciona bem no simulador. Por que um formulador de políticas ainda poderia rejeitá-la?

Lacuna simulação-realidade

O mundo do IAM é subespecificado: o que é ótimo nele pode não se transferir para o mundo real

Objetivos não modelados

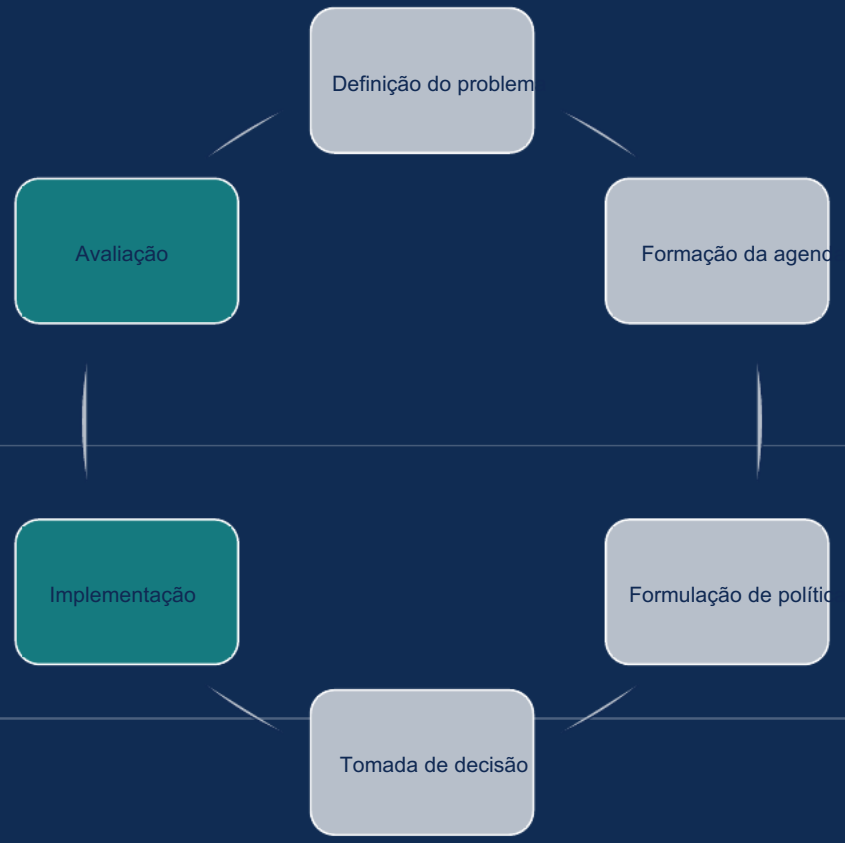
Equidade, legalidade e aceitabilidade social não estavam na recompensa. O que significa uma política ter bom desempenho?

Confiança e responsabilização

Quem responde por decisões derivadas do AR? Estratégias inexplicáveis resistem ao escrutínio institucional?

Parte 4: avaliação e implantação

- Como saber se uma política funcionou?
- Podemos estimar se uma política será popular ou socialmente aceitável?



Como saber se uma política funcionou? Inferência causal

Experimentos aleatorizados

- O padrão-ouro
- Atribuir a política aleatoriamente e comparar os grupos.
- Cientificamente robusto, mas difícil no mundo real.
- P. ex.: como aleatorizar um imposto sobre carbono entre países?

Diferenças em diferenças

- Comparar a evolução no tempo de unidades com e sem a política.
- Muito comum na literatura

Controle sintético

- Sem uma boa unidade de comparação → construir um "gêmeo" de uma unidade tratada a partir de um conjunto de unidades não tratadas.
- P. ex. o imposto sobre carbono sueco: emissões do transporte comparadas a uma "Suécia sintética" construída com outros países da OCDE
- Ver Andersson, J.J. Carbon Taxes and CO_2 Emissions: Sweden as a Case Study,
- Ver Gomez-Mahecha Colombian Carbon Tax: Evidence of Carbon Pricing in a Developing Context

Variáveis instrumentais

- Encontrar uma alavanca que mova a variável de política sem outro caminho a o resultado.
- P. ex.: velocidade do vento → mais geração renovável → o que acontece cor emissões? O tempo é aleatório: a resposta é causal.

O AM causal pode ampliar essas ferramentas: encontrar fatores de confusão de alta dimensão, efeitos heterogêneos e não lineares, formas funcionais flexíveis etc.

Prever não é avaliar causalmente

Previsão

P. ex.: “Quais serão as emissões no ano que vem?”
Ótimo para planejar e monitorar, mas pouco útil para entender se uma política é eficaz

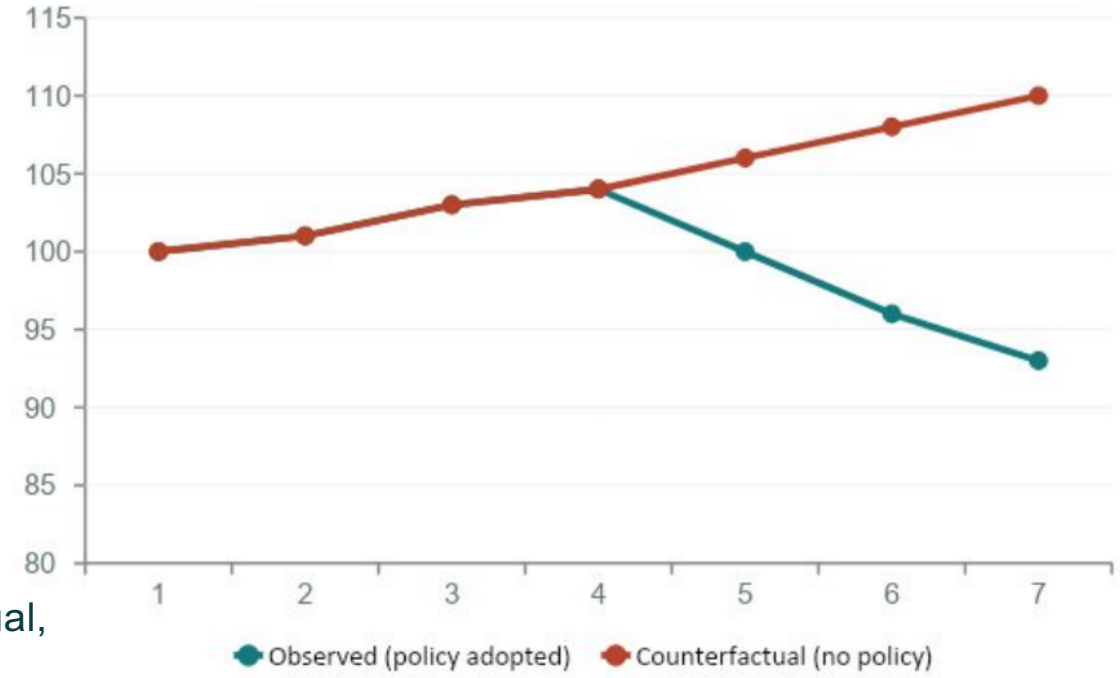
Avaliação causal

“O que este imposto sobre carbono mudou?”: é preciso um contrafactual,

O AM amplia as ferramentas de inferência causal para fatores de confusão de alta dimensão e efeitos heterogêneos.

Ver Chernozhukov et al Double/debiased machine learning for treatment and structural parameters

O contrafactual, ilustrado (estilizado)



Duas formas de precificar o carbono



Impostos sobre carbono

Fixamos o preço, a quantidade se ajusta

- Custos previsíveis para as empresas
- Emissões totais incertas



Limite e comércio (ETS)

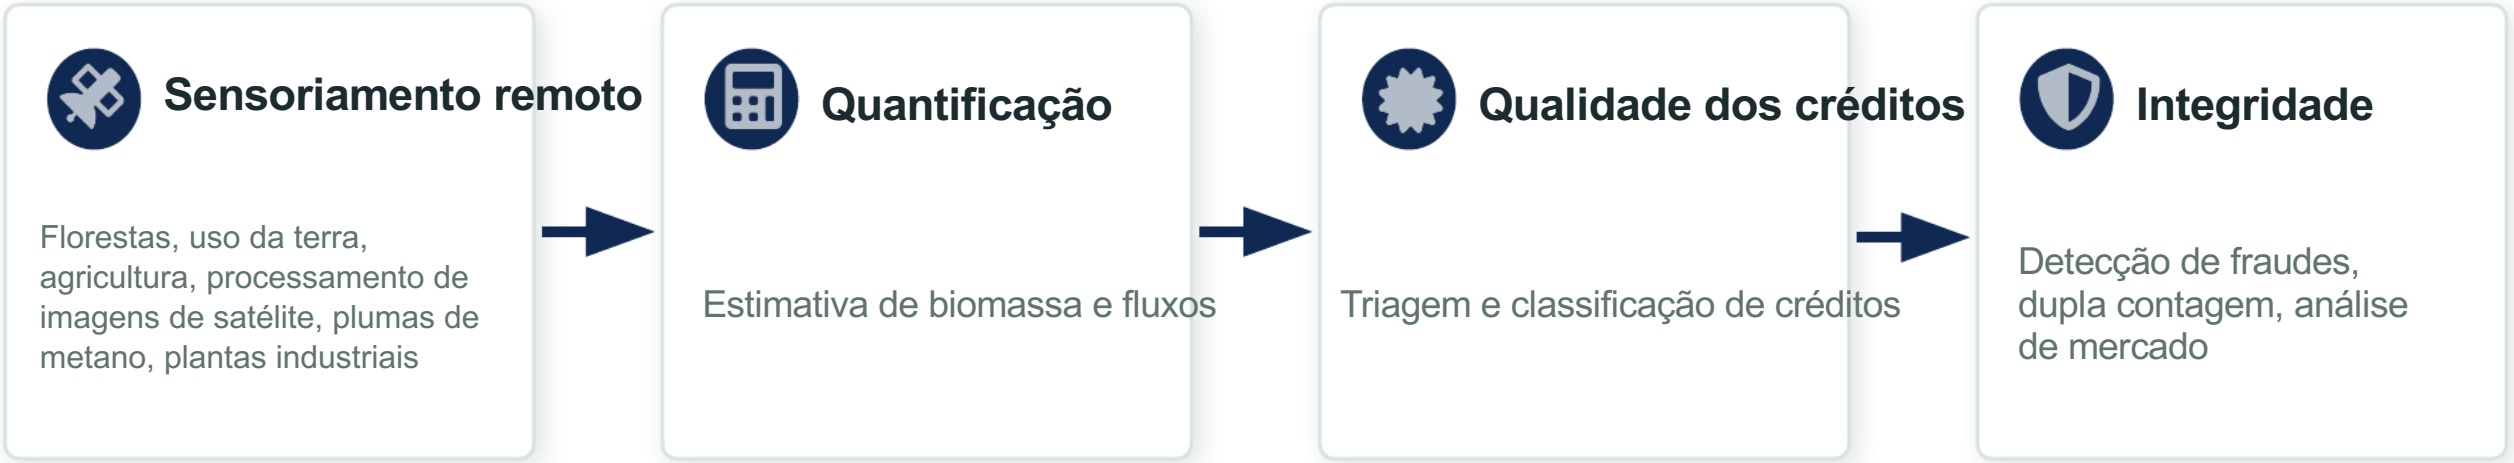
Fixamos a quantidade, o preço se ajusta

- Limite de emissões garantido
- Preços voláteis
- Cria um mercado de permissões

Nos dois casos, os mercados criam um problema de medição e verificação:

- É preciso contar, verificar e dar confiabilidade às toneladas, inclusive compensações de florestas, fazendas e fábrica do outro lado do mundo.
- Esse problema de verificação pode ser enfrentado com IA

IA ao longo da cadeia de créditos de carbono



Limitações da IA nos mercados de carbono

Falsa precisão contábil

- Uma tonelada “medida” por um modelo de AM pode acumular incertezas: não pode ser tratada como estimativa exata

Manipulação de métricas

- Métricas mensuráveis convidam à manipulação
- Projetos de captura de carbono vão se otimizar para o que os modelos recompensam

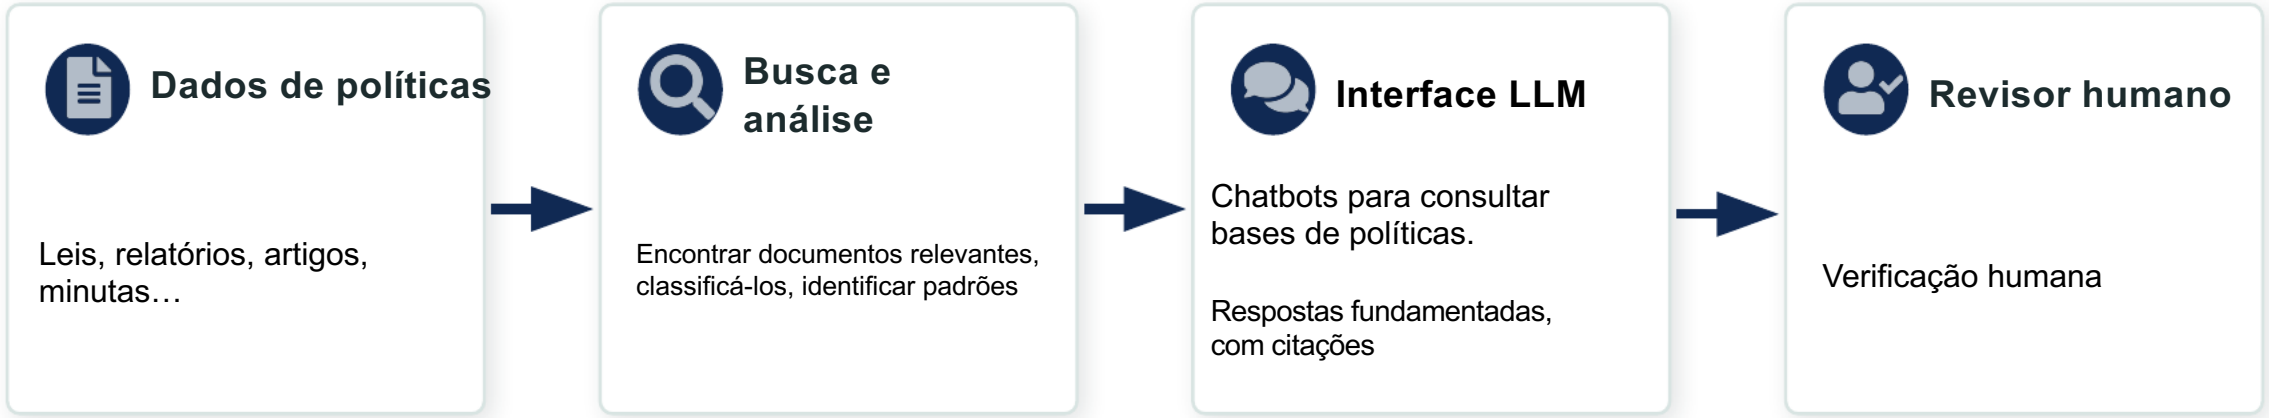
Visão de túnel

- Otimizar a tonelada de CO_2 mensurável deixa de lado cobenefícios de biodiversidade, justiça e governança

Verificação caixa-preta

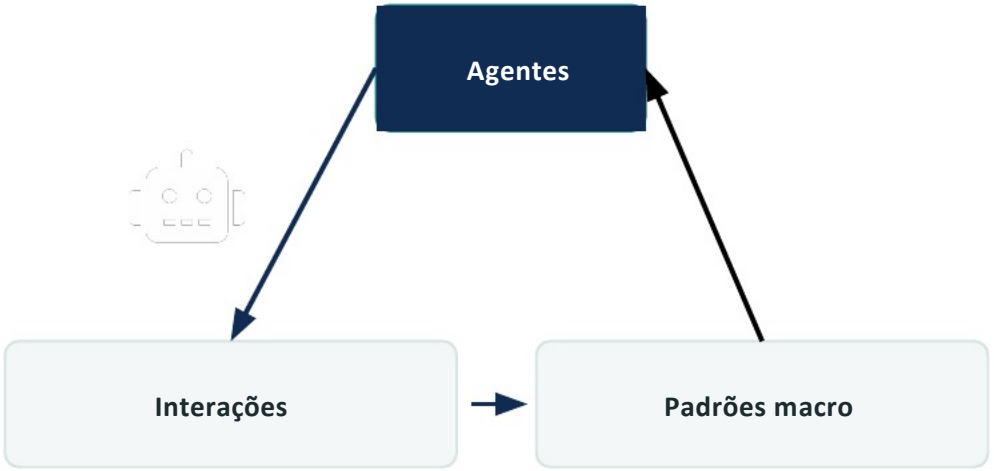
- Modelos proprietários não podem ser auditados
- A confiança nos mercados de carbono não deve depender de credores privados

LLMs no trabalho com políticas

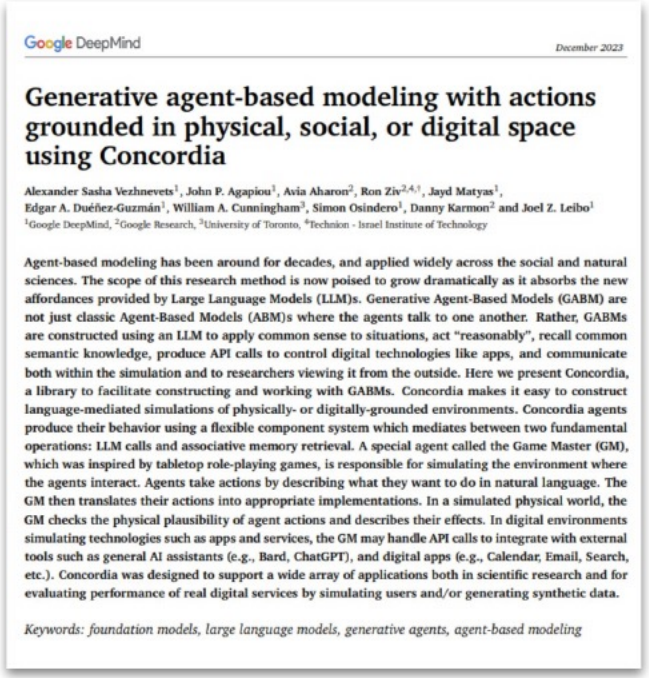


- Análise de documentos de políticas
- Síntese da literatura
- Perguntas e respostas sobre corpora de políticas
- Análise de grandes conjuntos de textos de políticas

Modelos baseados em agentes



- Atores heterogêneos: famílias, empresas, lobbies
- Dinâmicas macro que emergem do comportamento micro
- A aceitabilidade de uma política é explorada antes da implementação, não descoberta depois
- Os MBAs podem seguir regras predefinidas, mas também ser modelados como agentes que interagem via LLMs



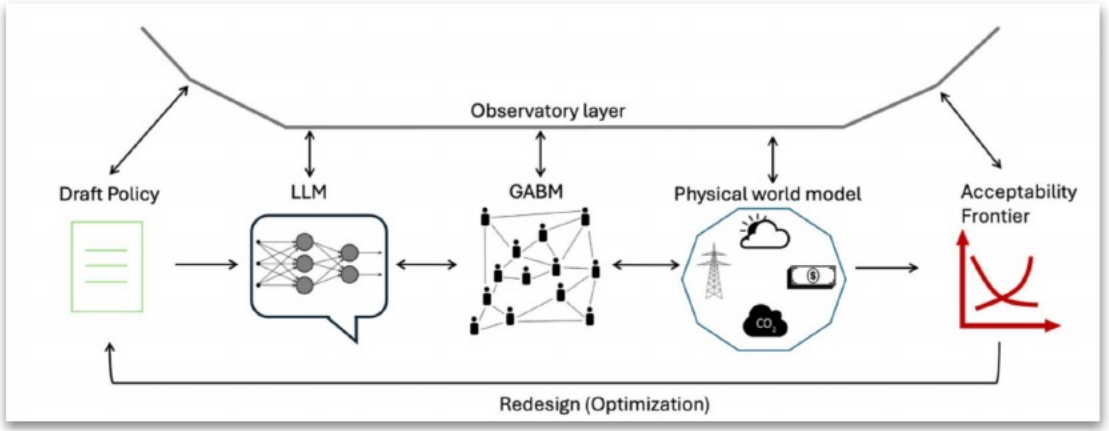
Google DeepMind *December 2023*

Generative agent-based modeling with actions grounded in physical, social, or digital space using Concordia

Alexander Sasha Vezhnevets[1], John P. Agapiou[1], Avia Aharon[2], Ron Ziv[2,4,†], Jayd Matyas[1], Edgar A. Duéñez-Guzmán[1], William A. Cunningham[3], Simon Osindero[1], Danny Karmon[2] and Joel Z. Leibo[1]
[1]Google DeepMind, [2]Google Research, [3]University of Toronto, [4]Technion - Israel Institute of Technology

Agent-based modeling has been around for decades, and applied widely across the social and natural sciences. The scope of this research method is now poised to grow dramatically as it absorbs the new affordances provided by Large Language Models (LLM)s. Generative Agent-Based Models (GABM) are not just classic Agent-Based Models (ABM)s where the agents talk to one another. Rather, GABMs are constructed using an LLM to apply common sense to situations, act "reasonably", recall common semantic knowledge, produce API calls to control digital technologies like apps, and communicate both within the simulation and to researchers viewing it from the outside. Here we present Concordia, a library to facilitate constructing and working with GABMs. Concordia makes it easy to construct language-mediated simulations of physically- or digitally-grounded environments. Concordia agents produce their behavior using a flexible component system which mediates between two fundamental operations: LLM calls and associative memory retrieval. A special agent called the Game Master (GM), which was inspired by tabletop role-playing games, is responsible for simulating the environment where the agents interact. Agents take actions by describing what they want to do in natural language. The GM then translates their actions into appropriate implementations. In a simulated physical world, the GM checks the physical plausibility of agent actions and describes their effects. In digital environments simulating technologies such as apps and services, the GM may handle API calls to integrate with external tools such as general AI assistants (e.g., Bard, ChatGPT), and digital apps (e.g., Calendar, Email, Search, etc.). Concordia was designed to support a wide array of applications both in scientific research and for evaluating performance of real digital services by simulating users and/or generating synthetic data.

Keywords: foundation models, large language models, generative agents, agent-based modeling



From Manivannan, Spaiser et al. Generative AI for climate governance and acceptability-constrained policy design

LLMs e MBAs: plausíveis, mas não validados

Alucinações

- Os LLMs tendem a alucinar informações
- Chatbots LLM em geral não conseguem distinguir se a informação que geraram é verdadeira ou falsa
- O trabalho com políticas exige citações verificáveis

Falta de contexto institucional

- Os modelos podem desconhecer normas, precedentes, mandatos, linhas vermelhas e contextos políticos em mudança

Vieses, confidencialidade, excesso de confiança

- Modelos às vezes treinados com dados enviesados
- Os LLMs parecem seguros das respostas, mesmo quando não estão
- Os LLMs podem vazar dados sensíveis

Modelos proprietários

- Pesos fechados e versões que mudam
- Reprodutibilidade e soberania: um problema para as instituições públicas
- De quem são os modelos? Quem paga por eles? Atores privados treinam modelos com informações públicas críticas?

A própria pegada ambiental da IA

Ligada à computação

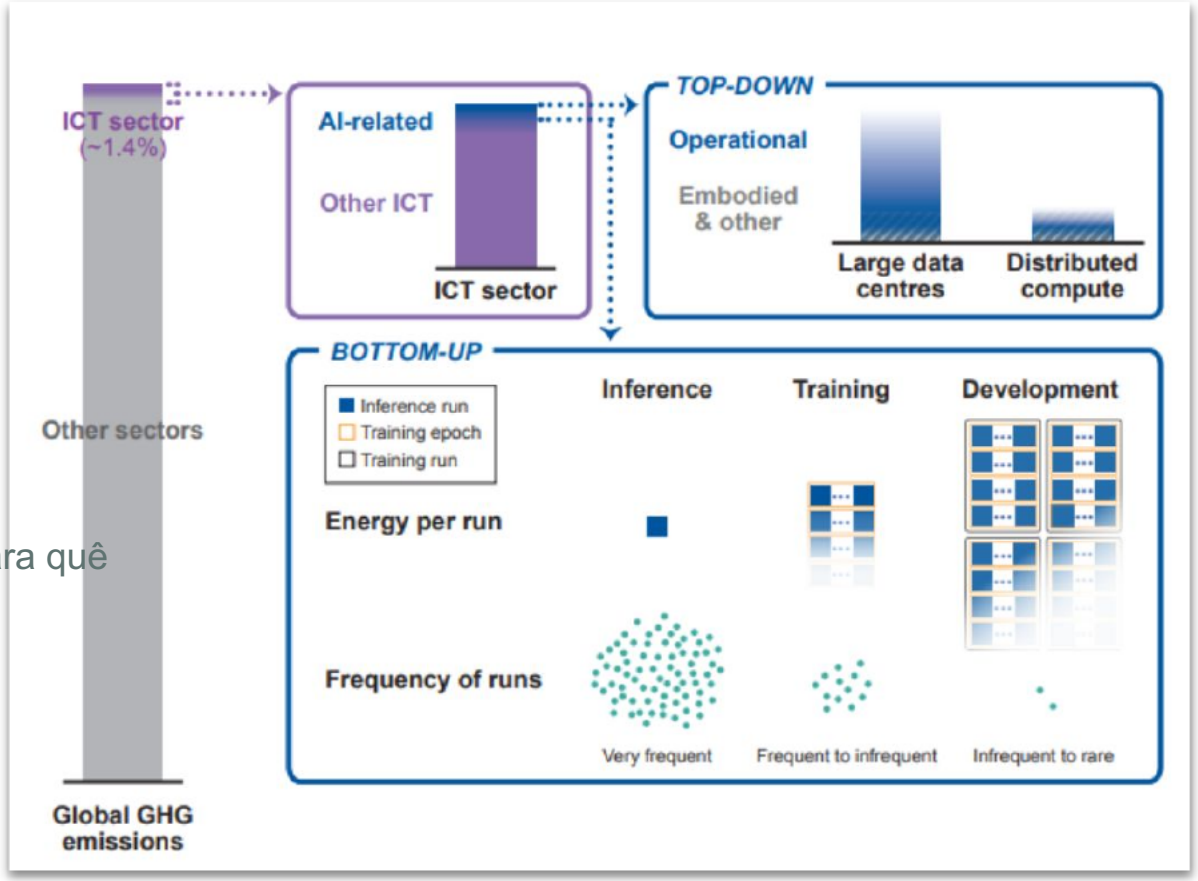
Energia de treinamento e inferência, hardware, água

Efeitos da aplicação do AM

Ganhos de eficiência vs. efeito rebote; quem usa a ferramenta e para quê

No nível do sistema

Mudanças de comportamento, lock-ins, demanda induzida



De Kaack et al Aligning artificial intelligence with climate change mitigation

A lacuna da implantação



Fechando a lacuna:

- Benchmarks de utilidade para as políticas, não só de precisão preditiva
- Incerteza bem calculada e comunicada em termos úteis para a decisão
- Colaborações integradas: cocriação com as pessoas e comunidades que vão usá-la e podem ser afetadas pela tecnologia
- Ampliar a capacidade institucional e a confiança

Ver https://eartharxiv.org/repository/view/13019/

Quiz nº 4

Que fatores você consideraria ao usar um LLM na análise de políticas climáticas?

https://partici.fi/32182658

Problemas em aberto e conclusões



Problemas em aberto

1

Benchmarks de utilidade para as políticas além da precisão

2

Políticas robustas sob incerteza profunda, em vez de uma única política “ótima”

3

Emuladores e cenários sintéticos que mantenham a interpretabilidade e a QI

4

Fluxos com LLMs seguros e transparentes para instituições públicas

5

Métodos de cocriação com decisores e comunidades afetadas

6

Integrar ameaças → impactos → resposta social → decisões políticas

7

Danos localizados: fechar a lacuna de resolução onde os dados são mais escassos

Inteligência climática integrada: um grande desafio

Cada parte desta aula foi uma ilha: medição, futuros, incerteza, agentes, avaliação.

Um grande objetivo de pesquisa da próxima década é conectá-las (ameaças, impactos, resposta socioeconômica e decisões políticas em um só ciclo) e entender como a própria IA afeta a ação climática.

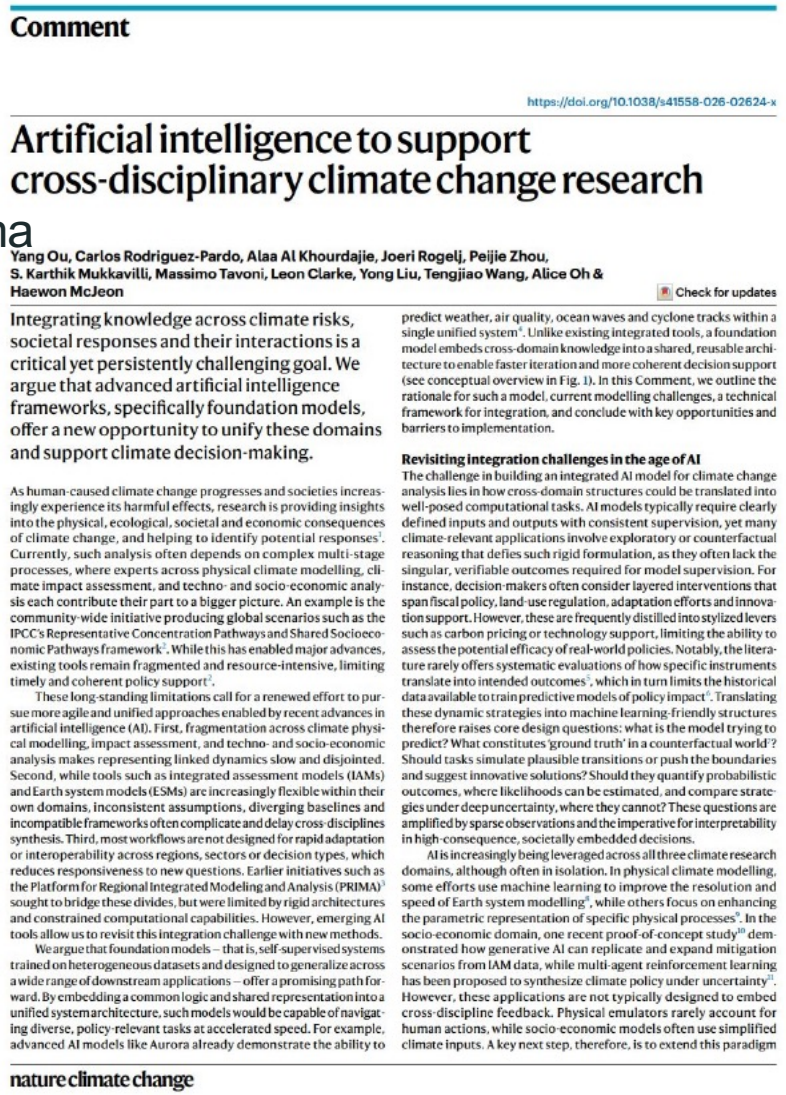

Stockholm Resilience Centre | Stockholm University

Research Edu

Stockholm Resilience Centre / Research / Synthesis reports / AI for a planet under pressure

AI for a planet under pressure

Editors: Victor Galaz & Maria Schewenius


Comment

https://doi.org/10.1038/s41558-026-02624-x

Artificial intelligence to support cross-disciplinary climate change research

Yang Ou, Carlos Rodriguez-Pardo, Alaa Al Khourdajie, Joeri Rogelj, Peijie Zhou, S. Karthik Mukkavilli, Massimo Tavoni, Leon Clarke, Yong Liu, Tengjiao Wang, Alice Oh & Haewon McJeon

Check for updates

Integrating knowledge across climate risks, societal responses and their interactions is a critical yet persistently challenging goal. We argue that advanced artificial intelligence frameworks, specifically foundation models, offer a new opportunity to unify these domains and support climate decision-making.

As human-caused climate change progresses and societies increasingly experience its harmful effects, research is providing insights into the physical, ecological, societal and economic consequences of climate change, and helping to identify potential responses[1]. Currently, such analysis often depends on complex multi-stage processes, where experts across physical climate modelling, climate impact assessment, and techno- and socio-economic analysis each contribute their part to a bigger picture. An example is the community-wide initiative producing global scenarios such as the IPCC's Representative Concentration Pathways and Shared Socioeconomic Pathways framework[2]. While this has enabled major advances, existing tools remain fragmented and resource-intensive, limiting timely and coherent policy support[3].

These long-standing limitations call for a renewed effort to pursue more agile and unified approaches enabled by recent advances in artificial intelligence (AI). First, fragmentation across climate physical modelling, impact assessment, and techno- and socio-economic analysis makes representing linked dynamics slow and disjointed. Second, while tools such as integrated assessment models (IAMs) and Earth system models (ESMs) are increasingly flexible within their own domains, inconsistent assumptions, diverging baselines and incompatible frameworks often complicate and delay cross-disciplines synthesis. Third, most workflows are not designed for rapid adaptation or interoperability across regions, sectors or decision types, which reduces responsiveness to new questions. Earlier initiatives such as the Platform for Regional Integrated Modeling and Analysis (PRIMA)[3] sought to bridge these divides, but were limited by rigid architectures and constrained computational capabilities. However, emerging AI tools allow us to revisit this integration challenge with new methods.

We argue that foundation models – that is, self-supervised systems trained on heterogeneous datasets and designed to generalize across a wide range of downstream applications – offer a promising path forward. By embedding a common logic and shared representation into a unified system architecture, such models would be capable of navigating diverse, policy-relevant tasks at accelerated speed. For example, advanced AI models like Aurora already demonstrate the ability to predict weather, air quality, ocean waves and cyclone tracks within a single unified system[4]. Unlike existing integrated tools, a foundation model embeds cross-domain knowledge into a shared, reusable architecture to enable faster iteration and more coherent decision support (see conceptual overview in Fig. 1). In this Comment, we outline the rationale for such a model, current modelling challenges, a technical framework for integration, and conclude with key opportunities and barriers to implementation.

Revisiting integration challenges in the age of AI

The challenge in building an integrated AI model for climate change analysis lies in how cross-domain structures could be translated into well-posed computational tasks. AI models typically require clearly defined inputs and outputs with consistent supervision, yet many climate-relevant applications involve exploratory or counterfactual reasoning that defies such rigid formulation, as they often lack the singular, verifiable outcomes required for model supervision. For instance, decision-makers often consider layered interventions that span fiscal policy, land-use regulation, adaptation efforts and innovation support. However, these are frequently distilled into stylized levers such as carbon pricing or technology support, limiting the ability to assess the potential efficacy of real-world policies. Notably, the literature rarely offers systematic evaluations of how specific instruments translate into intended outcomes[5], which in turn limits the historical data available to train predictive models of policy impact[6]. Translating these dynamic strategies into machine learning-friendly structures therefore raises core design questions: what is the model trying to predict? What constitutes 'ground truth' in a counterfactual world[7]? Should tasks simulate plausible transitions or push the boundaries and suggest innovative solutions? Should they quantify probabilistic outcomes, where likelihoods can be estimated, and compare strategies under deep uncertainty, where they cannot? These questions are amplified by sparse observations and the imperative for interpretability in high-consequence, societally embedded decisions.

AI is increasingly being leveraged across all three climate research domains, although often in isolation. In physical climate modelling, some efforts use machine learning to improve the resolution and speed of Earth system modelling[8], while others focus on enhancing the parametric representation of specific physical processes[9]. In the socio-economic domain, one recent proof-of-concept study[10] demonstrated how generative AI can replicate and expand mitigation scenarios from IAM data, while multi-agent reinforcement learning has been proposed to synthesize climate policy under uncertainty[11]. However, these applications are not typically designed to embed cross-discipline feedback. Physical emulators rarely account for human actions, while socio-economic models often use simplified climate inputs. A key next step, therefore, is to extend this paradigm

nature climate change


Position: AI Must Become Planet-Centered, Not Just Human-Centered

María Pérez-Ortiz [1]

Abstract

This position paper argues that contemporary AI paradigms are insufficient for supporting complex global goals and introduces Planet-Centered AI (PCAI) as a design philosophy and research agenda that reorients AI toward planetary-scale socio-ecological systems and their long-term trajectories. A planet-centered approach is grounded in systems thinking, treating Earth as an interconnected whole of which humans are part. We diagnose recurring limitations across AI frameworks—many of which remain human-centered—and show why these become especially consequential under current planetary conditions characterized by systemic risk, non-stationarity, and deep uncertainty. We then articulate how PCAI reshapes the AI lifecycle, from problem formulation and model design to evaluation and deployment, by emphasizing alignment with global agendas, developing system-aware AI foundations, trajectory-oriented evaluation, and monitorability. Finally, we advance a falsifiable claim: AI systems optimized without explicit consideration of systemic consequences are more likely to exacerbate systemic instability than to mitigate it.

1. Introduction

Over the past decade, the AI community has developed a range of paradigms to address the ethical, social, and technical risks of AI. Frameworks such as Human-Centered AI, Responsible AI, AI for Social Good/Sustainability, and AI safety have been essential in establishing that AI has far-reaching consequences, and that potential harms and broader impacts should inform algorithmic design and deployment.

Despite this progress, **this position paper argues that these paradigms are insufficient for enabling AI to meaningfully support societies in confronting complex challenges: ML must be reoriented toward a planet-centered paradigm that treats systemic risk, long-term impact, and global goals as first-order design objectives.**

As the world enters what is described as a polycrisis (Lawrence et al., 2024), risks arise not from isolated failures but from coupled systems whose interactions generate self-reinforcing and systemic dynamics. Consider the following example: rising ocean temperatures alter predator-prey dynamics, enabling jellyfish blooms that clog coastal power plant cooling intakes, triggering forced shutdowns and energy instability (Purcell et al., 2007). This is systemic risk, risks emerge from the coupling between systems. Similarly, climate change has been shown to aggravate more than half of known infectious diseases, through over a thousand distinct pathways linking physical, ecological, and social systems (Mora et al., 2022). In such settings, feedback loops, nonlinear interactions, and path dependence—where early interventions shape and constrain future outcomes—can amplify risks and lock societies into trajectories that are difficult to reverse (Delannoy et al., 2025; Steffen et al., 2018). Recent work shows that AI is increasingly entangled with polycrisis dynamics through material pathways (e.g., energy use, resource extraction, infrastructure lock-in) and informational pathways (e.g., shaping behavior, accelerating decision cycles, synchronizing systems), with the potential to intensify systemic instability (Creutzig et al., 2022).

It is precisely this systems perspective (Meadows, 2008)—focused on feedbacks, interactions, and trajectories—that remains absent from AI frameworks (Kondor et al., 2024). We argue that AI methods are poorly suited to supporting planetary challenges, which exhibit properties of "wicked problems" (Rittel & Webber, 1973): e.g. non-stationarity and feedback-driven dynamics. This mismatch matters because such conditions increasingly characterize high-stakes domains in which AI is deployed, such as climate governance, technology regulation, and public policy (Ilcic et al., 2025). Due to this misalignment, AI can generate systemic risks by interacting with or amplifying underlying system dynamics in unintended ways (Schön et al., 2025). Yet frameworks for anticipating and evaluating systemic effects remain limited, leaving concepts of systemic risk underdeveloped and inconsistently operationalized in AI governance (Carey, 2025; Stahl et al., 2023).

[1]Centre for AI, Department of Computer Science, University College London, London, UK. Correspondence to: María Pérez-Ortiz <maria.perez@ucl.ac.uk>.

Proceedings of the 43rd International Conference on Machine Learning, Seoul, South Korea. PMLR 306, 2026. Copyright 2026 by the author(s).

1

arXiv:2606.13704v1 [cs.CY] 9 Jun 2026

A caixa de ferramentas inicial

DADOS E FERRAMENTAS

- Climate Policy Radar
- Bases de cenários do IAMC
- Emuladores de IAM (p. ex. ML-IAM) e IAMs de código aberto / modelos de energia
- Population Dynamics Foundation Model
- Embeddings geoespaciais e TorchGeo
- Pacotes de inferência causal e econometria

COMUNIDADES E EVENTOS

- Climate Change AI: você já está aqui
- Workshops da CCAI no NeurIPS
- IAMC: grupo de trabalho de IA responsável para IAMs
- EGU · AGU · SISC · WCERE: onde se encontram clima, ciências da Terra e economia



Mensagens finais

A IA pode entrar em todas as etapas do ciclo das políticas

- Medição
- Futuros
- Avaliação
- Fluxos de trabalho
- Verificação

A restrição raramente é a precisão preditiva

- Validade causal
- Valores
- Confiança
- Restrições sociais
- Instituições
- Aceitabilidade social

A integração é a fronteira

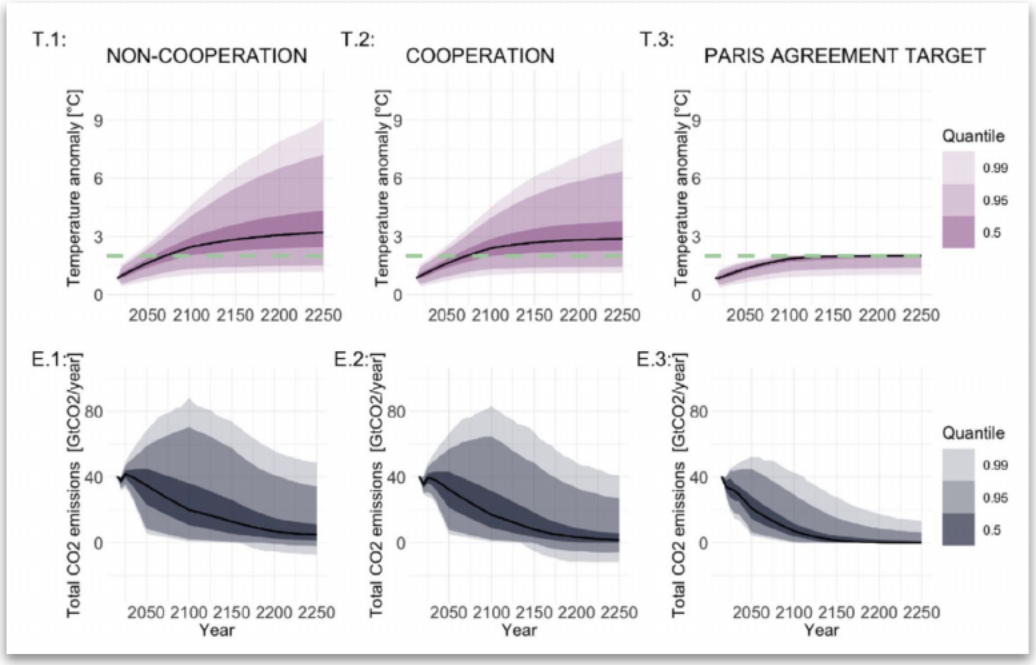
- Entre escalas
- Entre tipos de dados
- Entre etapas do ciclo das políticas
- Entre instituições e comunidades
- Ao longo da cadeia de modelagem

Partir de perguntas relevantes para as políticas e dos problemas dos formuladores, não das capacidades dos modelos nem do que se pode fazer com um conjunto de dados específico

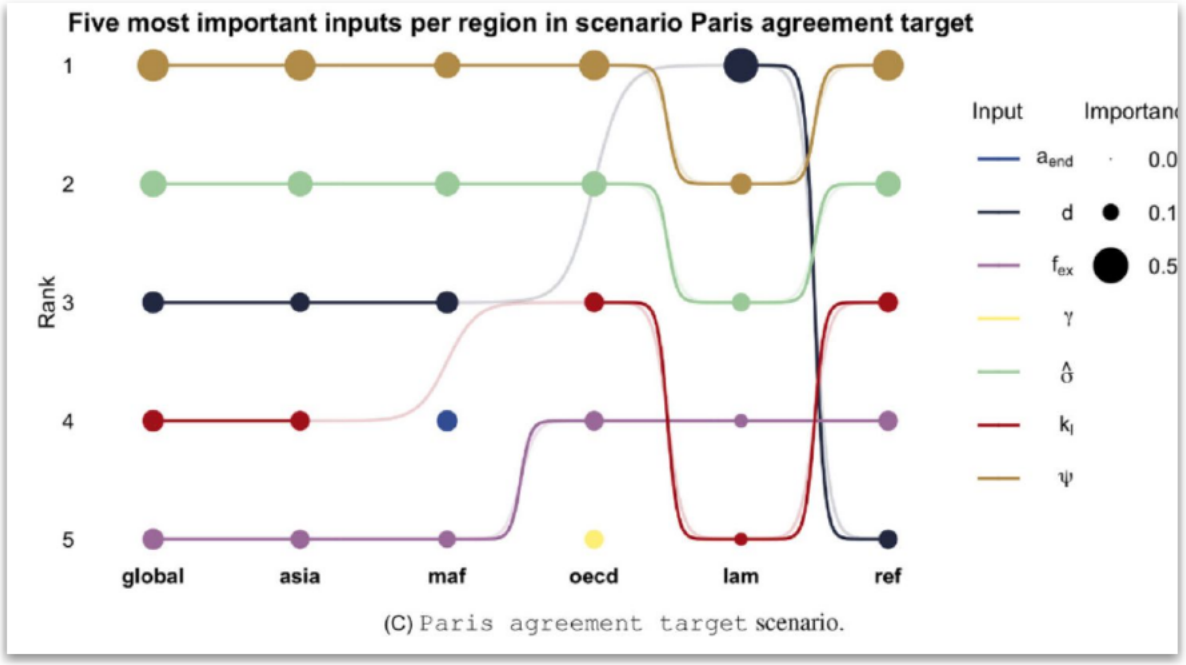
Obrigado pela atenção!

Quantificação da incerteza, análise de sensibilidade

Quantificação da incerteza

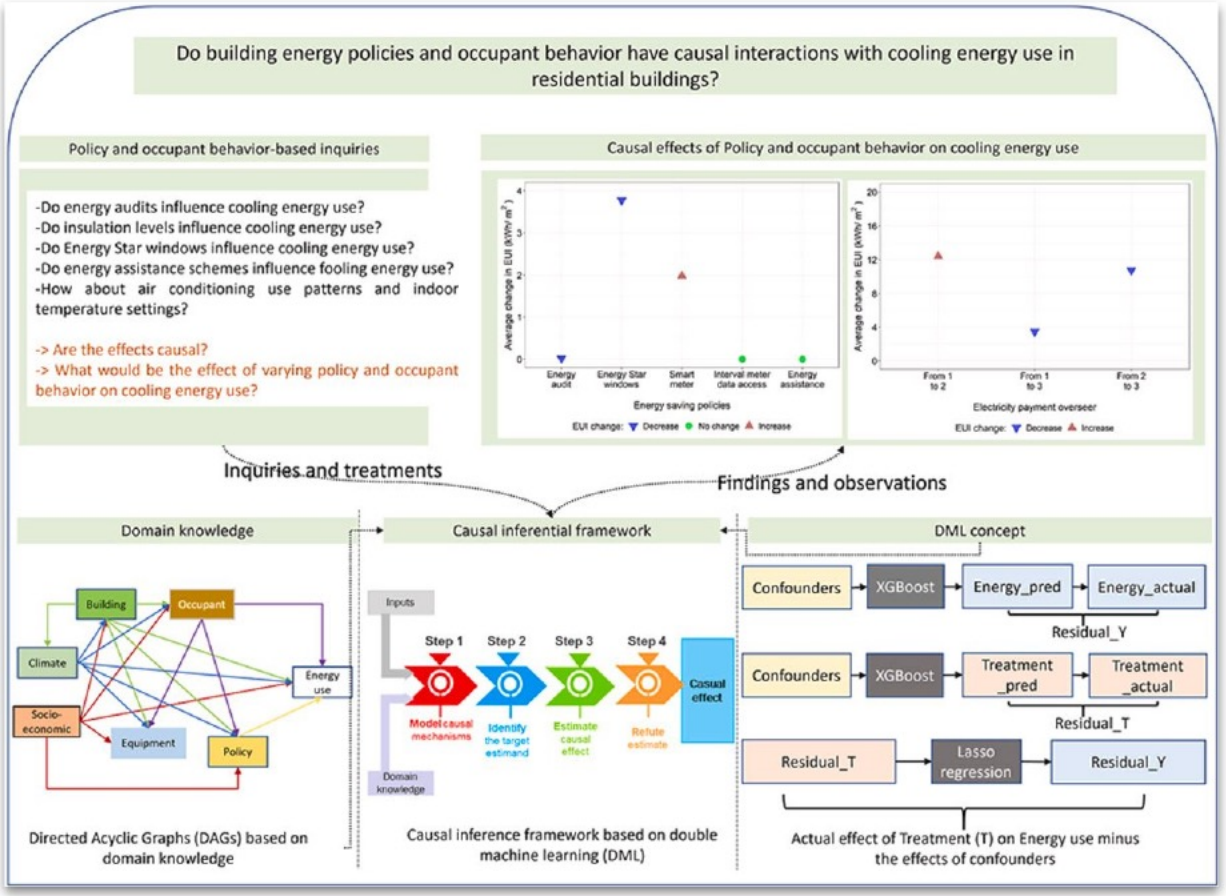


Sensibilidade e explicabilidade de caixas-pretas



Figuras de Chiani et al. Global sensitivity analysis of integrated assessment models with multivariate outputs https://onlinelibrary.wiley.com/doi/full/10.1111/risa.70002

AM causal na análise de políticas climáticas



De Nzivugira et al. Causal effects of policy and occupant behavior on cooling energy

OXFORD
JOHNS HOPKINS BLOOMBERG SCHOOL of PUBLIC HEALTH
American Journal of Epidemiology, 2025, 194, 185–194
https://doi.org/10.1093/aje/kwae171
Advance access publication date July 3, 2024
Practice of Epidemiology

A causal machine-learning framework for studying policy impact on air pollution: a case study in COVID-19 lockdowns

Claire Heffernan[1], Kirsten Koehler[2], Misti Levy Zamora[3], Colby Buehler[4], Drew R. Gentner[4], Roger D. Peng[5], Abhirup Datta*[,1]

[1]Department of Biostatistics, Bloomberg School of Public Health, Johns Hopkins University, Baltimore, MD 21205, United States
[2]Department of Environmental Health and Engineering, Bloomberg School of Public Health, Johns Hopkins University, Baltimore, MD 21205, United States
[3]Department of Public Health Sciences, School of Medicine, University of Connecticut, Farmington, CT 06030, United States
[4]Department of Chemical and Environmental Engineering, School of Engineering and Applied Science, Yale University, New Haven, CT 06520, United States
[5]Department of Statistics and Data Sciences, College of Natural Sciences, University of Texas, Austin, TX 78705, United States
*Corresponding author: Abhirup Datta, Department of Biostatistics, Johns Hopkins Bloomberg School of Public Health, 615 N. Wolfe Street, Room E3640, Baltimore, MD 21205 (abhidatta@jhu.edu)

Abstract

When studying the impact of policy interventions or natural experiments on air pollution, such as new environmental policies or the opening or closing of an industrial facility, careful statistical analysis is needed to separate causal changes from other confounding factors. Using COVID-19 lockdowns as a case study, we present a comprehensive framework for estimating and validating causal changes from such perturbations. We propose using flexible machine learning-based comparative interrupted time series (CITS) models for estimating such a causal effect. We outline the assumptions required to identify causal effects, showing that many common methods rely on strong assumptions that are relaxed by machine learning models. For empirical validation, we also propose a simple diagnostic criterion, guarding against false effects in baseline years when there was no intervention. The framework is applied to study the impact of COVID-19 lockdowns on atmospheric nitrogen dioxide (NO_2) levels in the eastern United States. The machine learning approaches guard against false effects better than common methods and suggest decreases in NO_2 levels in 4 US cities (Boston, Massachusetts; New York, New York; Baltimore, Maryland; and Washington, DC) during the pandemic lockdowns. The study showcases the importance of our validation framework in selecting a suitable method and the utility of a machine learning-based CITS model for studying causal changes in air pollution time series.

This article is part of a Special Collection on Environmental Epidemiology.

Key words: machine learning; interrupted time series; causal inference; COVID-19; air pollution.

Introduction

In 2020, lockdowns and other restrictions were implemented worldwide due to the COVID-19 pandemic. This decreased traffic volume.[1] Traffic is a major source of certain pollutants, like nitrogen dioxide (NO_2).[2] Many studies have been published on the effects of COVID-19 lockdowns on ambient levels of air pollutants, including NO_2. Gkatzelis et al[3] reviewed over 200 such papers. A variety of statistical methods and analyses were used, including measurement of percent reduction[4–8] between the lockdown period and a reference period, comparison of concentrations in the same period over multiple years,[9,10] the difference-in-differences approach,[11,12] and regression models, including comparative interrupted time series (CITS)[13,14] or prediction of counterfactual concentrations.[15,16] Models of air pollution under different emission scenarios, including chemical transport models, were also used.[17–20]

These methods often suffer from some of the following limitations. First, meteorological conditions were not always considered in previous studies. COVID-19 lockdowns in the United States were generally imposed around March 2020, and many pollutant concentrations increase in winter and decrease in summer in parts of the Northern Hemisphere due to meteorological factors, including greater emissions from combustion-based heating sources during winter.[21,22] Not including weather conditions would confound the lockdown effect estimates.

Second, many researchers do not estimate a causal effect or rely on unstated and unrealistic assumptions. The COVID-19 lockdown constitutes an example of a "sharp" policy intervention with a potential impact on air pollution. Other examples of such policies or natural experiments include copper smelt strikes in the southwestern United States,[23,24] steel mill closures in the US state of Utah,[25] and emissions reductions during the 2008 Olympic Games in Beijing, China.[26] Conclusions about a decrease in air pollution have often been based on comparisons of average concentrations during and before the experiment. It is important to assess whether such common approaches provide a causal estimate.

Third, parametric forms such as linearity are often assumed, which, if inaccurate, would bias estimation despite the inclusion of meteorological data.

The contributions of this article are 2-fold. First, we propose a flexible machine learning–based CITS framework for studying

Received: May 14, 2023. Accepted: June 26, 2024
© The Author(s) 2024. Published by Oxford University Press on behalf of the Johns Hopkins Bloomberg School of Public Health. All rights reserved. For permissions, please e-mail: journals.permissions@oup.com.

Downloaded from https://academic.oup.com/aje/article/194/1/185/7705275 by guest on 09 July 2026

Novas direções na interseção entre IA e solvers de IAM



arXiv:2312.06527v1 [cs.AI] 11 Dec 2023

Can Reinforcement Learning support policy makers? A preliminary study with Integrated Assessment Models

Theodore Wolf
University College London | Carbon Re
theo@carbonre.com

Nantas Nardelli
Carbon Re
nanta@carbonre.com

John Shawe-Taylor
University College London
j.shawe-taylor@ucl.ac.uk

María Pérez Ortiz
University College London
maria.perez@ucl.ac.uk

Abstract

Governments around the world aspire to ground decision-making on evidence. Many of the foundations of policy making — e.g. sensing patterns that relate to societal needs, developing evidence-based programs, forecasting potential outcomes of policy changes, and monitoring effectiveness of policy programs — have the potential to benefit from the use of large-scale datasets or simulations together with intelligent algorithms. These could, if designed and deployed in a way that is well grounded on scientific evidence, enable a more comprehensive, faster, and rigorous approach to policy making. Integrated Assessment Models (IAM) is a broad umbrella covering scientific models that attempt to link main features of society and economy with the biosphere into one modelling framework. At present, these systems are probed by policy makers and advisory groups in a hypothesis-driven manner. In this paper, we empirically demonstrate that modern Reinforcement Learning can be used to probe IAMs and explore the space of solutions in a more principled manner. While the implication of our results are modest since the environment is simplistic, we believe that this is a stepping stone towards more ambitious use cases, which could allow for effective exploration of policies and understanding of their consequences and limitations.

1 Introduction

Climate is a high dimensional dynamical system with strong inter-dependent components and long time dependencies, all of which interact to produce highly non-linear responses and behavior. Climate is also highly conditioned on human behavior – another greatly complex system – such that is now necessary to reason about climate change from a socio-climatic perspective [Moore et al., 2022]. To make progress towards achieving some kind of solution in the face of extreme consequences, policymakers and advisory groups employ *Integrated Assessment Models* (IAMs), state of the art models for climate change that combine knowledge about human development (such as economical theories) together with planetary sciences such as ecology and geophysics [Parson and Fisher-Vanden, 1997]. Exploring and analysing the properties of the IAMs employed for large scale assessments [Pörtner et al., 2022] - to e.g. measure fidelity against the real world – is generally intractable from a computational perspective, which leads researchers to implement poor simplifying assumptions and decrease their effectiveness [Asefi-Najafabady et al., 2021]. Smaller IAM models aim to provide an alternative by employing fewer state variables and simpler sets of dynamics, making them amenable to mathematical probing and analysis [Kittel et al., 2017, Nitzbon et al., 2017]. The

Tackling Climate Change with Machine Learning: workshop at NeurIPS 2023.

AR para encontrar novas soluções



Leveraging a Fully Differentiable Integrated Assessment Model for RL and Inference

Koen Ponse[*1] **Kai-Hendrik Cohrs**[*2]
Phillip Wozny[*3,4] Andrew Robert Williams[5,6] Tianyu Zhang[5,6] Erman Acar[7]
Yoshua Bengio[5,6,8] Aske Plaat[1] Thomas M. Moerland[1]
Pierre Gentine[9,10] Gustau Camps-Valls[2]

[*]Equal contribution
[1]Leiden University, [2]Universitat de València, [3]Vrije Universiteit Amsterdam, [4] Tilburg University, [5]Mila - Quebec AI Institute, [6]DIRO, Université de Montréal, [7]University of Amsterdam, [8]CIFAR, [9]Columbia University, [10]LEAP NSF Science and Technology Center

Abstract

Integrated Assessment Models (IAMs) such as RICE have long provided a foundation for studying the coupled dynamics of the global economy and climate system. Traditionally, these models have been used in a forward-simulation mode, with parameters hand-calibrated and dynamics treated as fixed. In this work, we introduce RICE-N-JAX, a fully differentiable implementation of the multi-region RICE-N model in JAX. Beyond significantly accelerating the training of multi-agent reinforcement learning (MARL) agents, differentiability opens new research directions, including automated calibration to historical data, recovery of latent regional behavioral parameters (e.g., risk aversion and time preferences) and sensitivity analysis of economic and technological assumptions. Moreover, it allows us to treat policy design and international negotiation mechanisms as learnable parameters within a gradient-based optimization framework. We outline new research opportunities that arise when an IAM becomes a differentiable environment and discuss implications for climate–economics modeling, machine learning for climate policy and the fusion of data- and theory-driven approaches.

1 Introduction

The impacts of climate change are already evident: ecosystems are shifting and extreme weather events are intensifying, threatening livelihoods and economic stability and underscoring the urgent need for action [Pörtner et al., 2022].

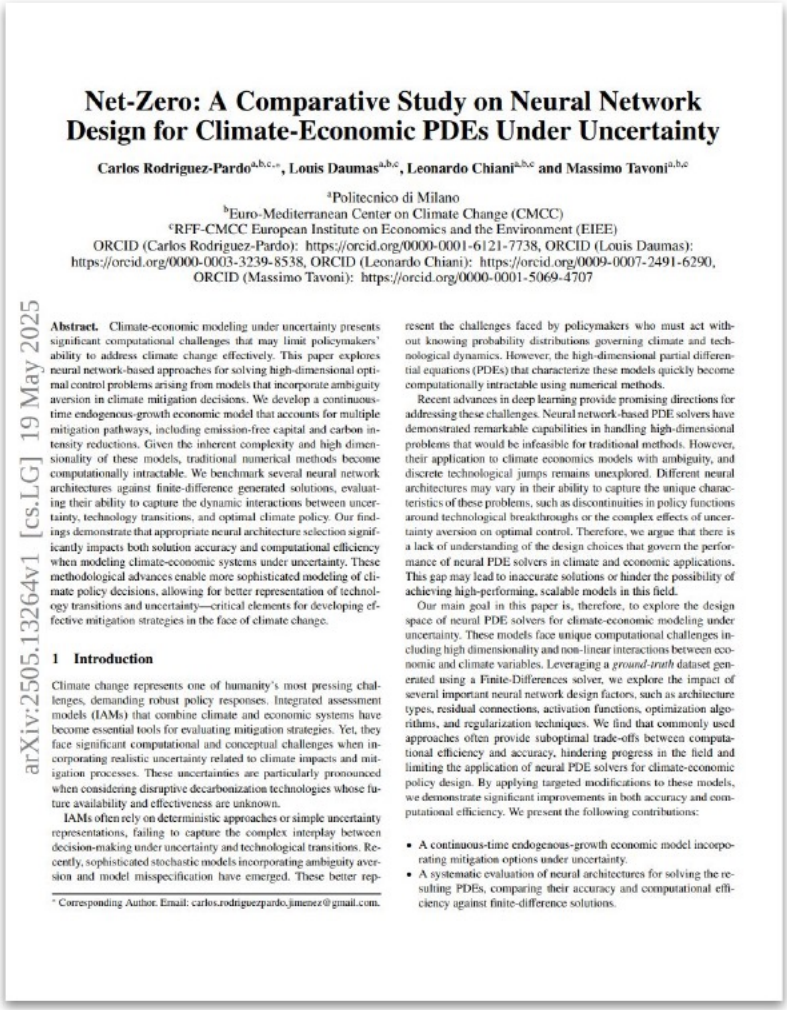
Climate change is a shared global challenge, yet mitigation entails trade-offs. Investments in low-carbon technologies and systemic transformation can constrain short-term growth and costs are unevenly distributed: wealthier nations can invest more readily, while developing countries must balance climate goals with basic development needs. This imbalance reinforces a collective-action dilemma, where self-interest threatens global progress [Gardiner, 2001, Erickson et al., 2015].

Integrated assessment models (IAMs) quantify these climate–economic trade-offs by linking CO_2 emissions, temperatures and growth dynamics. The pioneering Dynamic Integrated model of Climate and Economy (DICE) captures global interactions among population, technology, emissions and damages within a single economy [Nordhaus, 2007]. Its regional extension, the Regional Integrated model of Climate and Economy (RICE), disaggregates these processes across multiple re-

[*]Correspondence: k.ponse@liacs.leidenuniv.nl, kai.cohrs@uv.es

1st Workshop on Differentiable Systems and Scientific Machine Learning @ EurIPS 2025

IAMs diferenciáveis



arXiv:2505.13264v1 [cs.LG] 19 May 2025

Net-Zero: A Comparative Study on Neural Network Design for Climate-Economic PDEs Under Uncertainty

Carlos Rodriguez-Pardo[a,b,c,*], **Louis Daumas**[a,b,c], **Leonardo Chiani**[a,b,c] **and Massimo Tavoni**[a,b,c]

[a]Politecnico di Milano
[b]Euro-Mediterranean Center on Climate Change (CMCC)
[c]RFF-CMCC European Institute on Economics and the Environment (EIEE)
ORCID (Carlos Rodriguez-Pardo): https://orcid.org/0000-0001-6121-7738, ORCID (Louis Daumas): https://orcid.org/0000-0003-3239-8538, ORCID (Leonardo Chiani): https://orcid.org/0009-0007-2491-6290, ORCID (Massimo Tavoni): https://orcid.org/0000-0001-5069-4707

Abstract. Climate-economic modeling under uncertainty presents significant computational challenges that may limit policymakers' ability to address climate change effectively. This paper explores neural network-based approaches for solving high-dimensional optimal control problems arising from models that incorporate ambiguity aversion in climate mitigation decisions. We develop a continuous-time endogenous-growth economic model that accounts for multiple mitigation pathways, including emission-free capital and carbon intensity reductions. Given the inherent complexity and high dimensionality of these models, traditional numerical methods become computationally intractable. We benchmark several neural network architectures against finite-difference generated solutions, evaluating their ability to capture the dynamic interactions between uncertainty, technology transitions, and optimal climate policy. Our findings demonstrate that appropriate neural architecture selection significantly impacts both solution accuracy and computational efficiency when modeling climate-economic systems under uncertainty. These methodological advances enable more sophisticated modeling of climate policy decisions, allowing for better representation of technology transitions and uncertainty—critical elements for developing effective mitigation strategies in the face of climate change.

1 Introduction

Climate change represents one of humanity's most pressing challenges, demanding robust policy responses. Integrated assessment models (IAMs) that combine climate and economic systems have become essential tools for evaluating mitigation strategies. Yet, they face significant computational and conceptual challenges when incorporating realistic uncertainty related to climate impacts and mitigation processes. These uncertainties are particularly pronounced when considering disruptive decarbonization technologies whose future availability and effectiveness are unknown.

IAMs often rely on deterministic approaches or simple uncertainty representations, failing to capture the complex interplay between decision-making under uncertainty and technological transitions. Recently, sophisticated stochastic models incorporating ambiguity aversion and model misspecification have emerged. These better represent the challenges faced by policymakers who must act without knowing probability distributions governing climate and technological dynamics. However, the high-dimensional partial differential equations (PDEs) that characterize these models quickly become computationally intractable using numerical methods.

Recent advances in deep learning provide promising directions for addressing these challenges. Neural network-based PDE solvers have demonstrated remarkable capabilities in handling high-dimensional problems that would be infeasible for traditional methods. However, their application to climate economics models with ambiguity, and discrete technological jumps remains unexplored. Different neural architectures may vary in their ability to capture the unique characteristics of these problems, such as discontinuities in policy functions around technological breakthroughs or the complex effects of uncertainty aversion on optimal control. Therefore, we argue that there is a lack of understanding of the design choices that govern the performance of neural PDE solvers in climate and economic applications. This gap may lead to inaccurate solutions or hinder the possibility of achieving high-performing, scalable models in this field.

Our main goal in this paper is, therefore, to explore the design space of neural PDE solvers for climate-economic modeling under uncertainty. These models face unique computational challenges including high dimensionality and non-linear interactions between economic and climate variables. Leveraging a *ground-truth* dataset generated using a Finite-Differences solver, we explore the impact of several important neural network design factors, such as architecture types, residual connections, activation functions, optimization algorithms, and regularization techniques. We find that commonly used approaches often provide suboptimal trade-offs between computational efficiency and accuracy, hindering progress in the field and limiting the application of neural PDE solvers for climate-economic policy design. By applying targeted modifications to these models, we demonstrate significant improvements in both accuracy and computational efficiency. We present the following contributions:

- A continuous-time endogenous-growth economic model incorporating mitigation options under uncertainty.
- A systematic evaluation of neural architectures for solving the resulting PDEs, comparing their accuracy and computational efficiency against finite-difference solutions.

[*] Corresponding Author. Email: carlos.rodriguezpardo,jimenez@gmail.com.

Solvers neurais de EDP para velocidade e quantificação da incerteza