

L'IA POUR LES PRÉVISIONS METEOROLOGIQUES ET CLIMATIQUES : ETAT DES LIEUX ET PERSPECTIVES

Laure Raynaud

CNRM, Université de Toulouse, Météo-France, CNRS, Toulouse, France

laure.raynaud@meteo.fr

Avec des contributions scientifiques de plusieurs collègues.

Résumé

XXXXX

L'intelligence artificielle (IA), et en particulier les méthodes d'apprentissage profond utilisant les réseaux de neurones, a été exploitée avec succès dans un grand nombre d'applications ces dernières années. La prévision météorologique et climatique ne fait pas exception, les utilisations de l'IA dans ce domaine sont potentiellement nombreuses et pourraient conduire à des avancées méthodologiques majeures, associées à des gains significatifs en performance et en qualité. Toutes les étapes de la chaîne de production des prévisions sont concernées, de l'assimilation des données au post-traitement des prévisions, en passant par l'élaboration des modèles de prévision, de la très courte échéance aux projections climatiques.

Suite à cette nouvelle tendance, Météo-France a commencé à étudier différentes pistes pour intégrer l'IA dans le calcul et l'exploitation des prévisions météorologiques et climatiques. Qu'ils soient exploratoires ou plus proches d'une utilisation opérationnelle, ces travaux illustrent le potentiel de l'IA pour certaines de nos activités, et ouvrent de nouvelles questions et défis quant au statut de l'IA dans les prochaines évolutions des systèmes de prévision.

Nous décrivons brièvement quelques recherches en cours à Météo-France pour exploiter l'IA en tant que nouvel outil pour la modélisation atmosphérique. Différentes stratégies sont discutées, de l'hybridation entre les modèles physiques de prévision et l'IA, jusqu'au développement d'émulateurs 'tout IA' annonçant un potentiel changement de paradigme pour la prévision météorologique.

Mots clés

Prévision météorologique, apprentissage statistique, réseaux de neurones

Abstract

XXXXX

Artificial Intelligence (AI), and in particular deep learning methods based on neural networks, has been successfully leveraged in a growing number of areas in recent years. The applications of AI to weather and climate forecasting are potentially numerous, and could lead to major methodological breakthroughs, associated with significant gains in performance and quality. All stages in the forecast processing chain may be concerned, from data assimilation to forecasts analysis, as well as the development of models, from nowcasting to climate projections.

Following this new trend, Météo-France started investigating the use of AI for different aspects of weather and climate predictions. Whether exploratory or closer to operationalization, these works illustrate the potential of AI for some of our activities, and open up new questions and challenges regarding the status of AI in the next evolutions of forecasting systems.

We briefly describe and discuss ongoing research at Météo-France to leverage AI as a new component for atmospheric modelling, from soft hybridization of AI and physics-based weather forecasting models to the more disruptive full data-driven weather forecasting emulators.

Keywords

Weather prediction, machine learning, neural networks

1 Introduction

La prévision météorologique est le résultat d'une séquence d'étapes complexes dont l'élément central est le modèle de prévision. Le développement de ces modèles, initié dès les années 1950, s'appuie sur la connaissance experte des lois physiques qui gouvernent l'évolution de l'atmosphère. Plusieurs fois par jour, la résolution numérique des équations du modèle, sur des grilles plus ou moins fines, permet de produire des prévisions pour les prochaines heures et jours.

La prévision numérique du temps est un domaine en évolution constante. L'intégration de nouvelles observations et de représentations plus précises des processus physiques, en lien avec l'augmentation des ressources de calcul, permet d'améliorer régulièrement la qualité des prévisions et l'anticipation des événements à fort impact. Néanmoins, la modélisation reste une approximation du système réel, limitée par notre compréhension des processus en jeu et par les contraintes computationnelles.

L'utilisation de l'intelligence artificielle (IA) en météorologie n'est pas nouvelle. Dès les années 1990, les techniques d'IA ont permis des développements novateurs dans le post-traitement statistique des prévisions météorologiques. Diverses applications ont été développées, notamment à Météo-France, pour réduire les erreurs systématiques des prévisions. Par exemple, le traitement par forêts aléatoires des prévisions de pluies extrêmes permet de les corriger pour se rapprocher des valeurs observées (Taillardat et al., 2019).

En revanche, ce n'est que récemment que l'utilisation de l'IA s'est étendue au cœur de la modélisation atmosphérique. C'est en particulier la capacité de l'IA à apprendre des relations complexes et à opérer très rapidement dans sa phase d'inférence qui a motivé l'utilisation de ces approches pour améliorer les modèles de prévision et réduire leur coût de calcul. La complémentarité des approches physique et IA a initialement motivé le développement de systèmes de prévision « hybrides », combinant la modélisation physique classique et l'IA. Il s'agit par exemple de remplacer les éléments les plus coûteux ou les moins bien représentés d'un modèle physique par un algorithme d'IA. D'autres travaux se sont penchés sur la possibilité d'exploiter l'IA pour améliorer certaines caractéristiques des prévisions (finesse de l'échantillonnage spatial ou probabiliste par exemple), et in fine leur qualité, à moindre coût. Une nouvelle étape a été franchie il y a peu par plusieurs équipes de recherche, qui ont proposé de remplacer complètement le modèle physique par un modèle d'IA. Le travail précurseur de Dueben et Bauer (2018) avait jeté les bases d'une prévision purement statistique, mais en émettant de sérieuses réserves sur sa capacité à rivaliser un jour avec la prévision physique. Cinq ans plus tard, les progrès ont été bien plus rapides qu'attendus, et une partie de ces doutes est levée.

L'étude de Ravuri et al. (2021) est une des premières à montrer qu'un modèle 'tout IA' (de type génératif) peut réaliser des prévisions de précipitations réalistes à très courte échéance. Depuis 2022, une succession de travaux attaque le problème de la prévision globale à moyenne échéance (Bi et al., 2022 ; Lam et al., 2023, Lguensat et al., 2023). Ces modèles d'IA, dans la suite appelés *émulateurs*, sont représentés par exemple par les systèmes Pangu-Weather ou GraphCast. Entraînés sur plus de 40 ans de données, ils sont désormais compétitifs sur plusieurs aspects avec le modèle physique du Centre Européen de Prévision Météorologique à Moyen Terme (CEPMMT), considéré comme le meilleur modèle de prévision opérationnel actuellement (Ben Bouallègue et al., 2023). Cette percée très rapide des émulateurs est d'autant plus surprenante que, pour la première fois, elle n'est pas portée par les services météorologiques nationaux mais par des grandes entreprises internationales telles que Nvidia, Huawei, DeepMind ou Microsoft. C'est donc un potentiel double changement de paradigme pour la communauté météorologique.

La suite du document présente quelques travaux engagés à Météo-France pour exploiter l'IA, et en particulier les méthodes neuronales, dans le processus de prévision. Une analyse succincte des émulateurs existants et des pistes de recherche qu'ils ouvrent est également proposée.

2 L'IA pour la prévision à Météo-France : quelques premières réalisations

2.1 L'IA pour améliorer la physique des modèles

Les paramétrisations physiques, qui simulent les effets des processus sous-maille tels que le rayonnement, la convection ou la turbulence, sont actuellement parmi les composants les plus coûteux d'un modèle, ainsi qu'une des principales sources d'incertitude des prévisions météorologiques et climatiques. Plusieurs travaux ont commencé à examiner la possibilité de remplacer tout ou partie de ces paramétrisations par des algorithmes d'IA. A titre d'exemple citons le travail de Balogh (2022), qui a réalisé une simulation d'une durée d'un an avec le modèle ARPEGE-Climat où le schéma de convection profonde a été remplacé par des réseaux de neurones de type récurrents (Figure 1).

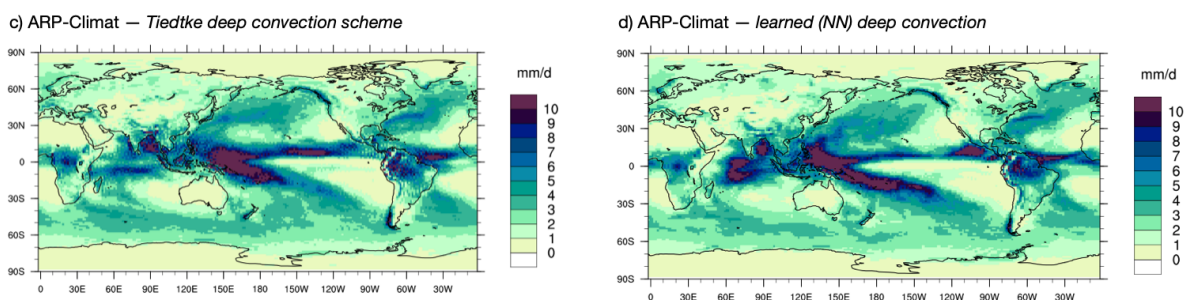


Figure 1: Précipitations annuelles moyennes prévues par la modèle ARPEGE-Climat. A gauche, prévision du modèle physique. A droite, prévision d'un modèle « hybride », où la paramétrisation de la convection profonde est remplacée par un réseau de neurones. Source : B. Balogh.

2.2 L'IA pour améliorer l'échantillonnage spatial : la super-résolution appliquée aux prévisions météo

Augmenter la résolution du modèle de prévision permet de mieux décrire les phénomènes météorologiques de fine échelle. C'est particulièrement important pour la prévision d'événements comme les orages, le brouillard, l'îlot de chaleur urbain ; mais au prix d'une augmentation significative, voire rédhibitoire, du coût de calcul. La descente d'échelle statistique, que l'on peut grossièrement comparer à la super-résolution, est une alternative à l'augmentation de résolution du modèle, qui consiste à apprendre une relation statistique entre les prévisions à basse résolution et les prévisions à plus haute résolution. Il est ainsi possible de simuler des prévisions haute résolution en appliquant a posteriori cette relation aux prévisions d'un modèle à basse résolution. De nombreuses études se sont penchées sur la capacité des réseaux de neurones, notamment convolutionnels, à résoudre ce problème, avec des résultats très prometteurs. On peut mentionner les travaux de Doury et al. (2022), qui proposent l'application d'une architecture de type U-Net pour la descente d'échelle de simulations climatiques (Figure 2).

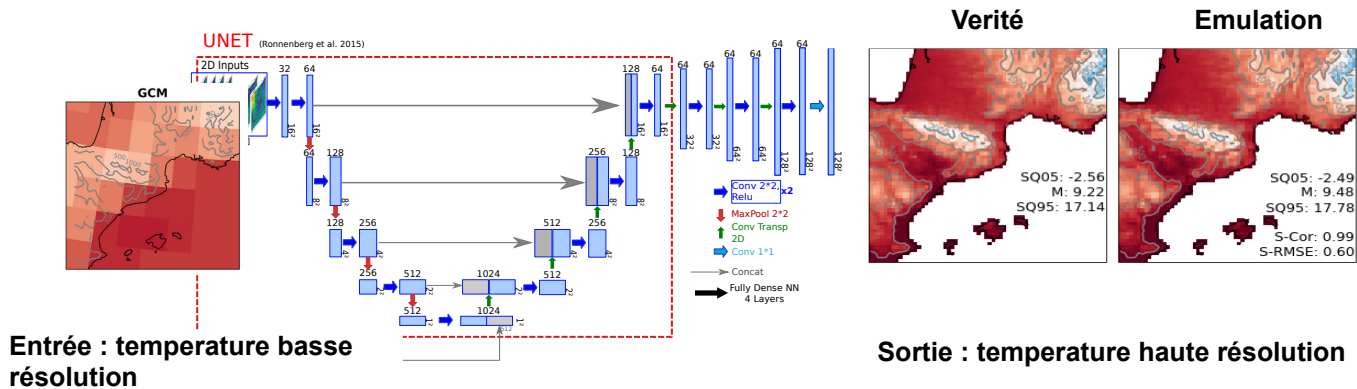


Figure 2 : Principe de la descente d'échelle statistique pour la prévision météorologique ou climatique. Source : A. Doury.

2.3 L'IA pour améliorer l'échantillonnage probabiliste : les méthodes génératives appliquées à la météo

La prévision d'ensemble est utilisée pour caractériser les différents scénarios d'évolution possibles grâce à la réalisation en parallèle de plusieurs prévisions. Devenue un élément incontournable de nombreux services de prévision, la prévision d'ensemble n'en reste pas moins fortement contrainte par les ressources de calcul disponibles, en particulier en ce qui concerne le nombre de réalisations (aussi appelées « membres »). Les prévisions d'ensemble actuellement opérationnelles n'utilisent pas plus de 50 membres, alors qu'une estimation précise des distributions de probabilité en requiert plusieurs centaines ou milliers. L'IA pourrait-elle permettre de générer des membres supplémentaires en se substituant au modèle de prévision ? Les travaux de Brochet et al. (2023) apportent de premiers éléments de réponse encourageants. S'appuyant sur une architecture de type Generative Adversarial Network (GAN), ils montrent qu'il est possible de produire des champs météorologiques réalistes, et ouvrent ainsi la voie à des prévisions d'ensemble hybrides de plusieurs dizaines voire centaines de membres (Figure 3).

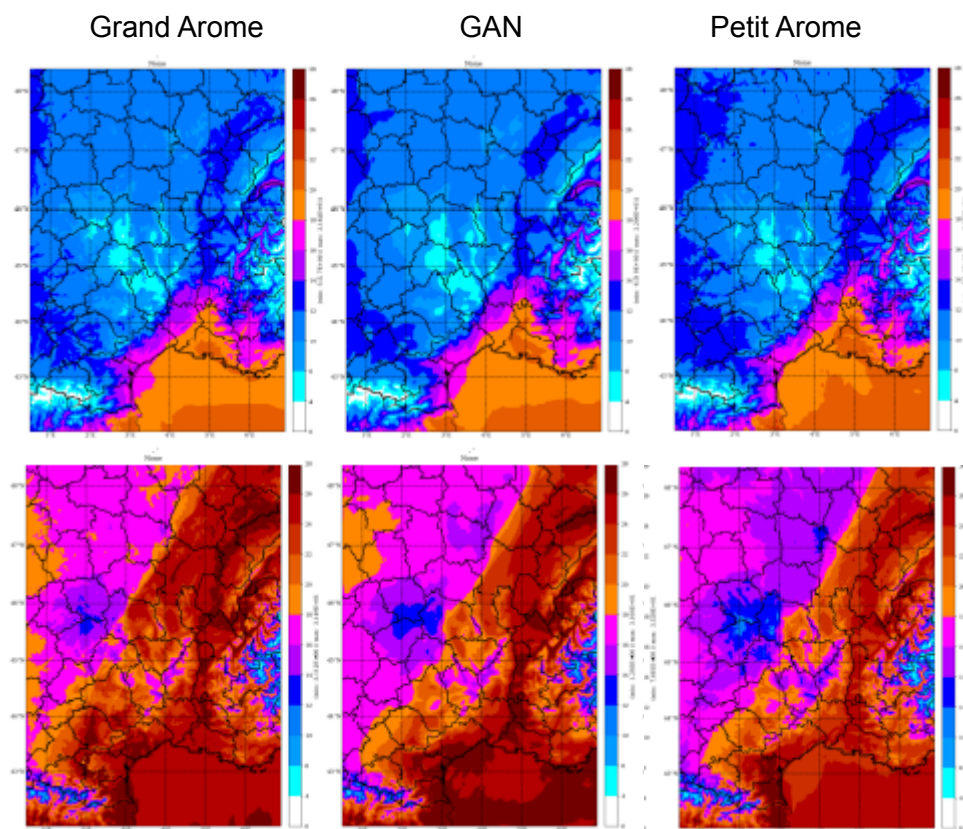


Figure 3 : Comparaison des quantiles min (ligne du haut) et max (ligne du bas) des distributions de température échantillonnées par trois ensembles. A gauche (resp. droite) un ensemble de 875 (resp. 16) membres utilisant le modèle de prévision Arome, au milieu un ensemble de 875 membres générés par un GAN (conditionné aux 16 membres Arome). Le GAN permet d'étendre la distribution du petit ensemble Arome et de s'approcher de celle du grand ensemble Arome. Les membres générés par le GAN sont par ailleurs physiquement cohérents (Brochet et al., 2023). Source : C. Brochet, G. Moldovan.

2.4 Les émulateurs sont-ils l'avenir de la prévision météo ?

Les émulateurs publiés récemment vont un cran plus loin que les réalisations présentées précédemment, en proposant une alternative complète aux modèles de prévision physiques, et en exploitant des architectures neuronales complexes, basées principalement sur les vision transformers, ou une représentation sous forme de graphes. Dans toutes ces expériences, la base d'apprentissage est la même, et correspond à la reconstruction de l'état de l'atmosphère depuis 1940 jusqu'à aujourd'hui, heure par heure, à une résolution horizontale de 30 km sur tout le globe. Ce jeu de données est une formidable source d'information sur notre système Terre et permet notamment de suivre l'évolution du climat, même si sa résolution spatiale est loin des standards des modèles de prévision en opération, qui atteignent aujourd'hui des résolutions globales inférieures à 10km et régionalement des résolutions kilométriques, voire hectométriques. Ces démonstrateurs offrent une représentation encore très partielle de l'atmosphère, avec un nombre limité de variables prévues, une résolution spatiale loin de l'état de l'art, et des cohérences physiques imparfaites, mais ils ouvrent un nouveau pan de recherche avec de multiples questions scientifiques et techniques, et des opportunités nouvelles pour la prévision opérationnelle.

La Figure 4 présente les performances de ces émulateurs, avec des scores objectifs meilleurs que ceux des prévisions du CEPMMT pour certaines variables et échéances. Ces émulateurs ont également montré leur capacité à simuler des événements à fort impact, tel qu'illustré ici sur la tempête Ciaran. Ces résultats, bien qu'encourageants, doivent encore être consolidés avant de pouvoir considérer ces émulateurs suffisamment robustes et fiables pour un usage en conditions opérationnelles.

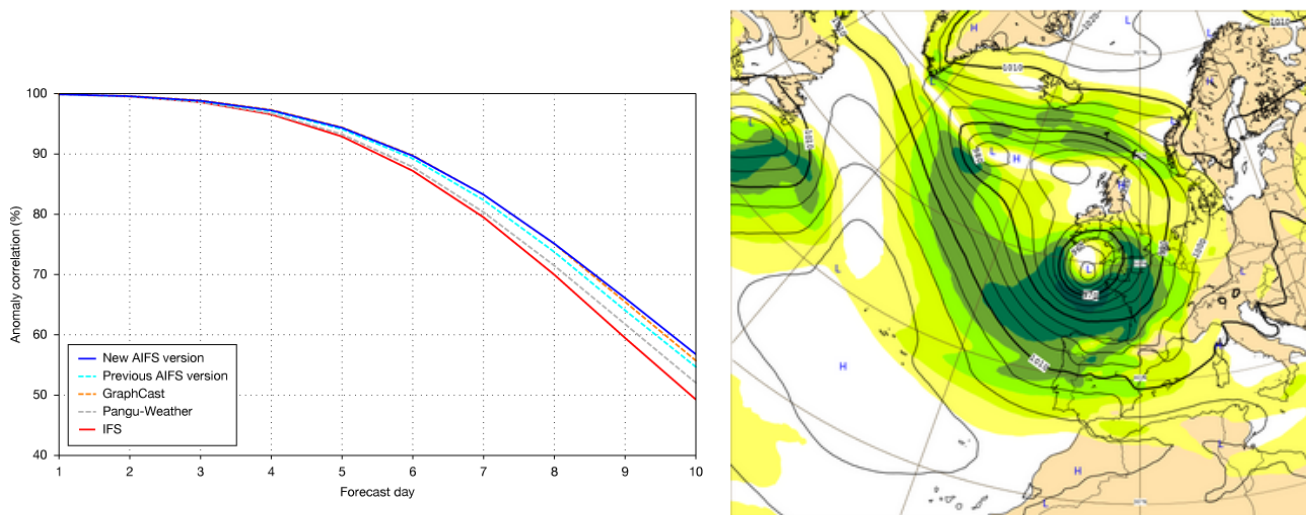


Figure 4 : Gauche : score de corrélation d'anomalie pour le géopotential à 500hPa en fonction de l'échéance de prévision (source : CEPMMT). Plusieurs émulateurs IA sont comparés à la prévision du CEPMMT (en rouge). Plus le score est proche de 100% meilleure est la prévision. Droite : prévision de l'émulateur Pangu Weather pour le cas de la tempête Ciaran (validité 2 novembre 2023 à 0 UTC), pression au niveau de la mer (isolignes) et force du vent à 850hPa (plages de couleurs), source : M. Pardé.

Malgré des faiblesses bien identifiées, la démonstration est faite qu'il est possible de prévoir une partie des paramètres météorologiques, avec une certaine qualité, et dans des temps très courts. Les temps de production sont de quelques secondes ou minutes, soit bien inférieurs à ceux des modèles de prévision physiques qui se comptent en dizaines de minutes, voire plus. Il demeure qu'en amont, il faut disposer de la capacité à réaliser la phase d'apprentissage qui, elle, peut prendre des temps longs, qui se comptent en semaines ou mois, mais qui sont hors du chemin critique de la production des prévisions en temps réel.

Pour que ces émulateurs deviennent de nouveaux outils exploitables pour la prévision du temps opérationnelle, et plus généralement pour toutes les applications nécessitant des données météorologiques, il reste de nombreux verrous à lever. Le premier enjeu est de développer des émulateurs adaptés aux besoins des usagers, entraînés sur des données à très haute résolution spatiale, et capables de prévoir les variables météorologiques d'intérêt et les incertitudes associées. Cela soulève la question de la disponibilité et de l'accessibilité de ces jeux de données, et de la capacité à mobiliser des ressources de calcul conséquentes pour des entraînements pouvant atteindre plusieurs semaines. Les émulateurs actuels ont pour la plupart été conçus pour des applications spécifiques. Le développement d'émulateurs plus génériques, de type modèles de fondation, est certainement la suite à envisager pour couvrir efficacement une large gamme d'objectifs (Nguyen et al., 2023). Enfin, une étape importante à franchir sera l'apprentissage des émulateurs sur des données multi-sources (modèles, observations), avec des qualités et des couvertures spatio-temporelles hétérogènes.

Le second enjeu est la mise au point d'outils et de diagnostics d'interprétabilité et d'explicabilité de ces émulateurs. A l'instar des modèles physiques, il est légitime de pouvoir déterminer si les émulateurs ont produit une bonne prévision pour les bonnes raisons ou, en cas de mauvaises prévisions, quels composants de l'architecture sont en cause. Une perspective sous-jacente est le développement de réseaux de neurones informés par la physique, pour forcer les émulateurs à produire des solutions physiquement cohérentes.

3 Conclusions

Si le développement incrémental de la prévision numérique du temps est souvent qualifié de 'révolution lente', c'est une révolution beaucoup plus rapide qui semble se mettre en marche avec l'avènement des premiers modèles de prévision par IA. C'est aussi un nouveau pan de recherche qui s'ouvre devant les services météorologiques, avec de nouveaux enjeux scientifiques et techniques. Cela ne doit néanmoins pas faire perdre de vue la poursuite des travaux d'amélioration des modèles de prévision physiques. Il ne s'agit pas, à ce stade, de remplacer l'un par l'autre, mais d'exploiter la complémentarité de ces deux approches.

Bibliographie

Balogh B., 2022. Vers une utilisation de l'Intelligence Artificielle dans un modèle numérique de climat. Thèse de doctorat en Océan, atmosphère, climat. Toulouse INPT.

Bi K., L. Xie, H. Zhang, X. Chen, X. Gu, Q. Tian, 2022 : Pangu-Weather - A 3D High-Resolution Model for Fast and Accurate Global Weather Forecast, arXiv preprint arXiv:2211.02556.

Ben Bouallègue Z. et al., 2023 : The rise of data-driven weather forecasting, a first statistical assessment of machine learning-based weather forecasts in an operational-like context

Brochet, C., L. Raynaud, N. Thome, M. Plu, and C. Rambour, 2023: Multivariate Emulation of Kilometer-Scale Numerical Weather Predictions with Generative Adversarial Networks: A Proof of Concept. *Artif. Intell. Earth Syst.*, 2, 230006, <https://doi.org/10.1175/AIES-D-23-0006.1>

Doury, A., Somot, S., Gadat, S. et al. Regional climate model emulator based on deep learning: concept and first evaluation of a novel hybrid downscaling approach. *Clim Dyn* (2022). <https://doi.org/10.1007/s00382-022-06343-98>

Dueben, P. D. et Bauer, P.: Challenges and design choices for global weather and climate models based on machine learning, *Geosci. Model Dev.*, 11, 3999–4009, <https://doi.org/10.5194/gmd-11-3999-2018>, 2018.

Lam R. *et al.*, Learning skillful medium-range global weather forecasting. *Science*, [DOI:10.1126/science.adi2336](https://doi.org/10.1126/science.adi2336)

Lguensat R., 2023 : Les nouveaux modèles de prévision météorologique basés sur l'intelligence artificielle : opportunité ou menace ? *La Météorologie* n°121 mai 2023 pp 11-15

Nguyen T., J. Brandstetter, A. Kapoor, J. K. Gupta and A. Grover, 2023 : ClimaX - A foundation model for weather and climate. *arXiv preprint arXiv:2301.10343v2*, 41p, 24 Jan 2023.

Ravuri, S., Lenc, K., Willson, M. *et al.* Skilful precipitation nowcasting using deep generative models of radar. *Nature* **597**, 672–677 (2021). <https://doi.org/10.1038/s41586-021-03854-z>

Taillardat, M., A. Fougères, P. Naveau, and O. Mestre, 2019: Forest-Based and Semiparametric Methods for the Postprocessing of Rainfall Ensemble Forecasting. *Wea. Forecasting*, **34**, 617–634, <https://doi.org/10.1175/WAF-D-18-0149.1>.