L’IA au service des politiques publiques

École d’été Climate Change AI 2026

Carlos Rodriguez-Pardo, PhD

Politecnico di Milano / EIEE / CMCC

Question d’échauffement :

Selon vous, quelle est l’application la plus prometteuse de l’IA dans les politiques climatiques ?

https://partici.fi/32182658

École d’été Climate Change AI 2026

Carlos Rodriguez-Pardo, PhD

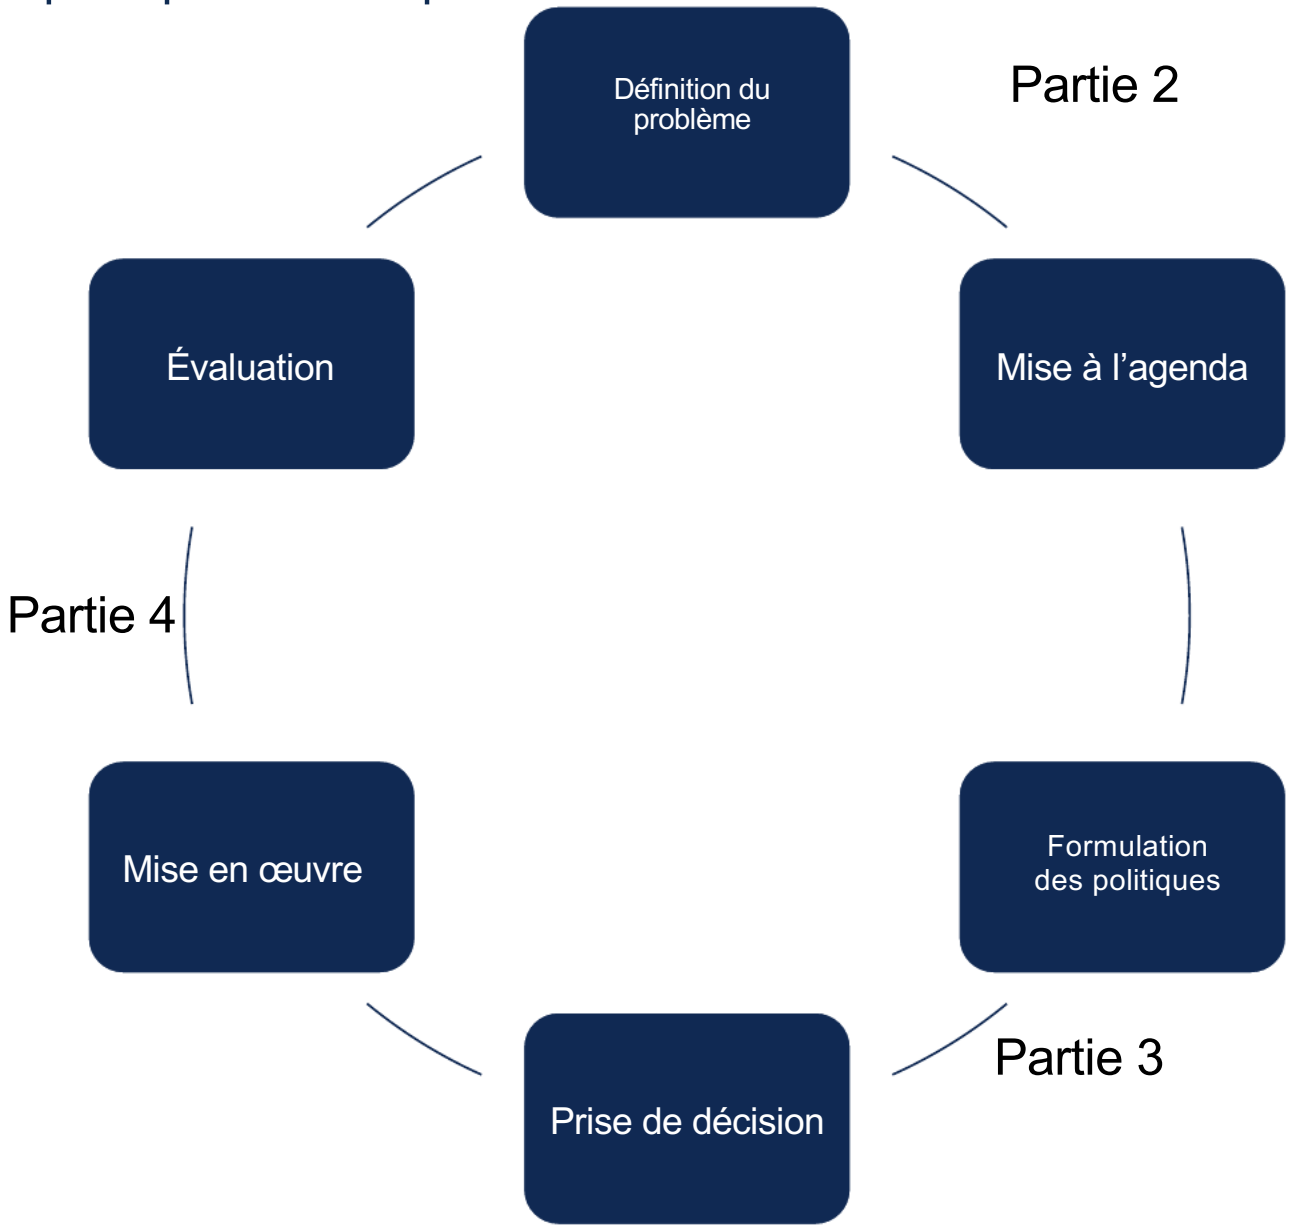
Politecnico di Milano / EIEE / CMCC

Programme du jour

	La question	Le rôle de l'IA
Partie 1 : fondements	Quels sont les objectifs de l'analyse des politiques climatiques ?	Aucun pour l'instant, simple introduction
Partie 2 : mesurer	Que se passe-t-il, qu'a-t-on essayé, qui est exposé ?	TAL sur des corpus de politiques · vision par ordinateur et télédétection · modèles de fondation géospatiaux / du système Terre
Partie 3 : modéliser les futurs	Que pourrait-il se passer selon les politiques et les acteurs ?	Émulateurs d'IAM · solveurs neuronaux d'EDP · AR et AR multi-agents
Partie 4 : évaluation et déploiement	Une politique a-t-elle fonctionné ? Sera-t-elle acceptée ? Peut-on s'y fier ?	AA causal · LLM · modèles multi-agents

Le cycle des politiques publiques

Où l'IA peut-elle aider les politiques climatiques ?



Quelles institutions participent à la décision publique ?

Internationales : CCNUCC, GIEC, UE

Gouvernements nationaux et régionaux

Collectivités locales

Acteurs sectoriels : fournisseurs d'électricité, autorités de transport

Acteurs privés : assureurs, entreprises, banques, certificateurs, etc.



- Des acteurs différents, aux problèmes et priorités différents
- Des échelles de temps différentes (politiques sur des décennies vs résultats trimestriels)
- Des leviers différents : taxes carbone, part des renouvelables, % de véhicules électriques dans les transports publics
- Des résolutions spatiales différentes (politiques continentales, urbanisme, rénovation des bâtiments…)

L'IA peut aider la décision publique à toutes ces échel

Que cherche à accomplir l’analyse des politiques climatiques ?



Estimer les dommages et les risques

Quelle gravité, où, pour qui et quand ?



Comparer les options, évaluer les arbitrages

Atténuation, adaptation ou acceptation des pertes.



Concevoir les instruments

Taxes, normes, subventions, plans, marchés.



Évaluer ce qui a fonctionné

Nos politiques ont-elles changé quelque chose, et dans quelles conditions ?



Décider dans l’incertitude

Des choix robustes malgré de profondes inconnues.

Les réponses politiques au changement climatique



Atténuation

Objectif : éviter ou réduire la concentration de GES dans l'atmosphère

Exemples :

- Normes sur les renouvelables
- Obligations de véhicules électriques
- Captage et stockage du carbone
- Taxes carbone
- Électrification



Adaptation

Objectif : réduire les dommages inévitables du réchauffement

Exemples :

- Protections contre les inondations
- Isolation des bâtiments
- Systèmes d'alerte précoce
- Infrastructures



Pertes et préjudices

Objectif : compenser ce qui ne peut être évité ni faire l'objet d'une adaptation

Exemples :

- Financement climatique
- Attribution

L'analyse des politiques doit comparer les trois et comprendre leur coût, leurs arbitrages et leur faisabilité. Il faut pour cela des instruments comme le coût social du carbone et des estimations des dommages.

La boîte à outils des instruments politiques

Tarification du carbone

Taxes et échange de quotas

Réglementation et normes

Interdictions, codes, règles d'efficacité

Subventions et investissements

R-D publique, renouvelables, rénovations

Politique industrielle

Stratégie industrielle verte

Planification de l'adaptation

Réduction des risques et résilience

Financement climatique

Qui paie, qui est indemnisé

Marchés carbone et compensation

Crédits, MRV, intégrité

Ces politiques peuvent se disputer les mêmes budgets

Le coût social du carbone

Le coût social du carbone est le dommage économique causé par une tonne supplémentaire de CO2 émise, exprimé en monnaie d'aujourd'hui.

+1 tonne de CO2 émise aujourd'hui

↓

Provoque un réchauffement supplémentaire, sur des siècles

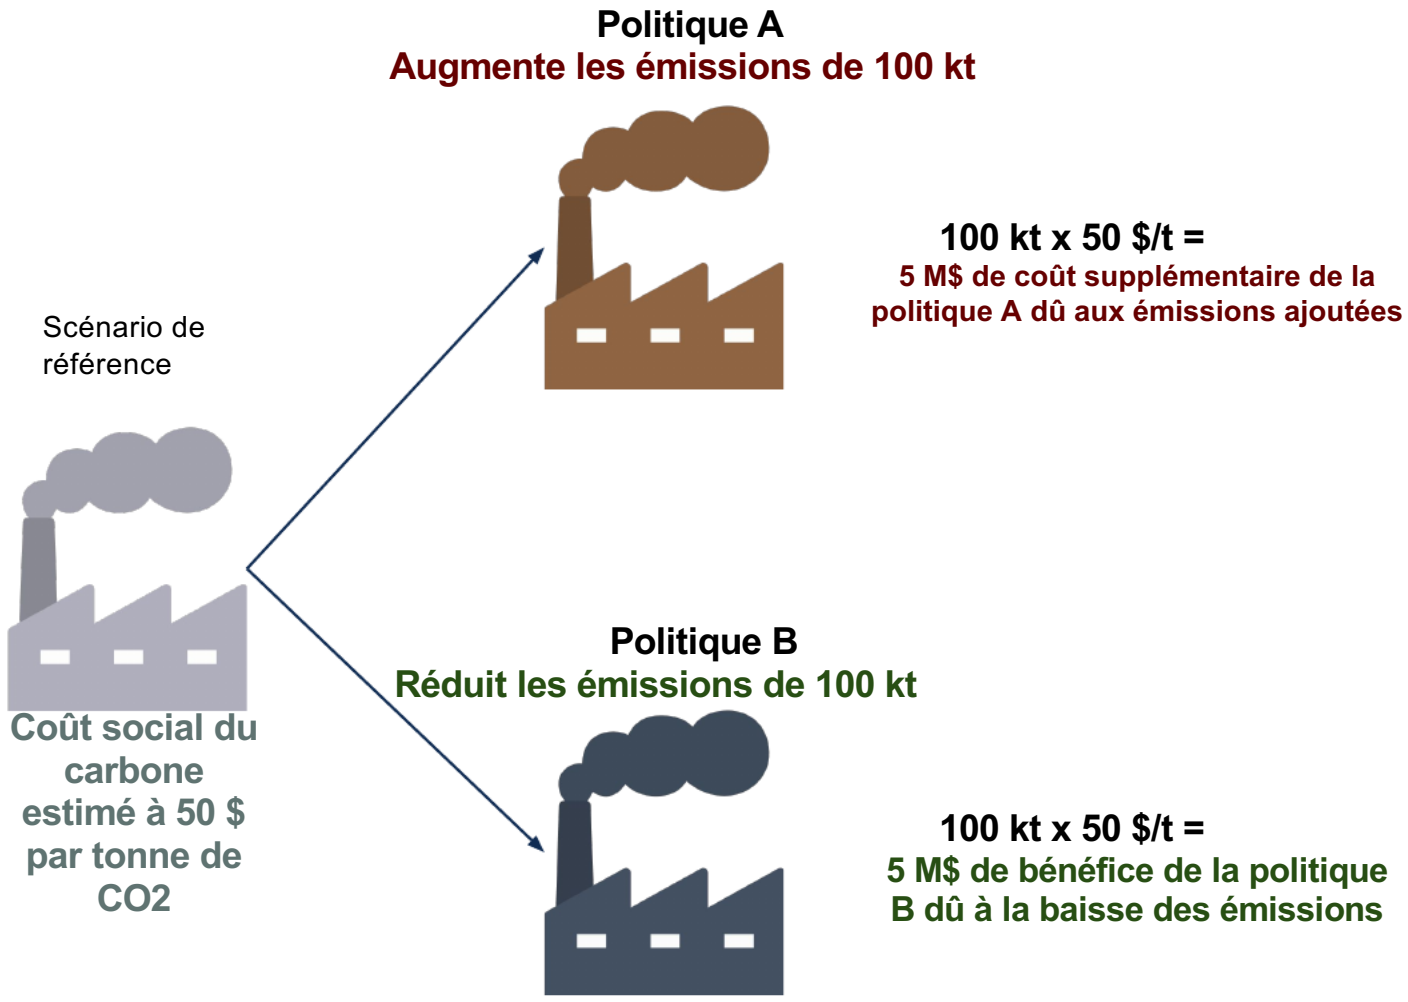
↓

Qui cause des dommages futurs : santé, cultures, capital…

↓

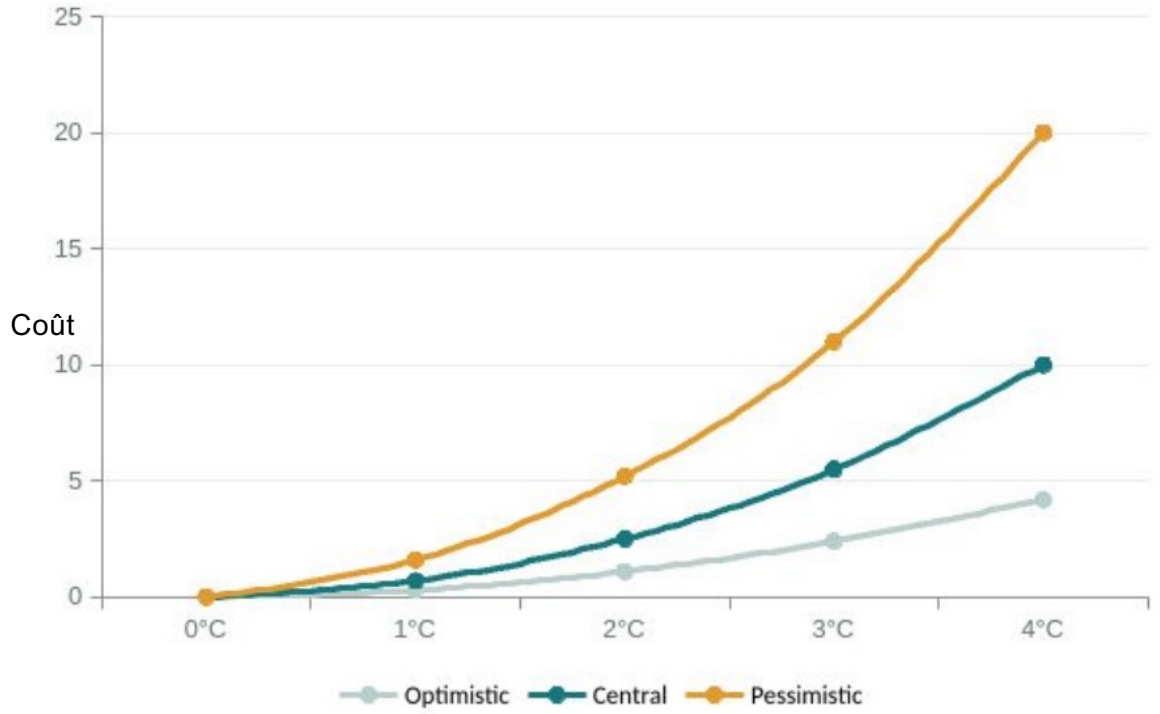
Actualiser ces dommages en valeur présente : $ / CO2

Toutes ces flèches cachent des modèles, des hypothèses et des incertitudes



Fonctions de dommages

- Traduire le réchauffement mondial en pertes économiques
- Estimées à partir de données historiques, extrapolées bien au-delà
- Ces fonctions sont très utilisées dans les modèles d'évaluation intégrée et d'autres instruments d'analyse des politiques
- Forme fonctionnelle, points de bascule et hypothèses d'adaptation sont tous contestés
- Leur incertitude a aussi des implications politiques



Quelle place pour l'IA dans tout cela ?

Données

Traiter des sources de données complexes et en tirer des enseignements : images satellitaires, documents de politique, réseaux, capteurs, données économiques…

Modèles

Aider à modéliser des systèmes socio-économiques et climatiques complexes :

- Modèles de fondation
- Modèles d'évaluation intégrée
- Apprentissage par renforcement

Décisions

- Estimer l'efficacité possible de différentes politiques
- Comprendre si les politiques passées été efficaces et dans quelles conditions
- Optimiser l'allocation des ressources

PARTIE 2 : MESURER

PARTIE 3 : MODÉLISER LES FUTURS

PARTIE 4 : ÉVALUER ET DÉPLOYER

Références utiles :

- 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 n° 1 :

De quelles informations avez-vous besoin pour estimer le coût social du carbone ?

Trajectoires d'émissions

Où va le monde ? Scénarios, incertitudes

Réponse climatique (TCRE)

Quel réchauffement par tonne de CO_2 supplémentaire ?

Fonction de dommages

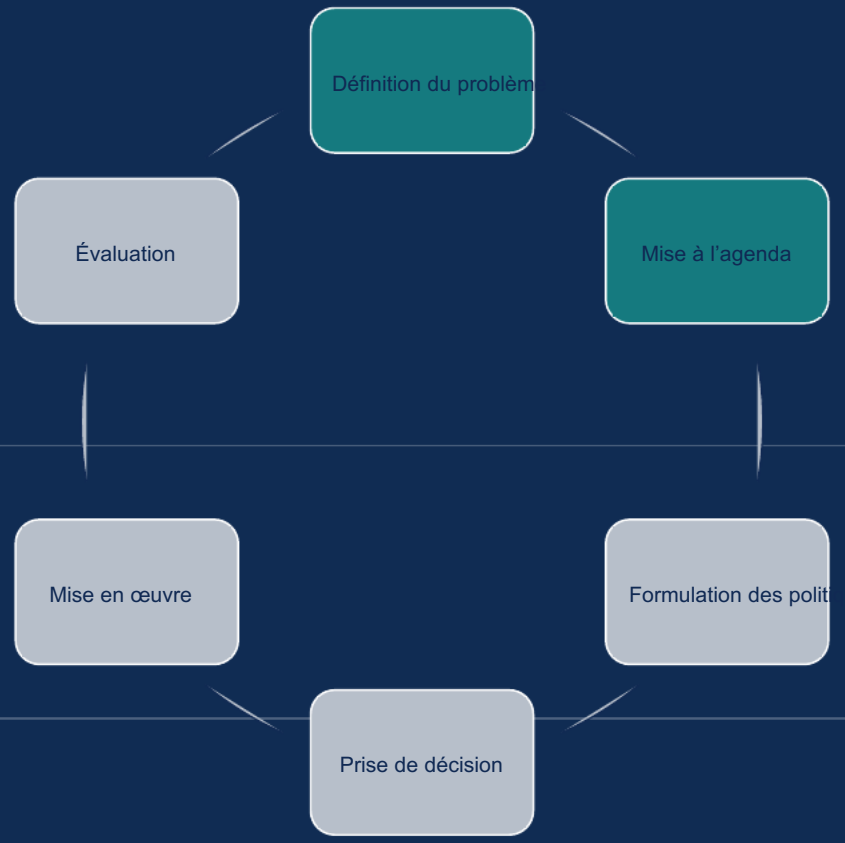
Quel est le coût de chaque unité de réchauffement supplémentaire ?

Actualisation

Quelle importance accordons-nous au futur par rapport au présent ?

Partie 2 : mesurer le monde des politiques et les impacts climatiques

- Quelles politiques existent ?
- Que se passe-t-il dans le monde ?
- Qui est exposé ?



Que faut-il savoir pour concevoir des politiques efficaces ?

Quelles politiques existent aujourd'hui ?

- Bases de politiques
- Suivis des politiques

Où se produisent les émissions ?

- Inventaires
- Estimations

Qui est exposé ? Qui sont les acteurs clés ?

Cartographie de la vulnérabilité

Que dit la littérature ?

Cartes des preuves, synthèses,

Où sont les lacunes de connaissances ?

Où sont les incertitudes ? Quelles données manquent ?

Comment savoir ce qui a déjà été essayé et étudié ?

Harmonisation des bases de données de politiques

Entrée :

- Documents nationaux fragmentés
- Bases mondiales, régionales, sectorielles

Méthodes

- Traitement automatique des langues,
- expertise, apprentissage à base de règles
- Apprentissage semi-supervisé

Résultat :

- Panels de politiques comparables entre pays
- Qui a adopté quelle politique et quand
- Format commun, aligné sur le GIEC

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

Cartographie de la littérature scientifique

Entrée :

- Des centaines de milliers d'articles sur les politiques climatiques
  - Impossible à lire et analyser pour un humain ou une équipe de recherche

Méthodes

- Traitement automatique des langues
- Classification de textes
- Cartographie thématique

Résultat :

- Cartes des preuves
- Lacunes de la littérature, preuves minces

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

Mesurer ce qui se passe, à une résolution utile aux politiques

Mesures haute résolution et qualité de l'air

- Estimations par AA des émissions de GES urbaines infranationales
  - Yu et al. https://www.nature.com/articles/s41597-026-06691-9
- Classification par AA des stations de qualité de l'air
  - Renna et al (https://www.nature.com/articles/s41597-026-06797-0.pdf)

Le défi de l'intégration

- Comment relier politiques, secteurs, émissions, territoires, populations et résultats ? Comment
- transformer des données et des modalités disjointes en preuves utiles aux politiques ?

Références :

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

Lire et comprendre les documents de politique

- TAL pour classer des programmes politiques (Sanford et al. doi:10.1017/S0007123425100719)

La chaîne de modélisation des impacts



L'IA accélère déjà ces maillons

Peu ou pas d'impact de l'IA

Données faibles, plus grosse lacune scientifique

Les cours IA pour la météo et IA pour les sciences du climat de l'école d'été CCAI26 traiteront ces sujets en profondeur. Ici, nous nous intéressons aux impacts climatiques et à la façon dont ils entrent dans les décisions publiques

Pourquoi la résolution compte

Maille mondiale

~100-1000km

- Un pays est-il sur la bonne voie ?
- Quelles sont les tendances climatiques dans cette région ?

Régions

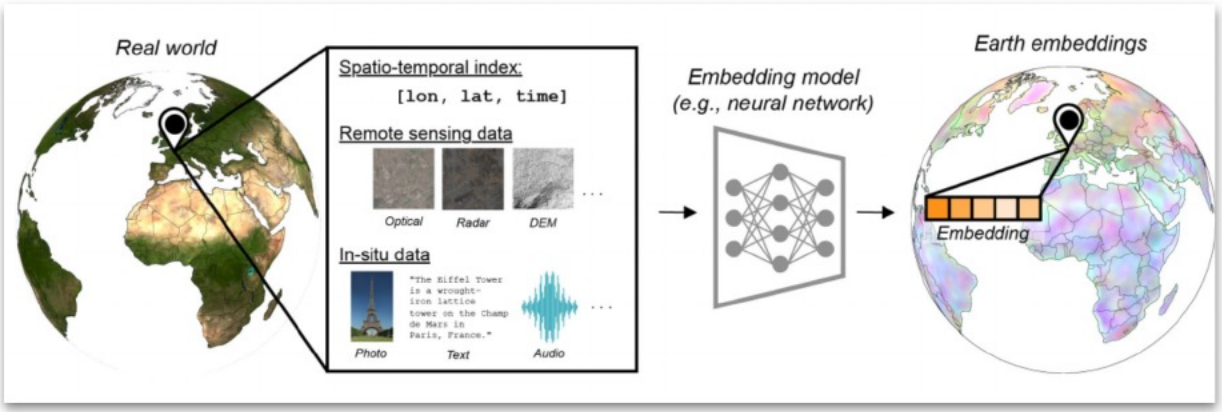
~10-100km

- Où allouer les fonds d'adaptation ?
- Quelles villes sont les plus exposées aux extrêmes ?
- Quelles populations sont les plus vulnérables ?

Pâtés de maisons

~10m-10km

- Quels quartiers ont besoin de protection contre les crues ?
- D'où viennent les émissions ?
- Où planter des arbres ?



Les plongements géospatiaux et les modèles de fondation du système Terre relient efficacement les résolutions : on apprend une représentation une fois, puis on la réutilise pour plusieurs tâches d'analyse des impacts, de reconstruction et de l'exposition.

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

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

De meilleures données changent les décisions réelles

Ciblage de l’adaptation

Qui protéger d’abord, et à quel coût ?

Financement climatique et pertes et préjudices

Des estimations de dommages plus précises améliorent les décisions financières

Écosystèmes et nature

Quels impacts climatiques sur la biodiversité, et où ? Quelles espèces sont les plus touchées ?

Assurance

Amélioration de la tarification, de l’assurabilité, de la couverture et de la gestion des risques

Planification des infrastructures

Que construire et comment ? Quelles probabilités de crues, de vagues de chaleur, de neige extrême ?

Évaluation distributive

Qui sera le plus touché par le changement climatique ? Quels impacts sur l’égalité et la santé ?

Exemple : allocation des fonds d’adaptation

Avec des données grossières et de faible qualité :

- Les fonds peuvent suivre tendances, biais, lobbying
- Les fonds peuvent manquer les populations qui en ont le plus besoin
- L’argent public est alloué de façon sous-optimale

Avec des données d’impact localisées à haute résolution

- Les fonds suivent l’exposition et la vulnérabilité
- Les fonds sont alloués de façon robuste et justifiable
- Les décideurs comprennent mieux les arbitrages et les limites

La mesure n’est pas neutre

Fausse précision

- Des résultats haute résolution peuvent sembler exacts, mais ne le sont souvent pas
- Beaucoup de jeux de données courants (p. ex. ERA5) cachent hypothèses et choix de modélisation, et des modèles
- Les incertitudes se cumulent de façon invisible

La disponibilité des données n’est pas uniforme

- La couverture des données est souvent plus faible précisément là où la vulnérabilité est plus forte
- Les modèles extrapolent donc et sont moins précis dans les régions plus vulnérables
- 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)

Documenté ne veut pas dire efficace

- Les bases de politiques recensent ce qui est écrit, pas forcément ce qui a été efficace

Pertes cachées

- Certaines variables sont plus difficiles à mesurer que d’autres. Les fonctions de dommages peuvent ignorer
  - Les dommages non marchands
  - La répartition des dommages
  - Les pertes culturelles
  - Les dommages écologiques

https://partici.fi/32182658

Quiz n° 2

Pourquoi une fonction de dommages mondiale ou des données d'émissions haute résolution pourraient-elles ne pas suffire pour décider où affecter les fonds d'adaptation ?

Précision ≠ pertinence

Modèles et données peuvent être moins précis là où la précision compte le plus

Vulnérabilités ignorées

Un même extrême climatique peut être une catastrophe pour une communauté et un simple désagrément pour une autre

Choix normatifs

Qui prioriser ? Le plus grand nombre, les plus vulnérables ? Efficacité ou équité ?

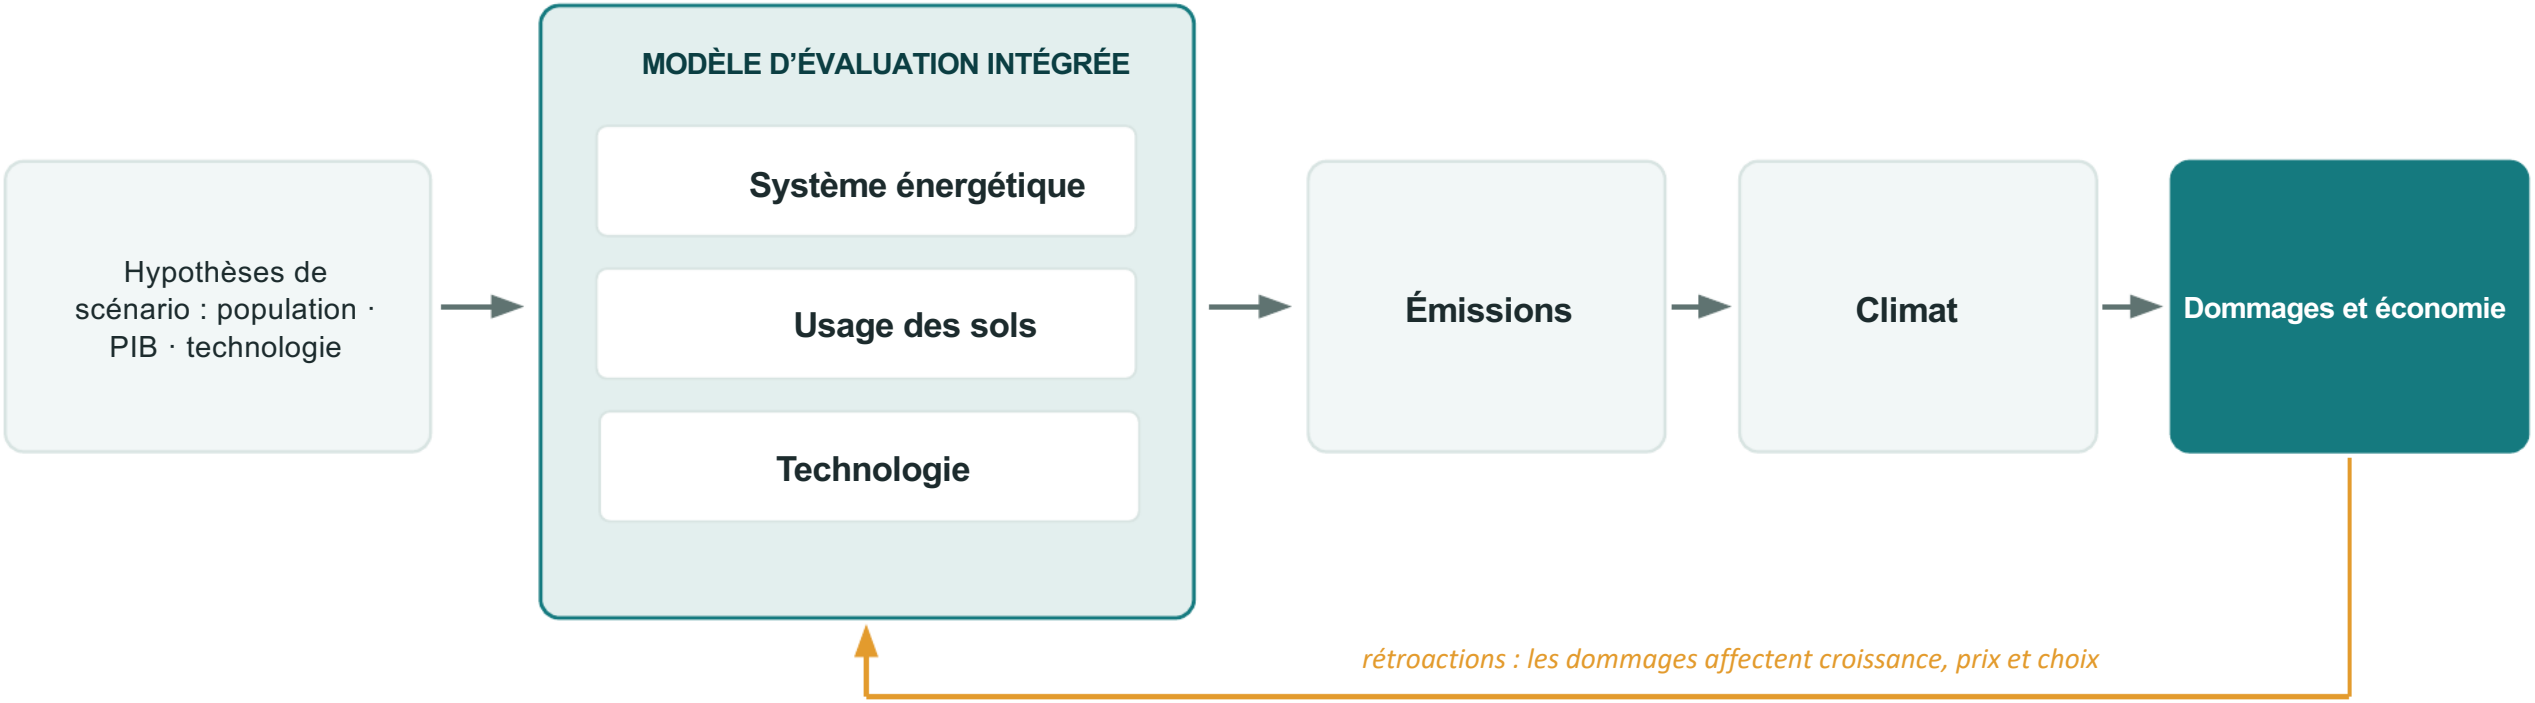
De meilleures données sont nécessaires mais pas suffisantes :
elles aident à recentrer les débats, mais ne peuvent pas décider quelles questions comptent pour les politiques

Partie 3 : modéliser les futurs et concevoir des options politiques

- Comment modéliser le climat et l'économie futurs ?
- Comment modéliser les multiples acteurs des politiques climatiques ?
- Comment garantir la fiabilité de nos modèles ?



Les modèles d'évaluation intégrée (IAM)



- Les IAM modélisent des mondes stylisés : utiles pour les questions « et si ? », pas pour prévoir
- Il existe différentes familles d'IAM :
  - IAM coûts-bénéfices (DICE)
  - IAM détaillés par processus (REMIND, WITCH)

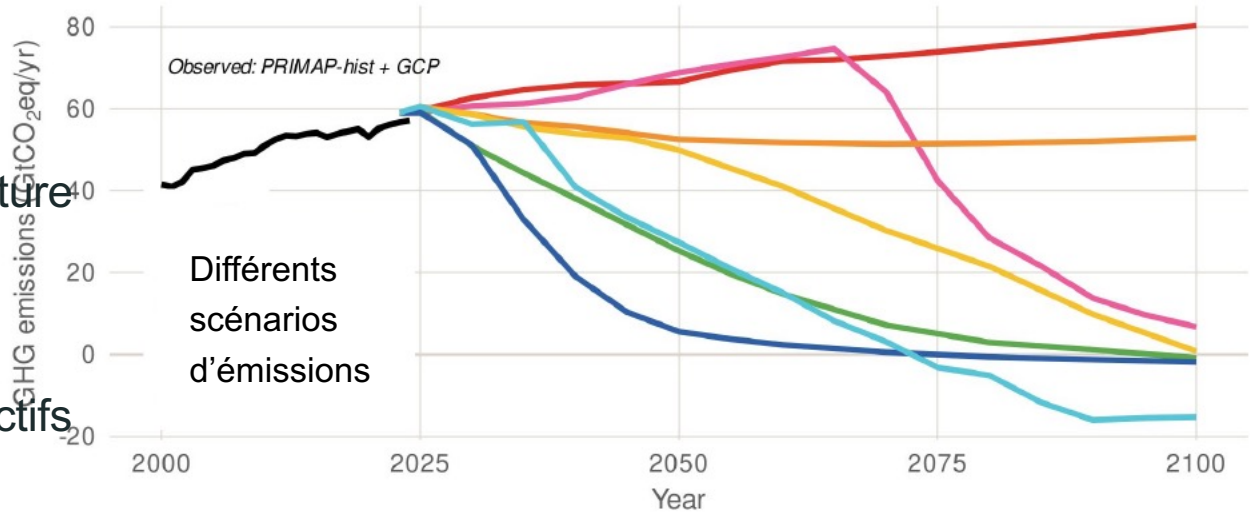
Ce qu'éclairent les IAM

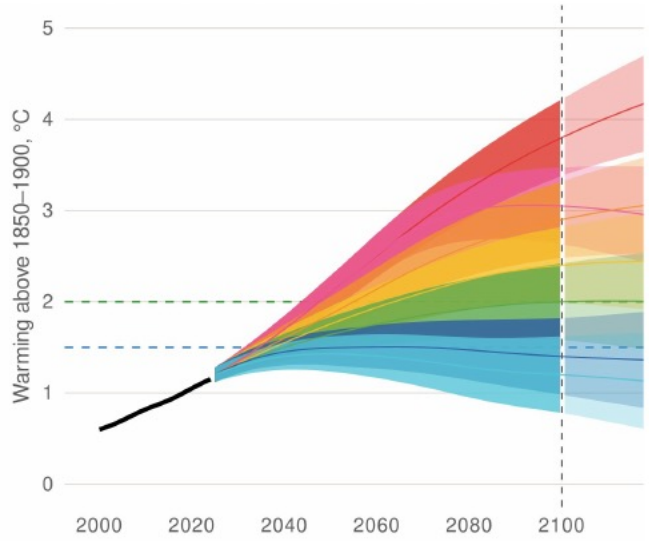
- Trajectoires au meilleur coût vers les objectifs de température
- Portefeuilles technologiques : combien d'éolien, de CSC, de nucléaire, quand, à quel coût
- Trajectoires de prix du carbone compatibles avec les objectifs
- Partage régional de l'effort et son (in)équité
- Bases de scénarios du GIEC

IAMC
Integrated Assessment Modeling Consortium
Founded 2007

ipcc
INTERGOVERNMENTAL PANEL ON climate change

Trajectoires d'émissions stylisées ($GtCO_2$/an)





L’IA pour émuler les IAM

- Les IAM sont utiles mais très coûteux en calcul
- Les ensembles de modèles pour mesurer l’incertitude peuvent devenir ingérables
- Les émulateurs d’AA peuvent aider :
  - Ils apprennent à relier les entrées et les sorties d’un IAM
  - Une fois entraînés, ils répondent instantanément
- ML-IAM permet d’explorer les scénarios de façon interactive
  - P. ex. Shin et al., ML-IAM v1.0 · Li et al. 2025, apprentissage profond pour les variables des scénarios mondiaux d’atténuation (https://egusphere.copernicus.org/preprints/2026/egusphere-2025-5305/)

1

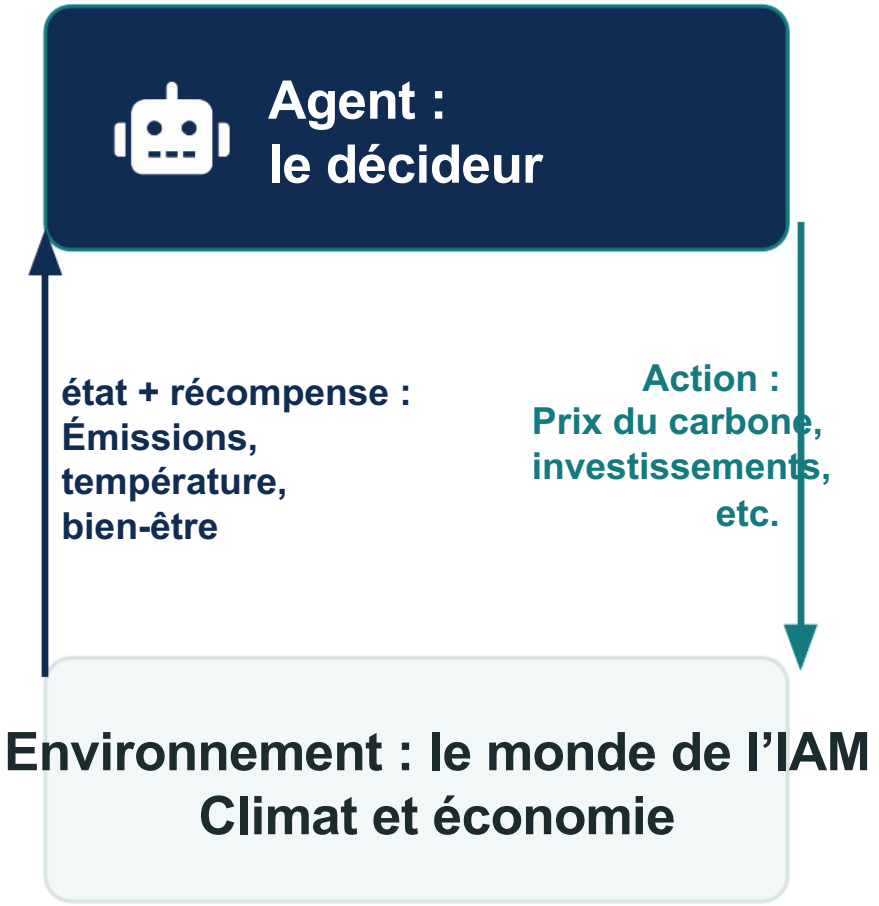
Scénario d’IAM
des heures à des jours de calcul

10 000+

évaluations de l’émulateur dans le même temps

(illustratif)

Apprentissage par renforcement : les politiques comme suites de décisions



- La politique climatique est séquentielle : agir, observer, ajuster, pendant des décennies
- L'AR explore des trajectoires de politiques, pas des réglages isolés
- Couplé aux IAM, l'AR peut atteindre des zones de l'espace des solutions que les solveurs classiques n'explorent jamais
- **Résultat utile : des stratégies candidates inattendues, jamais explorées**

Agents en concurrence et en coopération

- De nombreux acteurs, aux objectifs et priorités différents et changeants (pays, entreprises, régulateurs)
- Ils coopèrent, se font concurrence, profitent des efforts des autres ou s'ignorent
- L'AR multi-agents rend visibles et quantifiables les incitations divergentes et les échecs de coordination

	B réduit	**B profite**
A réduit	Tous paient, la planète gagne	A paie, B en profite
A profite	B paie, A en profite	**Personne ne paie : tout le monde perd**

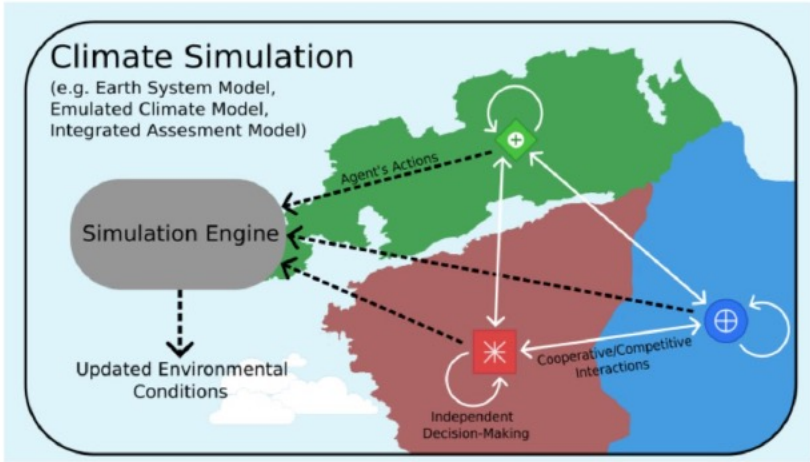
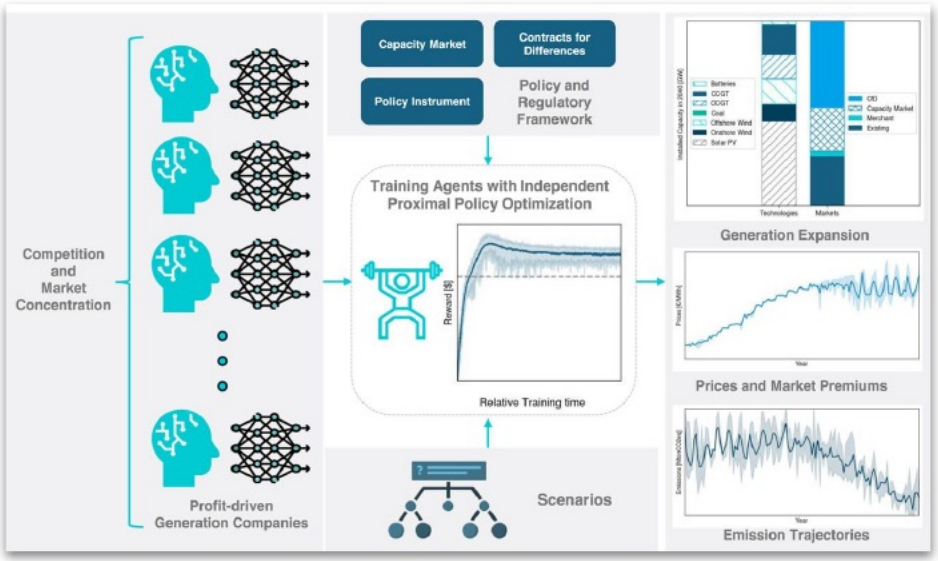


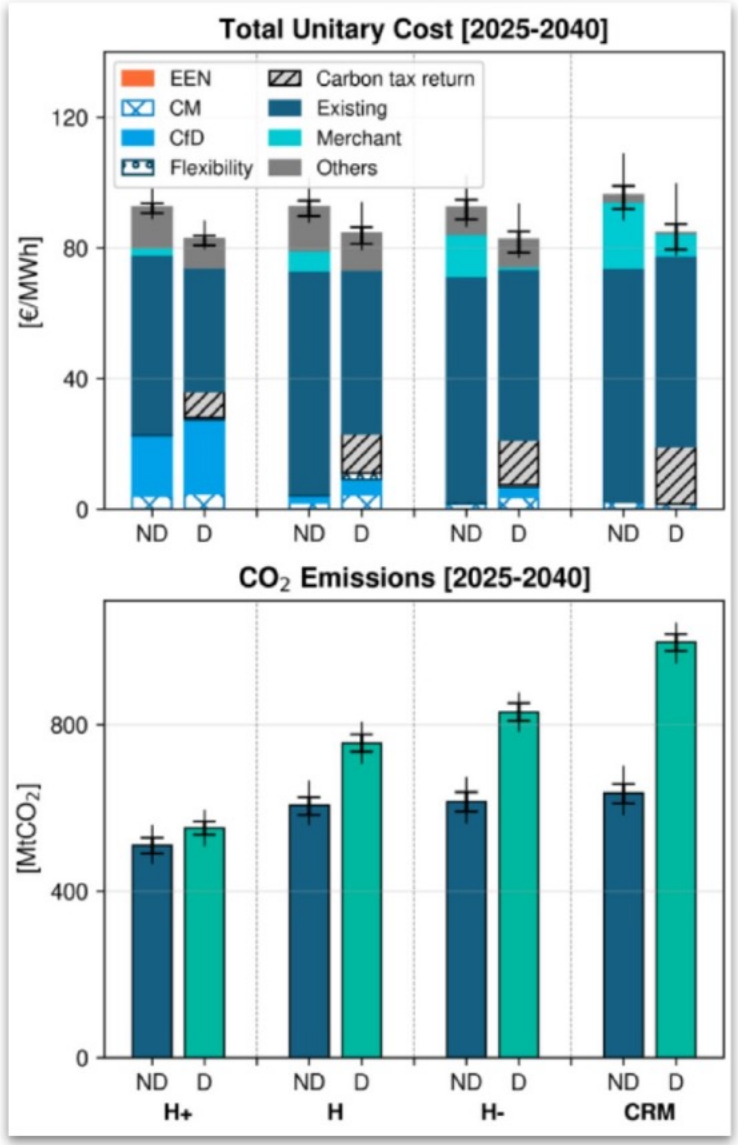
Figure tirée de Multi-Agent Reinforcement Learning Simulation for Environmental Policy Synthesis (Rudd-Jones et al.)

AR multi-agents pour concevoir la politique du marché électrique à long terme

- **Question : quelles conceptions de marché permettent une décarbonation profonde à des prix acceptables ?**
- **Approche : les producteurs sont des agents apprenants, qui enchérissent et investissent selon différentes règles de marché**
- Les agents révèlent des comportements stratégiques que l'analyse d'équilibre ne voit pas
- Les choix de conception déplacent visiblement les prix comme les résultats de décarbonation



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

Ce que l’AR ne peut pas décider

Les valeurs ne s’apprennent pas

- L’AR optimise à l’intérieur d’un problème formalisé.
- Ce que la société doit valoriser n’est pas quelque chose que l’AR peut ou doit optimiser

Une seule récompense ne peut pas modéliser des objectifs complexes, interdépendants et multidimensionnels

- Les fonctions de valeur des environnements d’AR peuvent écraser des objectifs pluriels et contestés.

Biais de visibilité

- Les espaces d’états et d’actions ne codent que ce qui est facilement mesurable et actionnable.
- Le reste est ignoré par construction

De nombreuses contraintes ne peuvent être entièrement modélisées

- Normes juridiques, culturelles et sociales, contraintes politiques et limites institutionnelles sont décisives pour la faisabilité des politiques

https://partici.fi/32182658

Quiz n° 3

Une politique issue de l’AR obtient de bons résultats en simulation. Pourquoi un décideur pourrait-il quand même la rejeter ?

Écart simulation-réalité

Le monde de l’IAM est sous-spécifié : ce qui y est optimal peut ne pas se transposer au monde réel

Objectifs non modélisés

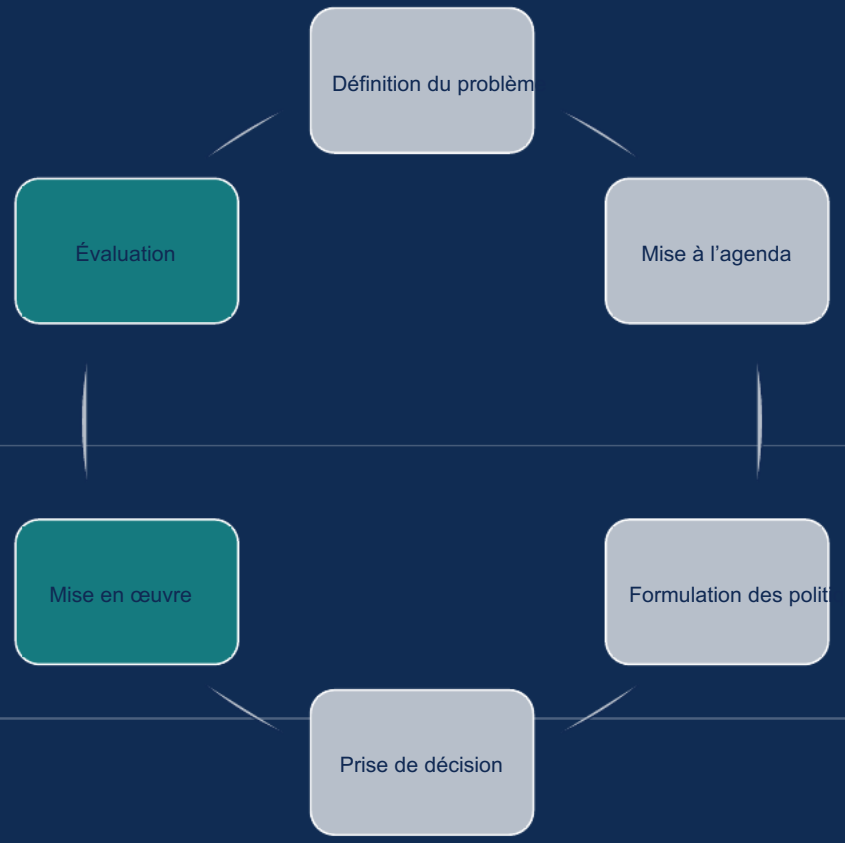
Équité, légalité, acceptabilité sociale ne figuraient pas dans la récompense. Que veut dire « bien fonctionner » pour une politique ?

Confiance et responsabilité

Qui répond des décisions issues de l’AR ? Des stratégies inexplicables résistent-elles à l’examen des institutions ?

Partie 4 : évaluation et déploiement

- Comment savoir si une politique a fonctionné ?
- Peut-on estimer si une politique sera populaire ou socialement acceptable ?



Comment savoir si une politique a fonctionné ? L'inférence causale

Expériences randomisées

- La référence absolue
- Attribuer la politique au hasard, comparer les groupes.
- Scientifiquement robuste mais difficile dans le monde réel.
- P. ex. : comment randomiser une taxe carbone entre pays ?

Différence de différences

- Comparer l'évolution dans le temps des unités soumises ou non à la politique.
- Très courant dans la littérature

Contrôle synthétique

- Sans bonne unité de comparaison → construire un « jumeau » d'une unité traitée à partir d'un ensemble d'unités non traitées.
- P. ex. la taxe carbone suédoise : émissions des transports comparées à une « Suède synthétique » construite à partir d'autres pays de l'OCDE
- Voir Andersson, J.J. Carbon Taxes and CO_2 Emissions: Sweden as a Case Study,
- Voir Gomez-Mahecha Colombian Carbon Tax: Evidence of Carbon Pricing in a Developing Context

Variables instrumentales

- Trouver un levier qui modifie la variable de politique sans autre lien avec le résultat.
- P. ex. : vitesse du vent → plus de production renouvelable → effet sur les émissions ? La météo est aléatoire : la réponse est causale.

L'AA causal peut étendre ces outils : repérer des facteurs de confusion en grande dimension, des effets hétérogènes et non linéaires, des formes fonctionnelles flexibles, etc.

Prédire n’est pas évaluer causalement

Prédiction

P. ex. : « Quelles seront les émissions l’an prochain ? »
Très utile pour planifier et suivre, mais peu utile
pour comprendre si une politique est efficace

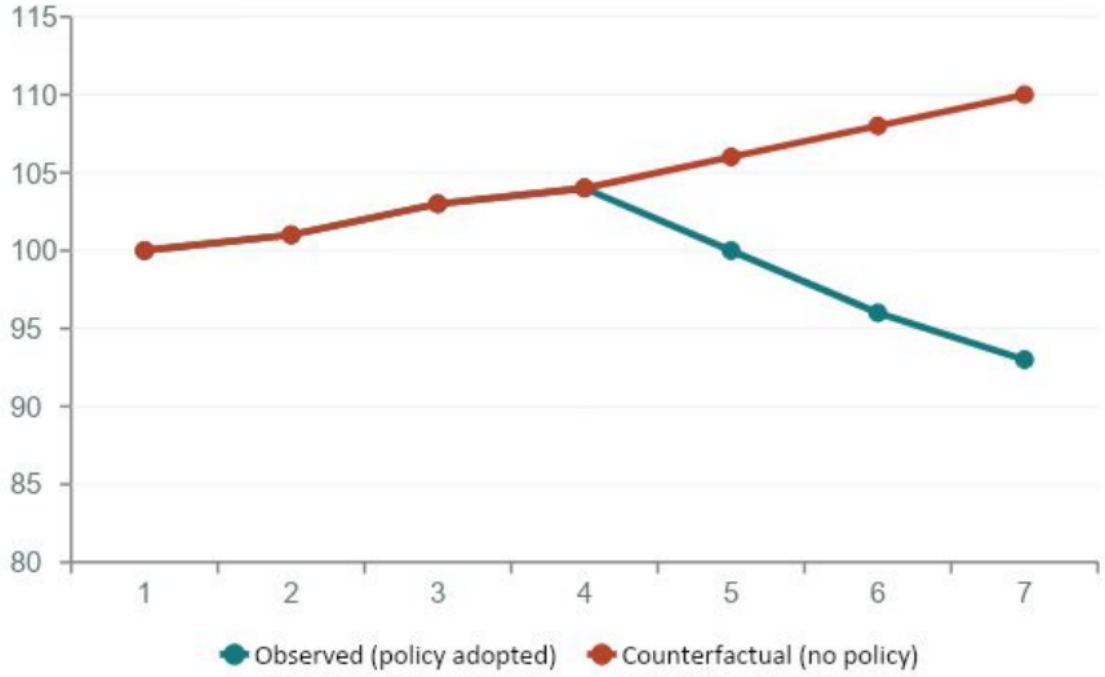
Évaluation causale

« Qu’a changé cette taxe carbone ? » : il faut un contrefactuel,

L’AA étend la boîte à outils de l’inférence causale aux facteurs de confusion en grande dimension et aux effets hétérogènes.

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

Le contrefactuel, illustré (stylisé)



Deux façons de tarifer le carbone



Taxes carbone

On fixe le prix, la quantité s'ajuste

- Coûts prévisibles pour les entreprises
- Émissions totales incertaines



Plafonnement et échange (SEQE)

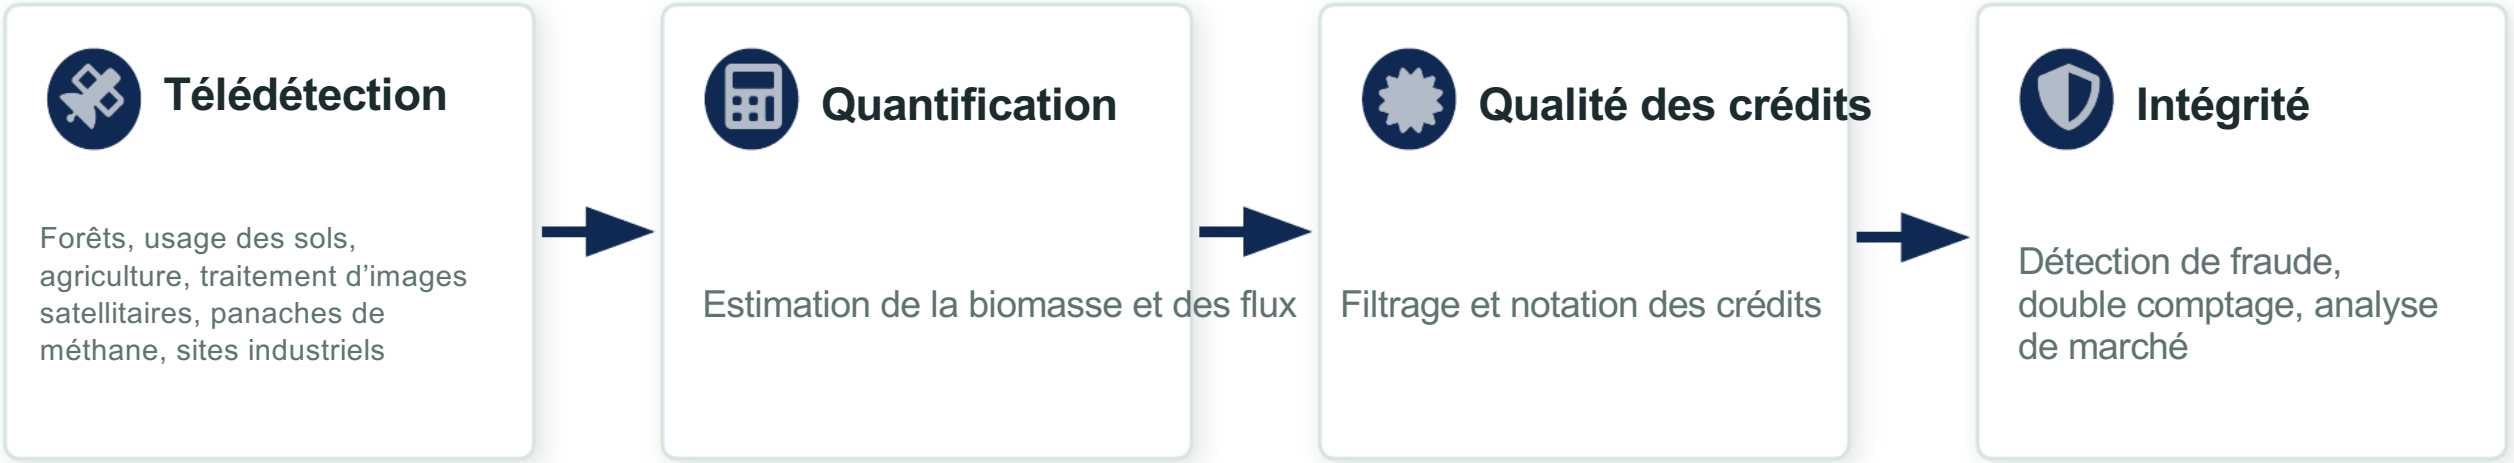
On fixe la quantité, le prix s'ajuste

- Plafond d'émissions certain
- Prix volatils
- Crée un marché des quotas

Dans les deux cas, les marchés posent un problème de mesure et de vérification :

- Il faut compter, vérifier et fiabiliser les tonnes, y compris les compensations de forêts, fermes et usines à l'autre bout du monde.
- Ce problème de vérification peut être traité avec l'IA

L’IA tout au long de la chaîne des crédits carbone



Les limites de l’IA sur les marchés carbone

Fausse précision comptable

- Une tonne « mesurée » par un modèle d’AA peut cumuler des incertitudes : elle ne peut être traitée comme une estimation exacte

Manipulation des indicateurs

- Des indicateurs mesurables invitent à la manipulation
- Les projets de captage du carbone s’optimiseront pour ce que les modèles récompensent

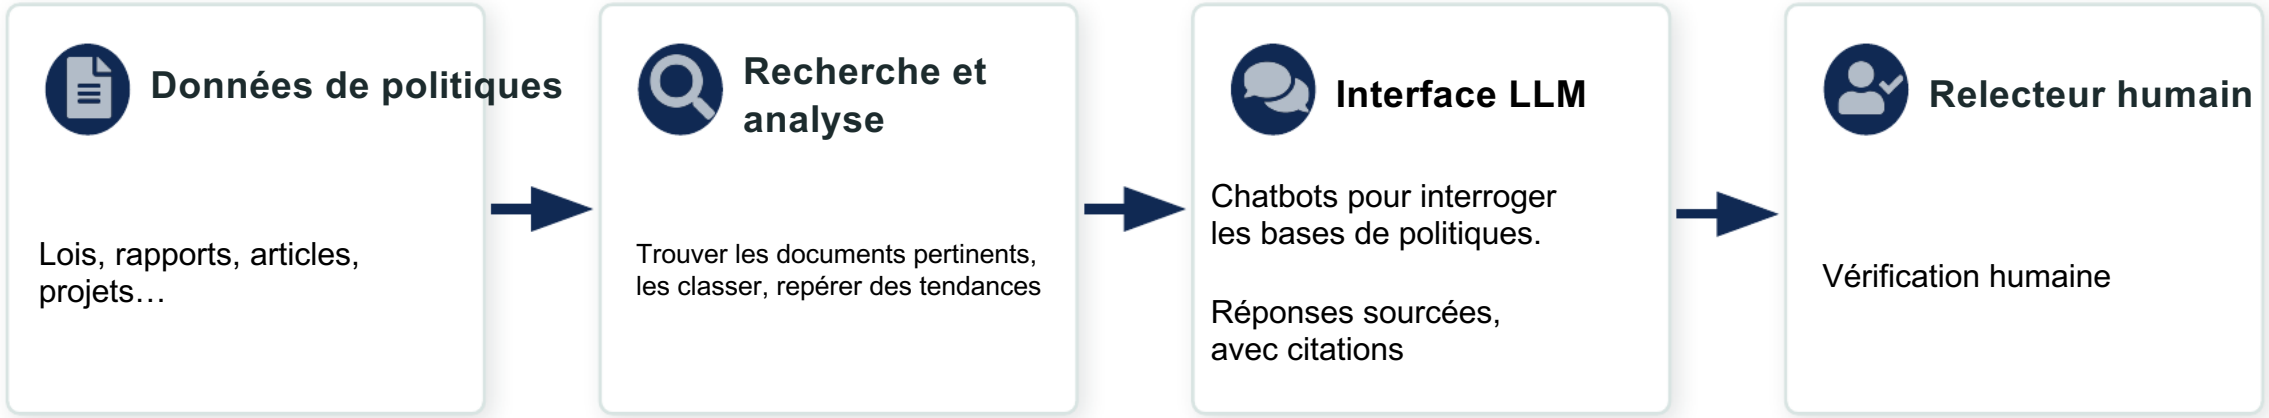
Vision en tunnel

- Optimiser la tonne de CO2 mesurable néglige les cobénéfices en biodiversité, justice et gouvernance

Vérification en boîte noire

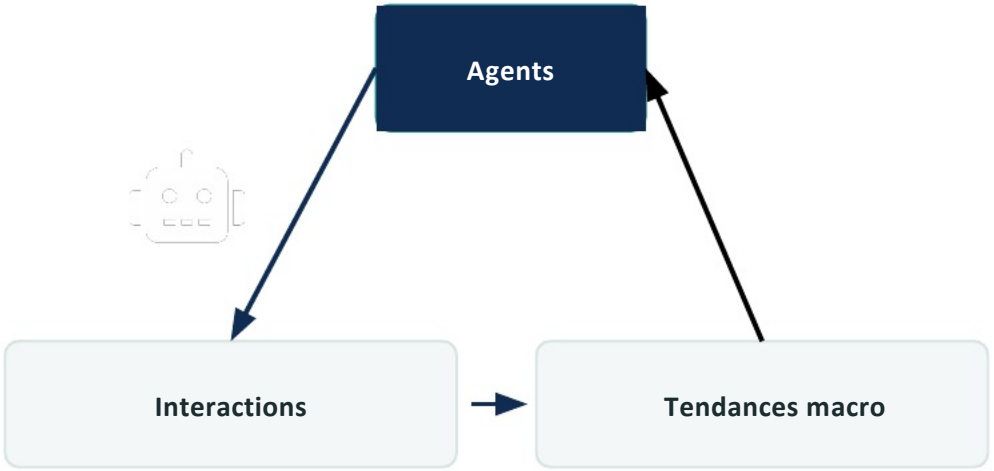
- Les modèles propriétaires ne peuvent être audités
- La confiance dans les marchés carbone ne doit pas reposer sur des créanciers privés

Les LLM dans le travail sur les politiques

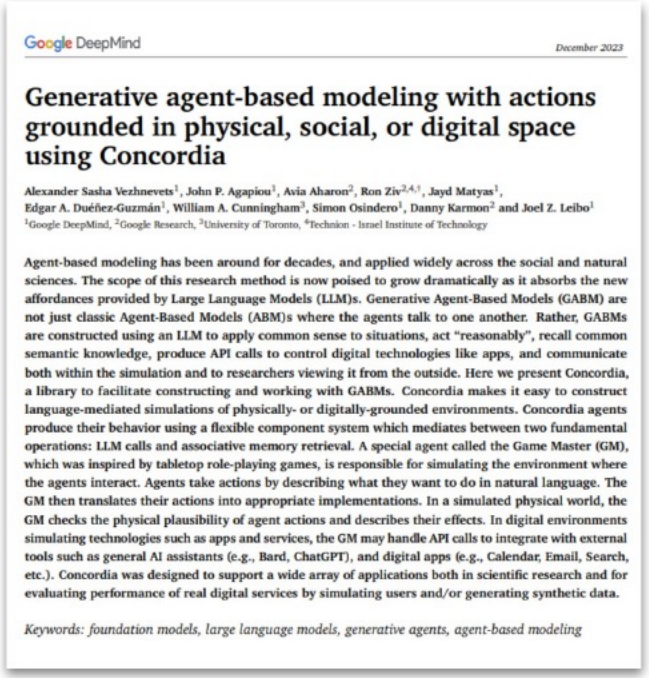


- Analyse de documents de politique
- Synthèse de la littérature
- Questions-réponses sur des corpus de politiques
- Analyse de grands ensembles de textes de politiques

Modèles multi-agents



- Acteurs hétérogènes : ménages, entreprises, lobbies
- Dynamiques macro émergeant des comportements micro
- L'acceptabilité d'une politique est explorée avant sa mise en œuvre, pas découverte après
- Les MMA peuvent suivre des règles prédéfinies, mais aussi être modélisés comme des agents interagissant via des LLM



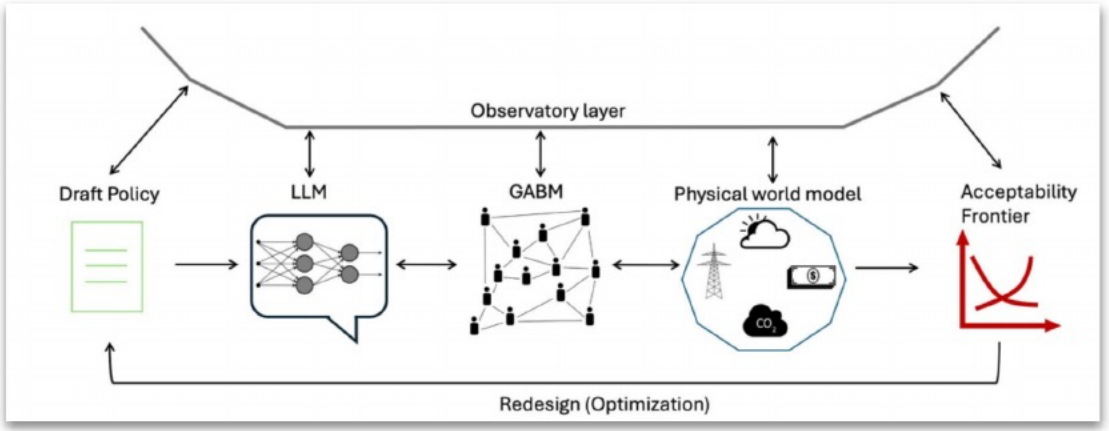
Google DeepMind December 2023

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 et MMA : plausibles mais non validés

Hallucinations

- Les LLM ont tendance à halluciner
- Les chatbots LLM ne savent généralement pas distinguer si les informations qu'ils produisent sont vraies ou fausses
- Le travail politique exige des citations vérifiables

Contexte institutionnel manquant

- Les modèles peuvent ignorer des normes, précédents, mandats, lignes rouges et contextes politiques changeants

Biais, confidentialité, excès de confiance

- Modèles parfois entraînés sur des données biaisées
- Les LLM paraissent sûrs de leurs réponses, même quand ils ne le sont pas
- Les LLM peuvent divulguer des données sensibles

Modèles propriétaires

- Poids fermés et versions changeantes
- Reproductibilité et souveraineté : un problème pour les institutions publiques
- À qui appartiennent les modèles ? Qui paie ? Des acteurs privés entraînent-ils des modèles sur des informations publiques critiques ?

L’empreinte environnementale de l’IA elle-même

Liée au calcul

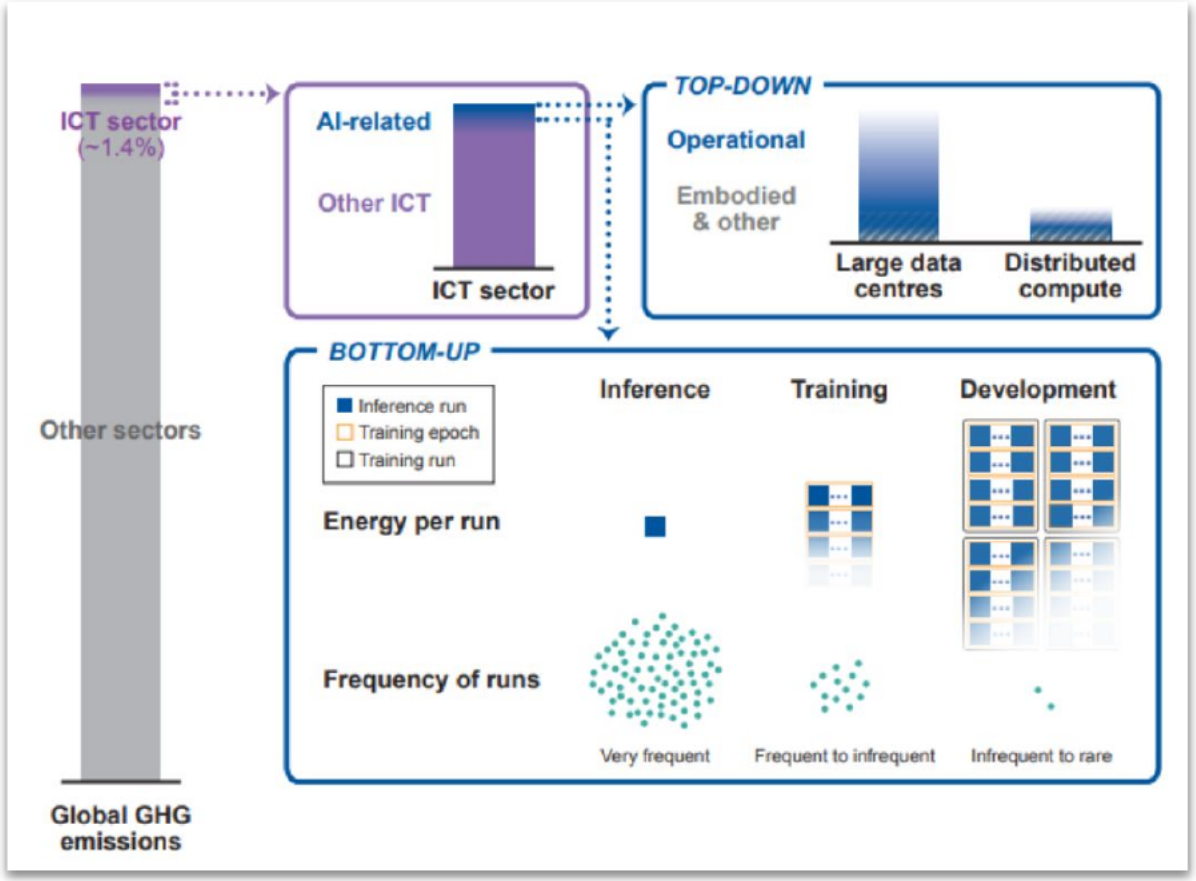
Énergie d’entraînement et d’inférence, matériel, eau

Effets de l’application de l’AA

Gains d’efficacité vs effet rebond ; qui utilise l’outil, et pour quoi

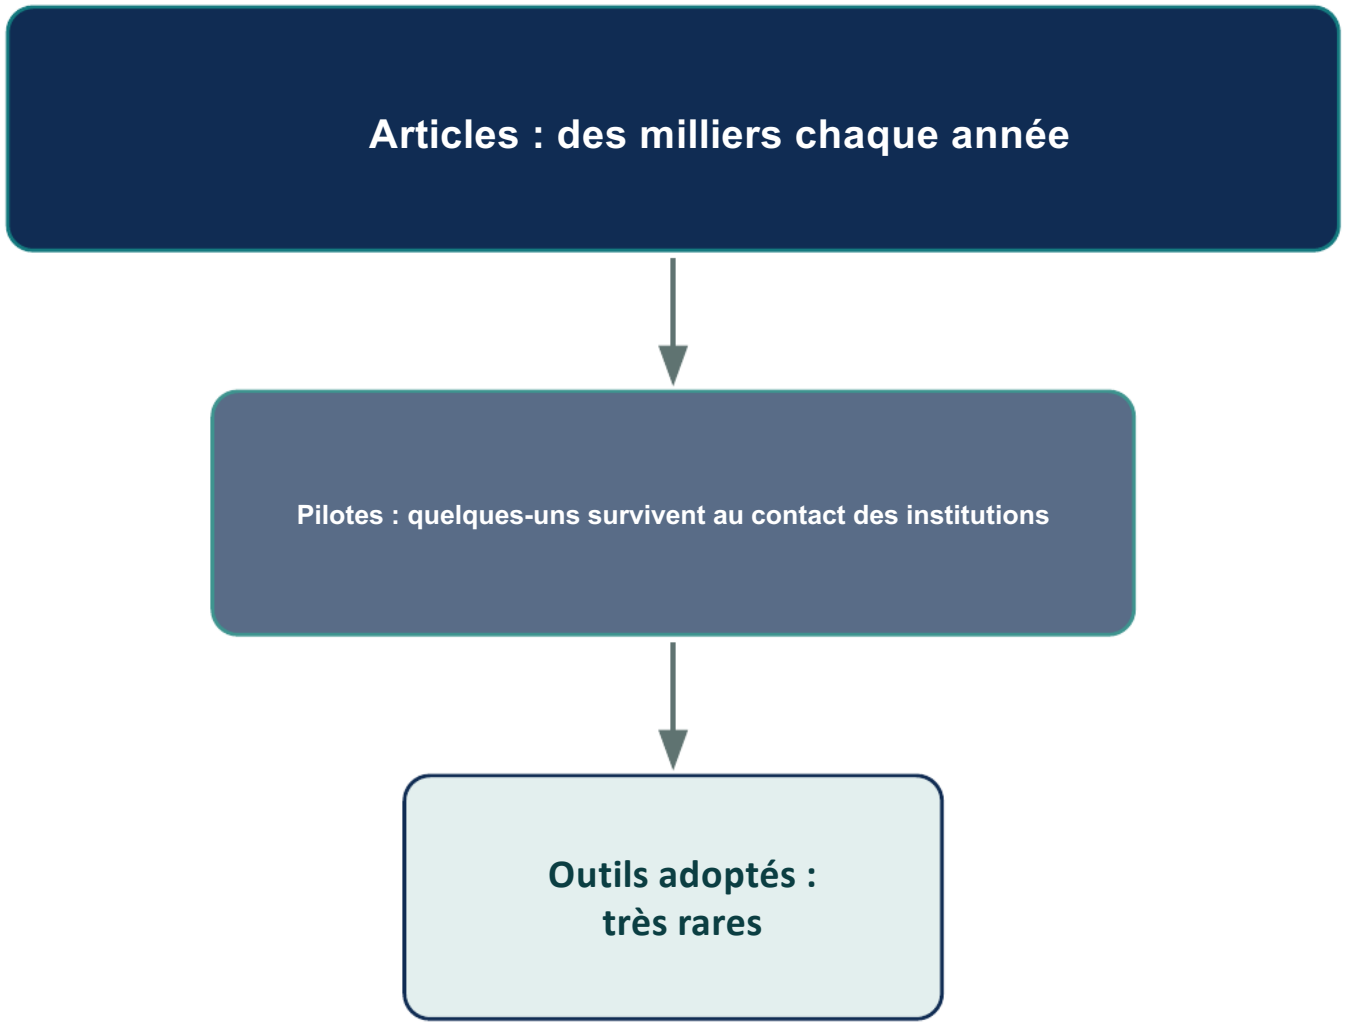
Au niveau du système

Changements de comportement, verrouillages, demande induite



D’après Kaack et al Aligning artificial intelligence with climate change mitigation

Le fossé du déploiement



Combler le fossé :

- Des référentiels d'utilité pour les politiques, pas seulement de précision prédictive
- Une incertitude bien calculée et communiquée en termes utiles à la décision
- Des collaborations ancrées : co-conception avec les personnes et communautés qui l'utiliseront et pourraient être touchées par la technologie
- Renforcer les capacités institutionnelles et la confiance

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

Quiz n° 4

Quels facteurs prendriez-vous en compte pour utiliser un LLM dans l'analyse des politiques climatiques ?

https://partici.fi/32182658

Problèmes ouverts et messages clés



Problèmes ouverts

1

Des référentiels d'utilité pour les politiques au-delà de la précision

2

Des politiques robustes face à une incertitude profonde, plutôt qu'une seule politique « optimale »

3

Des émulateurs et scénarios synthétiques qui préservent l'interprétabilité et la QI

4

Des chaînes LLM sûres et transparentes pour les institutions publiques

5

Des méthodes de co-conception avec les décideurs et les communautés concernées

6

Intégrer aléas → impacts → réponse sociale → décisions politiques

7

Dommages localisés : combler le déficit de résolution là où les données sont les plus rares

Une intelligence climatique intégrée : un grand défi

Chaque partie de ce cours était une île : mesure, futurs, incertitude, agents, évaluation.

Un grand enjeu de recherche de la décennie à venir : les relier (aléas, impacts, réponse socio-économique et décisions politiques en une seule boucle) et comprendre comment l'IA elle-même influe sur l'action climatique.

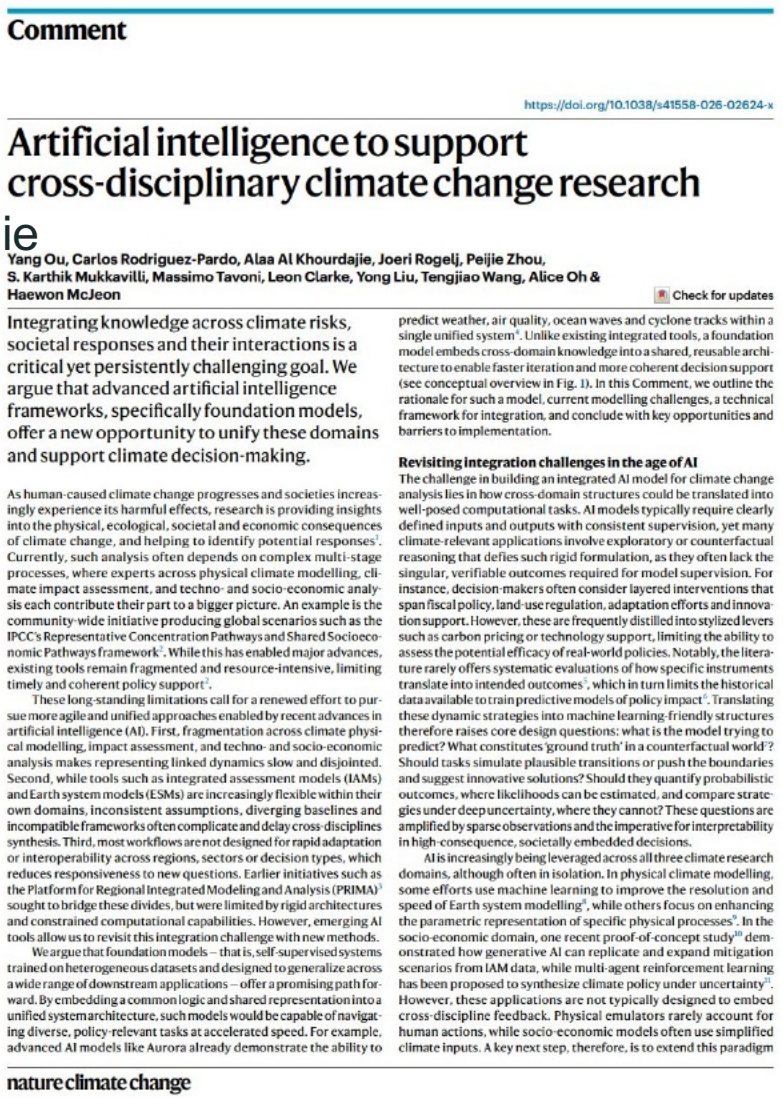

Stockholm Resilience Centre | Stockholm University

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


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).

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

La boîte à outils de départ

DONNÉES ET OUTILS

- Climate Policy Radar
- Bases de scénarios de l'IAMC
- Émulateurs d'IAM (p. ex. ML-IAM) et IAM open source / modèles énergétiques
- Population Dynamics Foundation Model
- Plongements géospatiaux et TorchGeo
- Paquets d'inférence causale et d'économétrie

COMMUNAUTÉS ET CONFÉRENCES

- Climate Change AI : vous y êtes déjà
- Ateliers CCAI à NeurIPS
- IAMC : groupe de travail IA responsable pour les IAM
- EGU · AGU · SISC · WCERE : là où se rencontrent climat, sciences de la Terre et économie



Messages clés

L’IA peut intervenir à chaque étape du cycle des politiques

- Mesure
- Futurs
- Évaluation
- Processus
- Vérification

La contrainte est rarement la précision prédictive

- Validité causale
- Valeurs
- Confiance
- Contraintes sociétales
- Institutions
- Acceptabilité sociale

L’intégration est la frontière

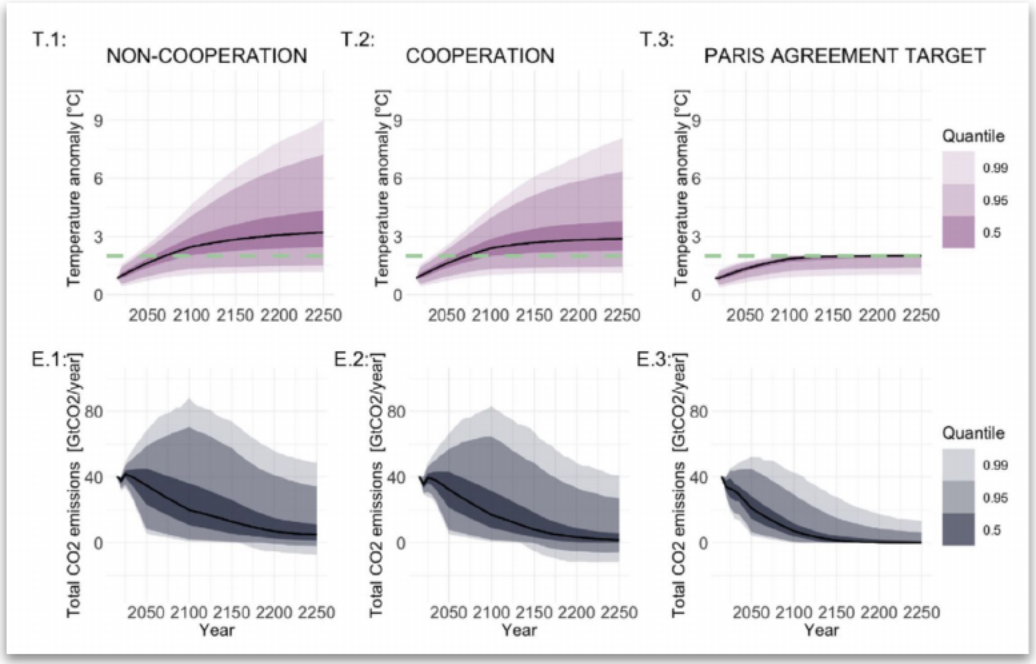
- Entre les échelles
- Entre les types de données
- Entre les étapes du cycle des politiques
- Entre institutions et communautés
- Le long de la chaîne de modélisation

Partir des questions utiles aux politiques et des problèmes des décideurs, pas des capacités des modèles ni de ce qu’on peut faire avec un jeu de données donné

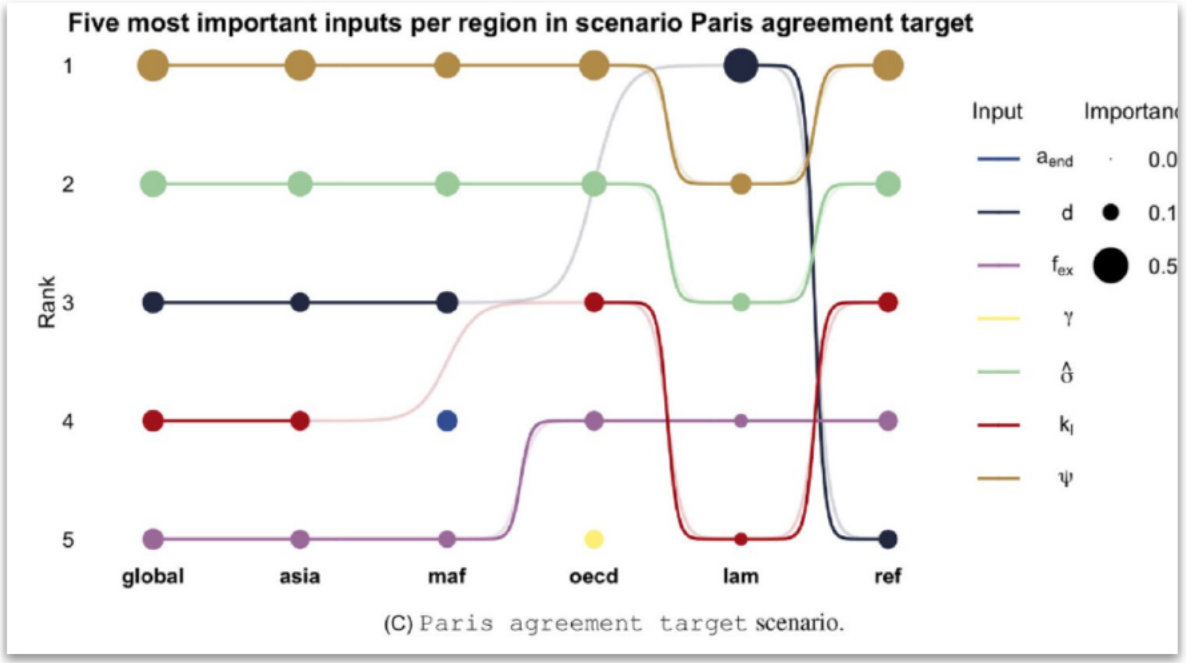
Merci de votre attention !

Quantification de l’incertitude, analyse de sensibilité

Quantification de l’incertitude

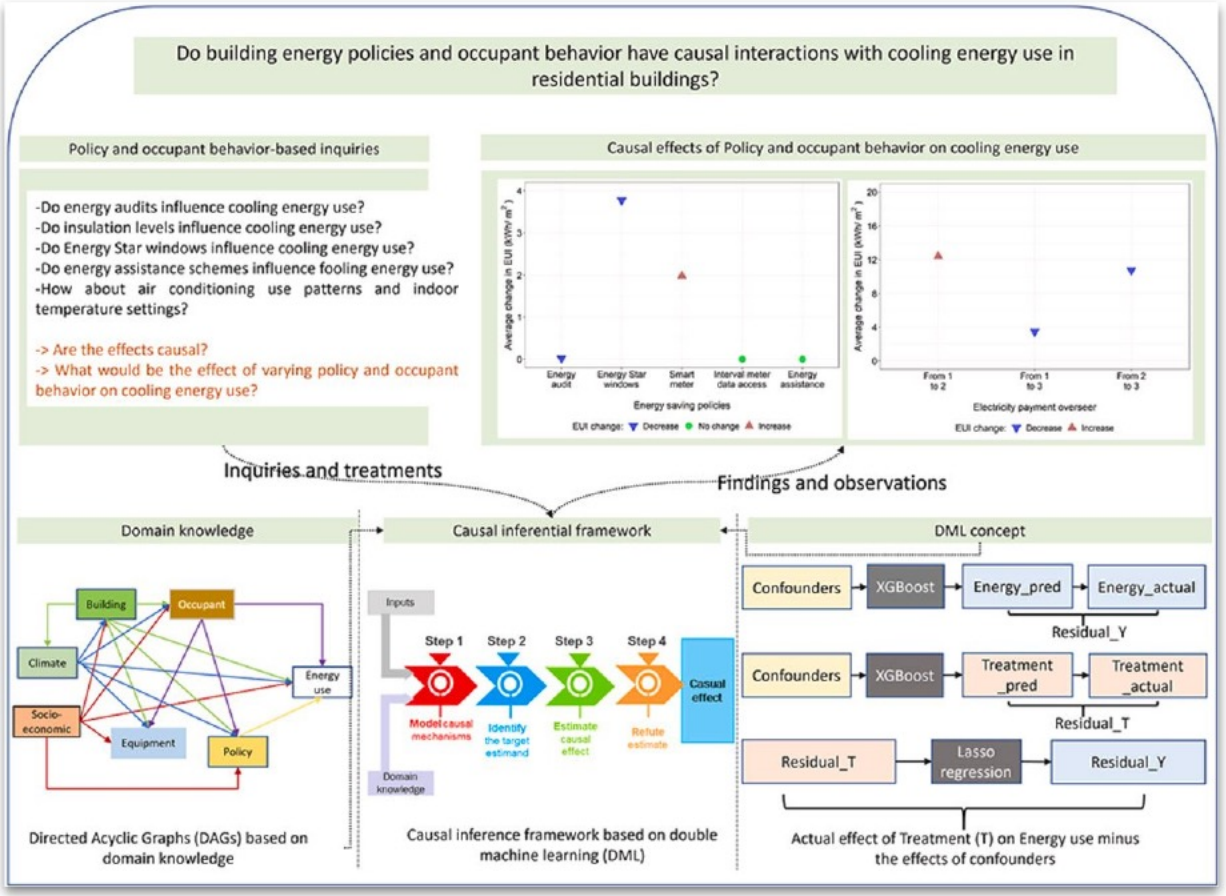


Sensibilité et explicabilité des boîtes noires



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

L'AA causal dans l'analyse des politiques climatiques



D'après Nzivugira et al. Causal effects of policy and occupant behavior on cooling energy

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

Nouvelles pistes à la croisée de l'IA et des solveurs d'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.

L'AR pour trouver de nouvelles solutions



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].

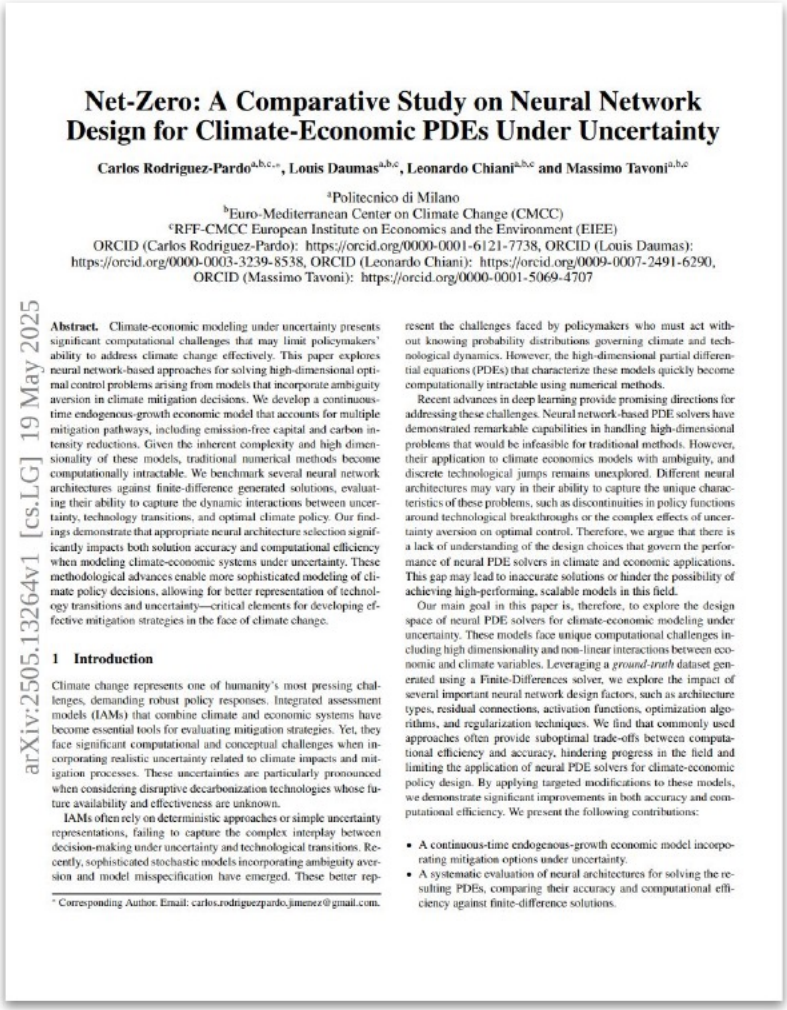
Climate change is a shared global challenge, yet mitigation entails trade-offs. Investments in low-carbon technologies and systemic transformation can constrain short-term growth and costs are unevenly distributed: wealthier nations can invest more readily, while developing countries must balance climate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



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.

Solveurs neuronaux d'EDP pour la vitesse et la quantification de l'incertitude