

Mesurer l'impact économique du climat

Théories récentes, économétrie, apprentissage automatique et apprentissage profond

Imad El Khlifi



Pourquoi cette note

Depuis une quinzaine d'années, l'économie du climat a profondément changé de visage. Les modèles d'évaluation intégrée des années 1990 ont été rejoints par une **économétrie du climat** fondée sur des données de panel à haute résolution, puis par les méthodes d'**apprentissage automatique** et d'**apprentissage profond**, désormais capables de prévoir le temps aussi bien que les modèles physiques. Cette note propose une carte de ces approches : les idées théoriques qui structurent le débat, les équations qui les traduisent, et les conditions de leur bon usage.

Sommaire

1	Des modèles d'évaluation intégrée à la « nouvelle » économie du climat	p. 2
2	Ce que dit la recherche empirique récente	p. 3
3	Mesurer le climat : données et indicateurs	p. 4
4	Économétrie I : panels, retards distribués et projections locales	p. 5
5	Économétrie II : séries temporelles, risque et dynamique de long terme	p. 6
6	Apprentissage automatique	p. 7
7	Apprentissage profond	p. 8
8	Causalité et interprétabilité : le chaînon manquant	p. 9
9	Quel outil pour quelle question ? Synthèse et références	p. 10

En une phrase

Aucune méthode ne domine les autres : l'économétrie identifie des effets causaux interprétables, l'apprentissage automatique capte les non-linéarités et prédit mieux, et les approches récentes cherchent précisément à combiner ces deux forces.

1. Des modèles intégrés à la nouvelle économie du climat

1.1 Le cadre fondateur : le modèle DICE de Nordhaus

William Nordhaus (prix Nobel 2018) a posé le cadre canonique : une économie de croissance de type Ramsey couplée à un module climatique simplifié. Le climat agit sur la production par une **fonction de dommages** qui réduit le PIB à mesure que la température s'élève. La dernière version, DICE-2023 (Barrage et Nordhaus, 2024), conserve cette architecture.

Équations clés d'un modèle d'évaluation intégrée (DICE)

$$Q_t = \Omega(T_t) [1 - \Lambda(\mu_t)] A_t K_t^\alpha L_t^{1-\alpha}$$
$$\Omega(T) = \frac{1}{1 + \psi_1 T + \psi_2 T^2}, \quad \Lambda(\mu) = \theta_1 \mu^{\theta_2}$$
$$\max_{\{c_t, \mu_t\}} W = \sum_t \frac{L_t}{(1 + \rho)^t} \frac{c_t^{1-\eta}}{1 - \eta}$$
$$SCC_t = - \frac{\partial W / \partial E_t}{\partial W / \partial C_t}, \quad r = \rho + \eta g$$

production nette des dommages et de l'abattement

dommages et coût de réduction des émissions

bien-être social intertemporel

coût social du carbone, règle de Ramsey

Deux paramètres concentrent l'essentiel du débat : la courbure de la fonction de dommages (ψ_2) et le taux d'actualisation (r). Le rapport Stern (2007), avec un ρ proche de zéro, justifiait une action immédiate et forte ; Nordhaus, avec une actualisation de marché, recommandait une montée graduelle de l'effort.

1.2 Trois remises en cause théoriques

- **Les queues épaisses (Weitzman, 2009).** Si la distribution du réchauffement possible a une queue épaisse, l'espérance des dommages peut devenir non bornée : c'est le « théorème lugubre », qui plaide pour une logique d'assurance plutôt que de coût-bénéfice.
- **Les points de bascule (Dietz et al., 2021).** L'intégration de seuils irréversibles (calotte glaciaire, permafrost, mousson) relève le coût social du carbone d'environ 25 %.
- **Des dommages sur la croissance, pas seulement sur le niveau.** Si le climat affecte le *taux* de croissance et non seulement le niveau du PIB, les pertes se cumulent dans le temps et deviennent beaucoup plus élevées. C'est la question centrale de la recherche empirique récente (page suivante).



Fig. 1. Deux fonctions de dommages. La forme retenue change radicalement les pertes au-delà de 3 °C. Calcul de l'auteur à partir des spécifications publiées.

2. Ce que dit la recherche empirique récente

À partir des années 2010, une littérature empirique a cherché à estimer directement la relation entre climat et activité, en exploitant les variations d'une année sur l'autre de la température et des précipitations au sein d'un même pays. L'idée clé : ces fluctuations sont quasi aléatoires, ce qui permet une identification causale (Dell, Jones et Olken, 2014 ; Hsiang, 2016).




Fig. 2. Relation non linéaire entre température et productivité, illustrée à partir des coefficients de Burke, Hsiang et Miguel (2015). Au-delà de l'optimum, chaque degré supplémentaire pèse davantage.

Tab. 1. Quelques résultats marquants de la littérature

Étude	Méthode	Résultat principal
Dell, Jones et Olken (2012)	Panel, effets fixes	+1°C réduit la croissance d'environ 1,3 point dans les pays pauvres
Burke, Hsiang et Miguel (2015)	Panel non linéaire	Optimum vers 13 °C ; pertes fortes et durables pour les pays chauds
Barrios, Bertinelli et Strobl (2010)	Panel	Le déclin des pluies explique une part du retard de croissance africain
Damania, Desbureaux et Zaveri (2020)	Panel spatial fin	Les chocs secs pèsent plus que les chocs humides, surtout là où l'agriculture est pluviale
Kahn et al. (2021)	ARDL en panel	Les écarts persistants aux normales historiques réduisent durablement le PIB par tête
Bilal et Känzig (2024)	Projections locales	+1°C de température <i>globale</i> réduit le PIB mondial d'environ 12 % ; coût social du carbone de 1367 \$/t

Une littérature encore fragile

Les ordres de grandeur divergent fortement selon les spécifications. Signe de cette fragilité, une étude très citée publiée dans *Nature* en 2024 (Kotz, Levermann et Wenz) a été rétractée en décembre 2025 après la découverte d'anomalies dans les données. La robustesse des résultats, et non leur spectaculaire, doit guider le choix méthodologique.

3. Mesurer le climat : données et indicateurs

Avant tout modèle, il faut transformer des champs météorologiques en variables économiquement pertinentes. Trois familles de sources dominent : les **stations** (longues séries, couverture inégale), les **réanalyses** comme ERA5 du Copernicus (grille horaire mondiale depuis 1940) et les **images satellitaires** (végétation, humidité du sol, lumières nocturnes).




FIG. 3. Chaîne de traitement type d'une étude climat-économie.

Indicateurs climatiques usuels

$$\tilde{T}_{it} = \frac{T_{it} - \bar{T}_i^{1961-1990}}{\sigma_{T,i}}$$

anomalie standardisée par rapport à la normale

$$DJ_{it}^+ = \sum_{d \in t} \max(0, T_{id} - T^*)$$

degrés-jours de chaleur au-dessus d'un seuil T^*

$$D_{it} = P_{it} - ETP_{it}, \quad SPEI_{it} = \Phi^{-1}(F(D_{it}))$$

indice de sécheresse (Vicente-Serrano et al., 2010)

$$NDVI = \frac{\rho_{PIR} - \rho_R}{\rho_{PIR} + \rho_R}$$

indice de végétation par satellite

$$X_{it} = \sum_{g \in i} w_g x_{gt}, \quad \sum_g w_g = 1$$

agrégation des cellules de grille g

3.1 Points d'attention

- **Le choix des poids w_g n'est pas neutre.** Une pondération par la surface donne un poids excessif aux zones désertiques ; une pondération par la population ou par les superficies cultivées reflète mieux l'exposition économique.
- **La moyenne annuelle masque l'essentiel.** Les dommages viennent souvent des extrêmes (vagues de chaleur, pluies intenses) et du calendrier : une sécheresse en février n'a pas le même effet qu'en juin pour les céréales. D'où l'intérêt des indicateurs saisonniers.
- **Les précipitations sont plus difficiles à mesurer** que la température : leur forte variabilité spatiale rend les réanalyses moins fiables, notamment en zone aride.
- **Les lumières nocturnes** (VIIRS) servent de proxy de l'activité locale là où les comptes régionaux sont rares ou tardifs.

4. Économétrie I : panels et projections locales

4.1 Le modèle de panel à effets fixes

C'est la spécification de référence de l'économétrie du climat. Les effets fixes pays absorbent tout ce qui est permanent (géographie, institutions), les effets fixes temporels les chocs communs (crises mondiales). L'effet climatique est donc identifié par les écarts d'un pays à sa propre moyenne.

Panel non linéaire (Burke et al., 2015)

$$g_{it} = \beta_1 T_{it} + \beta_2 T_{it}^2 + \gamma_1 P_{it} + \gamma_2 P_{it}^2 + \mu_i + \theta_t + \delta_i t + \delta_{i2} t^2 + \varepsilon_{it}$$

g_{it} : croissance du PIB par tête; μ_i, θ_t : effets fixes; $\delta_i t$: tendances propres à chaque pays. L'optimum de température vaut $T^* = -\beta_1/(2\beta_2)$.

4.2 Niveau ou croissance ? Les retards distribués

Pour distinguer un choc transitoire (le PIB revient à sa trajectoire) d'un choc persistant, on introduit des retards et on examine leur somme :

Modèle à retards distribués

$$g_{it} = \sum_{\ell=0}^L \beta_{\ell} T_{i,t-\ell} + \mu_i + \theta_t + \varepsilon_{it}, \quad \text{effet cumulé} = \sum_{\ell=0}^L \beta_{\ell}$$

Si $\sum \beta_{\ell} \approx 0$, l'effet est de niveau et se résorbe ; s'il reste négatif, le choc affecte durablement la croissance.

4.3 Les projections locales de Jordà (2005)

Devenues l'outil standard de la macroéconomie empirique, elles estiment directement la réponse à chaque horizon h , sans imposer la structure dynamique d'un VAR :

Projections locales en panel

$$y_{i,t+h} - y_{i,t-1} = \alpha_i^h + \tau_t^h + \beta^h S_{it} + \sum_{j=1}^p \phi_j^h \Delta y_{i,t-j} + \varepsilon_{i,t+h}, \quad h = 0, 1, \dots, H$$

La suite $\{\hat{\beta}^h\}_{h=0}^H$ trace la fonction de réponse au choc climatique S_{it} . C'est l'approche de Bilal et Känzig (2024). Les erreurs types doivent être corrigées de l'autocorrélation (Driscoll-Kraay ou Newey-West).




Fig. 4. Lecture d'une fonction de réponse : schéma illustratif, sans données réelles.

5. Économétrie II : séries temporelles et risque

5.1 VAR et VAR structurels

À l'échelle d'un pays, les séries sont courtes et les variables interdépendantes. Le VAR traite toutes les variables comme endogènes ; le climat y est généralement placé en premier, comme variable exogène au sens de Cholesky, puisque l'activité nationale n'influence pas la météo.

Modèle VAR(*p*) et réponses impulsionnelles

$$\mathbf{Y}_t = \mathbf{c} + \sum_{j=1}^p \mathbf{A}_j \mathbf{Y}_{t-j} + \mathbf{u}_t, \quad \mathbf{u}_t = \mathbf{B} \boldsymbol{\varepsilon}_t, \quad \mathbb{E}[\boldsymbol{\varepsilon}_t \boldsymbol{\varepsilon}_t'] = \mathbf{I}$$
$$\text{IRF}(h) = \frac{\partial \mathbf{Y}_{t+h}}{\partial \boldsymbol{\varepsilon}_t'} = \boldsymbol{\Psi}_h \mathbf{B}, \quad \boldsymbol{\Psi}_h = \sum_{j=1}^{\min(h,p)} \mathbf{A}_j \boldsymbol{\Psi}_{h-j}, \quad \boldsymbol{\Psi}_0 = \mathbf{I}$$

Variantes : VAR bayésien (séries courtes), VAR en panel, VARX avec climat strictement exogène.

5.2 Au-delà de la moyenne : la croissance à risque

Le climat affecte surtout les *mauvaises* années. La régression quantile permet d'estimer l'effet sur la queue gauche de la distribution, sur le modèle du *Growth-at-Risk* du FMI (Adrian, Boyarchenko et Giannone, 2019) :

Régression quantile et croissance à risque

$$Q_{\tau}(g_{t+h} \mid \mathbf{x}_t) = \mathbf{x}_t' \boldsymbol{\beta}(\tau), \quad \hat{\boldsymbol{\beta}}(\tau) = \arg \min_{\boldsymbol{\beta}} \sum_t \rho_{\tau}(g_{t+h} - \mathbf{x}_t' \boldsymbol{\beta})$$
$$\rho_{\tau}(u) = u \left(\tau - \mathbb{I}\{u < 0\} \right), \quad \text{GaR}_{5\%} = Q_{0,05}(g_{t+h} \mid \mathbf{x}_t)$$

Si $\hat{\boldsymbol{\beta}}(0,05)$ est nettement plus négatif que $\hat{\boldsymbol{\beta}}(0,5)$, le climat alourdit le risque extrême sans forcément déplacer la moyenne.

5.3 Dynamique de long terme : l'ARDL en panel

Kahn et al. (2021) modélisent l'écart de la température à sa norme historique et distinguent relation de long terme et ajustement de court terme (estimateur PMG de Pesaran, Shin et Smith, 1999) :

ARDL à correction d'erreur

$$\Delta y_{it} = \phi_i (y_{i,t-1} - \boldsymbol{\theta}' \mathbf{x}_{i,t-1}) + \sum_{j=1}^{p-1} \lambda_{ij} \Delta y_{i,t-j} + \sum_{j=0}^{q-1} \delta'_{ij} \Delta \mathbf{x}_{i,t-j} + \mu_i + \varepsilon_{it}$$

$\boldsymbol{\theta}$: coefficients de long terme communs ; $\phi_i < 0$: vitesse de retour à l'équilibre.

Tab. 2. Choisir un modèle économétrique

Modèle	Question traitée	Limite principale
Panel à effets fixes	Effet causal moyen entre pays	Peu informatif sur la dynamique
Projections locales	Réponse dans le temps à un choc	Intervalles larges aux longs horizons
VAR / SVAR	Interactions entre variables d'un pays	Séries courtes, nombre de paramètres
Régression quantile	Risque de queue (années extrêmes)	Exige des échantillons assez longs
ARDL en panel	Long terme et ajustement	Hypothèses sur l'ordre d'intégration

6. Apprentissage automatique

L'apprentissage automatique ne cherche pas d'abord un coefficient interprétable, mais la meilleure fonction $\hat{f}$ pour prédire y à partir de nombreuses variables, en contrôlant le surapprentissage. Il est utile pour la prévision des rendements agricoles, la prévision immédiate (*nowcasting*) du PIB et la sélection de variables climatiques parmi des centaines de candidats.

Régularisation : LASSO et Elastic Net

$$\hat{\beta} = \arg \min_{\beta} \frac{1}{n} \sum_{i=1}^n (y_i - \mathbf{x}_i' \beta)^2 + \lambda \left[\alpha \|\beta\|_1 + \frac{1-\alpha}{2} \|\beta\|_2^2 \right]$$

La pénalité $\|\cdot\|_1$ annule les coefficients inutiles : utile quand on dispose de nombreux indicateurs mensuels de pluie et de température fortement corrélés.

Forêts aléatoires et gradient boosting

$$\hat{f}_{\text{RF}}(\mathbf{x}) = \frac{1}{B} \sum_{b=1}^B h_b(\mathbf{x})$$

moyenne de B arbres sur échantillons bootstrap

$$\hat{f}_m(\mathbf{x}) = \hat{f}_{m-1}(\mathbf{x}) + \nu h_m(\mathbf{x}), \quad h_m \approx - \frac{\partial \mathcal{L}(y, f)}{\partial f} \Big|_{f=\hat{f}_{m-1}}$$

boosting : chaque arbre corrige les erreurs

$$\mathcal{L}^{(m)} = \sum_i \ell(y_i, \hat{y}_i^{(m)}) + \gamma J + \frac{\lambda}{2} \sum_{j=1}^J w_j^2$$

objectif régularisé de XGBoost

6.1 Valider sans tricher avec le temps

En séries temporelles, la validation croisée aléatoire est trompeuse : elle laisse le modèle « voir » le futur. On utilise une validation à fenêtre croissante, où chaque bloc de test est postérieur aux données d'entraînement.




Fig. 5. Validation croisée à fenêtre croissante (*expanding window*).

Mesures de performance hors échantillon

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum (y_i - \hat{y}_i)^2}, \quad \text{MAE} = \frac{1}{n} \sum |y_i - \hat{y}_i|, \quad R_{\text{oos}}^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y}_{\text{train}})^2}$$

Le test de Diebold-Mariano permet de vérifier si l'écart de précision entre deux modèles est significatif.

7. Apprentissage profond

Les réseaux de neurones profonds excellent lorsque les données sont massives et structurées : séries longues à haute fréquence, images satellitaires, champs météorologiques sur grille.

Cellule LSTM (Hochreiter et Schmidhuber, 1997)

$$\mathbf{f}_t = \sigma(\mathbf{W}_f[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_f)$$

$$\mathbf{i}_t = \sigma(\mathbf{W}_i[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_i)$$

$$\tilde{\mathbf{c}}_t = \tanh(\mathbf{W}_c[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_c)$$

$$\mathbf{c}_t = \mathbf{f}_t \odot \mathbf{c}_{t-1} + \mathbf{i}_t \odot \tilde{\mathbf{c}}_t$$

$$\mathbf{o}_t = \sigma(\mathbf{W}_o[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_o)$$

$$\mathbf{h}_t = \mathbf{o}_t \odot \tanh(\mathbf{c}_t)$$

Les portes **f**, **i**, **o** décident quoi oublier, retenir et transmettre : idéal pour la mémoire longue d'une sécheresse.




FIG. 6. Schéma simplifié d'une cellule LSTM.

Mécanisme d'attention des Transformers (Vaswani et al., 2017)

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^\top}{\sqrt{d_k}}\right) \mathbf{V}, \quad \mathbf{Q} = \mathbf{X}\mathbf{W}_Q, \mathbf{K} = \mathbf{X}\mathbf{W}_K, \mathbf{V} = \mathbf{X}\mathbf{W}_V$$

Chaque date ou chaque région « regarde » toutes les autres et pondère leur influence. Base des modèles de séries temporelles récents (Temporal Fusion Transformer, PatchTST).

Réseaux convolutifs pour les images satellitaires

$$(\mathbf{X} * \mathbf{K})_{u,v} = \sum_m \sum_n \mathbf{X}_{u+m, v+n} \mathbf{K}_{m,n}, \quad \mathbf{H}^{(l+1)} = \text{ReLU}(\mathbf{H}^{(l)} * \mathbf{K}^{(l)} + \mathbf{b}^{(l)})$$

Utilisés pour estimer les rendements agricoles, la pauvreté ou l'étendue des inondations à partir d'images Sentinel et Landsat.

La révolution des modèles météorologiques par IA

Depuis 2023, des réseaux entraînés sur les réanalyses ERA5 rivalisent avec les modèles physiques pour la prévision à moyen terme : GraphCast de Google DeepMind (réseaux de graphes), Pangu-Weather de Huawei, Aurora de Microsoft. Le Centre européen (ECMWF) a rendu son propre modèle AIFS opérationnel en 2025. Pour l'économiste, cela signifie des prévisions saisonnières plus accessibles et donc de meilleurs systèmes d'alerte pour l'agriculture et la gestion de l'eau.

8. Causalité et interprétabilité : le chaînon manquant

La frontière de la recherche se situe à la jonction des deux mondes : utiliser la souplesse de l'apprentissage automatique sans renoncer à l'identification causale ni à l'interprétation.

8.1 Double apprentissage automatique (Chernozhukov et al., 2018)

On veut l'effet θ d'un choc climatique D sur Y , en présence de nombreux contrôles $\mathbf{X}$ dont l'effet est inconnu et non linéaire.

Modèle partiellement linéaire et orthogonalisation

$$Y = \theta D + g(\mathbf{X}) + U, \quad D = m(\mathbf{X}) + V$$

$$\hat{\theta} = \frac{\sum_i \hat{V}_i (Y_i - \hat{\ell}(\mathbf{X}_i))}{\sum_i \hat{V}_i D_i}, \quad \hat{V}_i = D_i - \hat{m}(\mathbf{X}_i), \quad \ell(\mathbf{X}) = \mathbb{E}[Y | \mathbf{X}]$$

$\hat{\ell}$ et $\hat{m}$ sont estimés par n'importe quel algorithme (forêts, boosting, réseaux) avec *cross-fitting*; $\hat{\theta}$ reste convergent et asymptotiquement normal.

8.2 Forêts causales : des effets hétérogènes

Les forêts causales (Wager et Athey, 2018) estiment un effet propre à chaque unité, $\tau(\mathbf{x}) = \mathbb{E}[Y(1) - Y(0) | \mathbf{X} = \mathbf{x}]$: par exemple, l'effet d'une sécheresse selon le taux d'irrigation, la taille des exploitations ou la région. C'est précisément l'information utile pour cibler l'adaptation.

8.3 Expliquer les prédictions : les valeurs de Shapley

Valeur de Shapley et décomposition SHAP (Lundberg et Lee, 2017)

$$\phi_j = \sum_{S \subseteq F \setminus \{j\}} \frac{|S|! (|F| - |S| - 1)!}{|F|!} [f_{S \cup \{j\}}(\mathbf{x}_{S \cup \{j\}}) - f_S(\mathbf{x}_S)]$$

$$\hat{f}(\mathbf{x}) = \phi_0 + \sum_{j=1}^{|F|} \phi_j$$

Chaque variable reçoit sa contribution marginale moyenne sur toutes les coalitions possibles. La prédiction se décompose exactement en une somme de contributions, lisible par un décideur.

Interpréter n'est pas identifier

Une forte contribution SHAP indique qu'une variable aide à *prédire*, pas qu'elle *cause* le résultat. Pour une conclusion causale, il faut une stratégie d'identification (variation exogène, double apprentissage, expérience naturelle).

8.4 Autres approches en plein essor

- **Économétrie spatiale** : les chocs se diffusent entre régions voisines, $\mathbf{y} = \rho \mathbf{W} \mathbf{y} + \mathbf{X} \beta + \mathbf{u}$.
- **Contrôle synthétique** : construire un contrefactuel pondéré pour évaluer l'effet d'une catastrophe ou d'une politique d'adaptation sur une région donnée.
- **Modèles hybrides et émulateurs** : des réseaux apprennent à reproduire un modèle climatique ou un modèle intégré coûteux, ce qui permet d'explorer des milliers de scénarios.
- **Scénarios NGFS** : trajectoires macroéconomiques et climatiques harmonisées utilisées par les banques centrales et les ministères pour les analyses prospectives.

9. Quel outil pour quelle question ?




Fig. 7. Positionnement indicatif des familles de méthodes (appréciation qualitative de l'auteur). Couleurs : économétrie, modèles intégrés, apprentissage automatique, apprentissage profond, approches hybrides.

Cinq règles de bonne pratique

1. Partir de la question : effet causal, prévision ou scénario ne se traitent pas avec les mêmes outils.
2. Construire les indicateurs climatiques avec soin : pondération, saisonnalité, extrêmes.
3. Toujours tester hors échantillon et respecter l'ordre du temps.
4. Confronter plusieurs familles de modèles : la convergence des résultats vaut plus qu'un score isolé.
5. Expliquer les résultats, mais ne jamais confondre importance prédictive et causalité.

Références principales

- Adrian, T., Boyarchenko, N., Giannone, D. (2019). Vulnerable growth. *American Economic Review*, 109(4).
- Barrage, L., Nordhaus, W. (2024). Policies, projections, and the social cost of carbon : Results from the DICE-2023 model. *PNAS*, 121(13).
- Barrios, S., Bertinelli, L., Strobl, E. (2010). Trends in rainfall and economic growth in Africa. *Review of Economics and Statistics*, 92(2).
- Bilal, A., Känzig, D. (2024). The macroeconomic impact of climate change : Global vs. local temperature. NBER WP 32450.
- Burke, M., Hsiang, S., Miguel, E. (2015). Global non-linear effect of temperature on economic production. *Nature*, 527.
- Chernozhukov, V. et al. (2018). Double/debiased machine learning. *The Econometrics Journal*, 21(1).
- Damanian, R., Desbureaux, S., Zaveri, E. (2020). Does rainfall matter for economic growth ? *JEEM*, 102.
- Dell, M., Jones, B., Olken, B. (2012). Temperature shocks and economic growth. *AEJ : Macroeconomics*, 4(3) ; (2014) What do we learn from the weather ? *JEL*, 52(3).
- Dietz, S. et al. (2021). Economic impacts of tipping points in the climate system. *PNAS*, 118(34).
- Hsiang, S. (2016). Climate econometrics. *Annual Review of Resource Economics*, 8.
- Jordà, Ö. (2005). Estimation and inference of impulse responses by local projections. *AER*, 95(1).
- Kahn, M. et al. (2021). Long-term macroeconomic effects of climate change : A cross-country analysis. *Energy Economics*, 104.
- Lam, R. et al. (2023). Learning skillful medium-range global weather forecasting. *Science*, 382.
- Lundberg, S., Lee, S.-I. (2017). A unified approach to interpreting model predictions. *NeurIPS*.
- Pesaran, M. H., Shin, Y., Smith, R. (1999). Pooled mean group estimation of dynamic heterogeneous panels. *JASA*, 94.
- Vicente-Serrano, S. et al. (2010). A multiscale drought index sensitive to global warming : the SPEI. *Journal of Climate*, 23.
- Wager, S., Athey, S. (2018). Estimation and inference of heterogeneous treatment effects using random forests. *JASA*, 113.
- Weitzman, M. (2009). On modeling and interpreting the economics of catastrophic climate change. *REStat*, 91(1).