IA para las políticas públicas

Escuela de verano Climate Change AI 2026

Carlos Rodriguez-Pardo, PhD

Politecnico di Milano / EIEE / CMCC

Pregunta de calentamiento:

En tu opinión, ¿cuál es la aplicación más prometedora de la IA en la política climática?

https://partici.fi/32182658

Escuela de verano Climate Change AI 2026

Carlos Rodriguez-Pardo, PhD

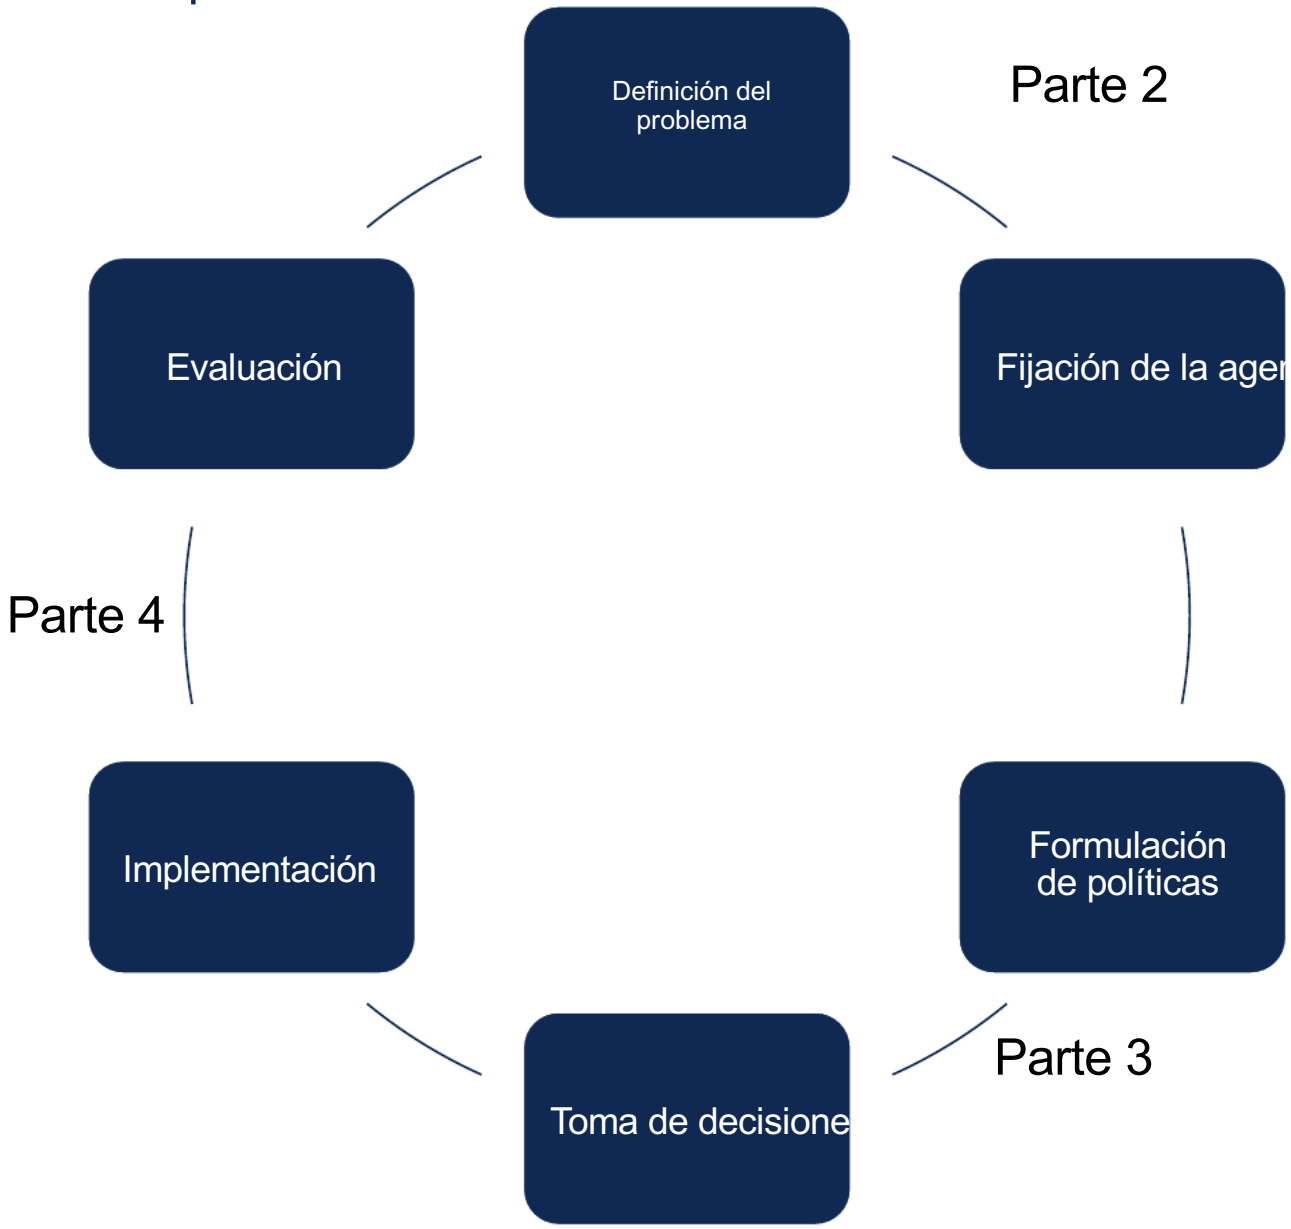
Politecnico di Milano / EIEE / CMCC

Agenda de hoy

	La pregunta	El papel de la IA
Parte 1: fundamentos	¿Cuáles son los objetivos del análisis de la política climática?	Ninguno todavía, solo una introducción
Parte 2: medir	¿Qué está pasando, qué se ha probado, quién está expuesto?	PLN sobre corpus de políticas · visión por computador y teledetección · modelos fundacionales geoespaciales / del sistema Tierra
Parte 3: modelizar futuros	¿Qué podría pasar con distintas políticas y actores?	Emuladores de IAM · solvers neuronales de EDP · AR y AR multiagente
Parte 4: evaluación y despliegue	¿Funcionó una política? ¿Se aceptará? ¿Es fiable?	AA causal · LLM · modelos basados en agentes

El ciclo de las políticas públicas

¿Dónde puede ayudar la IA a la política climática?



¿Qué instituciones participan en la toma de decisiones?

Internacionales: CMNUCC, IPCC, UE

Gobiernos nacionales y regionales

Gobiernos locales

Actores sectoriales: eléctricas, agencias de transporte

Actores privados: aseguradoras, empresas, bancos, certificadores, etc.

- Actores distintos con problemas y prioridades distintos
- Escalas temporales distintas (políticas a décadas vs. resultados trimestrales)
- Palancas distintas: impuestos al carbono, cuota de renovables, % de vehículos eléctricos en el transporte público
- Resoluciones espaciales distintas (políticas continentales, urbanismo, rehabilitación de edificios…)

La IA puede ayudar a la formulación de políticas en todas estas esc



¿Qué busca lograr el análisis de la política climática?

Estimar daños y riesgos

¿Qué gravedad, dónde, para quién y cuándo?

Comparar opciones, evaluar compensaciones

Mitigación, adaptación o aceptación de pérdidas.

Diseñar instrumentos

Impuestos, normas, subvenciones, planes, mercados.

Evaluar lo que funcionó

¿Cambiaron algo nuestras políticas, y en qué condiciones?

Decidir en la incertidumbre

Decisiones robustas pese a grandes incógnitas.

Respuestas políticas al cambio climático



Mitigación

Objetivo: evitar o reducir la concentración de GEI en la atmósfera

Ejemplos:

- Normas sobre renovables
- Mandatos de vehículos eléctricos
- Captura y almacenamiento de carbono
- Impuestos al carbono
- Electrificación



Adaptación

Objetivo: reducir los daños inevitables del calentamiento

Ejemplos:

- Defensas contra inundaciones
- Aislamiento de edificios
- Sistemas de alerta temprana
- Infraestructuras



Pérdidas y daños

Objetivo: compensar lo que no puede evitarse ni adaptarse

Ejemplos:

- Financiación climática
- Atribución

El análisis de políticas debe comparar las tres y entender su coste, sus compensaciones y su viabilidad. Para ello se necesitan instrumentos como el coste social del carbono y estimaciones de daños.

La caja de herramientas de instrumentos políticos

Fijación de precios del carbono

Impuestos y comercio de emisiones

Regulación y normas

Prohibiciones, códigos, normas de eficiencia

Subvenciones e inversión

I+D pública, renovables, rehabilitación

Política industrial

Estrategia industrial verde

Planificación de la adaptación

Reducción del riesgo y resiliencia

Financiación climática

Quién paga, quién es compensado

Mercados de carbono y compensaciones

Créditos, MRV, integridad

Estas políticas pueden competir por los mismos presupuestos

El coste social del carbono

El coste social del carbono es el daño económico causado por una tonelada adicional de CO2 emitida, expresado en dinero actual.

+1 tonelada de CO2 emitida hoy

↓

Provoca más calentamiento global durante siglos

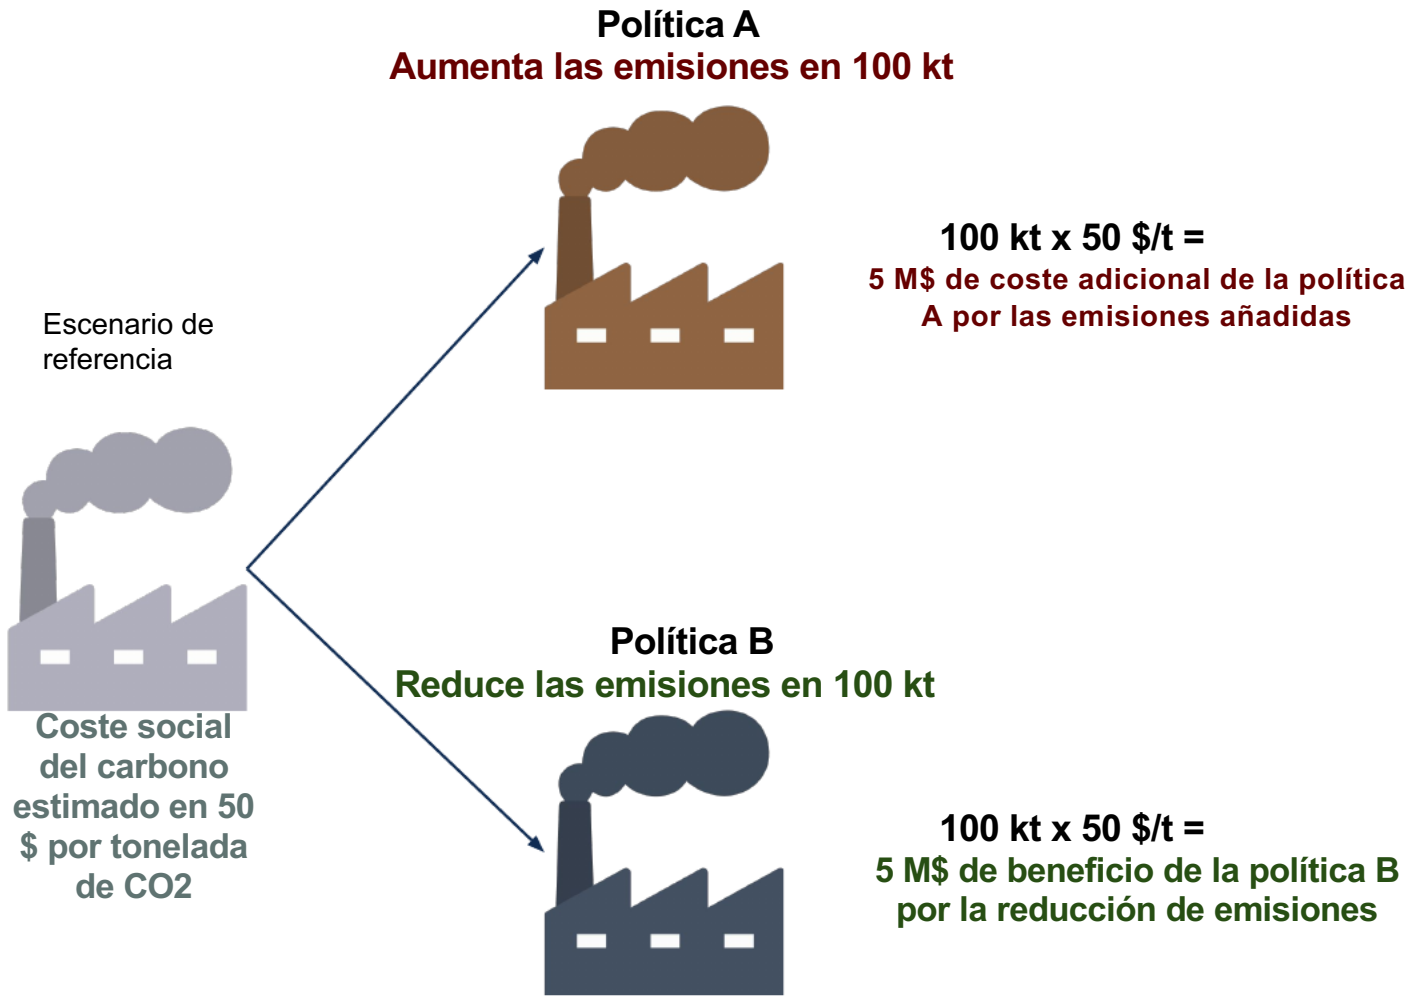
↓

Que causa daños futuros: salud, cultivos, capital…

↓

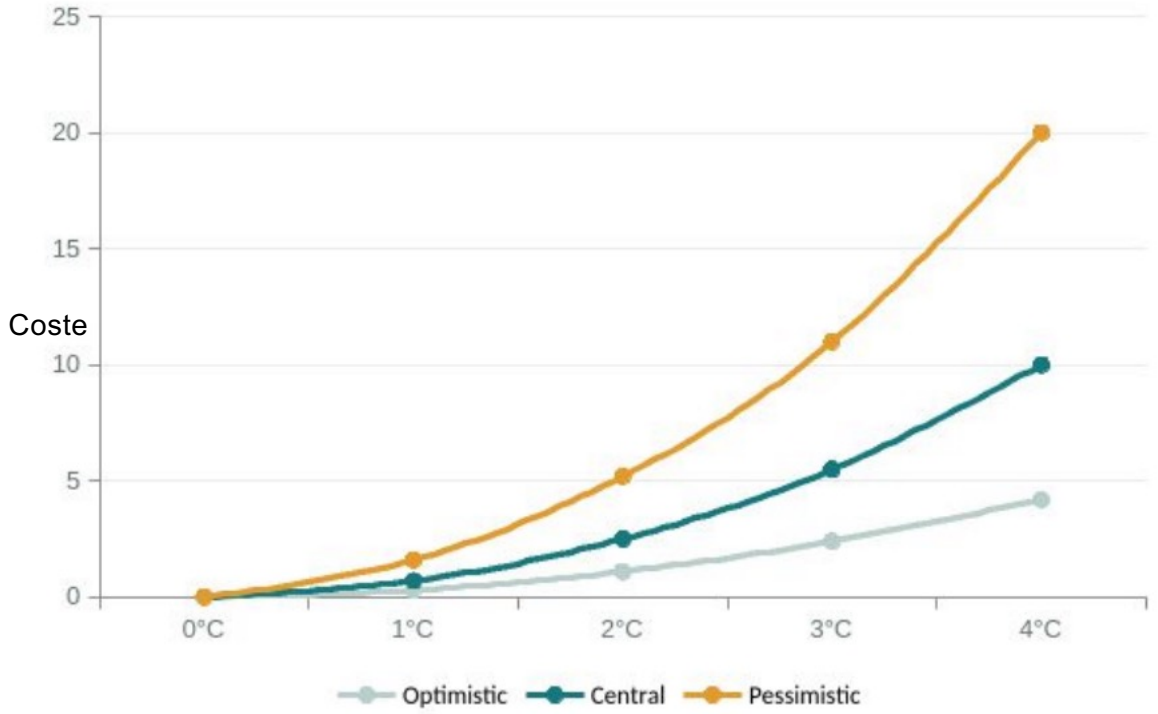
Descontar esos daños a valor presente: $ / CO2

Todas estas flechas esconden modelos, supuestos e incertidumbres



Funciones de daño

- Traducen el calentamiento global en pérdidas económicas
- Estimadas con datos históricos y extrapoladas mucho más allá
- Estas funciones se usan mucho en los modelos de evaluación integrada y otros instrumentos de análisis de políticas
- La forma funcional, los puntos de inflexión y los supuestos de adaptación están en discusión
- Su incertidumbre también tiene implicaciones políticas



¿Qué papel tiene la IA en todo esto?

Datos

Procesar fuentes de datos complejas y extraer conocimiento: imágenes satelitales, documentos de políticas, redes, sensores, datos económicos…

PARTE 2: MEDIR

Modelos

Ayudar a modelizar sistemas socioeconómicos y climáticos complejos:

- Modelos fundacionales
- Modelos de evaluación integrada
- Aprendizaje por refuerzo

PARTE 3: MODELIZAR FUTUROS

Decisiones

- Estimar la posible eficacia de distintas políticas
- Entender si las políticas pasadas fueron eficaces y en qué condiciones
- Optimizar la asignación de recursos

PARTE 4: EVALUAR Y DESPLEGAR

Referencias útiles:

- 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

Test n.º 1:

¿Qué información necesitas para estimar el coste social del carbono?

Trayectorias de emisiones

¿Hacia dónde va el mundo? Escenarios, incertidumbres

Respuesta climática (TCRE)

¿Cuánto calentamiento por tonelada adicional de CO2?

Función de daño

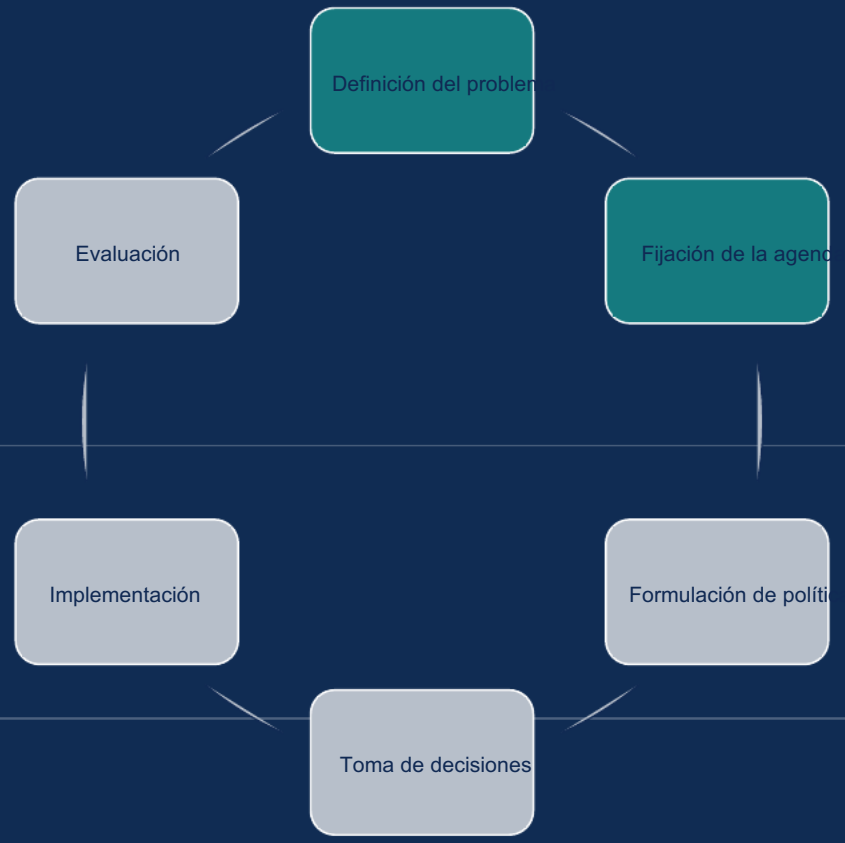
¿Cuál es el coste de cada unidad adicional de calentamiento?

Descuento

¿Cuánto nos importa el futuro en comparación con el presente?

Parte 2: medir el mundo de las políticas y los impactos climáticos

- ¿Qué políticas existen?
- ¿Qué está pasando en el mundo?
- ¿Quién está expuesto?



¿Qué necesitamos saber para diseñar políticas eficaces?

¿Qué políticas existen hoy?

- Bases de políticas
- Seguimiento de políticas

¿Dónde se producen las emisiones?

- Inventarios
- Estimaciones

¿Quién está expuesto? ¿Quiénes son los actores clave?

Mapeo de la vulnerabilidad

¿Qué dice la literatura?

Mapas de evidencia, revisiones,

¿Dónde están las lagunas de evidencia?

¿Dónde están las incertidumbres? ¿Qué evidencia falta?

¿Cómo saber qué se ha probado y estudiado antes?

Armonización de bases de datos de políticas

Entrada:

- Documentos nacionales fragmentados
- Bases mundiales, regionales y sectoriales

Métodos

- Procesamiento del lenguaje natural,
- conocimiento experto, aprendizaje con reglas
- Aprendizaje semisupervisado

Resultado:

- Paneles de políticas comparables entre países
- Quién adoptó qué política y cuándo
- Formato común, alineado con el IPCC

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

Mapeo de la literatura científica

Entrada:

- Cientos de miles de artículos sobre política climática
  - Imposible de leer y analizar para una persona o un equipo de investigación

Métodos

- Procesamiento del lenguaje natural
- Clasificación de textos
- Mapeo temático

Resultado:

- Mapas de evidencia
- Lagunas en la literatura, evidencia escasa

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

Medir lo que ocurre, con una resolución útil para las políticas

Medición de alta resolución y calidad del aire

- Estimaciones con AA de emisiones urbanas de GEI subnacionales
  - Yu et al. https://www.nature.com/articles/s41597-026-06691-9
- Clasificación con AA de estaciones de calidad del aire
  - Renna et al (https://www.nature.com/articles/s41597-026-06797-0.pdf)

Leer y comprender documentos de políticas

- PLN para clasificar programas electorales (Sanford et al. doi:10.1017/S0007123425100719)

El reto de la integración

- ¿Cómo vincular políticas, sectores, emisiones, territorios, poblaciones y resultados? ¿Cómo
- convertir datos y modalidades dispersos en evidencia útil para las políticas?

Referencias:

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

La cadena de modelización de impactos



La IA ya acelera estos eslabones

Poco o ningún impacto de la IA

Datos débiles, mayor laguna científica

Las clases de IA para la meteorología e IA para las ciencias del clima de la escuela CCAI26 tratarán estos temas a fondo. Aquí nos centramos en los impactos climáticos y en cómo entran en las decisiones políticas

Por qué importa la resolución

Celda global

~100-1000km

- ¿Va un país por buen camino?
- ¿Cuáles son los patrones climáticos de esta región?

Regiones

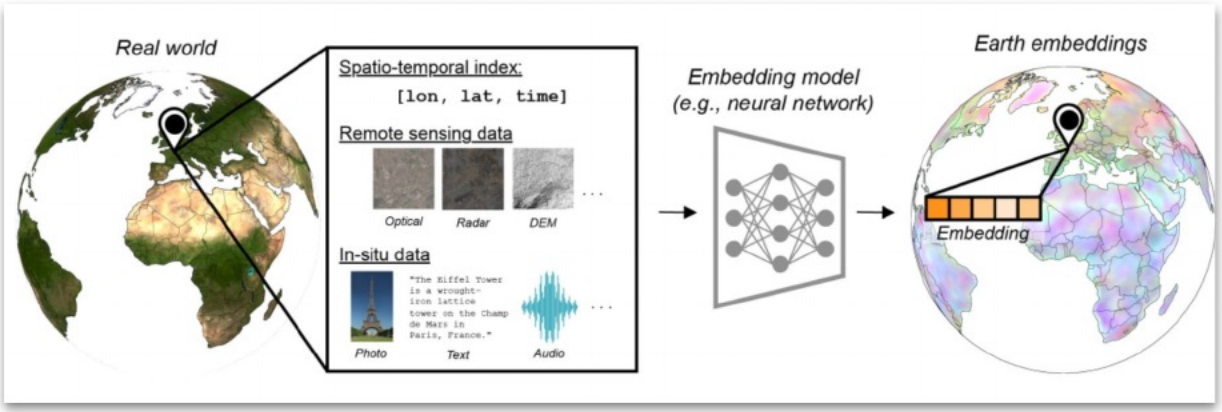
~10-100km

- ¿Adónde deben ir los fondos de adaptación?
- ¿Qué ciudades son más vulnerables a los extremos?
- ¿Qué poblaciones son más vulnerables?

Manzanas urbanas

~10m-10km

- ¿Qué barrios necesitan protección contra inundaciones?
- ¿De dónde vienen las emisiones?
- ¿Dónde plantar árboles?



Los embeddings geoespaciales y los modelos fundacionales del sistema Tierra conectan bien las resoluciones: se aprende una representación una vez y se reutiliza en varias tareas de análisis de impactos, reconstrucción y exposición.

Ejemplos: 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/)

Mejores datos cambian decisiones reales

Focalización de la adaptación

¿A quién se protege primero y a qué coste?

Financiación climática y pérdidas y daños

Estimaciones de daños más precisas mejoran las decisiones financieras

Ecosistemas y naturaleza

¿Qué impactos climáticos sufre la biodiversidad y dónde? ¿Qué especies son las más afectadas?

Seguros

Mejoras en tarificación, asegurabilidad, cobertura y gestión del riesgo

Planificación de infraestructuras

¿Qué construir y cómo? ¿Qué probabilidad hay de grandes inundaciones, olas de calor, nevadas extremas?

Evaluación distributiva

¿Quién será el más afectado por el cambio climático? ¿Qué impactos tendrá en la igualdad y la salud?

Ejemplo: asignación de fondos de adaptación

Con datos gruesos y de baja calidad:

- Los fondos pueden seguir tendencias, sesgos, lobbies
- Los fondos pueden no llegar a las poblaciones que más los necesitan
- El dinero público se asigna de forma subóptima

Con datos de impacto localizados de alta resolución

- Los fondos siguen la exposición y la vulnerabilidad
- Los fondos se asignan de forma robusta y defendible
- Los decisores entienden mejor las compensaciones y los límites

La medición no es neutral

Falsa precisión

- Los resultados de alta resolución parecen exactos, pero muchas veces no lo son
- Muchos conjuntos de datos comunes (p. ej. ERA5) ocultan supuestos y decisiones de modelización, y modelos
- Las incertidumbres se acumulan de forma invisible

La disponibilidad de datos no es uniforme

- La cobertura de datos suele ser menor justo donde la vulnerabilidad es mayor
- Por eso los modelos extrapolan y son menos precisos en las regiones más vulnerables
- P. ej.: 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 no significa eficaz

- Las bases de políticas registran lo que está escrito, no necesariamente lo que fue eficaz

Pérdidas ocultas

- Algunas variables son más difíciles de medir que otras. Las funciones de daño pueden pasar por alto
  - Los daños no de mercado
  - La distribución de los daños
  - Las pérdidas culturales
  - Los daños ecológicos

https://partici.fi/32182658

Test n.º 2

¿Por qué una función de daño global o datos de emisiones de alta resolución podrían no bastar para decidir adónde deben ir los fondos de adaptación?

Precisión ≠ relevancia

Modelos y datos pueden ser menos precisos donde más importa la precisión

Vulnerabilidades omitidas

Un mismo extremo climático puede ser un desastre para una comunidad y una simple molestia para otra

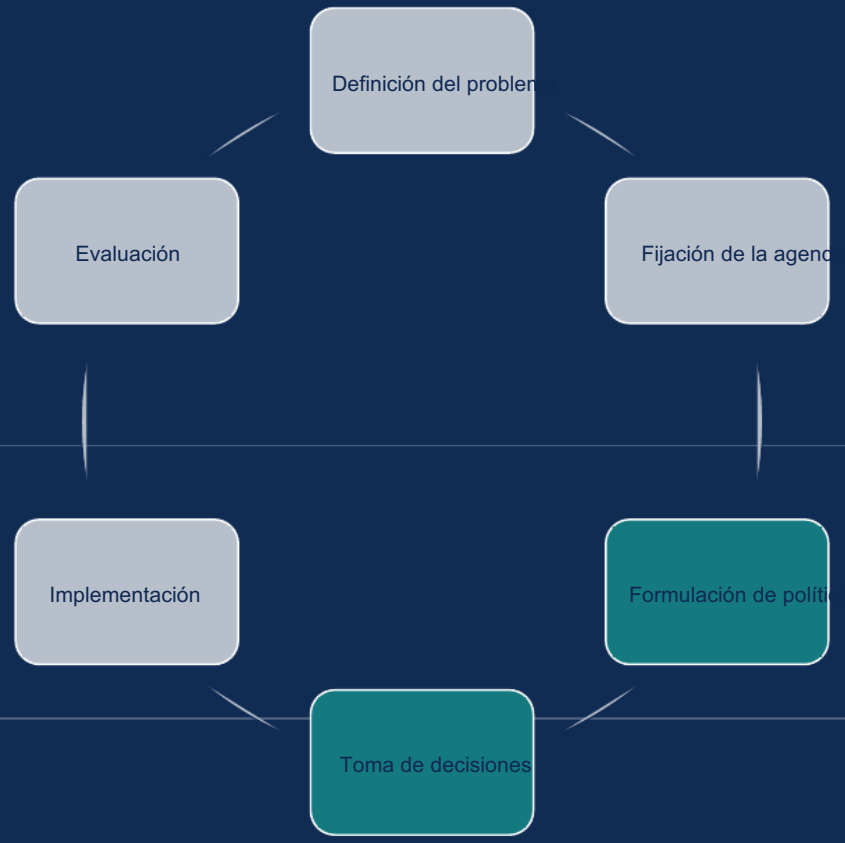
Elecciones normativas

¿A quién priorizar? ¿A la mayoría, a los más vulnerables? ¿Eficiencia o equidad?

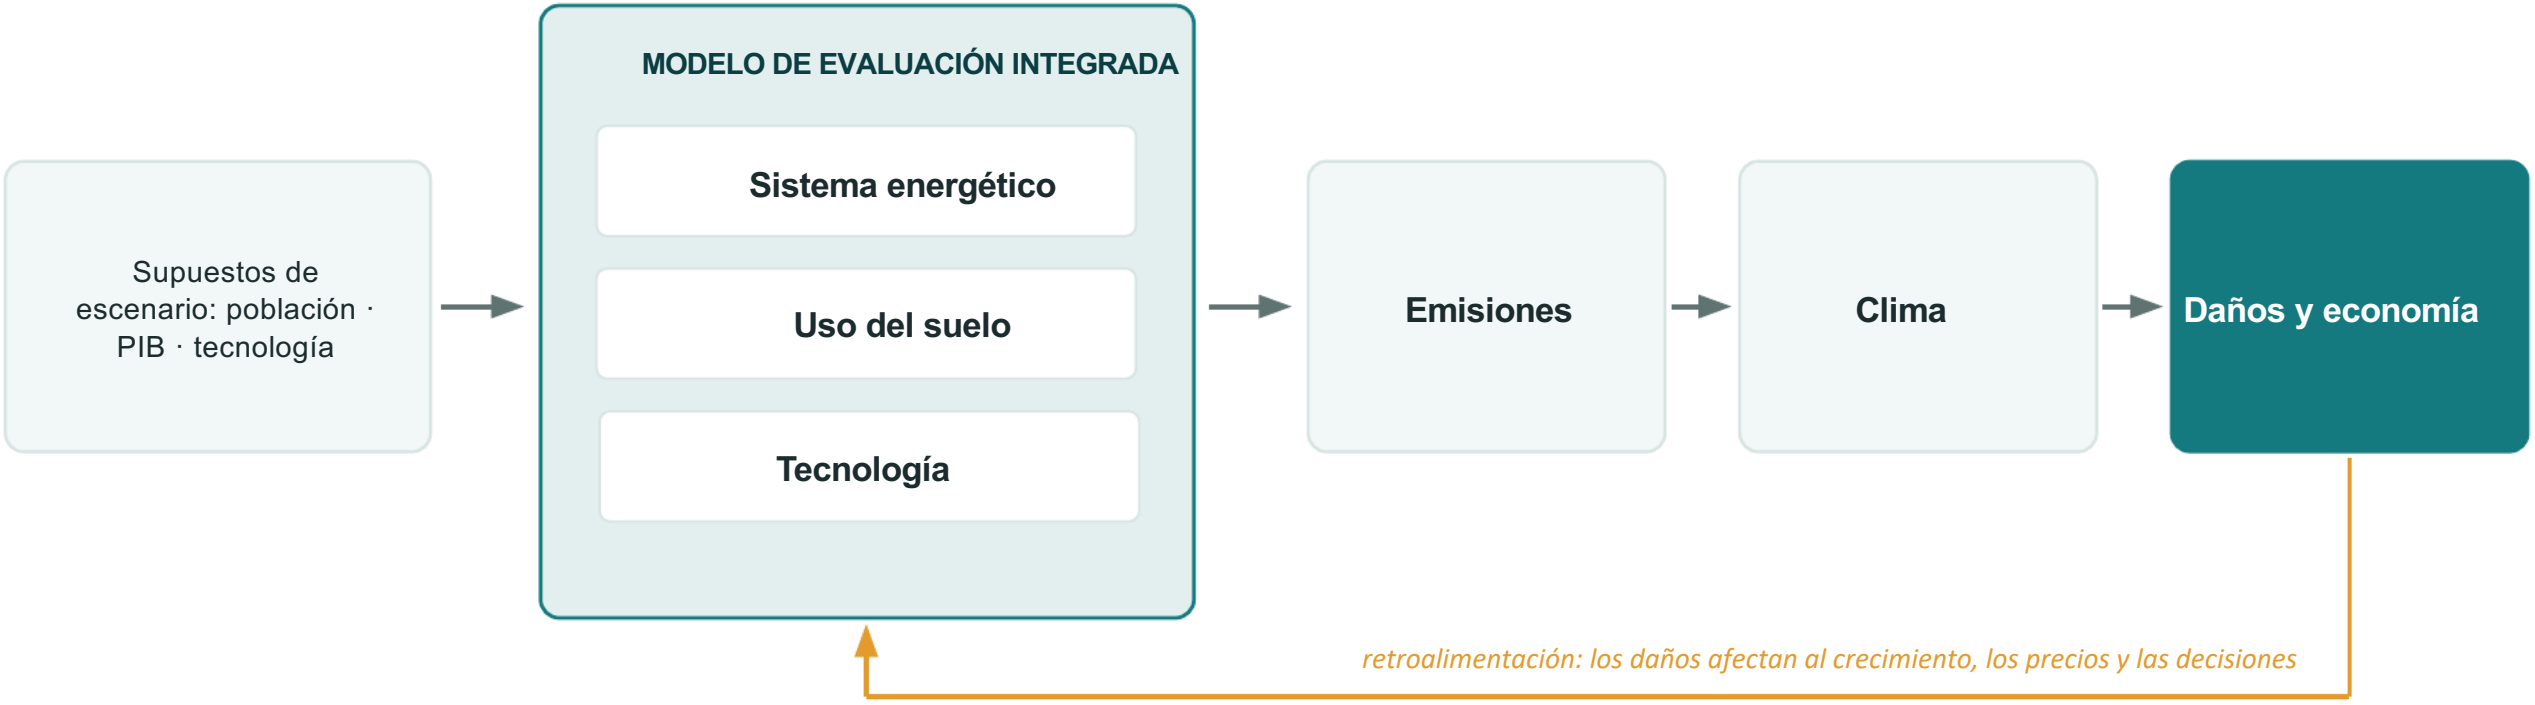
Mejores datos son necesarios pero no suficientes:
ayudan a acotar los debates, pero no pueden decidir qué preguntas son relevantes para las políticas

Parte 3: modelizar futuros y diseñar opciones de política

- ¿Cómo modelizar el clima y la economía futuros?
- ¿Cómo modelizar los múltiples actores de la política climática?
- ¿Cómo asegurar que nuestros modelos sean fiables?



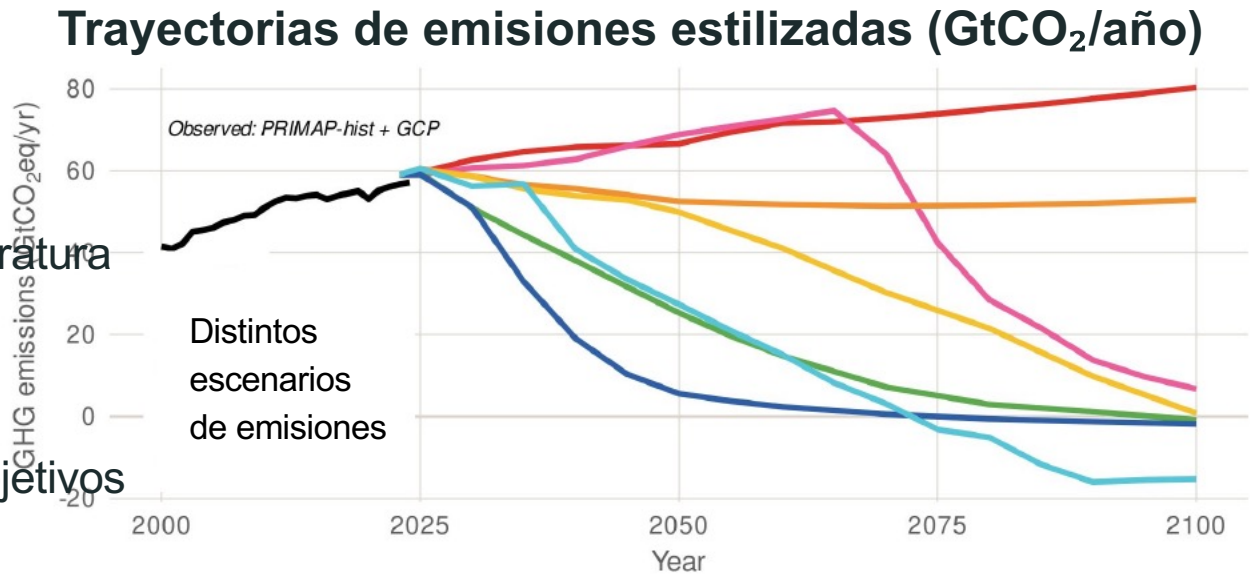
Modelos de evaluación integrada (IAM)

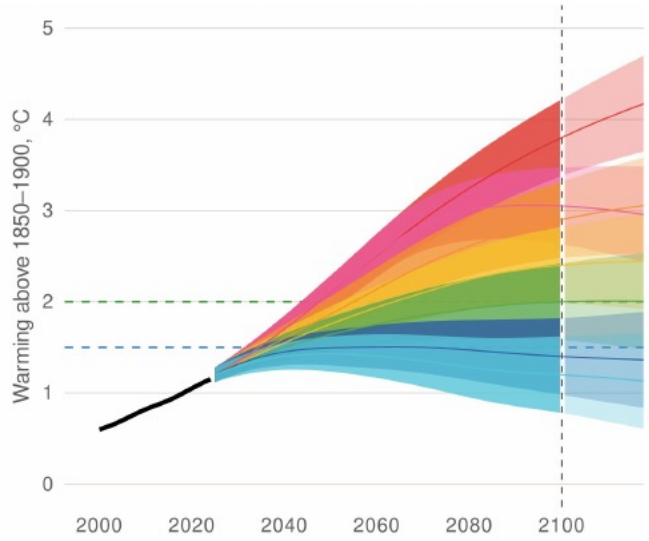


- Los IAM modelizan mundos estilizados: útiles para preguntas «¿y si…?», no para prever
- Hay distintas familias de IAM:
  - IAM de coste-beneficio (DICE)
  - IAM detallados por procesos (REMIND, WITCH)

Qué aportan los IAM

- Trayectorias de menor coste hacia los objetivos de temperatura
- Carteras tecnológicas: cuánta eólica, CAC, nuclear, cuándo y a qué coste
- Trayectorias del precio del carbono coherentes con los objetivos
- Reparto regional del esfuerzo y su (in)equidad
- Bases de escenarios del IPCC





IAMC
Integrated Assessment Modeling Consortium
Founded 2007

ipcc
INTERGOVERNMENTAL PANEL ON climate change

IA para emular los IAM

- Los IAM son útiles pero muy costosos computacionalmente
- Los conjuntos de modelos para medir la incertidumbre pueden volverse inabordables
- Los emuladores de AA pueden ayudar:
  - Aprenden a relacionar entradas y salidas de un IAM
  - Una vez entrenados, responden al instante
- ML-IAM permite explorar escenarios de forma interactiva
  - P. ej. Shin et al., ML-IAM v1.0 · Li et al. 2025, aprendizaje profundo para variables de escenarios mundiales de mitigación (https://egusphere.copernicus.org/preprints/2026/egusphere-2025-5305/)

1

Escenario de IAM
de horas a días de cómputo

10 000+

evaluaciones del emulador en el mismo tiempo

(ilustrativo)

Aprendizaje por refuerzo: las políticas como secuencias de decisiones



- La política climática es secuencial: actuar, observar, ajustar, durante décadas
- El AR explora trayectorias de políticas, no ajustes aislados
- Acoplado a los IAM, el AR puede llegar a zonas del espacio de soluciones que los solvers clásicos nunca visitan
- **Resultado útil: estrategias candidatas sorprendentes, nunca exploradas**

Agentes que compiten y cooperan

- Muchos actores, con objetivos y prioridades distintos y cambiantes (países, empresas, reguladores)
- Cooperan, compiten, se aprovechan o se ignoran
- El AR multiagente hace visibles y cuantificables los incentivos desalineados y los fallos de coordinación

	B reduce	**B se aprovecha**
A reduce	Todos pagan, gana el planeta	A paga, B se beneficia
A se aprovecha	B paga, A se beneficia	**Nadie paga: todos pierden**

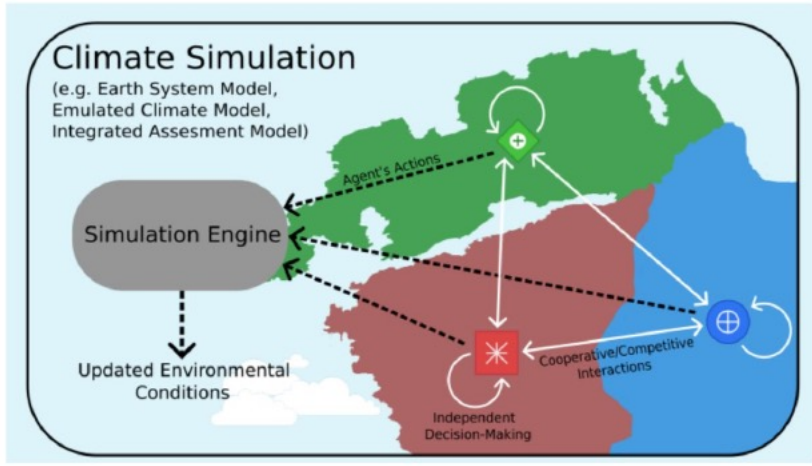
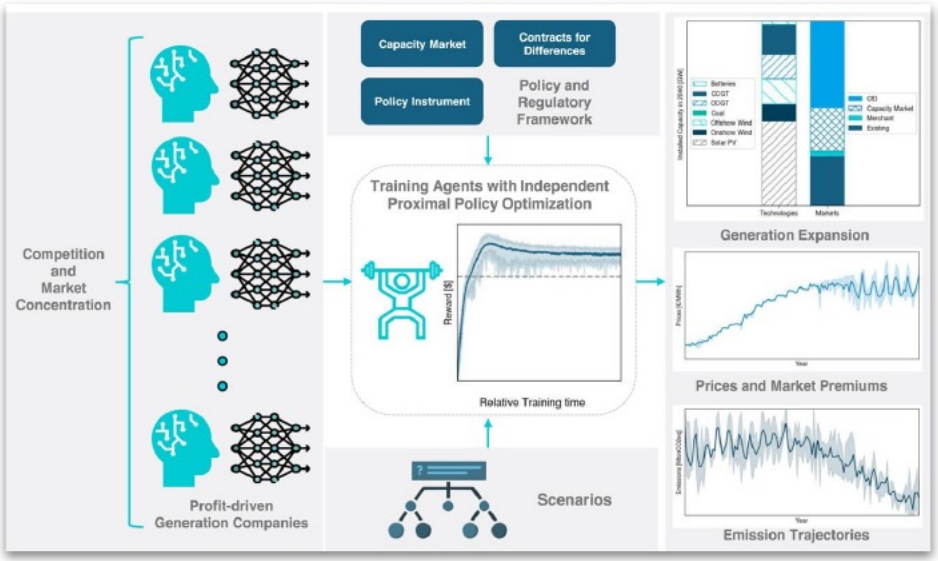


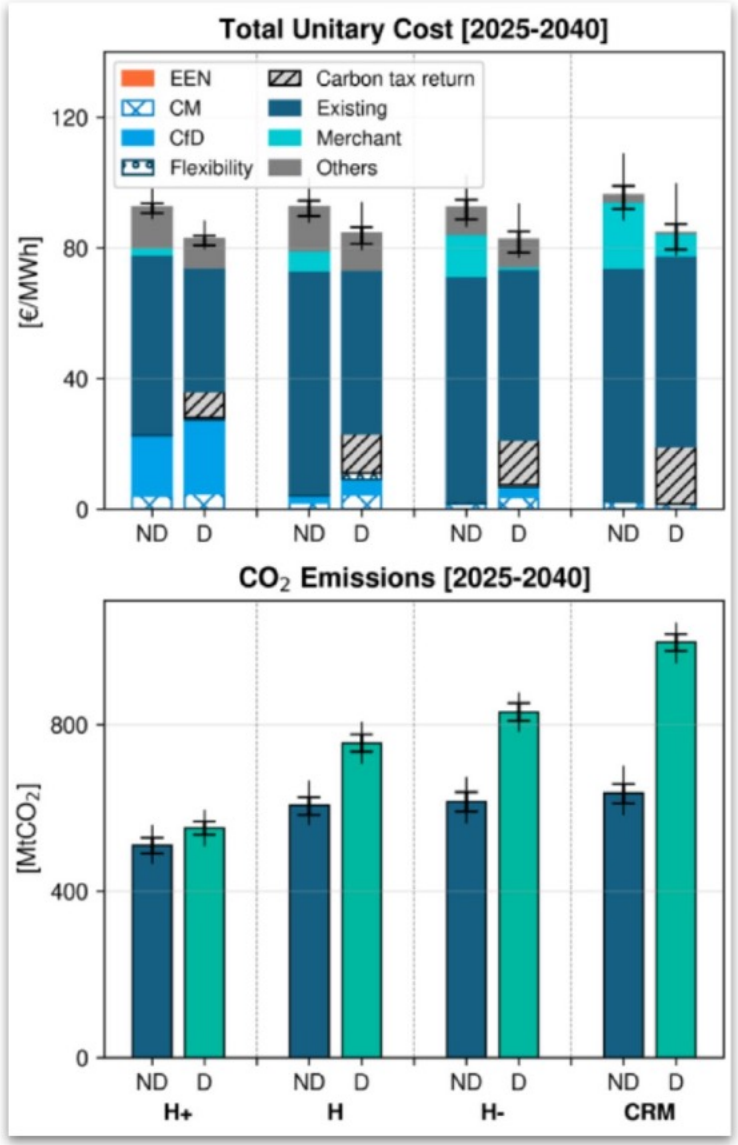
Figura de Multi-Agent Reinforcement Learning Simulation for Environmental Policy Synthesis (Rudd-Jones et al.)

AR multiagente para diseñar la política del mercado eléctrico a largo plazo

- **Pregunta: ¿qué diseños de mercado logran una descarbonización profunda a precios aceptables?**
- **Enfoque: los generadores son agentes que aprenden, pujan e invierten con distintas reglas de mercado**
- Los agentes revelan comportamientos estratégicos que el análisis de equilibrio no ve
- Las decisiones de diseño cambian visiblemente los precios y la descarbonización



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

Lo que el AR no puede decidir



Los valores no se aprenden

- El AR optimiza dentro de un problema
- formalizado. Lo que la sociedad debe valorar no es algo que el AR pueda o deba optimizar



Una única recompensa no puede modelizar objetivos complejos, interconectados y multidimensionales

- Las funciones de valor de los entornos de AR pueden aplanar objetivos plurales y en disputa.



Sesgo de visibilidad

- Los espacios de estados y acciones solo codifican lo fácilmente medible y accionable.
- Todo lo demás se ignora por diseño



Muchas restricciones no pueden modelizarse del todo

- Las normas legales, culturales y sociales, las restricciones políticas y los límites institucionales son clave para la viabilidad de las políticas

https://partici.fi/32182658

Test n.º 3

Una política de AR funciona bien en el simulador. ¿Por qué podría rechazarla un responsable político?

Brecha simulación-realidad

El mundo del IAM está infraespecificado: lo óptimo en él puede no trasladarse al mundo real

Objetivos no modelizados

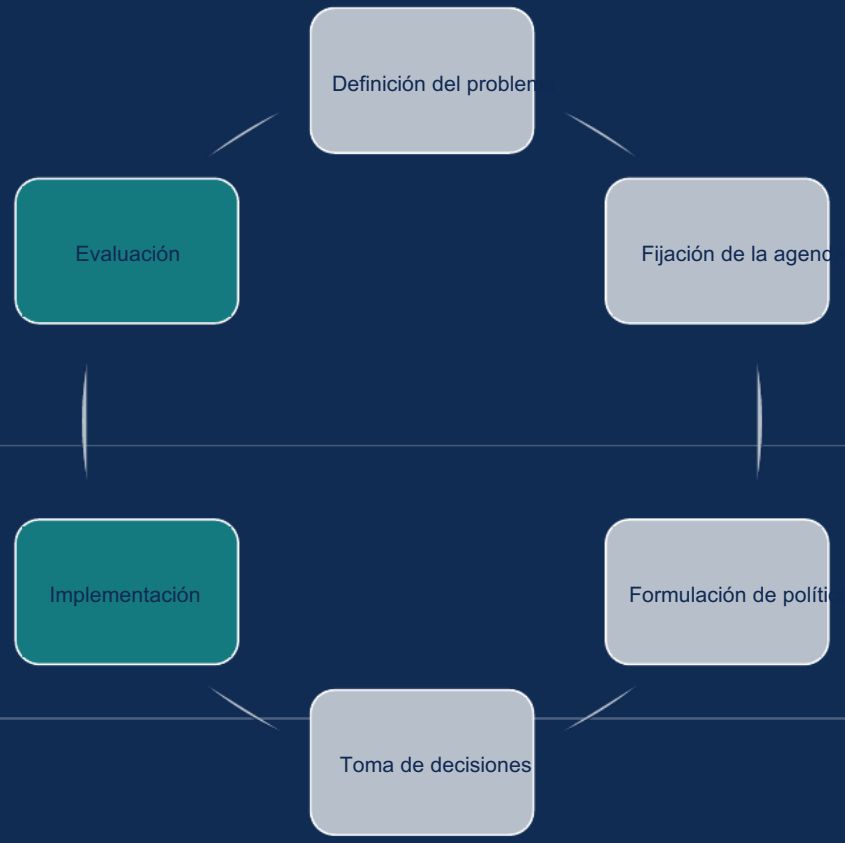
La equidad, la legalidad y la aceptabilidad social no estaban en la recompensa. ¿Qué significa que una política funcione bien?

Confianza y rendición de cuentas

¿Quién responde de las decisiones derivadas del AR? ¿Sobreviven las estrategias inexplicables al escrutinio institucional?

Parte 4: evaluación y despliegue

- ¿Cómo sabemos si una política funcionó?
- ¿Podemos estimar si una política será popular o socialmente aceptable?



¿Cómo sabemos si una política funcionó? Inferencia causal

Experimentos aleatorizados

- El patrón de referencia
- Asignar la política al azar y comparar grupos.
- Científicamente robusto, pero difícil en el mundo real.
- P. ej.: ¿cómo aleatorizar un impuesto al carbono entre países?

Diferencias en diferencias

- Comparar la evolución en el tiempo de unidades con y sin la política.
- Muy habitual en la literatura

Control sintético

- Sin una buena unidad de comparación → construir un «gemelo» de una unidad tratada a partir de un conjunto de unidades no tratadas.
- P. ej. el impuesto al carbono sueco: emisiones del transporte frente a una «Suecia sintética» construida con otros países de la 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

Variables instrumentales

- Encontrar una palanca que mueva la variable de política sin otra vía hacia el resultado.
- P. ej.: velocidad del viento → más generación renovable → ¿qué pasa con la emisiones? El tiempo es aleatorio: la respuesta es causal.

El AA causal puede ampliar estas herramientas: detectar factores de confusión de alta dimensión, efectos heterogéneos y no lineales, formas funcionales flexibles, etc.

Predecir no es evaluar causalmente

Predicción

P. ej.: «¿Cuáles serán las emisiones el año que viene?»
Muy útil para planificar y hacer seguimiento, pero poco útil para saber si una política es eficaz

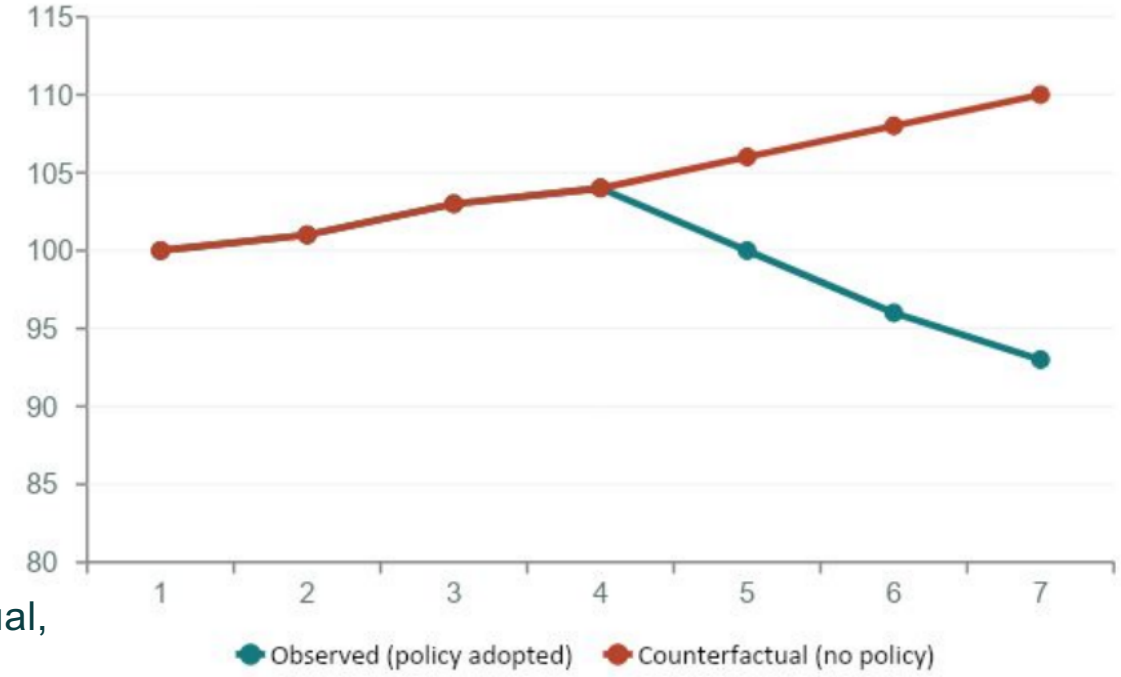
Evaluación causal

«¿Qué cambió este impuesto al carbono?»: se necesita un contrafactual,

El AA amplía la caja de herramientas de la inferencia causal a factores de confusión de alta dimensión y efectos heterogéneos.

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

El contrafactual, ilustrado (estilizado)



Dos formas de poner precio al carbono



Impuestos al carbono

Fijamos el precio, la cantidad se ajusta

- Costes previsibles para las empresas
- Emisiones totales inciertas



Límites y comercio (ETS)

Fijamos la cantidad, el precio se ajusta

- Límite de emisiones seguro
- Precios volátiles
- Crea un mercado de derechos

En ambos casos, los mercados plantean un problema de medición y verificación:

- Hay que contar, verificar y dar fiabilidad a las toneladas, incluidas compensaciones de bosques, granjas y fábricas al otro lado del mundo.
- Este problema de verificación puede abordarse con IA

La IA a lo largo de la cadena de créditos de carbono



Límites de la IA en los mercados de carbono

Falsa precisión contable

- Una tonelada «medida» con un modelo de AA puede acumular incertidumbres: no puede tratarse como una estimación exacta

Manipulación de métricas

- Las métricas medibles invitan a la manipulación
- Los proyectos de captura de carbono se optimizarán para lo que premien los modelos

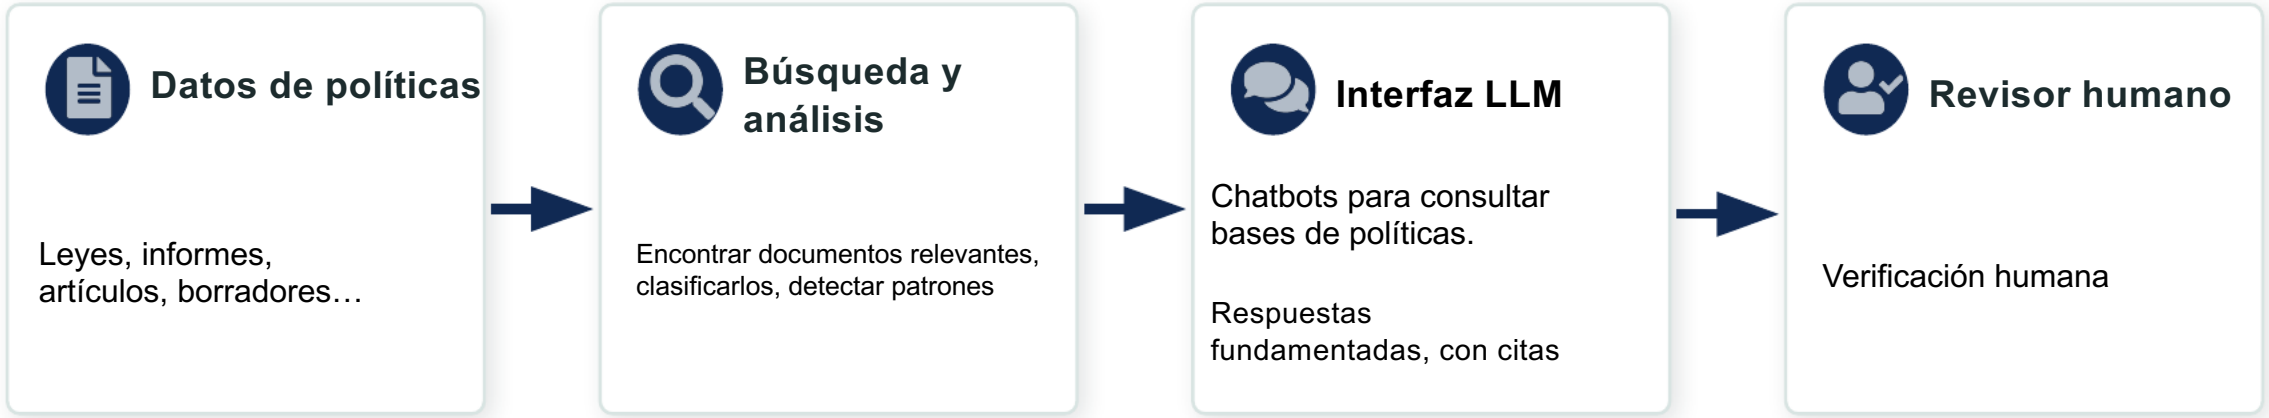
Visión de túnel

- Optimizar la tonelada de CO_2 medible deja de lado los cobeneficios de biodiversidad, justicia y gobernanza

Verificación de caja negra

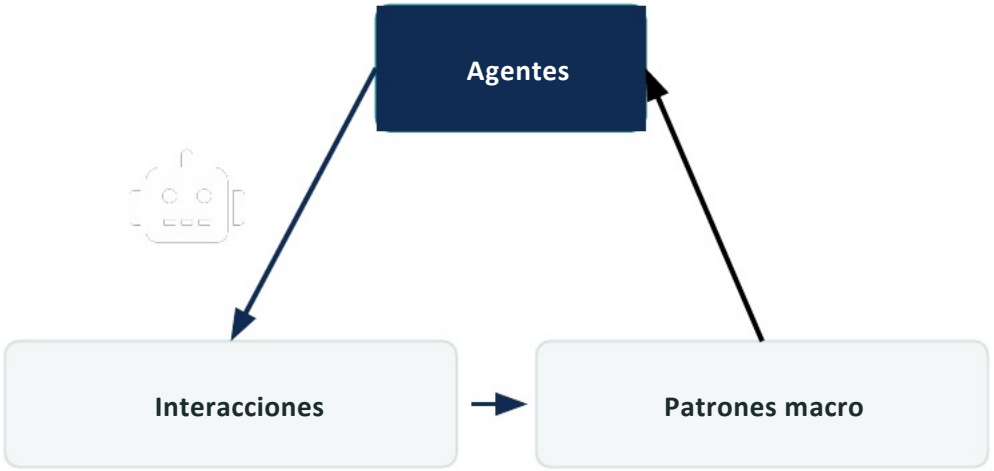
- Los modelos propietarios no pueden auditarse
- La confianza en los mercados de carbono no debe depender de acreedores privados

Los LLM en el trabajo sobre políticas

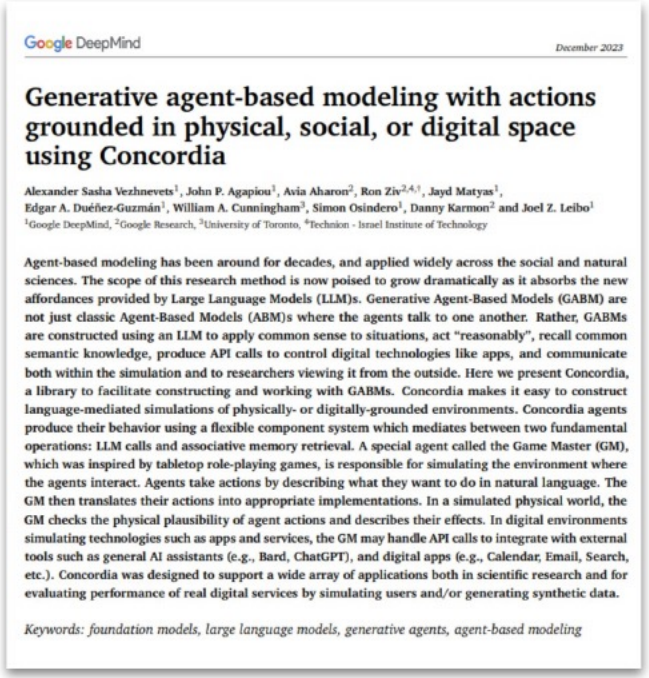


- Análisis de documentos de políticas
- Síntesis de la literatura
- Preguntas y respuestas sobre corpus de políticas
- Análisis de grandes conjuntos de textos de políticas

Modelos basados en agentes



- Actores heterogéneos: hogares, empresas, lobbies
- Dinámicas macro que emergen del comportamiento micro
- La aceptabilidad de una política se explora antes de implantarla, no se descubre después
- Los MBA pueden seguir reglas predefinidas, pero también modelizarse como agentes que interactúan mediante LLM



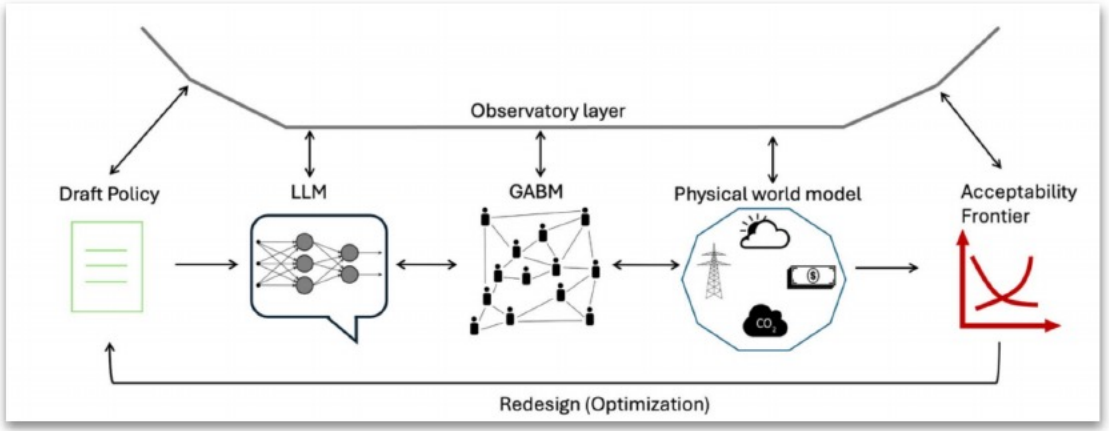
Google DeepMind *December 2023*

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

LLM y MBA: plausibles, pero sin validar



Alucinaciones

- Los LLM tienden a alucinar información
- Los chatbots LLM no suelen ser capaces de distinguir si la información que generan es verdadera o falsa
- El trabajo político exige citas verificables



Falta de contexto institucional

- Los modelos pueden desconocer normas, precedentes, mandatos, líneas rojas y contextos políticos cambiantes



Sesgos, confidencialidad, exceso de confianza

- Modelos a veces entrenados con datos sesgados
- Los LLM parecen seguros de sus respuestas, aunque no lo estén
- Los LLM pueden filtrar datos sensibles



Modelos propietarios

- Pesos cerrados y versiones cambiantes
- Reproducibilidad y soberanía: un problema para las instituciones públicas
- ¿De quién son los modelos? ¿Quién los paga? ¿Entrenan actores privados modelos con información pública crítica?

La propia huella ambiental de la IA

Ligada al cómputo

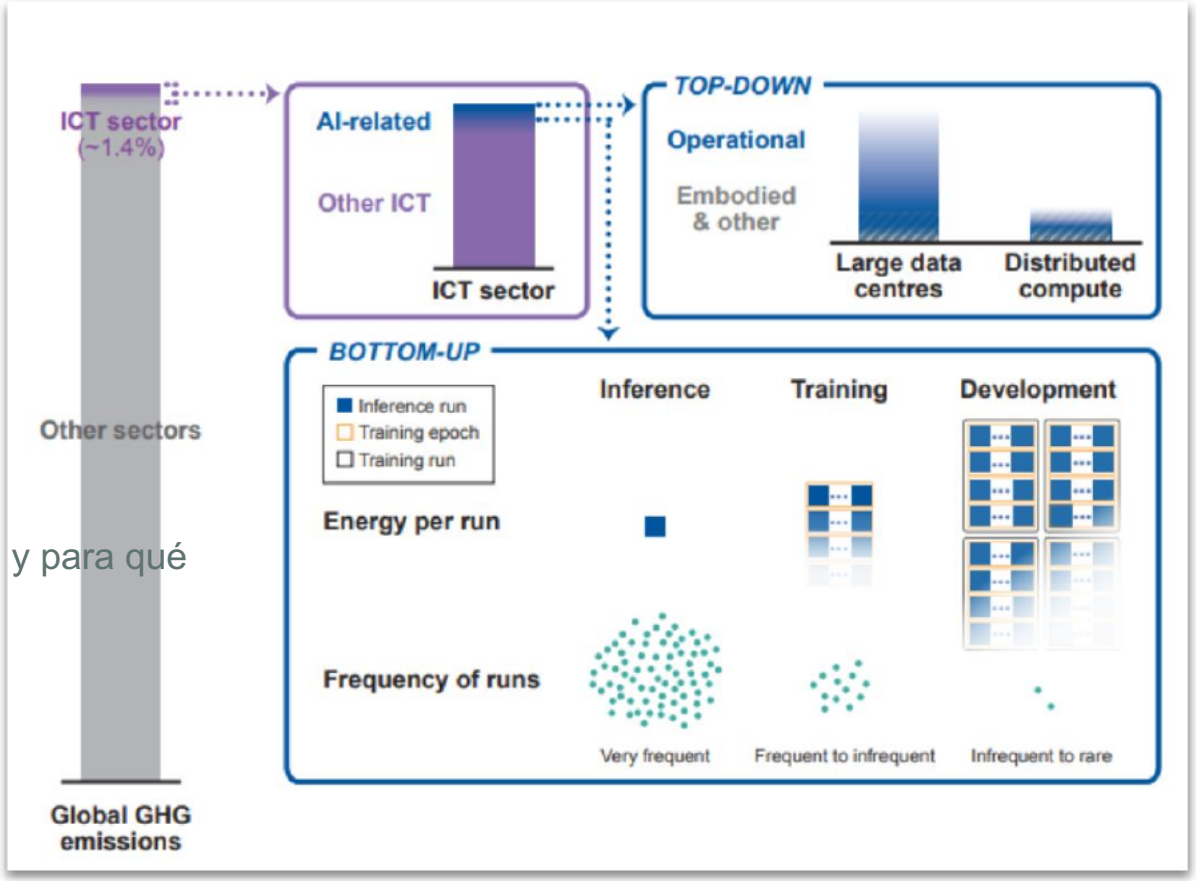
Energía de entrenamiento e inferencia, hardware, agua

Efectos de aplicar el AA

Ganancias de eficiencia vs. efecto rebote; quién usa la herramienta y para qué

A nivel de sistema

Cambios de comportamiento, bloqueos, demanda inducida



De Kaack et al Aligning artificial intelligence with climate change mitigation

La brecha del despliegue



Cerrar la brecha:

- Bancos de prueba de utilidad para las políticas, no solo de precisión predictiva
- Incertidumbre bien calculada y comunicada en términos útiles para decidir
- Colaboraciones integradas: codiseño con las personas y comunidades que la usarán y podrían verse afectadas por la tecnología
- Aumentar la capacidad institucional y la confianza

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

Test n.º 4

¿Qué factores tendrías en cuenta al usar un LLM en el análisis de la política climática?

https://partici.fi/32182658

Problemas abiertos y conclusiones



Problemas abiertos

1

Bancos de prueba de utilidad para las políticas más allá de la precisión

2

Políticas robustas ante una incertidumbre profunda, frente a una única política «óptima»

3

Emuladores y escenarios sintéticos que mantengan la interpretabilidad y la CI

4

Flujos de trabajo con LLM seguros y transparentes para instituciones públicas

5

Métodos de codiseño con decisores y comunidades afectadas

6

Integrar amenazas → impactos → respuesta social → decisiones políticas

7

Daños localizados: cerrar la brecha de resolución donde los datos son más escasos

Inteligencia climática integrada: un gran reto

Cada parte de esta clase era una isla: medición, futuros, incertidumbre, agentes, evaluación.

Un gran objetivo de investigación de la década que viene es conectarlas (amenazas, impactos, respuesta socioeconómica y decisiones políticas en un solo ciclo) y entender cómo la propia IA afecta a la acción climática.

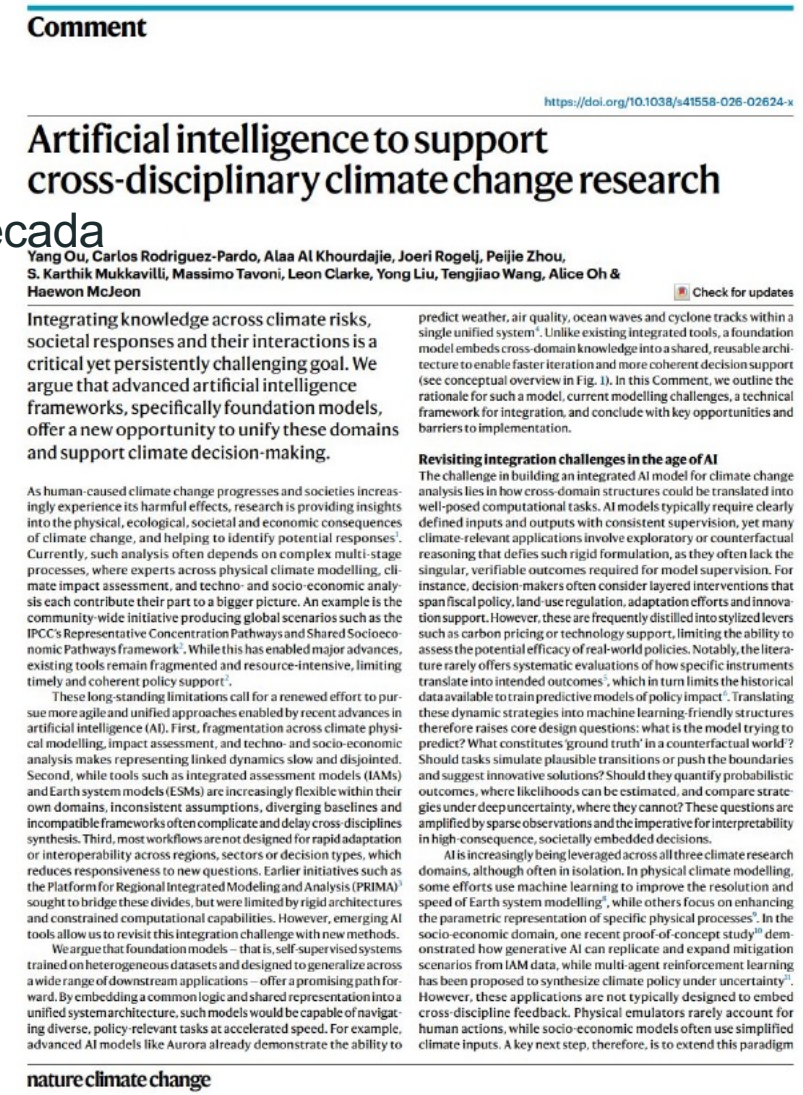

Stockholm Resilience Centre | Stockholm University

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

La caja de herramientas inicial

DATOS Y HERRAMIENTAS

- Climate Policy Radar
- Bases de escenarios del IAMC
- Emuladores de IAM (p. ej. ML-IAM) e IAM de código abierto / modelos energéticos
- Population Dynamics Foundation Model
- Embeddings geoespaciales y TorchGeo
- Paquetes de inferencia causal y econometría

COMUNIDADES Y CONGRESOS

- Climate Change AI: ya estás aquí
- Talleres de CCAI en NeurIPS
- IAMC: grupo de trabajo de IA responsable para los IAM
- EGU · AGU · SISC · WCERE: donde se encuentran clima, ciencias de la Tierra y economía



Mensajes clave

La IA puede intervenir en cada etapa del ciclo de las políticas

- Medición
- Futuros
- Evaluación
- Flujos de trabajo
- Verificación

La limitación rara vez es la precisión predictiva

- Validez causal
- Valores
- Confianza
- Restricciones sociales
- Instituciones
- Aceptabilidad social

La integración es la frontera

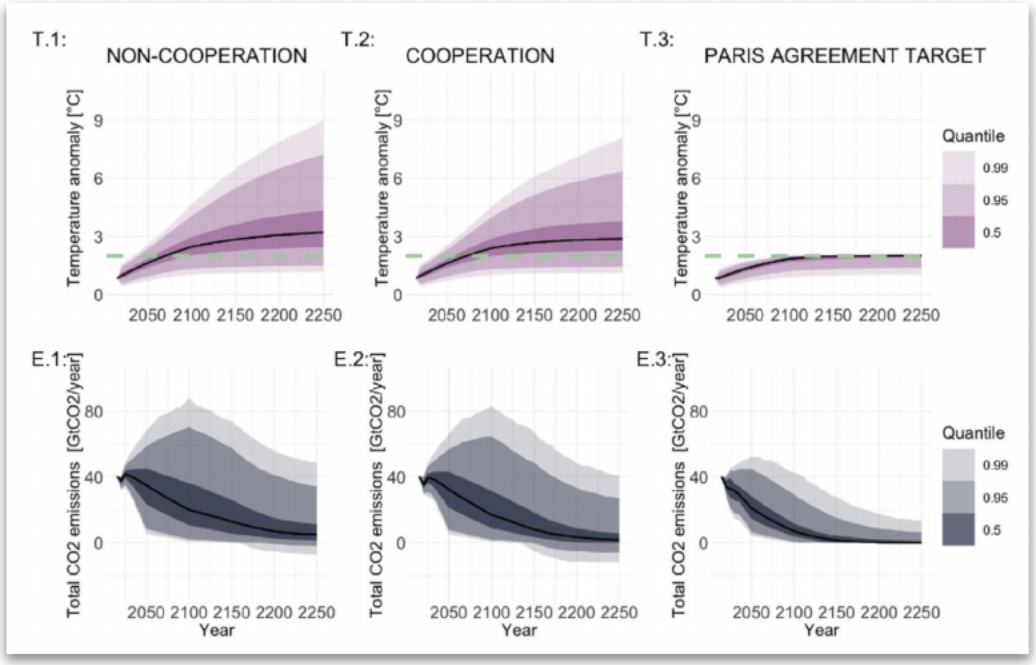
- Entre escalas
- Entre tipos de datos
- Entre etapas del ciclo de las políticas
- Entre instituciones y comunidades
- A lo largo de la cadena de modelización

Partir de preguntas relevantes para las políticas y de los problemas de los responsables políticos, no de las capacidades de los modelos ni de lo que se puede hacer con un conjunto de datos concreto

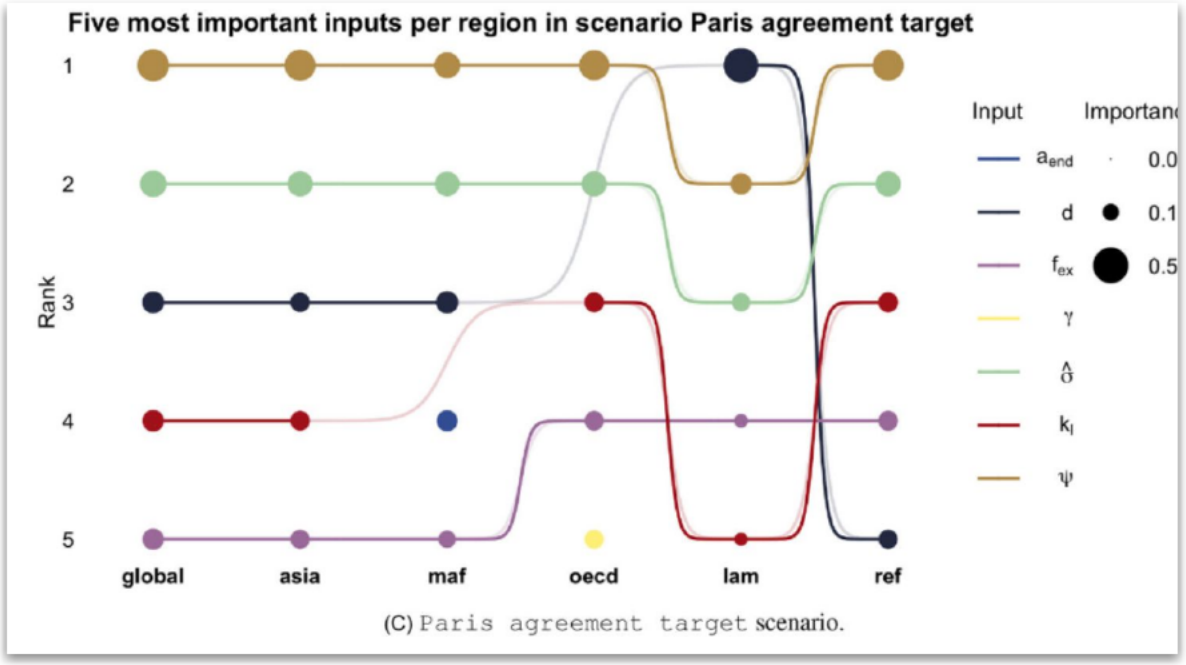
¡Gracias por su atención!

Cuantificación de la incertidumbre, análisis de sensibilidad

Cuantificación de la incertidumbre

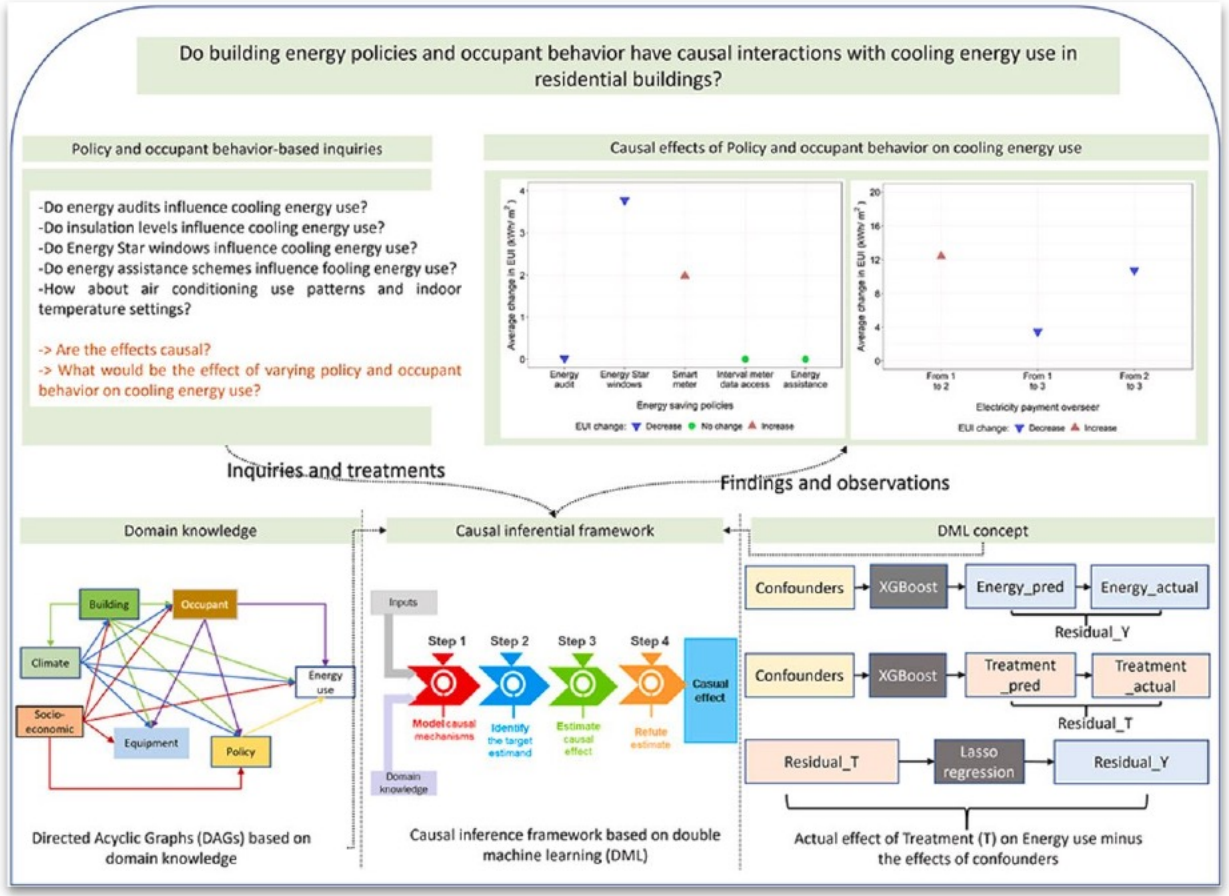


Sensibilidad y explicabilidad de cajas negras



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

AA causal en el análisis de la política climática



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

Nuevas direcciones en la intersección de la IA y los 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 nuevas soluciones



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].

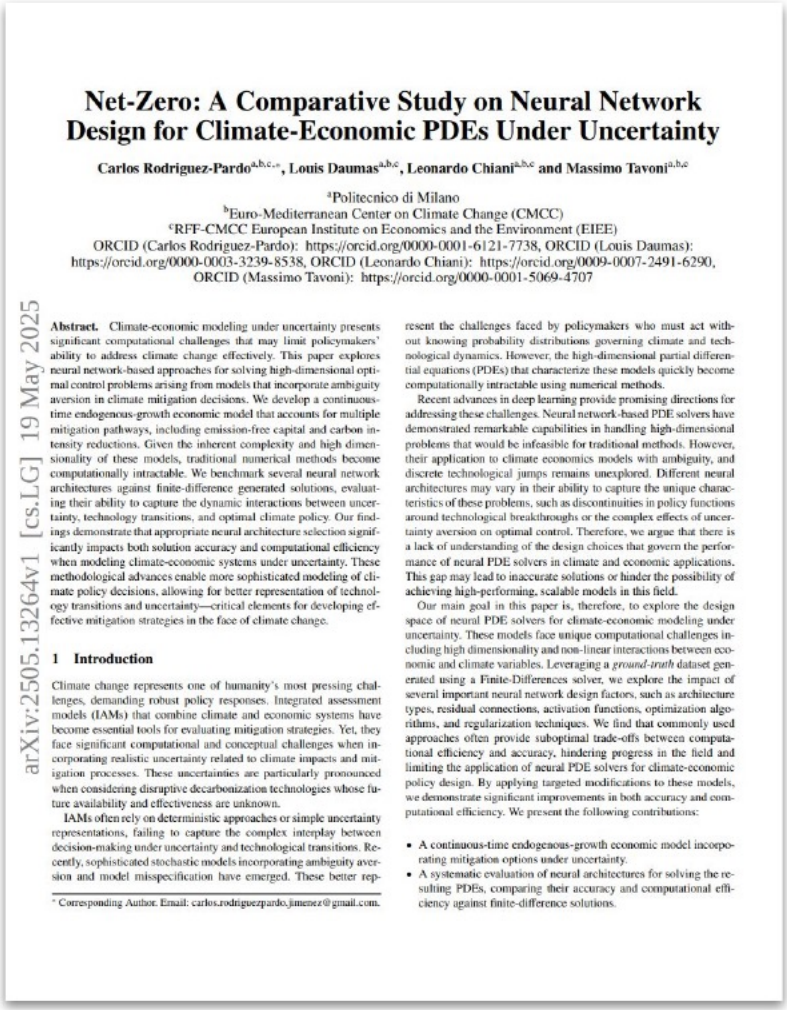
Climate change is a shared global challenge, yet mitigation entails trade-offs. Investments in low-carbon technologies and systemic transformation can constrain short-term growth and costs are unevenly distributed: wealthier nations can invest more readily, while developing countries must balance climate 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

IAM diferenciables



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 neuronales de EDP para la velocidad y la cuantificación de la incertidumbre