

Predicción numérica del tiempo: ¿basada en leyes o en datos?

E. RODRÍGUEZ CAMINO, AME

1 Primeros pasos

Cuando en enero de 1904, el físico noruego Vilhelm Bjerknes publicó su trascendental artículo "El problema de la predicción del tiempo desde el punto de vista de la mecánica y la física" en *Meteorologische Zeitschrift*, en tan solo siete páginas desarrolló la idea de un modelo matemático de la dinámica atmosférica basado únicamente en las leyes de la física, particularmente la mecánica y la termodinámica, en contraposición a la práctica generalizada de predecir el tiempo basada en las observaciones y métodos empíricos de predicción. Aunque su modelo no era practicable en aquellos días –por lo que su propuesta tardó en encontrar aceptación en el campo de la meteorología– hoy sabemos que su idea fue revolucionaria y marcó el desarrollo posterior de la predicción numérica del tiempo (PNT) y de la meteorología moderna.

En 1922, Lewis Fry Richardson sentó en su libro titulado "Weather Prediction by Numerical Process" (Predicción del Tiempo mediante Proceso Numérico) las bases teóricas y prácticas para implementar la PNT. Richardson desarrolló la propuesta

de Bjerknes de integrar las ecuaciones diferenciales que describen la evolución de la atmósfera a partir de unas condiciones iniciales determinadas por las observaciones. Aunque Richardson desarrolló un plan muy ambicioso basado en el uso de incipientes métodos numéricos para resolver las ecuaciones diferenciales, también reconoció las limitaciones tecnológicas de su tiempo ("quizás algún día en un futuro lejano será posible hacer avanzar los cálculos más rápido que lo que avanza el tiempo ... pero eso es un sueño") ya que se requerirían avances significativos tanto en la tecnología informática como en los métodos numéricos para realizar de forma práctica los cálculos rápidos y precisos que se precisaban.

En la década de 1930, Carl-Gustaf Rossby contribuyó significativamente a la mejor comprensión de los patrones de circulación atmosférica y de los fenómenos a gran escala regidos por la formación y propagación de lo que posteriormente se denominaron ondas de Rossby, que son oscilaciones que se producen en la atmósfera (y también en los océanos) y que tienen su origen en el principio de conser-

vación de la vorticidad potencial. Su trabajo en este campo inició los fundamentos para el desarrollo posterior de modelos filtrados para la predicción numérica del tiempo.


El ENIAC (acrónimo de *Electronic Numerical Integrator And Computer*) fue uno de los primeros ordenadores de uso general, aunque su propósito inicial era para uso militar por el ejército de los Estados Unidos. En su desarrollo fueron decisivas las ideas de John von Neumann, mientras que la implementación práctica fue dirigida por el ingeniero John Presper Eckert y el físico John Mauchly. Su puesta en marcha en 1945 simultáneamente con la creación de un grupo de meteorología en Princeton dirigido por Jule Charney fue decisivo para generar la primera predicción numérica operativa del tiempo basada en un modelo barotrópico para la ecuación de la vorticidad, siguiendo las ideas del propio Rossby, para simular solamente las ondas de gran escala y poder simplificar y hacer resoluble el problema de cálculo de acuerdo a la capacidad del ENIAC. El mismo Charney junto con von Neumann y con Ragnar Fjörtoft firmaron en 1950 el artículo que describe la primera predicción numérica operativa del tiempo (Smagorinsky 1983).

Los pioneros de la informática von Neumann y Mauchly estaban ambos interesados en la predicción numérica del tiempo, pero querían abordar el problema desde direcciones diametralmente opuestas. Mauchly, aunque era físico, tenía una formación sólida como ingeniero y quería analizar grandes volúmenes de datos meteorológicos para poder así revelar las posibles relaciones entre los ciclos meteorológicos y los ciclos de las manchas solares, y posteriormente utilizar esas relaciones para predecir el tiempo. Por el contrario, von Neumann, que tenía una gran formación teórica en matemáticas y física, retomó la línea de trabajo de Bjerknes, Richardson y Rossby planteando la hipótesis de que el tiempo podría predecirse aplicando las leyes de la física a la atmósfera, subdividiendo ésta en una rejilla de puntos y resolviendo las ecuaciones correspondientes en



Representación artística del concepto de fábrica de predicciones planteado por Richardson.
(Fuente: Francois Schuiten).

Predicción numérica del tiempo: ¿basada en leyes o en datos?



Uso de técnicas de ML para realizar predicciones del tiempo. (Fuente: Elaboración sobre imagen MTG-I1 EUMETSAT)

cada punto. En cualquier caso, ambos enfoques requerían una inmensa cantidad de cálculos que superaba la capacidad humana y de ahí la necesidad de realizar los cálculos con un ordenador electrónico. Mauchly y von Neumann ejemplifican los dos enfoques opuestos y complementarios del progreso científico, en general, y de la predicción numérica del tiempo en particular: el enfoque basado en datos y el enfoque basado en hipótesis. El enfoque de la ciencia basado en datos, también denominado inductivismo, es una rama del empirismo, que basa la adquisición del conocimiento a partir de la experiencia. El enfoque basado en hipótesis, también denominado deductivismo, es una rama del racionalismo que basa la adquisición del conocimiento a partir del razonamiento (Saravanan 2022).

Finalmente, la línea deductivista basada en las leyes físicas descritas en forma de ecuaciones diferenciales defendida inicialmente por von Neumann se impuso y durante los últimos 70 años de desarrollo de la predicción numérica del tiempo hemos asistido a grandes hitos que han permitido mejorar la calidad y precisión de las predicciones. El aumento en la resolución de los modelos que ha avanzado en paralelo con el desarrollo de ordenadores cada vez más potentes, la asimila-

ción de más y mejores observaciones con algoritmos cada vez más sofisticados, el desarrollo de parametrizaciones físicas cada vez más detalladas y complejas, la introducción de la predicción por conjuntos para describir el comportamiento caótico de la atmósfera, entre otros hitos científicos y tecnológicos, han permitido alcanzar un nivel de desarrollo en la predicción numérica del tiempo que ha llegado a ser calificada como una revolución silenciosa (*quiet revolution*, en inglés) en el área de las ciencias físicas comparable a otras revoluciones científicas recientes como la simulación del cerebro humano o la evolución inicial del universo (Bauer *et al.* 2015).

2 Sistemas de predicción basados en técnicas de aprendizaje automático

En los años más recientes estamos asistiendo a una eclosión de la inteligencia artificial generativa, en forma de modelos de lenguaje e imagen. Este surgimiento de técnicas basadas en inteligencia artificial (IA) y el subconjunto de la misma basado en aprendizaje automático (ML por *machine learning*, en inglés) ha sido impulsado por: i) un aumento sin precedentes en el volumen de datos (cientos de terabytes de datos que probablemente se producirán

en un solo día con las predicciones meteorológicas a escala kilométrica) de los que se hace cada vez más difícil extraer toda la información relevante utilizando métodos convencionales; ii) un aumento del conocimiento en IA y ML; iii) desarrollos en hardware informático para permitir el entrenamiento de herramientas de aprendizaje automático con miles de millones de parámetros entrenables a partir de muchos terabytes de datos; iv) disponibilidad y facilidad de uso de software de código abierto. No obstante, el uso de algunos algoritmos de ML y modelos estadísticos está bien establecido en la comunidad de PNT, por ejemplo, mediante el uso de análisis de componentes principales o el uso de técnicas de asimilación de datos que también pueden interpretarse como ML. Sin embargo, en lo que respecta al uso de técnicas complejas de aprendizaje automático, como las redes neuronales profundas, la ciencia del sistema terrestre todavía está rezagada respecto de otras disciplinas de investigación. El mismo Centro Europeo de Predicción a Plazo Medio (ECMWF, por sus siglas en inglés) publicó en 2021 en su hoja de ruta en este campo para la próxima década una lista de aplicaciones basadas en ML que están siendo implementadas, exploradas y planificadas en las diferentes partes de la cadena operativa de su sistema de predicción. Se puede mencionar entre otras muchas otras aplicaciones de las técnicas de ML: uso de redes neuronales para monitorizar observaciones, uso de redes neuronales para la asimilación de datos SMOS de humedad del suelo en la superficie terrestre, el uso de redes neuronales para las ligaduras débiles en el marco de la asimilación 4D-Var, emulación del esquema de parametrización para el arrastre de ondas de gravedad, emuladores para generar código del modelo tangente lineal y adjunto en la asimilación de datos 4D-Var, árboles de decisión para el posprocesamiento de predicciones por conjuntos de precipitación, etc. (Dueben *et al.* 2021).

La situación ha cambiado rápidamente en los dos últimos años cuando grandes empresas tecnológicas como NVIDIA, Huawei y Google DeepMind avanzaron en la calidad de las predicciones meteorológicas con sus respectivos modelos FourCastNet, Pangu-Weather y GraphCast basados exclusivamente en ML hasta acercarse a la pericia del modelo IFS del ECMWF. El mismo ECMWF ha desarrolla-

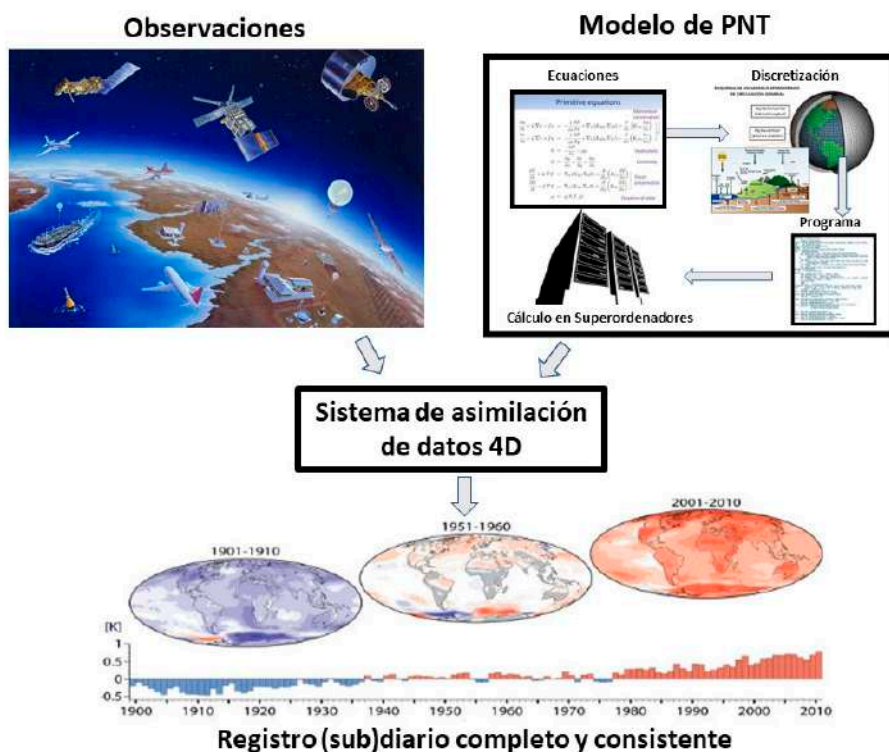
do su propio modelo íntegramente basado en ML (denominado Artificial Intelligence/Integrated Forecasting System (AIFS)) con código abierto para comparar con los arriba mencionados y explorar vías alternativas de trabajo. Ha trascendido mucho en los medios de comunicación que estos modelos basados en ML requieren para generar su predicción de sólo un minuto en una única unidad de procesamiento gráfica (GPU, del inglés) y que por lo tanto consumen una ínfima cantidad de energía en comparación con el modelo IFS. Sin embargo, la lectura no es tan simple ya que todos estos modelos basados exclusivamente en ML actualmente dependen en gran medida del IFS ya que utilizan datos del reanálisis ERA5 (generados con el IFS) para su entrenamiento, validación y establecimiento de condiciones iniciales. La calidad de las predicciones se ha medido fundamentalmente utilizando el error cuadrático medio, siendo los modelos ML en su fase de entrenamiento diseñados para minimizar precisamente este mismo índice. La evaluación de la calidad de las predicciones es una tarea mucho más compleja que la simple comparación de un único índice de verificación, normalmente hay que considerar una batería de índices que miden diferentes aspectos de

la predicción, también hay que considerar si se suavizan o no las predicciones de los eventos extremos (que es donde las predicciones tienen más valor), y sobre todo hay que verificar si las predicciones muestran o no una imagen físicamente consistente de todas las variables. El diseño de la fase de entrenamiento es esencial en las predicciones basadas exclusivamente en ML para optimizar uno u otro aspecto de las predicciones (Chantry *et al.* 2023).

3 El reanálisis como herramienta para estudiar el clima

Como hemos visto el reanálisis es un elemento esencial para entrenar, evaluar e inicializar las predicciones exclusivamente basadas en ML. La idea de generar reanálisis se remonta a 1988, cuando Bengtsson y Shukla se plantearon recalcular la serie de análisis generados para producir condiciones iniciales en los sistemas operativos de predicción numérica del tiempo. Esta serie de análisis cumplía la necesidad diaria de generar condiciones iniciales pero al mismo tiempo adolecían de varias limitaciones. En primer lugar, los primeros sistemas de asimilación de datos tenían fuertes limitaciones para asimilar ciertos

tipos de observaciones no convencionales y no eran tan potentes como los sistemas posteriores de asimilación variacional 4D. En segundo lugar, los cambios en los modelos de predicción introducidos con el tiempo generaban además inconsistencias en la serie temporal de análisis. Un reanálisis es en definitiva una reconstrucción retrospectiva de condiciones meteorológicas pasadas utilizando un único sistema avanzado de asimilación 4D y un único modelo numérico. Un reanálisis asimila todas las observaciones disponibles con un código único tanto para asimilación como para predicción. El objetivo principal de un reanálisis es proporcionar conjuntos coherentes y consistentes de análisis a lo largo de un período de tiempo específico que pueda ser utilizado para fines climáticos. A pesar de estar disponibles los reanálisis, su uso para realizar estudios climáticos, en particular, de cambio climático se demoró. De hecho, aunque los primeros reanálisis comenzaron a estar disponibles en las décadas de 1980 y 1990, la comunidad científica tardó todavía algún tiempo en aprovechar completamente estos conjuntos de datos para estudios de cambio climático a largo plazo. Debido a la necesidad de datos consistentes y de larga duración para evaluar las tendencias climáticas, los conjuntos de datos de reanálisis se convirtieron en herramientas valiosas ya que permiten examinar las variabilidades y tendencias de una amplia gama de variables climáticas consistentes entre sí a lo largo de décadas, proporcionando una base sólida para investigar el cambio climático, para validar modelos climáticos, para realizar estudios de impacto y, desde la irrupción de los sistemas de predicción basados en ML, para entrenar estos sistemas. Los reanálisis, sin embargo, han estado sujetos a ciertas críticas debido a las discrepancias que hay entre los diferentes reanálisis –si bien estas diferencias permiten caracterizar la incertidumbre–, su insuficiente resolución espacial para ciertas aplicaciones, sus sesgos y su dependencia de los modelos, etc. Estas características de los reanálisis pueden hacer que éstos no sean adecuados para ciertas aplicaciones climáticas.




El reanálisis combina observaciones pasadas de la atmósfera con un modelo de PNT en un sistema de asimilación de datos para proporcionar un registro completo y consistente de condiciones meteorológicas. (Fuentes: OMM, Copernicus).

4 Gemelos digitales del sistema Tierra

Un gemelo digital es un sistema informático que imita la estructura, el contexto y el comportamiento de un sistema (o

Predicción numérica del tiempo: ¿basada en leyes o en datos?



sistema de sistemas) real bien sea natural, diseñado (normalmente de ingeniería) o social, que se actualiza dinámicamente con datos de su gemelo físico, y que tiene una capacidad predictiva para informar decisiones que generan valor. La interacción bidireccional entre lo virtual y lo físico es el elemento fundamental de los gemelos digitales. Los gemelos digitales son inmensamente prometedores para acelerar los descubrimientos científicos y revolucionar las industrias. Pueden llegar a ser una herramienta fundamental para la toma de decisiones basada en una combinación sinérgica de modelos y datos. Los usos de gemelos digitales son diversos y proliferan, con aplicaciones en múltiples áreas de la ciencia, la tecnología y la sociedad, y su potencial tiene un alcance muy amplio (NAP 2023).

Sin embargo, el término “gemelo digital” referido al sistema Tierra puede llegar a ser engañoso ya que nunca será posible duplicar la complejidad del sistema Tierra en su multiplicidad de escalas, procesos y retroalimentaciones. Y aquí quizás vendría a cuento una mención al cuento de Jorge Luis Borges titulado “Del rigor en la ciencia” en el que abordó el tema de la exactitud y la representación. En este cuento, Borges presenta la idea de un imperio en el que el arte de la cartografía se ha llevado a tal extremo que el mapa del imperio es del mismo tamaño que el imperio mismo. Esta situación

lleva a problemas prácticos y filosóficos, ya que el mapa, siendo tan detallado y exacto, se convierte en un objeto inútil y problemático. Esta historia se ha interpretado de muchas maneras a lo largo del tiempo, pero una de las lecturas más comunes es la crítica a la idea de que cualquier representación, por más detallada y precisa que sea, siempre será una simplificación o una interpretación de la realidad, y nunca podrá capturar completamente la complejidad y la totalidad de lo que pretende representar. Es decir, aplicado al caso de los gemelos digitales siempre habrá una gran distancia y diferencia entre el gemelo digital, necesariamente más simple, y el sistema Tierra de una complejidad difícilmente alcanzable. En cualquier caso, se puede decir que lo que distingue un gemelo digital de una simulación es quizás la utilización de métodos y enfoques más eficientes, heredando el concepto de gemelo digital todos los esfuerzos en modelización que se han venido realizando durante décadas. Aunque el concepto de gemelo digital se va a utilizar principalmente para realizar predicciones del tiempo y escenarios hipotéticos de proyecciones climáticas, su uso cada vez más extendido posiblemente será para experimentar y aprender más sobre la física del sistema climático en general.

Las predicciones de muy alta resolución –también llamadas hiperlocales–

se van a beneficiar no sólo de modelos desarrollados a las resoluciones kilométricas y mayores, sino también de la incorporación de nuevos tipos de datos capaces de capturar los intrincados detalles de las condiciones atmosféricas locales, características superficiales e interacciones humanas. Además de datos de satélite y radar de alta resolución que pueden proporcionar información detallada sobre patrones de nubes, intensidad de precipitación, contenido de humedad atmosférica y otros fenómenos y procesos locales, se pueden incorporar datos de sensores y redes asociados al internet de las cosas (IoT, de su acrónimo en inglés), incluyendo sensores de IoT integrados en áreas urbanas influenciados por islas de calor urbanas, infraestructuras, usos del suelo y actividades humanas, extracción de datos meteorológicos a partir de datos generados para otros fines (p.ej., atenuación de las señales de comunicación por microondas entre torres de telefonía móvil pueden proporcionar una imagen precisa y detallada de la distribución espacial y la cantidad de precipitación), imágenes hiperespectrales, etc.

Con la irrupción de técnicas basadas en ML, lo que realmente se plantea no es si un gemelo digital se basará en ecuaciones o en datos sino cómo será la combinación adecuada de teoría física, integración numérica y/o aproximaciones ML. Además, hay que considerar que el número de

grados de libertad que no están resueltos en el sistema Tierra excede con creces el número de grados de libertad disponibles en los datos. Por lo tanto, se necesita información previa adicional (por ejemplo, ecuaciones que rigen la física y las leyes de conservación, conocimientos específicos del dominio) para poder reducir las demandas de datos (Willard *et al.* 2020; Kashinath *et al.* 2021).

Sin embargo, lo realmente relevante de un gemelo digital es la explicabilidad (es decir, comprender los pasos desde la entrada hasta la salida) del mismo. La explicabilidad influye en la confianza en las predicciones, y el hecho de que estas herramientas puedan usarse de manera más amplia y cómo hacerlo, que permitan realizar ajustes y optimizaciones y que se promueva el aprendizaje de nueva ciencia (NAP 2023).

5 Conclusiones y perspectivas

Parece que nos encontramos en una encrucijada o punto de bifurcación en la evolución de los modelos de predicción numérica del tiempo y por extensión de los modelos climáticos, si bien estos últimos poseen unas características que hacen que los enfoques basados en datos contemplen otras soluciones distintas a las que se aplican en la predicción del tiempo. Se ha comprobado que los modelos predictivos basados en ML pueden

reducir drásticamente el coste computacional de una predicción una vez que el modelo ha sido convenientemente entrenado y evaluado. Este menor coste computacional de las predicciones deja la puerta abierta a la construcción de *ensembles* con muchos más miembros de los que actualmente se calculan permitiendo realizar una exploración más exhaustiva de las posibles evoluciones atmosféricas y su incertidumbre. No es descabellado pensar que se podría pasar de *ensembles* basados en decenas de miembros a *ensembles* basados en centenas o incluso millares de miembros. Además de cara a la distribución de las predicciones, y a la vista de los resultados obtenidos con técnicas de ML, se podría contemplar distribuir directamente unas condiciones iniciales generadas con sofisticados métodos de asimilación de datos a la vez que un modelo de predicción basado en ML de forma que el usuario calculase rápidamente sus propias predicciones para reducir sustancialmente el flujo de datos (Chancry *et al.* 2023).

Parece claro que la modelización convencional basada en las ecuaciones físicas que se ha venido desarrollando en los últimos 70 años va a experimentar grandes transformaciones en los próximos tiempos incorporando de distintas formas los avances experimentados por las técnicas basadas en ML. Los modelos basados en ecuaciones físicas han

sido el ingrediente clave para generar tanto condiciones iniciales para las predicciones numéricas operativas como para los reanálisis. Un tipo de modelos híbridos que se beneficien de las ventajas de ambos enfoques con modelos basados en ecuaciones físicas para verificar, entrenar y mejorar el sistema y modelos basados en datos para optimizar el cálculo de las predicciones e incrementar los recursos de la predicción por conjuntos podría conducirnos a un nuevo paradigma en la predicción numérica del tiempo que integrase lo mejor de ambos enfoques que ahora desde algunas instancias se presentan como contrapuestos.

Los principales centros operativos de predicción numérica del tiempo tienen un acceso inigualable a los datos del sistema Tierra y la experiencia en el desarrollo de modelos basados en leyes físicas. Los datos son el ingrediente esencial de cualquier modelo basado en ML por lo que se plantea ahora es el equilibrio óptimo entre modelización física y modelización ML para seguir mejorando los pronósticos. Además, ciertos enfoques y líneas de desarrollo, como por ejemplo la predicción unificada (*seamless*, en inglés) a lo largo de las diferentes escalas temporales, tendrán que ser repensados y reformulados cuando se integren los modelos basados en ecuaciones físicas y en datos en forma de modelos híbridos.

Referencias

- Bauer, P., Thorpe, A., Brunet, G., 2015. The quiet revolution of numerical weather prediction. *Nature*, 525(7567), 47-55. <https://doi.org/10.1038/nature14956>
- Bengtsson, L., and Shukla, J., 1988. Integration of Space and In Situ Observations to Study Global Climate Change. *Bull. Amer. Meteor. Soc.*, 69, 1130-1143, [https://doi.org/10.1175/1520-0477\(1988\)069<1130:IOSA IS>2.0.CO;2](https://doi.org/10.1175/1520-0477(1988)069<1130:IOSA IS>2.0.CO;2)
- Bjerknes, V., 1904. Das Problem der Wettervorhersage, betrachtet vom Standpunkte der Mechanik und der Physik. *Meteorologische Zeitschrift* 21 No.1 pp. 1-7.
- Borges, J.L., 1946. Del rigor de la ciencia. Cuentos completos, Editorial Debolsillo, 2023, 560 páginas, ISBN-10: 8499891624, ISBN-13: 978-8499891620
- Chantry, M., Ben Bouallegue, Z., Magnusson, L., Maier-Gerber, M., Dramsch, J., 2023. The rise of machine learning in weather forecasting. *ECMWF Science Blog*, <https://www.ecmwf.int/en/about/media-centre/science-blog/2023/rise-machine-learning-weather-forecasting>

<https://www.ecmwf.int/en/about/media-centre/science-blog/2023/rise-machine-learning-weather-forecasting>

- Charney, J.G., Fjörtoft, R. and Neumann, J.V., 1950. Numerical integration of the Barotropic vorticity equation. *Tellus*, 2(4), 237-254. <https://doi.org/10.1111/j.2153-3490.1950.tb00336.x>
- Düben, P., Modigliani, U., Geer, A., Siemen, S., Pappenberger, F., Bauer, P., Brown, A., Palkovic, M., Raoult, B., Wedi, N., Baousis, V., 2021. Machine learning at ECMWF: A roadmap for the next 10 years. *ECMWF Technical memorandum No. 878*, <https://doi.org/10.21957/ge7ckgm>
- Kashinath, K., Mustafa, M., Albert, A., Wu, J.L., Jiang, C., Esmailzadeh, S. *et al.*, 2021. Physics-informed machine learning: case studies for weather and climate modelling. *Philosophical Transactions of the Royal Society A*, 379(2194), 20200093, <https://doi.org/10.1098/rsta.2020.0093>
- NAP, 2023. Foundational Research Gaps and Future Directions for Digital Twins. *National Academies of Sciences, Engineering, and Medicine*, Washington, DC: The National Academies Press. <https://doi.org/10.17226/26894>

National Academies of Sciences, Engineering, and Medicine, Washington, DC: The National Academies Press. <https://doi.org/10.17226/26894>

- Richardson, L.F., 1922. *Weather Prediction by Numerical Process*. Cambridge Univ. Press. Second Edition 2007, ISBN: 978-0-521-68044-8.
- Saravanan, R., 2022. *The Climate Demon: Past, Present and Future of Climate Prediction*. Cambridge University Press. ISBN-10: 1009018043; ISBN-13: 978-1009018043; 398 páginas.
- Smagorinsky, J., 1983: The beginnings of numerical weather prediction and general circulation modeling: Early recollections. *Advances in Geophysics*, 25, 3-37, [https://doi.org/10.1016/S0065-2687\(08\)60170-3](https://doi.org/10.1016/S0065-2687(08)60170-3)
- Willard, J., Jia, X., Xu, S., Steinbach, M., and Kumar, V., 2020. Integrating physics-based modeling with machine learning: a survey. *arXiv:2003.04919*. <https://doi.org/10.1145/1122445.1122456>