L’IA per le politiche pubbliche

Scuola estiva Climate Change AI 2026

Carlos Rodriguez-Pardo, PhD

Politecnico di Milano / EIEE / CMCC

Domanda di riscaldamento:

Secondo voi, qual è l’applicazione più promettente dell’IA nelle politiche climatiche?

https://partici.fi/32182658

Scuola estiva Climate Change AI 2026

Carlos Rodriguez-Pardo, PhD

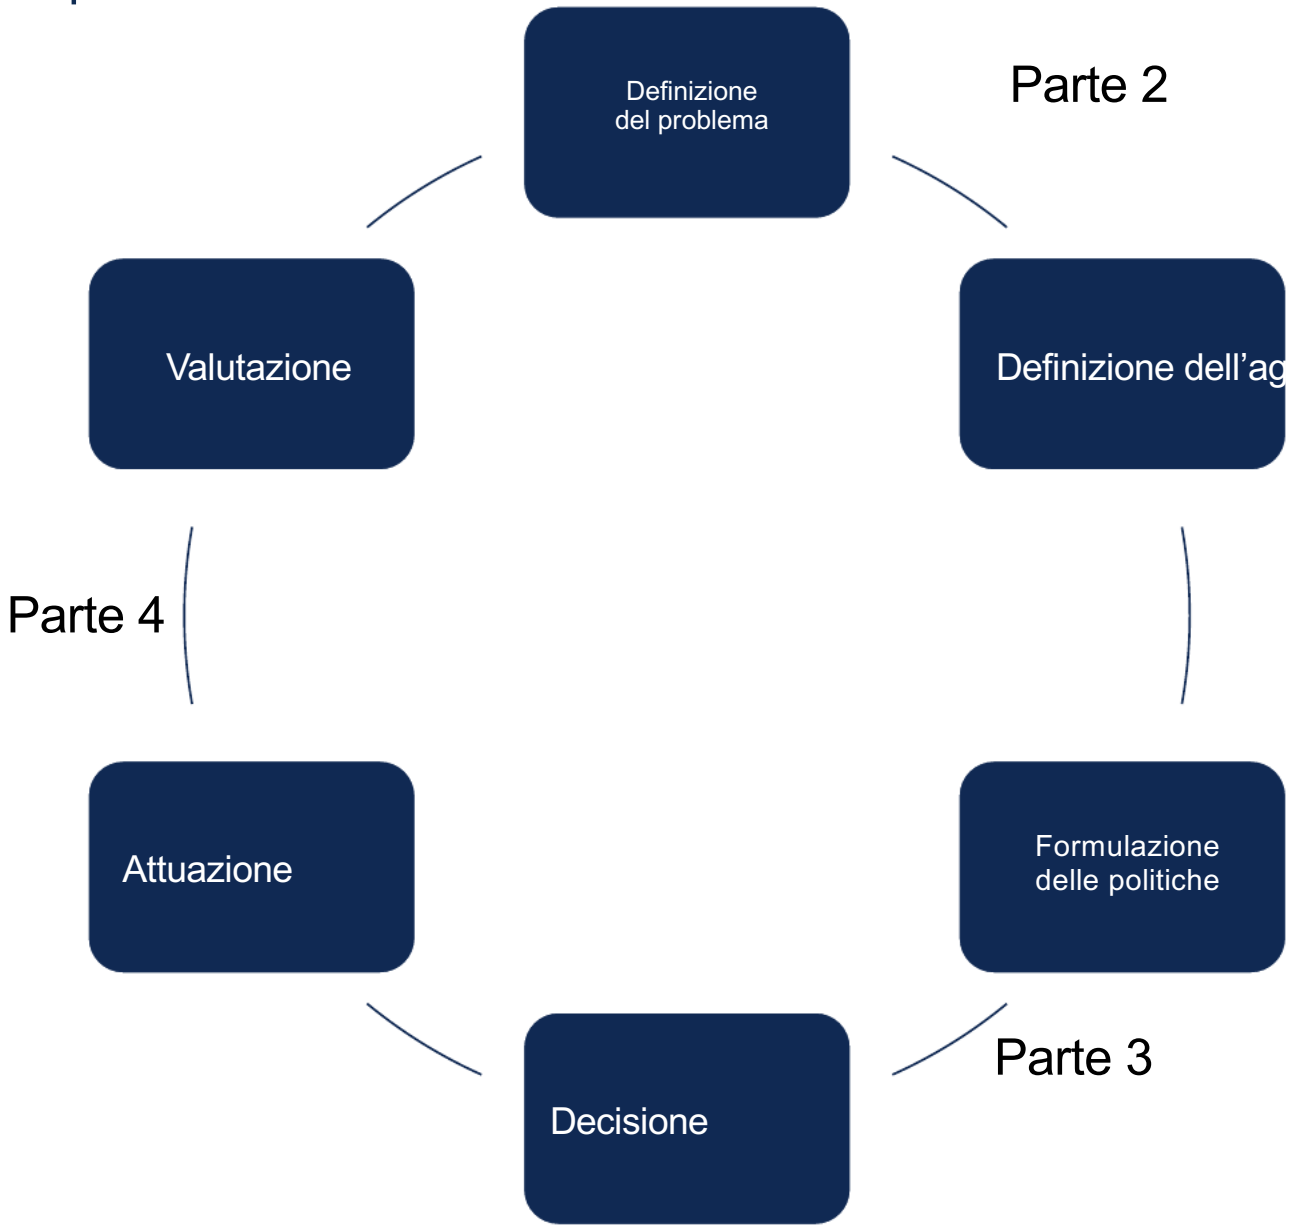
Politecnico di Milano / EIEE / CMCC

Programma di oggi

	La domanda	Il ruolo dell'IA
Parte 1: fondamenti	Quali sono gli obiettivi dell'analisi delle politiche climatiche?	Nessuno per ora, solo un'introduzione
Parte 2: misurare	Che cosa succede, che cosa si è provato, chi è esposto?	NLP su corpora di politiche · computer vision e telerilevamento · modelli fondazionali geospaziali / del sistema Terra
Parte 3: modellare i futuri	Che cosa potrebbe succedere con politiche e attori diversi?	Emulatori di IAM · solutori neurali di EDP · AR e AR multi-agente
Parte 4: valutazione e messa in opera	Una politica ha funzionato? Sarà accettata? È affidabile?	AA causale · LLM · modelli ad agenti

Il ciclo delle politiche pubbliche

Dove può aiutare l'IA nelle politiche climatiche?



Quali istituzioni partecipano alle decisioni politiche?

Internazionali: UNFCCC, IPCC, UE

Governi nazionali e regionali

Enti locali

Attori settoriali: fornitori di elettricità, agenzie dei trasporti

Attori privati: assicuratori, imprese, banche, certificatori, ecc.



- Attori diversi con problemi e priorità diversi
- Scale temporali diverse (politiche decennali vs utili trimestrali)
- Leve diverse: tasse sul carbonio, quota di rinnovabili, % di veicoli elettrici nel trasporto pubblico
- Risoluzioni spaziali diverse (politiche continentali, urbanistica, ristrutturazioni edilizie…)

L’IA può aiutare le politiche a tutte queste scale

Che cosa cerca di ottenere l’analisi delle politiche climatiche?

Stimare danni e rischi

Quanto grave, dove, per chi e quando?

Confrontare opzioni, valutare compromessi

Mitigazione, adattamento o accettazione delle perdite.

Progettare gli strumenti

Tasse, norme, sussidi, piani, mercati.

Valutare che cosa ha funzionato

Le nostre politiche hanno cambiato qualcosa, e a quali condizioni?

Decidere nell’incertezza

Scelte robuste nonostante grandi incognite.

Le risposte politiche ai cambiamenti climatici



Mitigazione

Obiettivo: evitare o ridurre la concentrazione di gas serra nell'atmosfera

Esempi:

- Standard sulle rinnovabili
- Obblighi per i veicoli elettrici
- Cattura e stoccaggio del carbonio
- Tasse sul carbonio
- Elettrificazione



Adattamento

Obiettivo: ridurre i danni inevitabili del riscaldamento

Esempi:

- Difese dalle alluvioni
- Isolamento degli edifici
- Sistemi di allerta precoce
- Infrastrutture



Perdite e danni

Obiettivo: compensare ciò che non si può evitare né adattare

Esempi:

- Finanza climatica
- Attribuzione

L'analisi delle politiche deve confrontare le tre e capirne costi, compromessi e fattibilità. Servono strumenti come il costo sociale del carbonio e le stime dei danni.

La cassetta degli attrezzi delle politiche

Prezzo del carbonio

Tasse e scambio di quote

Regolamentazione e standard

Divieti, codici, regole di efficienza

Sussidi e investimenti

R&S pubblica, rinnovabili, ristrutturazioni

Politica industriale

Strategia industriale verde

Pianificazione dell'adattamento

Riduzione dei rischi e resilienza

Finanza climatica

Chi paga, chi viene compensato

Mercati del carbonio e compensazioni

Crediti, MRV, integrità

Queste politiche possono contendersi gli stessi bilanci

Il costo sociale del carbonio

Il costo sociale del carbonio è il danno economico causato da una tonnellata in più di CO2 emessa, espresso in moneta di oggi.

+1 tonnellata di CO2 emessa oggi

↓

Provoca altro riscaldamento globale per secoli

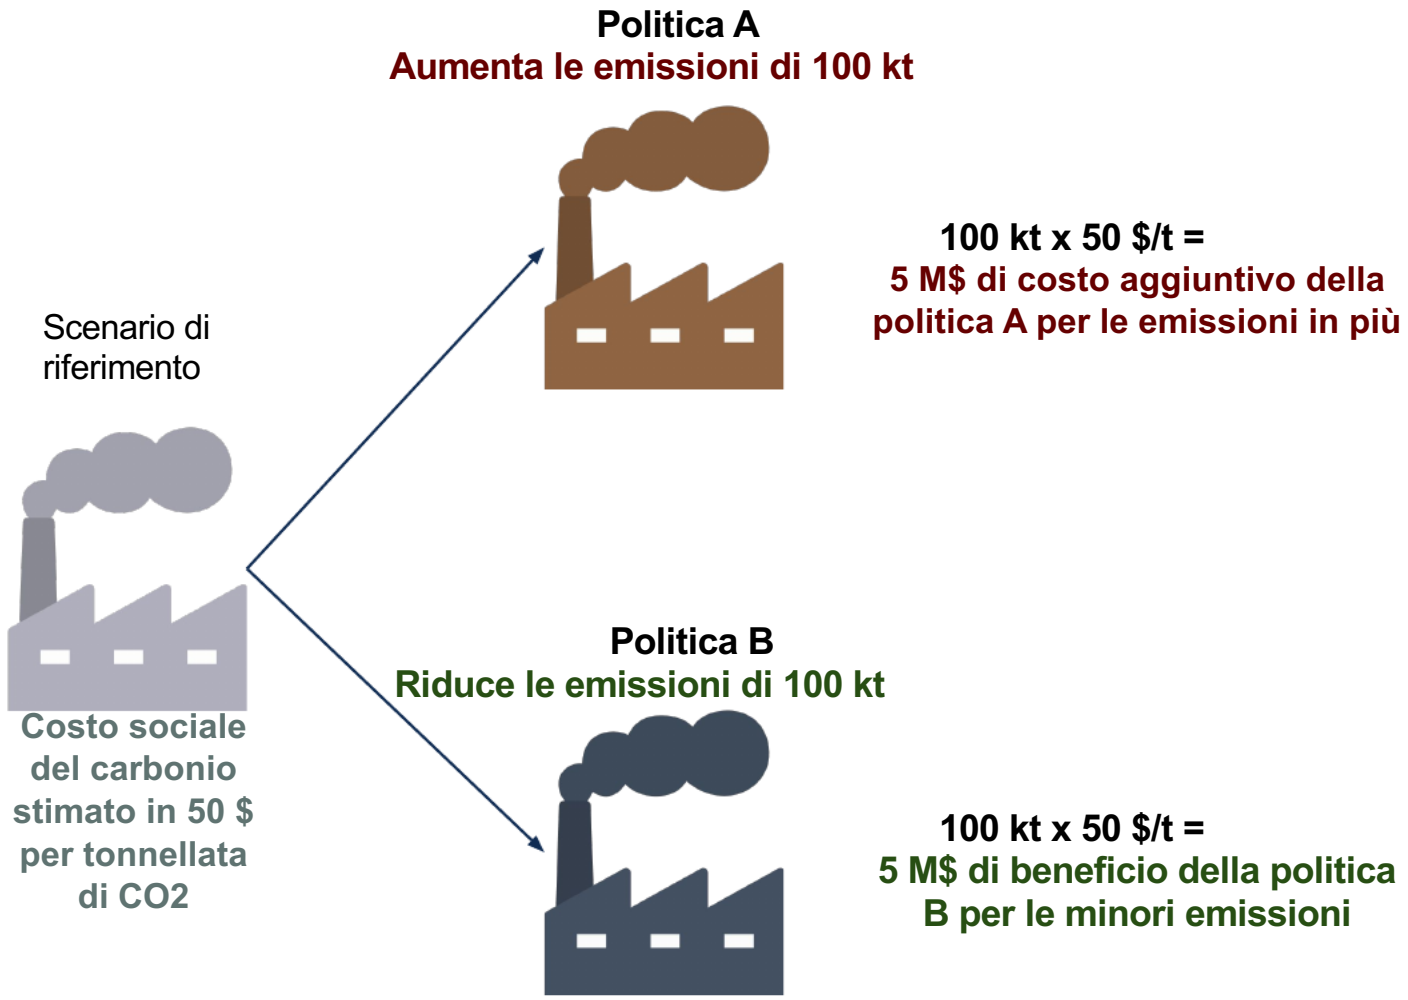
↓

Che causa danni futuri: salute, raccolti, capitale…

↓

Attualizzare quei danni al valore presente: $ / CO2

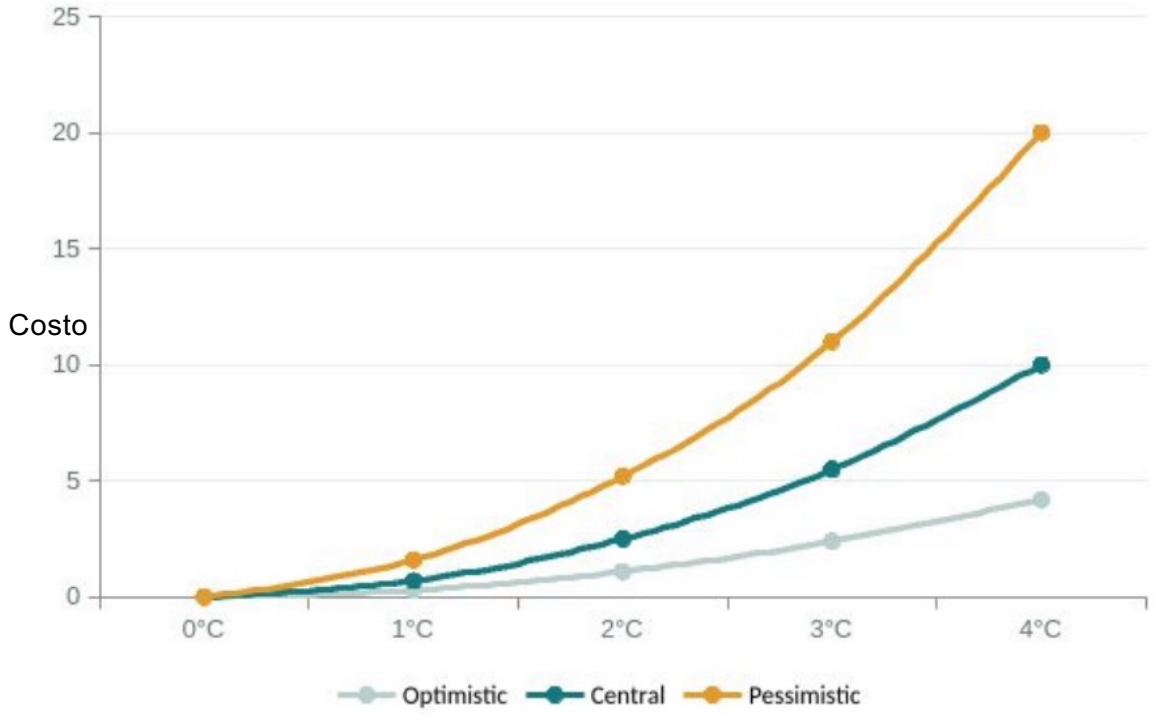
Tutte queste frecce nascondono modelli, ipotesi e incertezze



Funzioni di danno

- Traducono il riscaldamento globale in perdite economiche
- Stimate da dati storici ed estrapolate ben oltre

- Queste funzioni sono molto usate nei modelli di valutazione integrata e in altri strumenti di analisi delle politiche
- Forma funzionale, punti di non ritorno e ipotesi di adattamento sono tutti contestati
- Anche la loro incertezza ha implicazioni politiche



Dove si colloca l’IA in tutto questo?

Dati

Elaborare fonti di dati complesse e trarne indicazioni: immagini satellitari, documenti politici, reti, sensori, dati economici…

Modelli

Aiutare a modellare sistemi socioeconomici e climatici complessi:

- Modelli fondazionali
- Modelli di valutazione integrata
- Apprendimento per rinforzo

Decisioni

- Stimare la possibile efficacia di diverse politiche
- Capire se le politiche passate sono state efficaci e a quali condizioni
- Ottimizzare l’allocazione delle risorse

PARTE 2: MISURARE

PARTE 3: MODELLARE I FUTURI

PARTE 4: VALUTARE E METTERE IN OPERA

Riferimenti utili:

- 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:

Quali informazioni servono per stimare il costo sociale del carbonio?

Traiettorie di emissione

Dove sta andando il mondo? Scenari, incertezze

Risposta climatica (TCRE)

Quanto riscaldamento per ogni tonnellata di CO_2 in più?

Funzione di danno

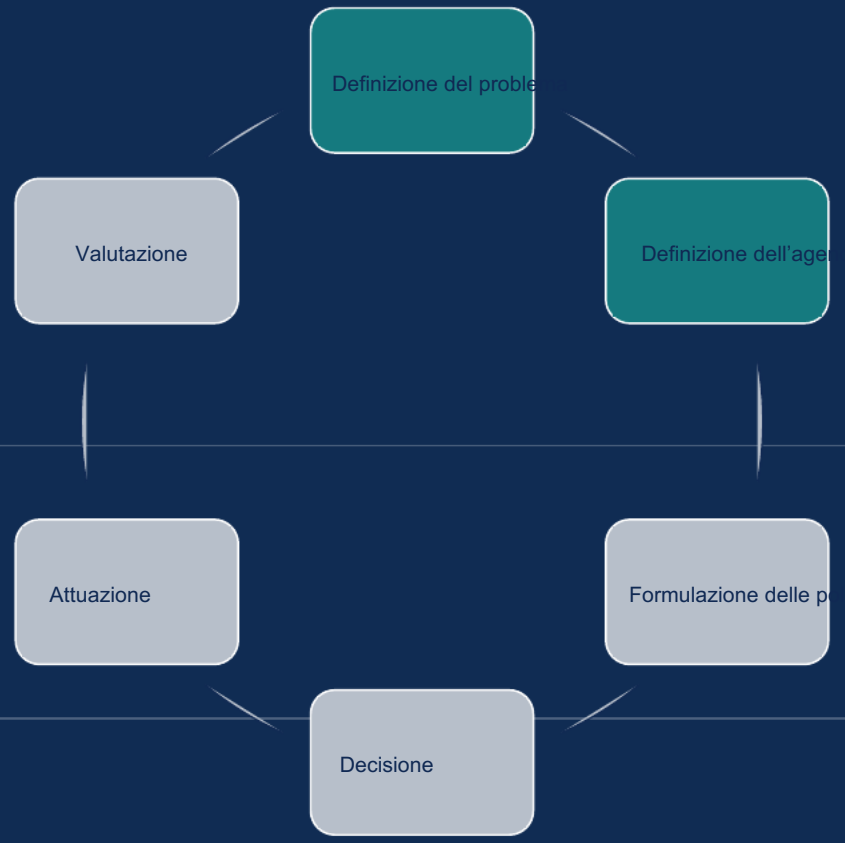
Qual è il costo di ogni unità di riscaldamento in più?

Attualizzazione

Quanto ci importa del futuro rispetto al presente?

Parte 2: misurare il mondo delle politiche e gli impatti climatici

- Quali politiche esistono?
- Che cosa succede nel mondo?
- Chi è esposto?



Che cosa serve sapere per progettare politiche efficaci?



Quali politiche esistono oggi?

- Banche dati delle politiche
- Monitoraggi delle politiche



Dove avvengono le emissioni?

- Inventari
- Stime



Chi è esposto? Chi sono gli attori chiave?

Mappatura della vulnerabilità



Che cosa dice la letteratura?

Mappe delle evidenze, rassegne,



Dove sono le lacune di evidenza?

Dove sono le incertezze? Quali evidenze mancano?

Come sapere che cosa è già stato provato e studiato?

Armonizzazione delle banche dati sulle politiche

Input:
- Documenti nazionali frammentati
- Banche dati globali, regionali, settoriali

Metodi
- Elaborazione del linguaggio naturale,
- conoscenza esperta, apprendimento a regole
- Apprendimento semi-supervisionato

Output:
- Panel di politiche confrontabili tra paesi
- Chi ha adottato quale politica e quando
- Formato comune, allineato all'IPCC

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

Mappatura della letteratura scientifica

Input:
- Centinaia di migliaia di articoli sulle politiche climatiche
  - Impossibile da leggere e analizzare per una persona o un gruppo di ricerca

Metodi
- Elaborazione del linguaggio naturale
- Classificazione dei testi
- Mappatura dei temi

Output:
- Mappe delle evidenze
- Lacune della letteratura, evidenze scarse

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

Misurare ciò che accade, a una risoluzione utile alle politiche

Misure ad alta risoluzione e qualità dell'aria

- Stime con AA delle emissioni urbane di gas serra subnazionali
  - Yu et al. https://www.nature.com/articles/s41597-026-06691-9
- Classificazione con AA delle stazioni di qualità dell'aria
  - Renna et al (https://www.nature.com/articles/s41597-026-06797-0.pdf)

Leggere e capire i documenti politici

- NLP per classificare i programmi politici (Sanford et al. doi:10.1017/S0007123425100719)

La sfida dell'integrazione

- Come collegare politiche, settori, emissioni, territori, popolazioni e risultati? Come
- trasformare dati e modalità disgiunti in evidenze utili alle politiche?

Riferimenti:

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

La catena di modellazione degli impatti



L'IA accelera già questi anelli

Impatto dell'IA scarso o nullo

Dati deboli, la lacuna scientifica più grande

Le lezioni IA per il meteo e IA per le scienze del clima della scuola CCAI26 tratteranno a fondo questi temi. Qui ci concentriamo sugli impatti climatici e su come entrano nelle decisioni politiche

Perché la risoluzione conta

Cella globale

~100-1000km

- Un paese è sulla buona strada?
- Quali sono le tendenze climatiche di quest'area?

Regioni

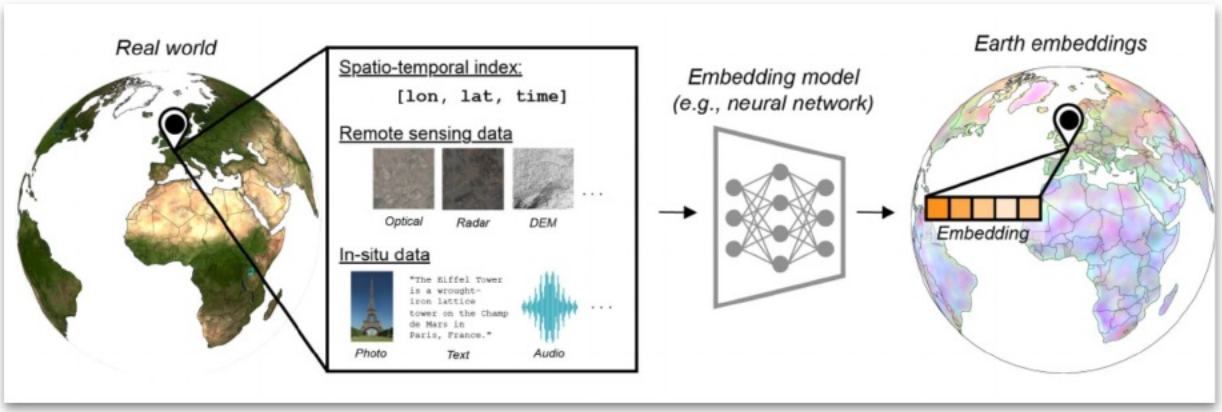
~10-100km

- Dove destinare i fondi per l'adattamento?
- Quali città sono più vulnerabili agli estremi?
- Quali popolazioni sono più vulnerabili?

Isolati urbani

~10m-10km

- Quali quartieri hanno bisogno di protezione dalle alluvioni?
- Da dove vengono le emissioni?
- Dove piantare alberi?



Gli embedding geospaziali e i modelli fondazionali del sistema Terra collegano bene le risoluzioni: si apprende una rappresentazione una volta e la si riutilizza in più analisi di impatti, ricostruzione ed esposizione.

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

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

Dati migliori cambiano le decisioni reali

Mirare l’adattamento

Chi proteggere per primo, e a quale costo?

Finanza climatica e perdite e danni

Stime dei danni più accurate migliorano le decisioni finanziarie

Ecosistemi e natura

Quali impatti climatici sulla biodiversità, e dove? Quali specie sono più colpite?

Assicurazioni

Miglioramenti in prezzi, assicurabilità, copertura e gestione del rischio

Pianificazione delle infrastrutture

Che cosa costruire e come? Quali probabilità di grandi alluvioni, ondate di calore, nevicate estreme?

Valutazione distributiva

Chi sarà più colpito dai cambiamenti climatici? Quali impatti su uguaglianza e salute?

Esempio: allocazione dei fondi per l’adattamento

Con dati grossolani e di bassa qualità:

- I fondi possono seguire tendenze, bias, lobbying
- I fondi possono non andare alle popolazioni che ne hanno più bisogno
- Il denaro pubblico è allocato in modo subottimale

Con dati di impatto localizzati ad alta risoluzione

- I fondi seguono esposizione e vulnerabilità
- I fondi sono allocati in modo robusto e difendibile
- I decisori capiscono meglio compromessi e limiti

La misura non è neutrale

Falsa precisione

- I risultati ad alta risoluzione sembrano esatti, ma spesso non lo sono
- Molti dataset comuni (ad es. ERA5) nascondono ipotesi e scelte di modellazione, e modelli
- Le incertezze si sommano in modo invisibile

La disponibilità di dati non è uniforme

- La copertura dei dati tende a essere minore proprio dove la vulnerabilità è maggiore
- Per questo i modelli estrapolano e sono meno accurati nelle regioni più vulnerabili
- Ad es.: 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)

Documentato non significa efficace

- Le banche dati registrano ciò che è scritto, non necessariamente ciò che è stato efficace

Perdite nascoste

- Alcune variabili sono più difficili da misurare di altre. Le funzioni di danno possono trascurare
  - I danni non di mercato
  - La distribuzione dei danni
  - Le perdite culturali
  - I danni ecologici

https://partici.fi/32182658

Quiz n. 2

Perché una funzione di danno globale o dati di emissione ad alta risoluzione potrebbero non bastare per decidere dove destinare i fondi per l'adattamento?

Precisione ≠ pertinenza

Modelli e dati possono essere meno precisi dove la precisione conta di più

Vulnerabilità trascurate

Lo stesso estremo climatico può essere un disastro per una comunità e un semplice disagio per un'altra

Scelte normative

Chi privilegiare? I più numerosi, i più vulnerabili? Efficienza o equità?

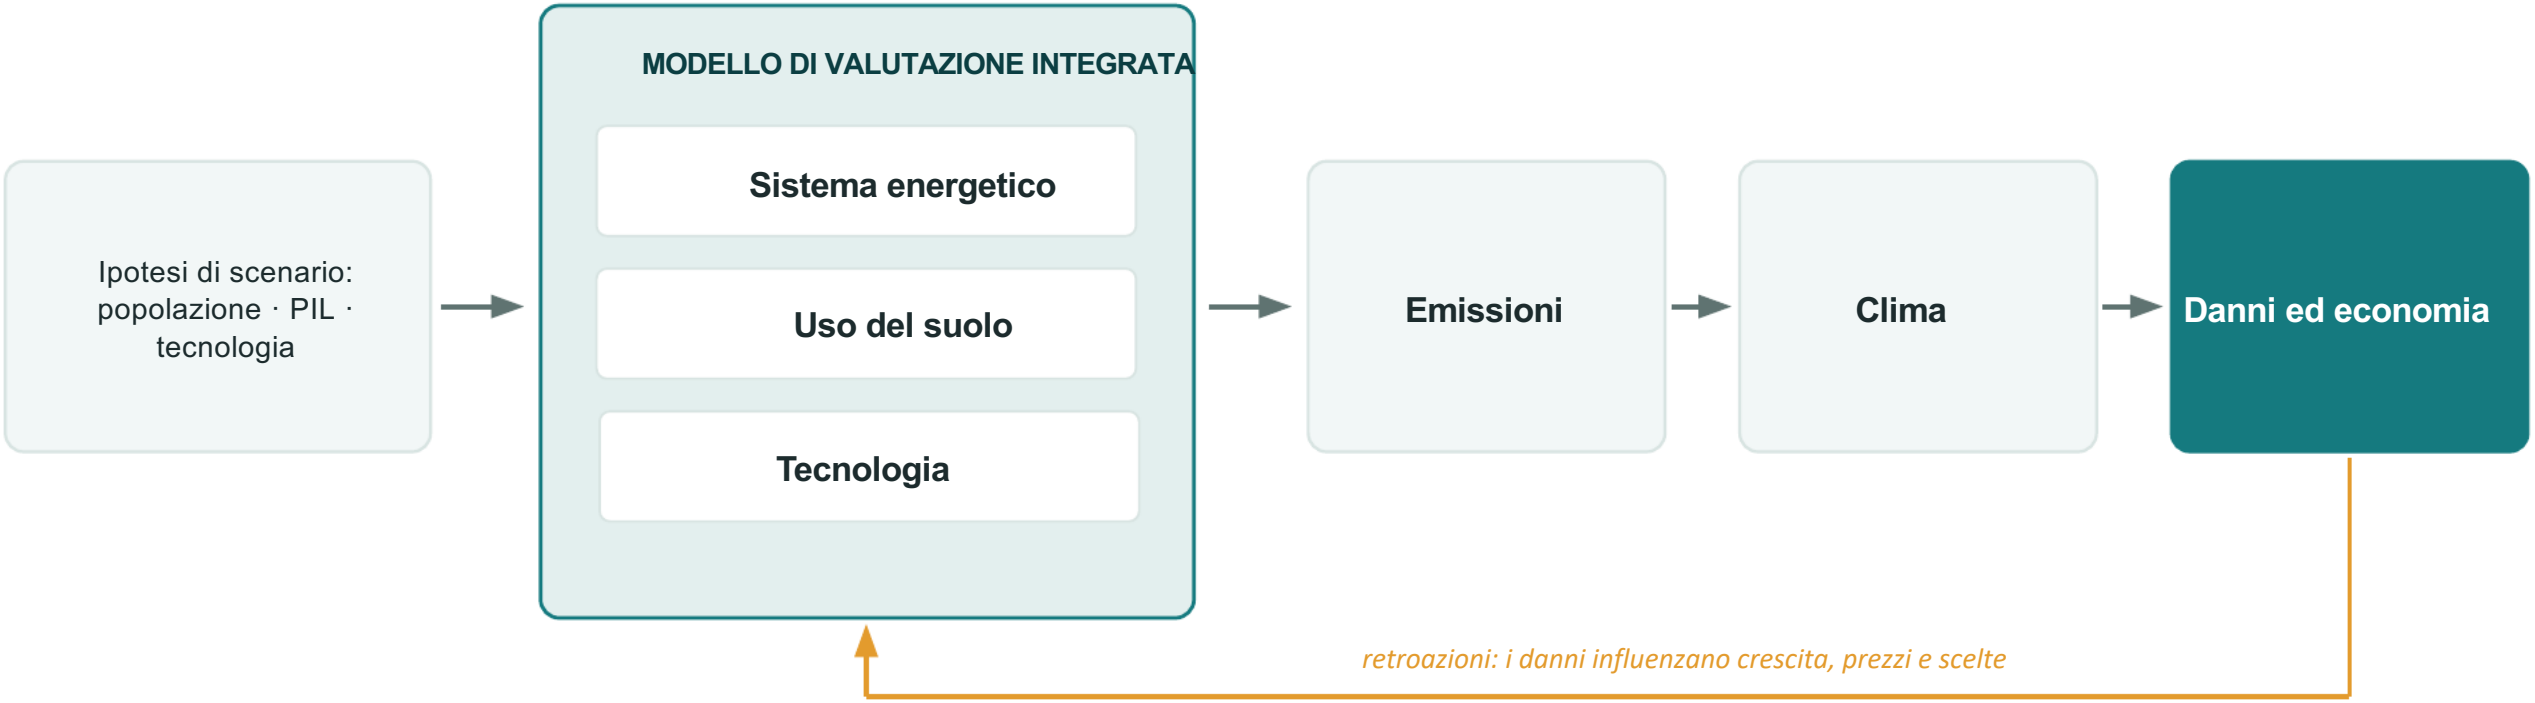
Dati migliori sono necessari ma non sufficienti:
aiutano a circoscrivere i dibattiti, ma non possono decidere quali domande contano per le politiche

Parte 3: modellare i futuri e progettare opzioni politiche

- Come modellare il clima e l’economia futuri?
- Come modellare i molti attori delle politiche climatiche?
- Come garantire che i nostri modelli siano affidabili?



Modelli di valutazione integrata (IAM)



- Gli IAM modellano mondi stilizzati: utili per domande «e se?», non per fare previsioni
- Esistono diverse famiglie di IAM:
  - IAM costi-benefici (DICE)
  - IAM dettagliati per processo (REMIND, WITCH)

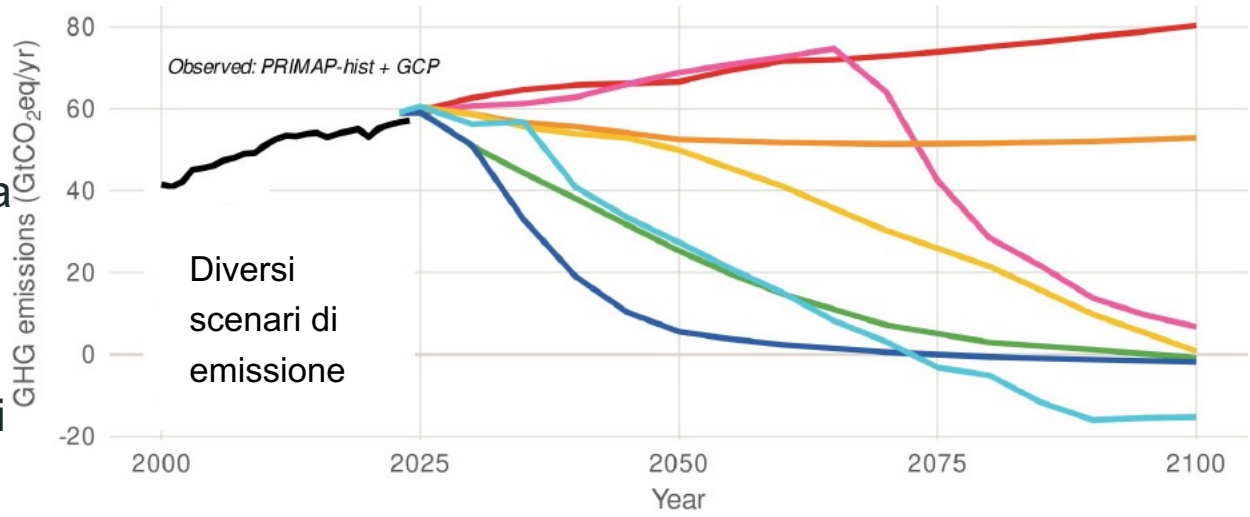
Che cosa ci dicono gli IAM

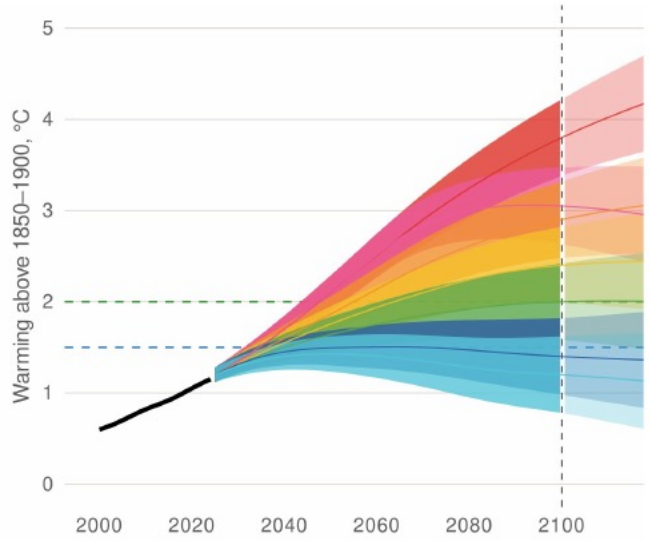
- Traiettorie a costo minimo verso gli obiettivi di temperatura
- Portafogli tecnologici: quanto eolico, CCS, nucleare, quando e a che costo
- Traiettorie del prezzo del carbonio coerenti con gli obiettivi
- Ripartizione regionale degli sforzi e sua (in)equità
- Banche dati di scenari dell'IPCC

IAMC
Integrated Assessment Modeling Consortium
Founded 2007

ipcc
INTERGOVERNMENTAL PANEL ON climate change

Traiettorie di emissione stilizzate ($GtCO_2$/anno)





L’IA per emulare gli IAM

- Gli IAM sono utili ma molto costosi dal punto di vista computazionale
- Gli ensemble di modelli per misurare l’incertezza possono diventare ingestibili
- Gli emulatori di AA possono aiutare:
  - Imparano a collegare input e output di un IAM
  - Una volta addestrati, rispondono all’istante
- ML-IAM consente di esplorare gli scenari in modo interattivo
  - Ad es. Shin et al., ML-IAM v1.0 · Li et al. 2025, deep learning per le variabili degli scenari globali di mitigazione (https://egusphere.copernicus.org/preprints/2026/egusphere-2025-5305/)

1

Scenario IAM
da ore a giorni di calcolo

10.000+

valutazioni dell’emulatore nello stesso tempo

(illustrativo)

Apprendimento per rinforzo: le politiche come sequenze di decisioni



- La politica climatica è sequenziale: agire, osservare, correggere, per decenni
- L'AR esplora traiettorie di politiche, non singole impostazioni
- Accoppiato agli IAM, l'AR può raggiungere zone dello spazio delle soluzioni che i solutori classici non esplorano mai
- **Risultato utile: strategie candidate sorprendenti, mai esplorate**

Agenti in competizione e cooperazione

- Molti attori, con obiettivi e priorità diversi e in continua evoluzione (paesi, imprese, regolatori)
- Cooperano, competono, fanno i furbi o si ignorano
- L'AR multi-agente rende visibili e quantificabili gli incentivi disallineati e i fallimenti di coordinamento

	B riduce	**B ne approfitta**
A riduce	Tutti pagano, il pianeta vince	A paga, B ne beneficia
A ne approfitta	B paga, A ne beneficia	**Nessuno paga: tutti perdono**

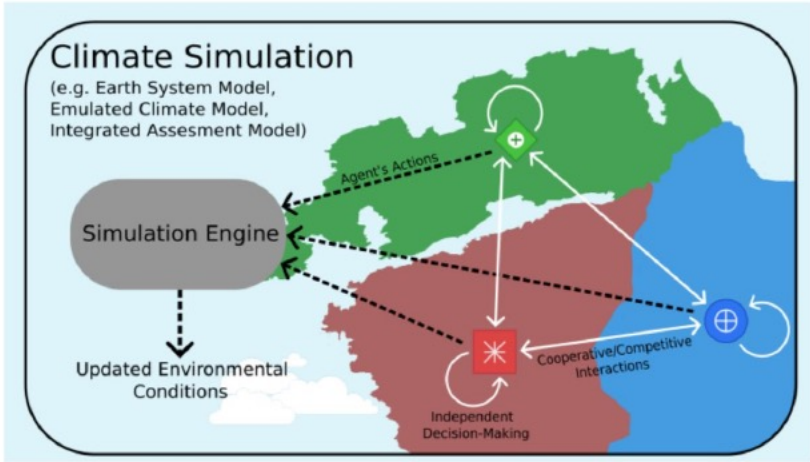
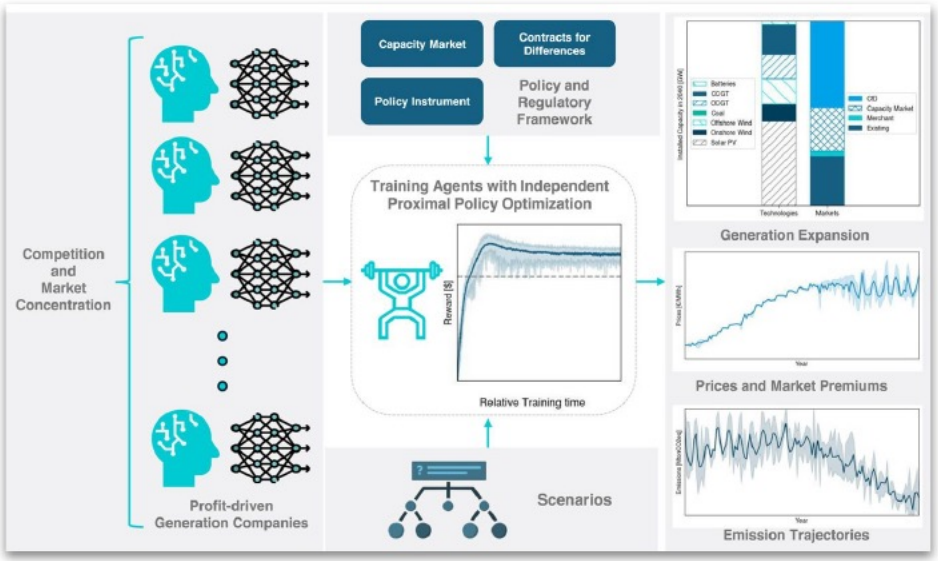


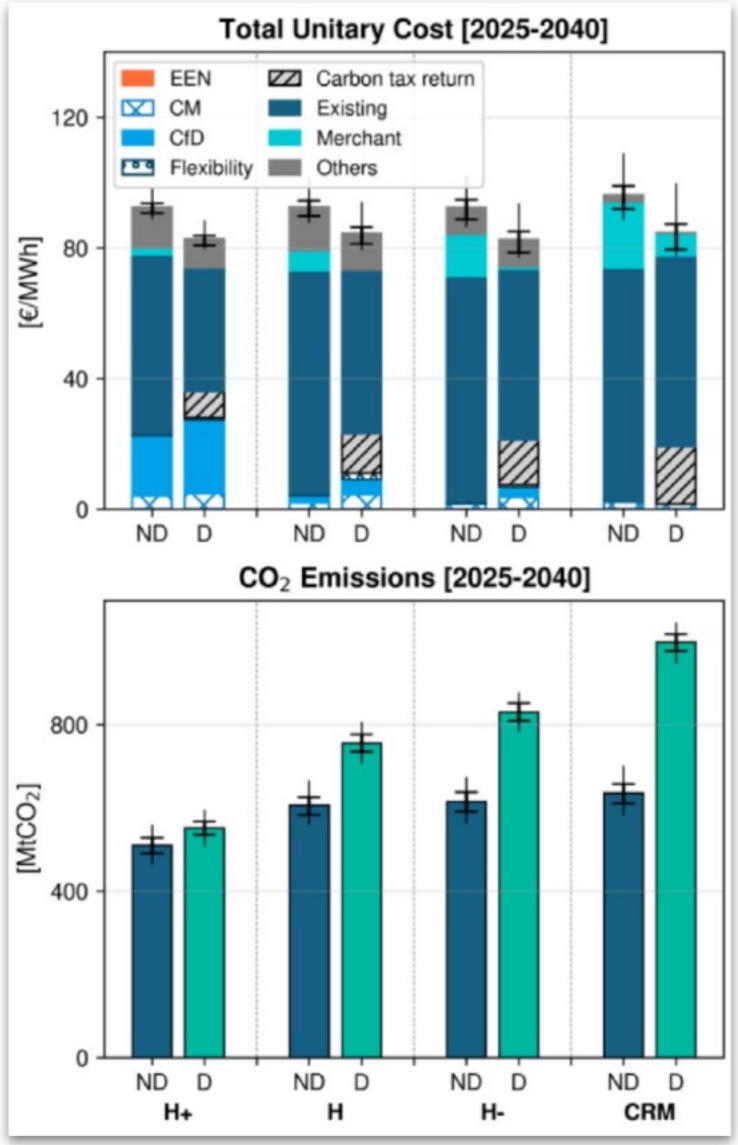
Figura da Multi-Agent Reinforcement Learning Simulation for Environmental Policy Synthesis (Rudd-Jones et al.)

AR multi-agente per progettare la politica del mercato elettrico a lungo termine

- **Domanda: quali assetti di mercato portano a una decarbonizzazione profonda a prezzi accettabili?**
- **Approccio: i produttori sono agenti che apprendono, fanno offerte e investono con regole di mercato alternative**
- Gli agenti rivelano comportamenti strategici che l'analisi di equilibrio non coglie
- Le scelte di progettazione spostano visibilmente prezzi e risultati di decarbonizzazione



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

Che cosa l’AR non può decidere

I valori non si apprendono

- L’AR ottimizza all’interno di un problema
- formalizzato. Ciò che la società deve valorizzare non è qualcosa che l’AR possa o debba ottimizzare

Una sola ricompensa non può modellare obiettivi complessi, interconnessi e multidimensionali

- Le funzioni di valore degli ambienti di AR possono appiattire obiettivi plurali e contesi.

Bias di visibilità

- Gli spazi di stato e di azione codificano solo ciò che è facilmente misurabile e attuabile. Il resto
- è ignorato per costruzione

Molti vincoli non possono essere modellati del tutto

- Norme giuridiche, culturali e sociali, vincoli politici e limiti istituzionali sono decisivi per la fattibilità delle politiche

https://partici.fi/32182658

Quiz n. 3

Una politica basata sull'AR funziona bene nel simulatore. Perché un decisore potrebbe comunque respingerla?

Divario simulazione-realtà

Il mondo dell'IAM è sottospecificato: ciò che vi è ottimale può non trasferirsi al mondo reale

Obiettivi non modellati

Equità, legalità e accettabilità sociale non erano nella ricompensa. Che cosa significa che una politica funziona bene?

Fiducia e responsabilità

Chi risponde delle decisioni derivate dall'AR? Strategie inspiegabili resistono al vaglio delle istituzioni?

Parte 4: valutazione e messa in opera

- Come sappiamo se una politica ha funzionato?
- Possiamo stimare se una politica sarà popolare o socialmente accettabile?



Come sappiamo se una politica ha funzionato? L'inferenza causale

Esperimenti randomizzati

- Il gold standard
- Assegnare la politica a caso e confrontare i gruppi.
- Scientificamente robusto ma difficile nel mondo reale.
- Ad es.: come randomizzare una tassa sul carbonio tra paesi?

Differenza nelle differenze

- Confrontare l'evoluzione nel tempo delle unità con e senza la politica.
- Molto comune in letteratura

Controllo sintetico

- Senza una buona unità di confronto → costruire un «gemello» di un'unità trattata da un insieme di unità non trattate.
- Ad es. la tassa sul carbonio svedese: emissioni dei trasporti confrontate con una «Svezia sintetica» costruita da altri paesi OCSE
- Vedi Andersson, J.J. Carbon Taxes and CO_2 Emissions: Sweden as a Case Study,
- Vedi Gomez-Mahecha Colombian Carbon Tax: Evidence of Carbon Pricing in a Developing Context

Variabili strumentali

- Trovare una leva che muova la variabile politica senza altri legami con il risultato.
- Ad es.: velocità del vento → più produzione rinnovabile → che cosa succede emissioni? Il meteo è casuale: la risposta è causale.

L'AA causale può estendere questi strumenti: individuare confondenti ad alta dimensionalità, effetti eterogenei e non lineari, forme funzionali flessibili, ecc.

Prevedere non è valutare in modo causale

Previsione

Ad es.: «Quali saranno le emissioni l'anno prossimo?»
Ottimo per pianificare e monitorare, ma poco utile per capire se una politica è efficace

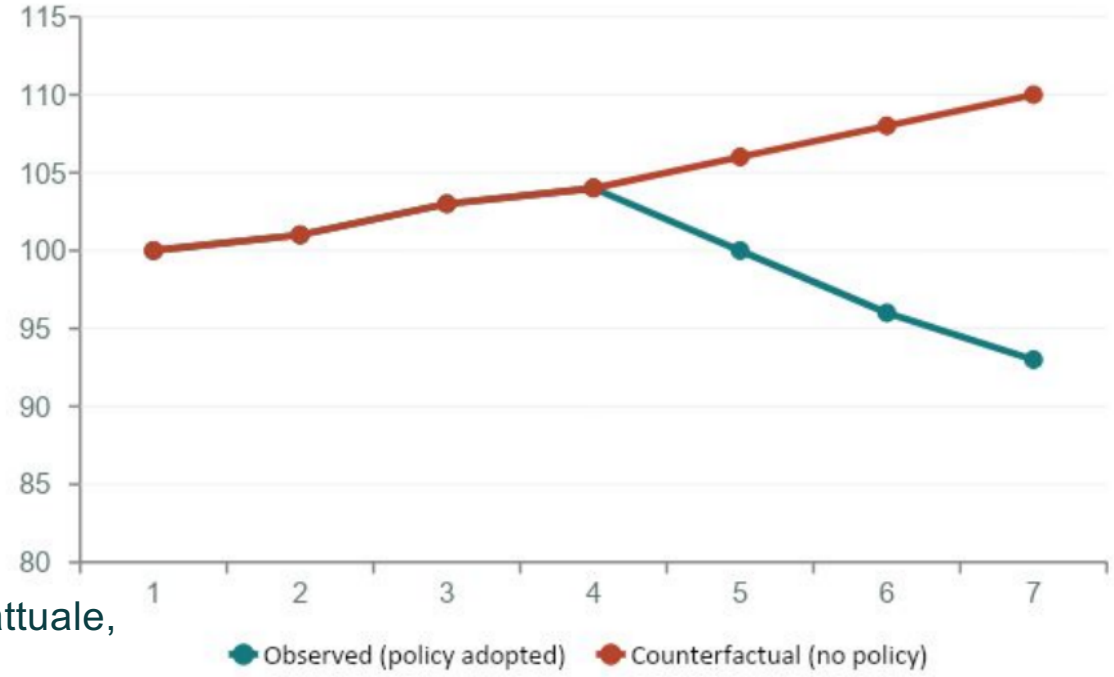
Valutazione causale

«Che cosa ha cambiato questa tassa sul carbonio?»: serve un controfattuale,

L'AA estende gli strumenti dell'inferenza causale a confondenti ad alta dimensionalità ed effetti eterogenei.

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

Il controfattuale, illustrato (stilizzato)



Due modi di dare un prezzo al carbonio



Tasse sul carbonio

Si fissa il prezzo, la quantità si adegua

- Costi prevedibili per le imprese
- Emissioni totali incerte



Cap & trade (ETS)

Si fissa la quantità, il prezzo si adegua

- Tetto alle emissioni certo
- Prezzi volatili
- Crea un mercato delle quote

In entrambi i casi, i mercati pongono un problema di misura e verifica:

- Le tonnellate vanno contate, verificate e rese affidabili, incluse le compensazioni da foreste, aziende agricole e fabbr dall'altra parte del mondo.
- Questo problema di verifica può essere affrontato con l'IA

L’IA lungo la filiera dei crediti di carbonio

Telerilevamento

Foreste, uso del suolo, agricoltura, elaborazione di immagini satellitari, pennacchi di metano, siti industriali

Quantificazione

Stima di biomassa e flussi

Qualità dei crediti

Selezione e rating dei crediti

Integrità

Rilevamento delle frodi, doppio conteggio, analisi di mercato

I limiti dell'IA nei mercati del carbonio

Falsa precisione contabile

- Una tonnellata «misurata» da un modello di AA può accumulare incertezze: non può essere trattata come una stima esatta

Manipolazione delle metriche

- Le metriche misurabili invitano alla manipolazione
- I progetti di cattura del carbonio si ottimizzeranno per ciò che i modelli premiano

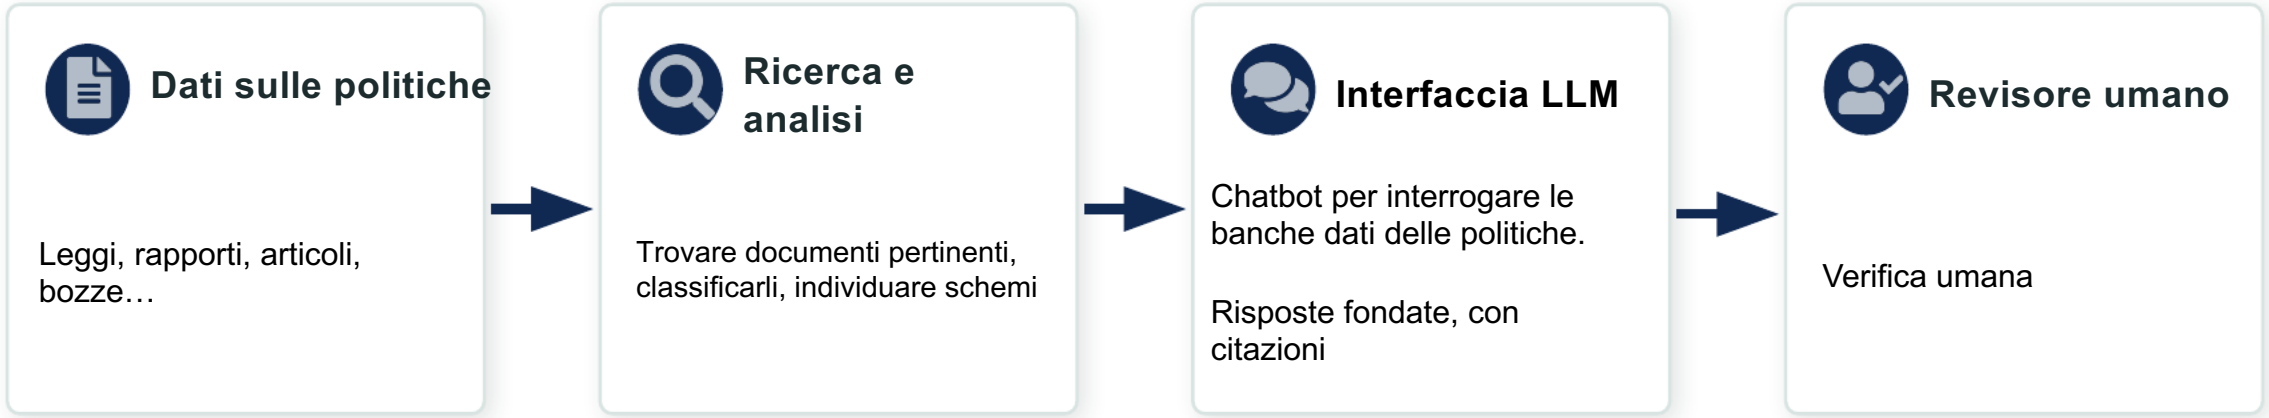
Visione a tunnel

- Ottimizzare la tonnellata di CO_2 misurabile trascura i co-benefici per biodiversità, giustizia e governance

Verifica a scatola nera

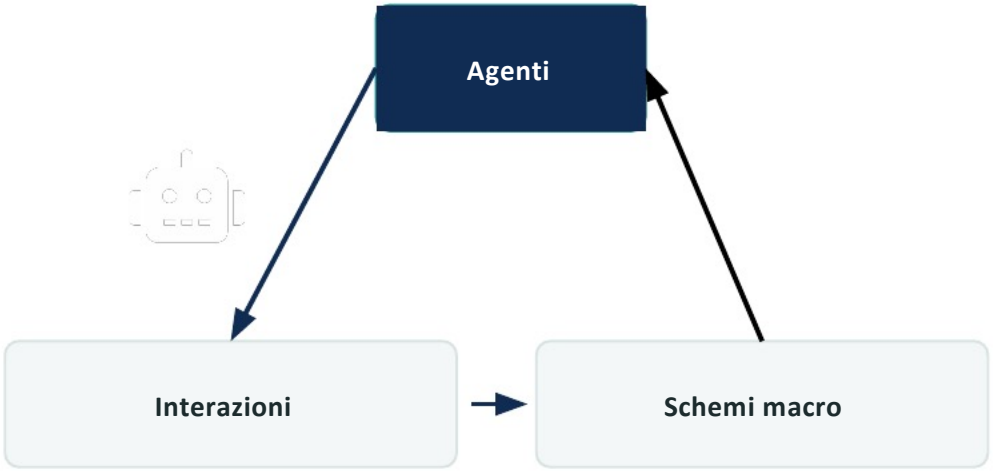
- I modelli proprietari non possono essere verificati
- La fiducia nei mercati del carbonio non deve dipendere da creditori privati

Gli LLM nel lavoro sulle politiche

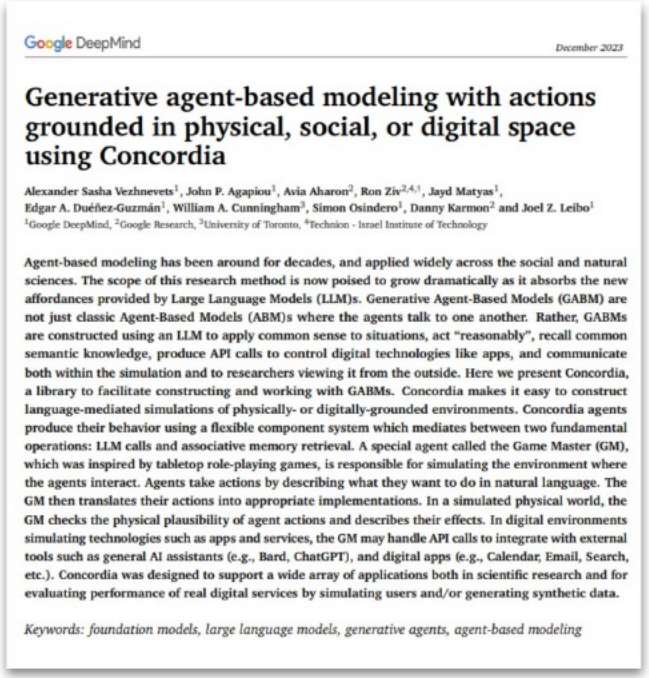


- Analisi di documenti politici
- Sintesi della letteratura
- Domande e risposte su corpora di politiche
- Analisi di grandi raccolte di testi sulle politiche

Modelli ad agenti



- Attori eterogenei: famiglie, imprese, lobby
- Dinamiche macro che emergono dai comportamenti micro
- L'accettabilità di una politica viene esplorata prima dell'attuazione, non scoperta dopo
- Gli ABM possono seguire regole predefinite, ma anche essere modellati come agenti che interagiscono tramite LLM



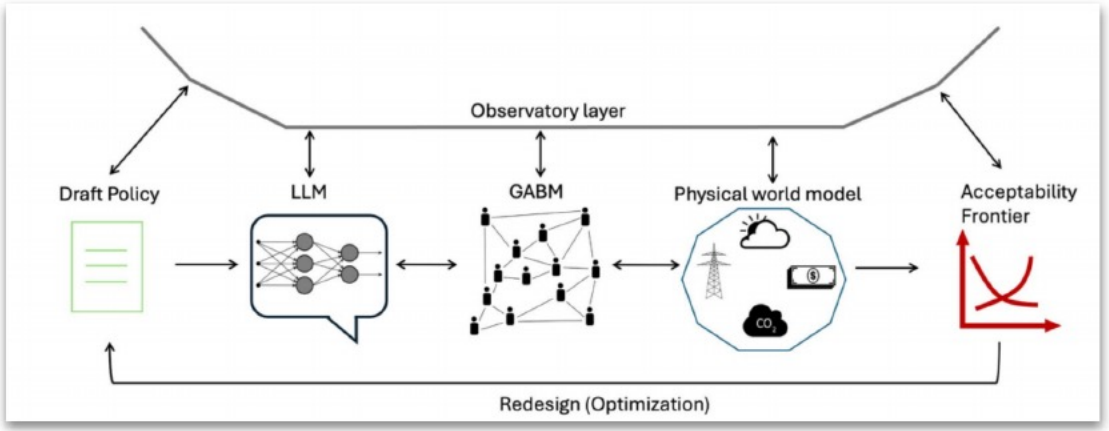
Google DeepMind *December 2023*

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 e ABM: plausibili, ma non validati



Allucinazioni

- Gli LLM tendono ad avere allucinazioni
- I chatbot LLM in genere non sanno distinguere se le informazioni prodotte sono vere o false
- Il lavoro politico richiede citazioni verificabili



Contesto istituzionale mancante

- I modelli possono ignorare norme, precedenti, mandati, linee rosse e contesti politici in evoluzione



Bias, riservatezza, eccesso di sicurezza

- Modelli talvolta addestrati su dati distorti
- Gli LLM sembrano sicuri delle risposte, anche quando non lo sono
- Gli LLM possono divulgare dati sensibili



Modelli proprietari

- Pesi chiusi e versioni che cambiano
- Riproducibilità e sovranità: un problema per le istituzioni pubbliche
- Di chi sono i modelli? Chi li paga? Soggetti privati addestrano modelli su informazioni pubbliche critiche?

L’impronta ambientale dell’IA stessa

Legata al calcolo

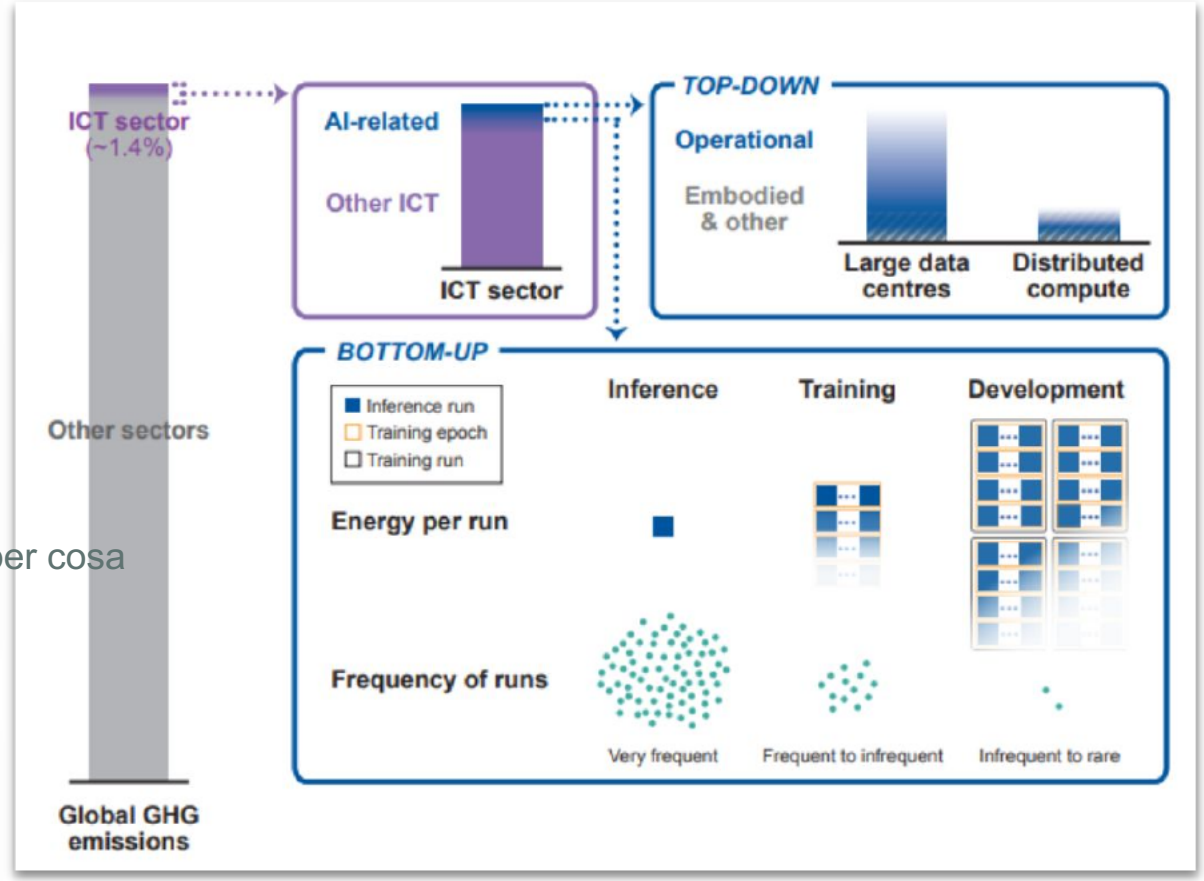
Energia di addestramento e inferenza, hardware, acqua

Effetti dell’applicazione dell’AA

Guadagni di efficienza vs effetto rimbalzo; chi usa lo strumento, e per cosa

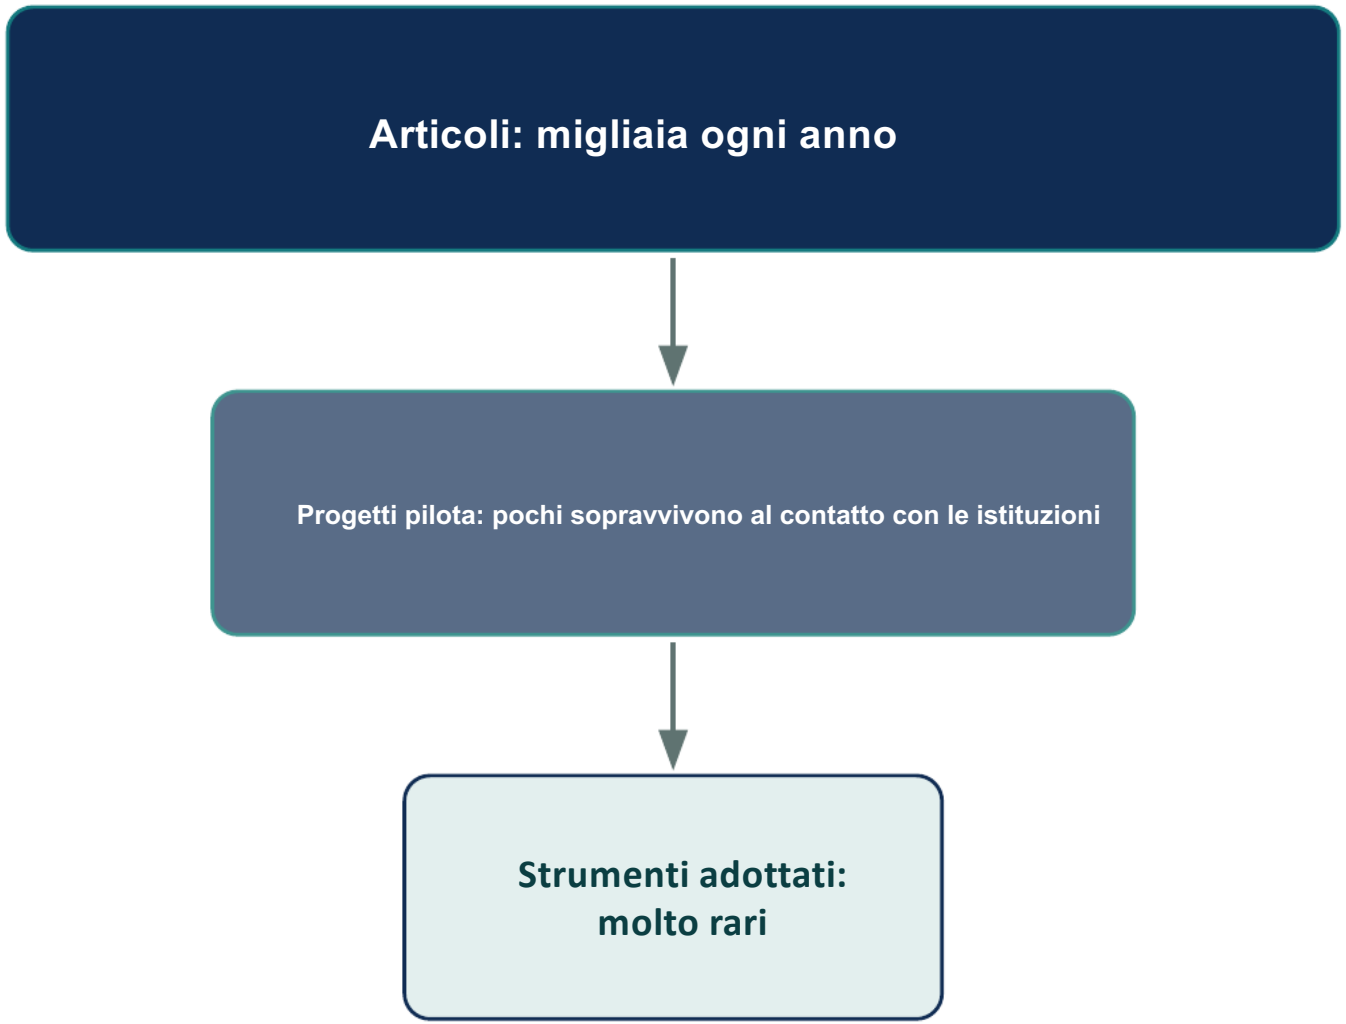
A livello di sistema

Cambiamenti di comportamento, lock-in, domanda indotta



Da Kaack et al Aligning artificial intelligence with climate change mitigation

Il divario della messa in opera



Colmare il divario:

- Benchmark di utilità per le politiche, non solo di accuratezza predittiva
- Incertezza ben calcolata e comunicata in termini utili alle decisioni
- Collaborazioni integrate: co-progettazione con le persone e le comunità che la useranno e potrebbero esserne toccate
- Rafforzare capacità istituzionali e fiducia

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

Quiz n. 4

Quali fattori considerereste nell'usare un LLM per l'analisi delle politiche climatiche?

https://partici.fi/32182658

Problemi aperti e messaggi chiave



Problemi aperti

1

Benchmark di utilità per le politiche oltre l'accuratezza

2

Politiche robuste in condizioni di incertezza profonda, invece di un'unica politica «ottimale»

3

Emulatori e scenari sintetici che preservino interpretabilità e QI

4

Flussi di lavoro con LLM sicuri e trasparenti per le istituzioni pubbliche

5

Metodi di co-progettazione con decisori e comunità interessate

6

Integrare pericoli → impatti → risposta sociale → decisioni politiche

7

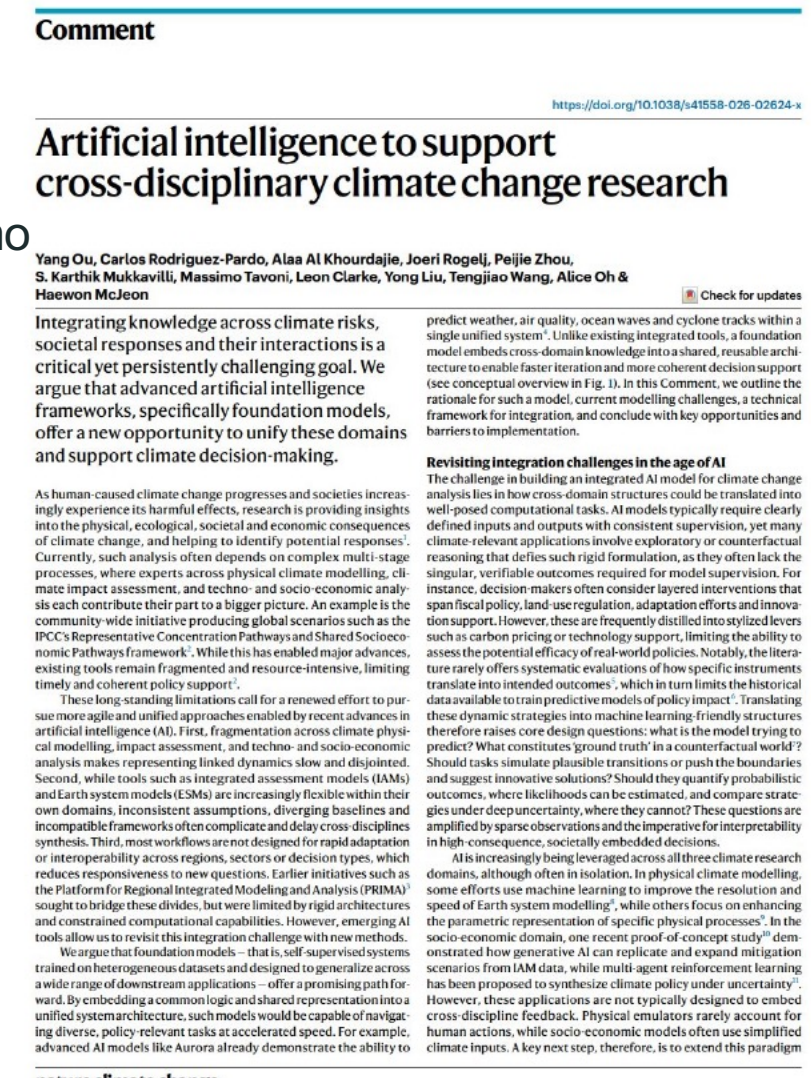
Danni localizzati: colmare il divario di risoluzione dove i dati sono più scarsi

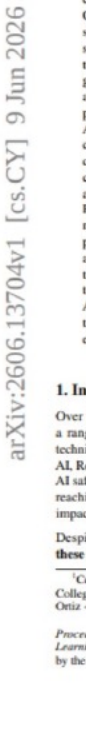
Un’intelligenza climatica integrata: una grande sfida

Ogni parte di questa lezione era un’isola: misura, futuri, incertezza, agenti, valutazione.

Un grande obiettivo di ricerca del prossimo decennio è collegarle (pericoli, impatti, risposta socioeconomica e decisioni politiche in un unico ciclo) e capire come l’IA stessa influisce sull’azione climatica.









La cassetta degli attrezzi di base

DATI E STRUMENTI

- Climate Policy Radar
- Banche dati di scenari IAMC
- Emulatori di IAM (ad es. ML-IAM) e IAM open source / modelli energetici
- Population Dynamics Foundation Model
- Embedding geospaziali e TorchGeo
- Pacchetti di inferenza causale ed econometria

COMUNITÀ E CONVEGNI

- Climate Change AI: ci siete già
- Workshop CCAI a NeurIPS
- IAMC: gruppo di lavoro sull'IA responsabile per gli IAM
- EGU · AGU · SISC · WCERE: dove si incontrano clima, scienze della Terra ed economia



Messaggi chiave

L’IA può intervenire in ogni fase del ciclo delle politiche

- Misura
- Futuri
- Valutazione
- Flussi di lavoro
- Verifica

Il vincolo raramente è l’accuratezza predittiva

- Validità causale
- Valori
- Fiducia
- Vincoli sociali
- Istituzioni
- Accettabilità sociale

L’integrazione è la frontiera

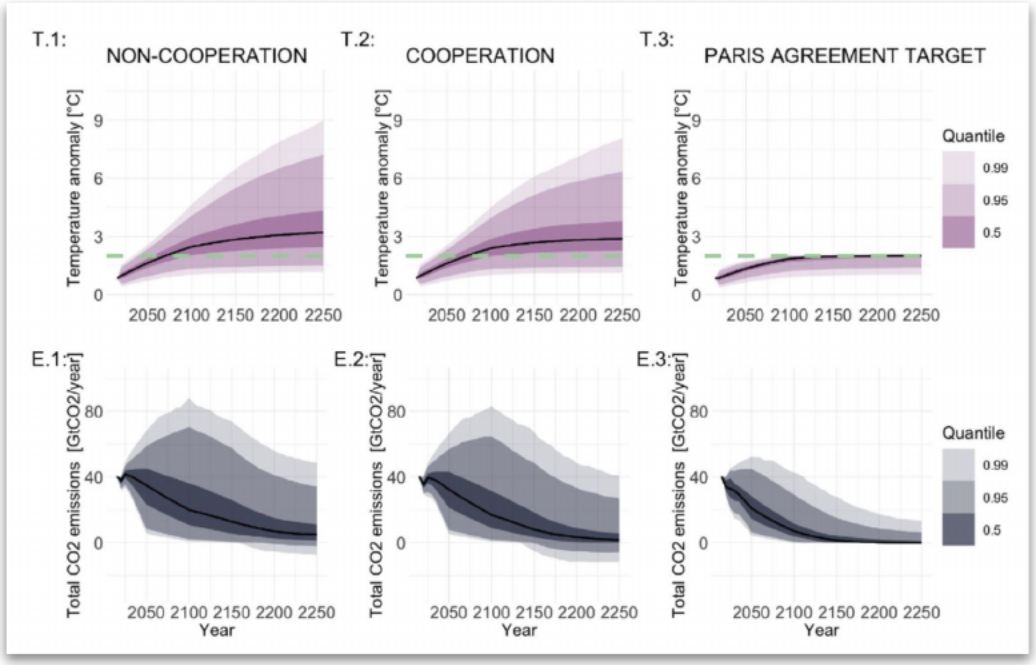
- Tra scale diverse
- Tra tipi di dati
- Tra fasi del ciclo delle politiche
- Tra istituzioni e comunità
- Lungo la catena di modellazione

Partire dalle domande utili alle politiche e dai problemi dei decisori, non dalle capacità dei modelli né da ciò che si può fare con un dataset specifico

Grazie per l’attenzione!

Quantificazione dell’incertezza, analisi di sensibilità

Quantificazione dell’incertezza



Sensibilità e spiegabilità delle scatole nere

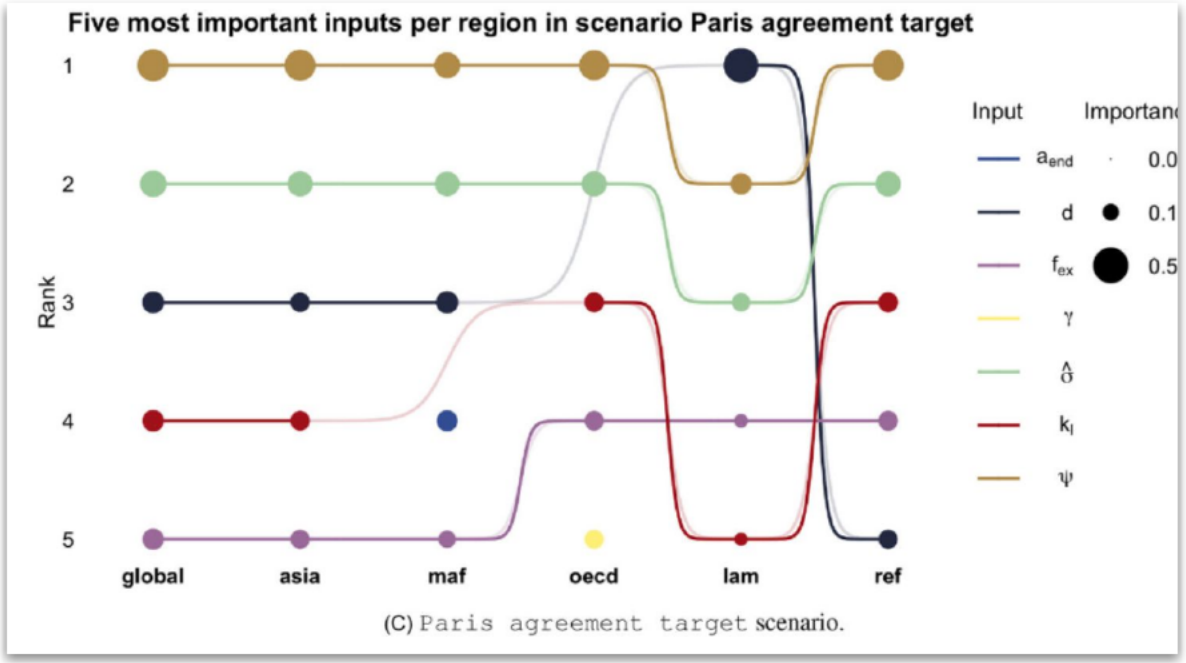
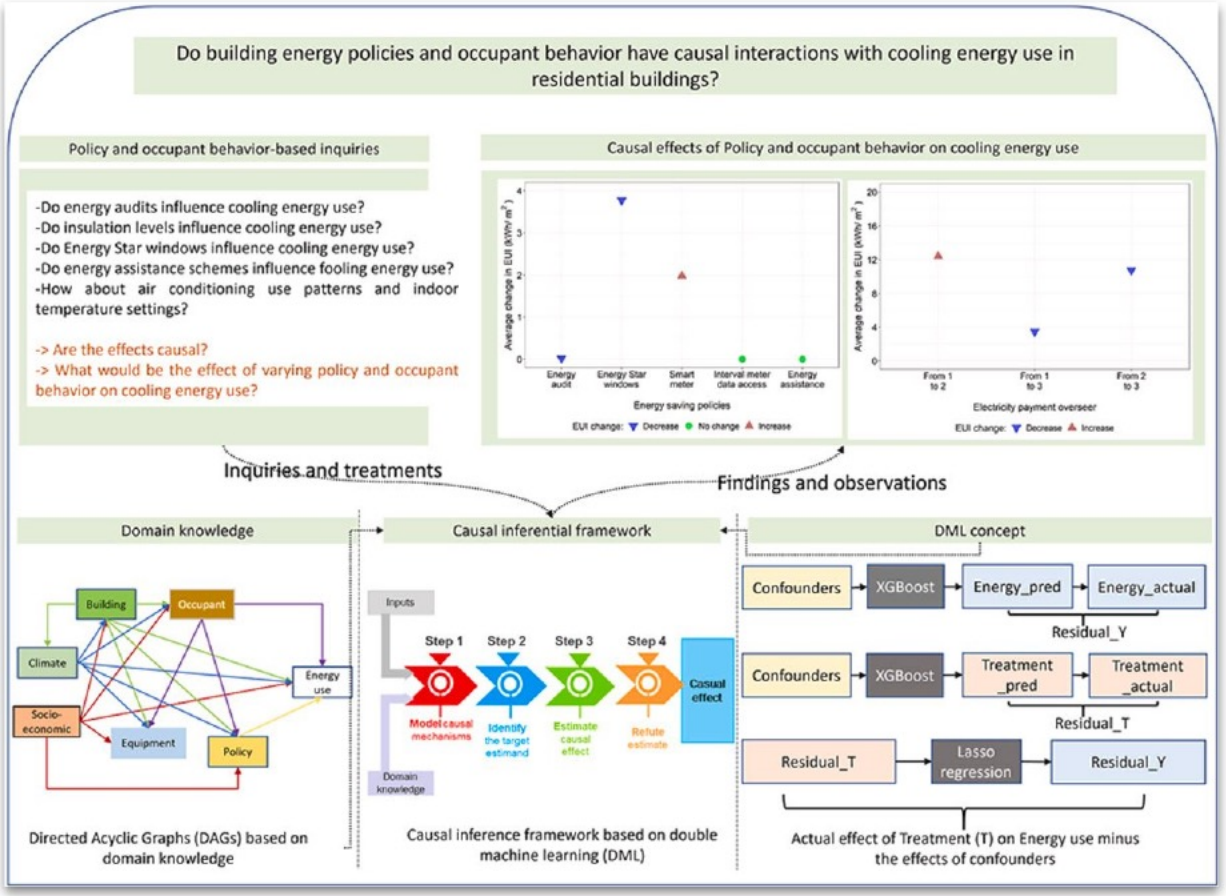


Figure da Chiani et al. Global sensitivity analysis of integrated assessment models with multivariate outputs https://onlinelibrary.wiley.com/doi/full/10.1111/risa.70002

L'AA causale nell'analisi delle politiche climatiche



Da 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

Nuove direzioni all'incrocio tra IA e solutori di 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 per trovare nuove soluzioni



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].

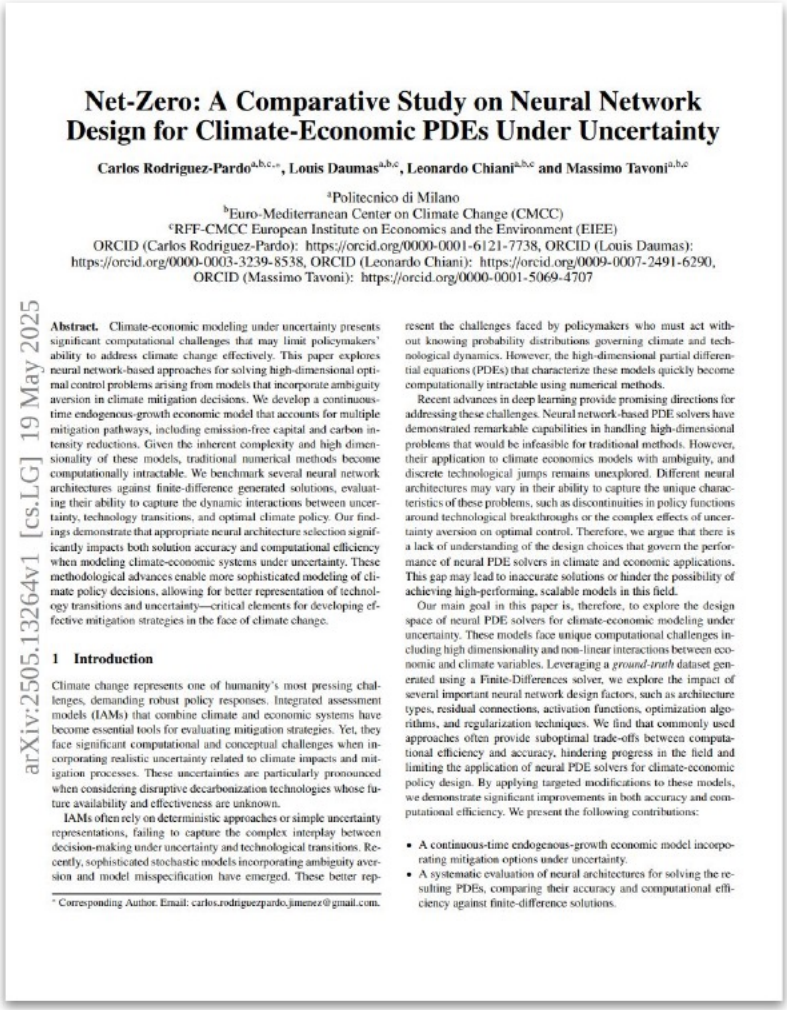
Climate change is a shared global challenge, yet mitigation entails trade-offs. Investments in low-carbon technologies and systemic transformation can constrain short-term growth and costs are unevenly distributed: wealthier nations can invest more readily, while developing countries must balance climate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



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.

Solutori neurali di EDP per velocità e quantificazione dell'incertezza