

# *Fizyka Pogody i Klimatu, zima 2024*

## *Szymon Malinowski*

*Historia i praktyka numerycznej prognozy pogody,  
Prognozy klimatu.*

Na początku XX w.

**V.F.K. Bjerknes** i jego koledzy z tzw. norweskiej szkoły meteorologii, wykorzystując m.in. wyniki prac lorda Kelvina i polskiego fizyka L. Silbersteina w dziedzinie mechaniki płynów, zaproponowali i rozwinęli układ równań opisujący rozwój pól meteorologicznych w czasie.

Stosując prawa hydrodynamiki i termodynamiki do opisu przepływów atmosferycznych stworzyli podstawy nowoczesnej meteorologii dynamicznej.

Niestety ten skomplikowany układ równań różniczkowych cząstkowych, obejmujący równania ruchu, równanie ciągłości i równania termodynamiki, nie daje się prosto rozwiązać.



*V. Bjerknes*

$$\frac{d\mathbf{u}}{dt} + 2\boldsymbol{\Omega} \times \mathbf{u} = -\frac{1}{\rho} \nabla p - \nabla \Phi + F_u$$

$$c_p \frac{dT}{dt} - \alpha \omega = Q + F_T$$

$$\frac{d\rho}{dt} = -\rho \nabla \cdot \mathbf{u}$$

Ten układ równań:

zasada zachowania pędu, zasada zachowania energii oraz równanie ciągłości (czyli zasada zachowania masy,

uzupełniony równaniem konstytutywnym (np. równaniem gazu doskonałego dla powietrza) nosi nazwę „równań pierwotnych” (ang. „primitive equations”) i jest podstawą geofizycznej dynamiki płynów.

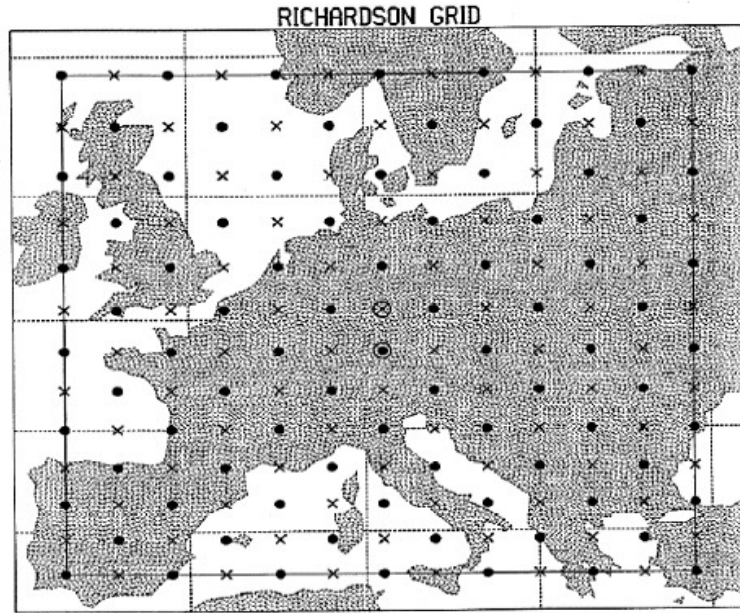


**Lewis Fry Richardson** służąc w wojsku jako sanitariusz polowy podczas I Wojny Światowej rozwiązał ten w sposób przybliżony, zastępując równania różniczkowe równaniami różnicowymi.

Obszar atmosfery nad Europą Zachodnią podzielił na jednakowe, regularne kostki i na podstawie danych pomiarowych z rozłożonych nierównomiernie stacji pomiarowych w każdej z nich wyznaczył przez interpolację danych początkowe wartości ciśnienia, temperatury, kierunku i prędkości wiatru.


Następnie obliczył krok po kroku przewidywane sześć godzin później wartości tych pól w każdym oczku siatki.





Wynik okazał się kompletnie niezgodny z wynikami obserwacji w chwili czasu odpowiadającej prognozie.

Wynik obliczeń nie mógł być dobry, ponieważ dokonując przybliżeń Richardson nie znał kilku warunków matematycznych, jakie powinny spełniać jego kostki i kroki obliczeniowe. Warunki te odkryto dopiero w latach 30. i 40. XX w.



$U, V$	$P$	$U, V$
$P$	$U, V$	$P$
$U, V$	$P$	$U, V$

Richardson popełnił też inny błąd, którego wtedy nie mógł uniknąć: nie przeprowadził asymilacji danych i miał problemy związane z aliasingiem.


Mimo niepowodzenia opublikował w 1922 r. wyniki pracy w rozprawie **“Weather Forecasting By Numerical Process”**.

Pozostaje ona wspaniałym przykładem świadczącym, że warto opublikować nawet negatywny wynik, jeśli został otrzymany w wyniku rzetelnej pracy naukowej.

Szukanie błędu w prognozie Richardsona doprowadziło do sprecyzowania podstawowych warunków analizy numerycznej i doprowadziło do rozwoju obliczeniowej mechaniki płynów.








Amerykański meteorolog **Jule Charney** podczas stażu naukowego na uniwersytecie w Oslo, siedzibie norweskiej szkoły meteorologii, zaproponował daleko idące uproszczenia układu równań przepływów atmosferycznych, które pozwoliły na sporządzenie pierwszej poprawnej matematycznie i numerycznie prognozy pogody. Charney wraz z amerykańskim matematykiem pochodzenia węgierskiego, Johnem **von Neumannem** przeprowadzili obliczenia pod koniec roku 1952 na słynnym komputerze EINAC. Było to też pierwsze poprawne numerycznie rozwiązanie zagadnienia obliczeniowej dynamiki płynów

# *Electronic Numerical Integrator And Computer*




**ENIAC zajmował pomieszczenie o rozmiarach  
10 na 15 metrów**




Pierwsze prognozy numeryczne nie były lepsze niż prognozy opracowywane przez doświadczonych meteorologów, były natomiast znacznie bardziej kosztowne. Tak więc do połowy lat 70. XX w. trwała rywalizacja pomiędzy metodami tradycyjnymi, wspomaganymi m.in. przez rozwijającą się meteorologię satelitarną i radarową, a metodami numerycznymi.

Numeryczne prognozy pogody stawały się coraz lepsze wraz ze wzrostem mocy obliczeniowej komputerów, powstawaniem nowych metod numerycznego rozwiązywania równań różniczkowych oraz coraz doskonalszych postaci układu równań dynamiki i termodynamiki, uwzględniających procesy radiacyjne w atmosferze, powstawanie chmur i opadów, a także oddziaływanie atmosfery z powierzchnią Ziemi.

**Prognozy numeryczne** (ang. **Numerical Weather Prediction, NWP**). Startując z warunku początkowego, uzyskanego na podstawie analizy stanu atmosfery, rozwiązuje się układ równań (model matematyczny) opisujących procesy dynamiczne i termodynamiczne w atmosferze (m.in. związane z oddziaływaniem promieniowania elektromagnetycznego na atmosferę, z ruchami mas powietrza oraz z cyklem hydrologicznym).



Skuteczność prognozy geopotencjału powierzchni 500 hPa w modelach globalnych.




Procesy fizyczne mające znaczenie dla prognozowania pogody. Nie wszystkie są jednoznacznie rozwiązane w obecnych modelach NWP, ale są one reprezentowane poprzez parametryzacje opisujące ich wkład do rozwiązywanych skal w kategoriach masy, pędu i przenoszenia ciepła.



## Zwyczajna numeryczna prognoza pogody „od kuchni”.

Pełny model numeryczny, za pomocą którego otrzymuje się numeryczną prognozę pogody, nazywany **numerycznym modelem prognostycznym**, składa się z trzech części (poziomów):

- zamkniętego układu równań opisujących zjawiska fizyczne w atmosferze (tworzącego matematyczny model meteorologiczny),
- algorytmów numerycznego rozwiązywania równań modelu matematycznego,
- kodu (programu komputerowego), który pozwala na uzyskanie rozwiązania na konkretnym superkomputerze czy maszynie obliczeniowej.




N24 octahedral Gaussian grid



Dane meteorologiczne potrzebne do rozwiązania uzyskuje się w wyniku procedury zwanej **asymilacją danych meteorologicznych**.

Przebiega ona w 2 etapach; pierwszy polega na kontroli i weryfikacji danych z pomiarów i obserwacji (odrzućenie danych obarczonych błędem pomiaru lub transmisji), drugi — na przyjęciu danych wyjściowych do modelu prognostycznego, a następnie na zasilaniu bieżącej już prognozy nowymi nadchodzącymi danymi.





Asymilacja danych do modelu.

Czerwona linia – rzeczywistość.

Zielone linie – kolejne prognozy w „wirtualnej rzeczywistości” modelu.


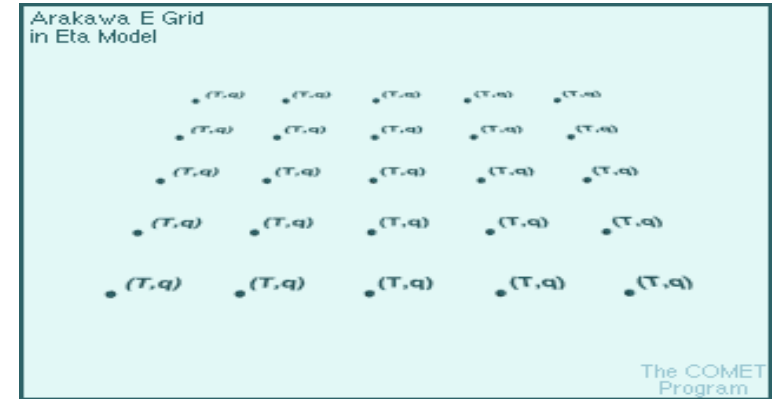
Niebieskie i czarne strzałki – wprowadzanie danych rzeczywistych do modelu i obliczenia kolejnej prognozy.



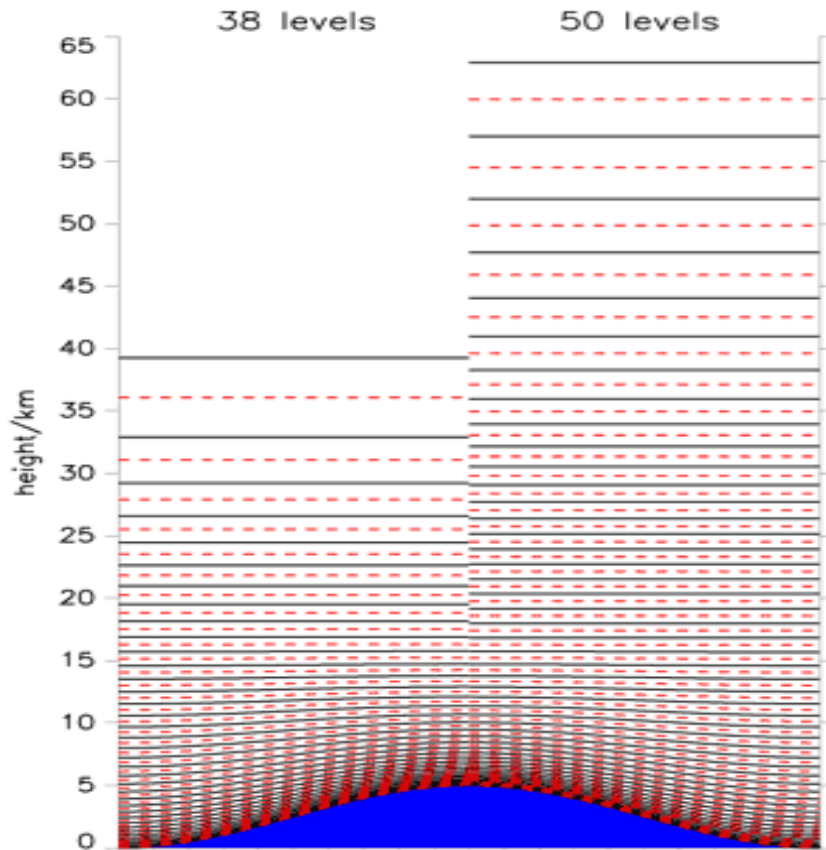
Po asymilacji danych pola parametrów fizycznych muszą być ze sobą zgodne, np. pola wiatru, ciśnienia, temperatury i wilgotności muszą spełniać zależności zakodowane w równaniach modelu.

Pola muszą też być powiązane z wirtualną postacią modelu prognostycznego, tj. tzw. siatką obliczeniową.


Wymiary oczka siatki w poziomie zależą od rodzaju modelu numerycznego i wynoszą od kilkudziesięciu kilometrów w przypadku **modelu globalnego** do kilku (kilkunastu) kilometrów w przypadku **modelu mezoskalowego**.

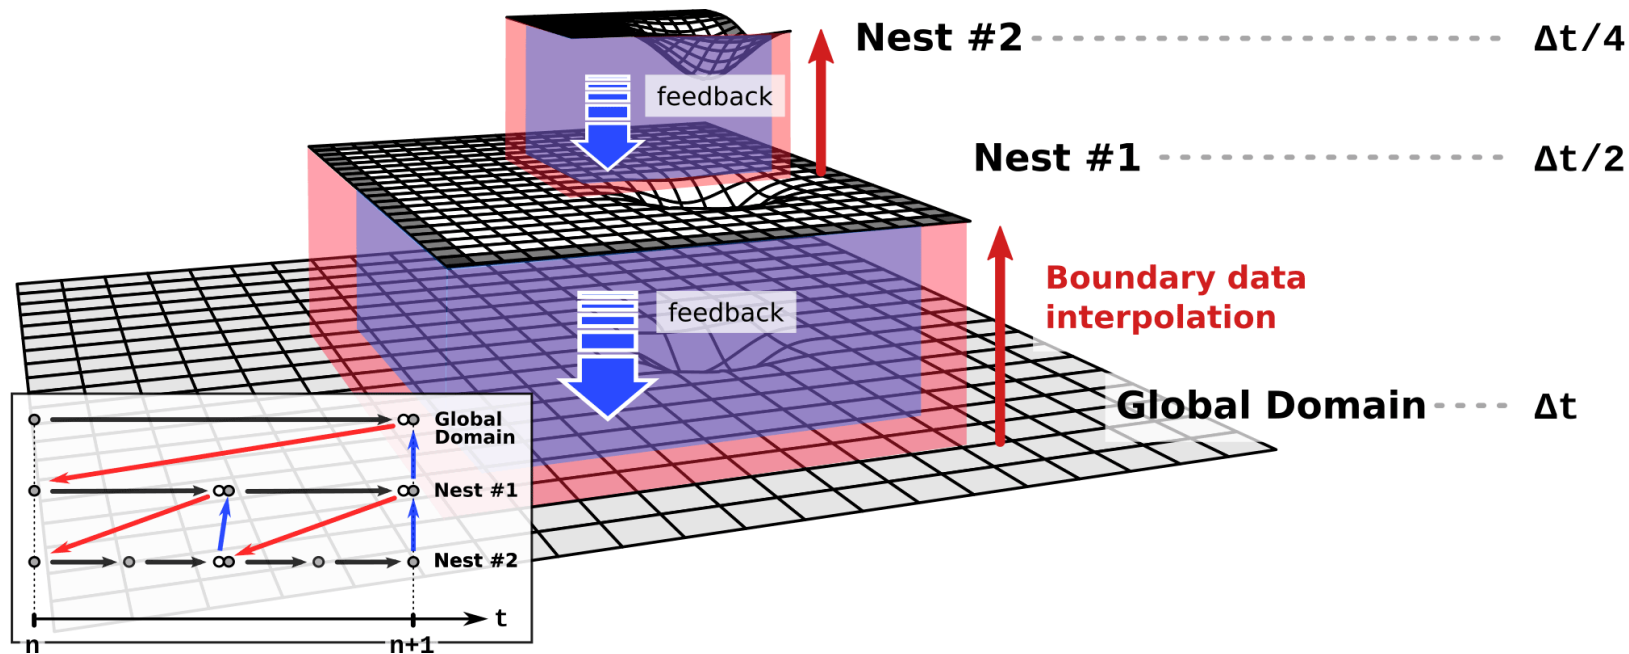


W pionie siatka obejmuje obszar troposfery i znaczną część stratosfery; ma kilkadziesiąt poziomów sięgających wys. 30–40 km, zagęszczonych w dolnych warstwach atmosfery.



**Operational  
model levels  
(91-level model)**






Zagnieżdżanie siatek obliczeniowych lub modeli pozwala, korzystając z wyników obliczeń w większej skali (warunki brzegowe) wykonać bardziej precyzyjne obliczenia na wybranych obszarach.



Pole chmur konwekcyjnych  
nad południową Polską.

Model EULAG na siatce 1km  
zagnieżdżony w siatce modelu  
numerycznego UMPL.

Piotrowski , Z.P., Smolarkiewicz P.K, **Malinowski  
S.P.** And Wyszogrodzki A.A., **2009**: On numerical  
realizability of thermal convection. *J. Comput.  
Phys.*, **228**,: 6268-6290;  
doi:10.1016/j.jcp.2009.05.023



Horyzontalne skale konwekcji: od 300 km (rozmiar kowadła) po 50-100 m - małe chmurki.

Pionowa skala – od 100m do 16km.

Oczka siatki modeli w poziomie: od kilkudziesięciu km – model globalny, do 1km - najlepsze modele mezoskalowe.

Oczka w pionie: od kilkunastu m w warstwie przyziemnej po kilkaset m w górnej troposferze i stratosferze.

Zdjęcie: NASA

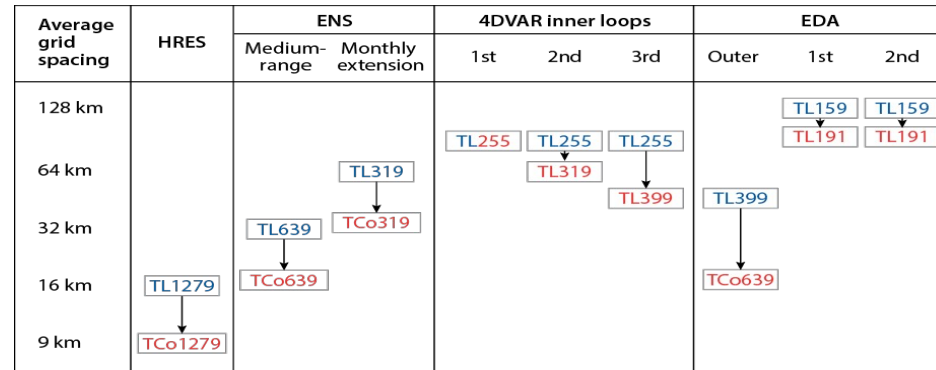


## Introduction – A history



- Resolution increases of the deterministic 10-day medium-range Integrated Forecast System (IFS) over ~25 years at ECMWF:

- 1987: T 106 (~125km)
- 1991: T 213 (~63km)
- 1998: T<sub>L</sub>319 (~63km)
- 2000: T<sub>L</sub>511 (~39km)
- 2006: T<sub>L</sub>799 (~25km)
- 2010: T<sub>L</sub>1279 (~16km)
- 2015?: T<sub>L</sub>2047 (~10km)



- 2020-???: (~1-10km) Non-hydrostatic, convection-permitting, different cloud-microphysics and turbulence parametrization, different dynamics-physics interaction ?

modele mezoskalowe muszą być o krok lub dwa z przodu... i są

---

Challenges for a New Generation  
of Regional Forecast Models

*Workshop on Concepts for Convective Parameterizations  
in Large-Scale Models III: Increasing Resolution and Parameterization;  
Warsaw, Poland, 17–19 March 2010*

Yano, Geleyn,  
Malinowski

Naukowcy wierzyli, że w modelach o siatce pozwalającej bezpośrednio rozwiązywać głęboką konwekcję będzie można pominąć jej parametryzację i bezpośrednio odtwarzać chmury Cb, struktury mezoskalowe, dobrze symulować opady konwekcyjne.

Jednak, jak pokazują dyskutowane na spotkaniu wyniki badań pokazują że gęsta siatka i „wyłączenie” dotychczasowych parametryzacji pociąga za sobą poważne a niedoceniane dotąd konsekwencje. **Modele generują albo biedne, silnie zlokalizowane obszary opadów konwekcyjnych, albo nie są w stanie wygenerować opadu nawet w warunkach silnej niestabilności.** Poprawa prognozy związana z zagęszczeniem siatki modelu jest nieznaczna.

**Możliwość odtworzenia rzeczywistych struktur konwekcyjnych ze wzrostem rozdzielczości siatki poprawia się bardzo powoli. Jeden z uczestników spotkania demonstrował wyniki pokazujące, że żeby dobrze odtworzyć strukturę prądów konwekcyjnych w wyidealizowanej potrzebna jest siatka modelu o rozdzielczości 50m.**



# Wnioski:

Nadzieja, że nowe modele numeryczne o zwiększonej rozdzielczości poprawia znacząco prognozę niebezpiecznych zjawisk konwekcyjnych nie zawsze potwierdza się.

Pomimo ogromnych postępów w modelowaniu, niekompletna znajomość podstawowych procesów fizycznych prowadzących do organizacji konwekcji oraz procesów wewnątrz chmur oraz trudności w rozdzieleniu procesów bezpośrednio rozwiązywanych na siatce modelu i tych które wymagają parametryzacji ograniczają wiarygodność wyników


Szczegółowa i dokładna (w przestrzeni) prognoza zjawisk konwekcyjnych jest na razie poza naszym zasięgiem.

W nowcastingu rola teledetekcji radarowej i satelitarnej na długo pozostanie kluczowa.

Jak widać, mimo ogromnego postępu w nauce i technice prognozy numeryczne nie są doskonałe; można też udowodnić, że nie byłyby doskonałe nawet w przypadku znalezienia idealnego układu równań, opisujących procesy w atmosferze, i rozwiązania go niezwykle dokładnie.

Odkrycia tego dokonał w 1963 r. amerykański meteorolog Edward N. Lorenz.




To odkrycie pozwala ulepszać prognozy w inny sposób niż przez coraz dokładniejsze przybliżenia i drobniejsze siatki.






Równanie Naviera–Stokesa, które jest podstawowym równaniem dynamiki atmosfery, jest nieliniowe, co oznacza, że jego rozwiązanie (wynik obliczeń) jest najczęściej niezwykle wrażliwe na niewielkie zmiany warunku początkowego, od którego rozpoczyna się obliczenia.

Cechę tę ma też cały układ równań opisujący przepływy atmosferyczne. Innymi słowy wynik ekstrapolacji w czasie (prognoza pogody) jest bardzo czuły na dokładność, z jaką określamy początkowy stan atmosfery.

Niewielka przyczyna: fluktuacja temperatury czy wiatru, może po krótkim czasie wywołać ogromny skutek. To są najistotniejsze wnioski z odkrycia Lorenza, które sam autor na jednym z odczytów opisał poetycko: trzepot skrzydeł motyla w amazońskiej puszczy może wywołać huragan na Atlantyku.




Odkrycie Lorenza  
można zilustrować w  
języku teorii  
prawdopodobieństwa,  
ściślej mówiąc  
analizując tzw. rozkład  
prawdopodobieństwa.






Wiązka prognoz pogody : równoległe prognozy pogody startujące z nieznacznie (w granicach błędu pomiaru) różnych warunków początkowych





wiązka prognoz – niebieskie;  
prognoza deterministyczna – zielona;  
rzeczywista ewolucja atmosfery – czerwona;  
niepewność warunku początkowego - kółko.




Schemat cyklu analizy i prognozy.

Poprzez minimalizację w czterech wymiarach z wykorzystaniem technik wariacyjnych, tworzone są lepsze oszacowania (trajektorie 4D-Var) są tworzone przy zmniejszonej odległości do obserwacji. Następny następny cykl prognoz ensemble jest inicjowany na podstawie tych udoskonalonych analiz.

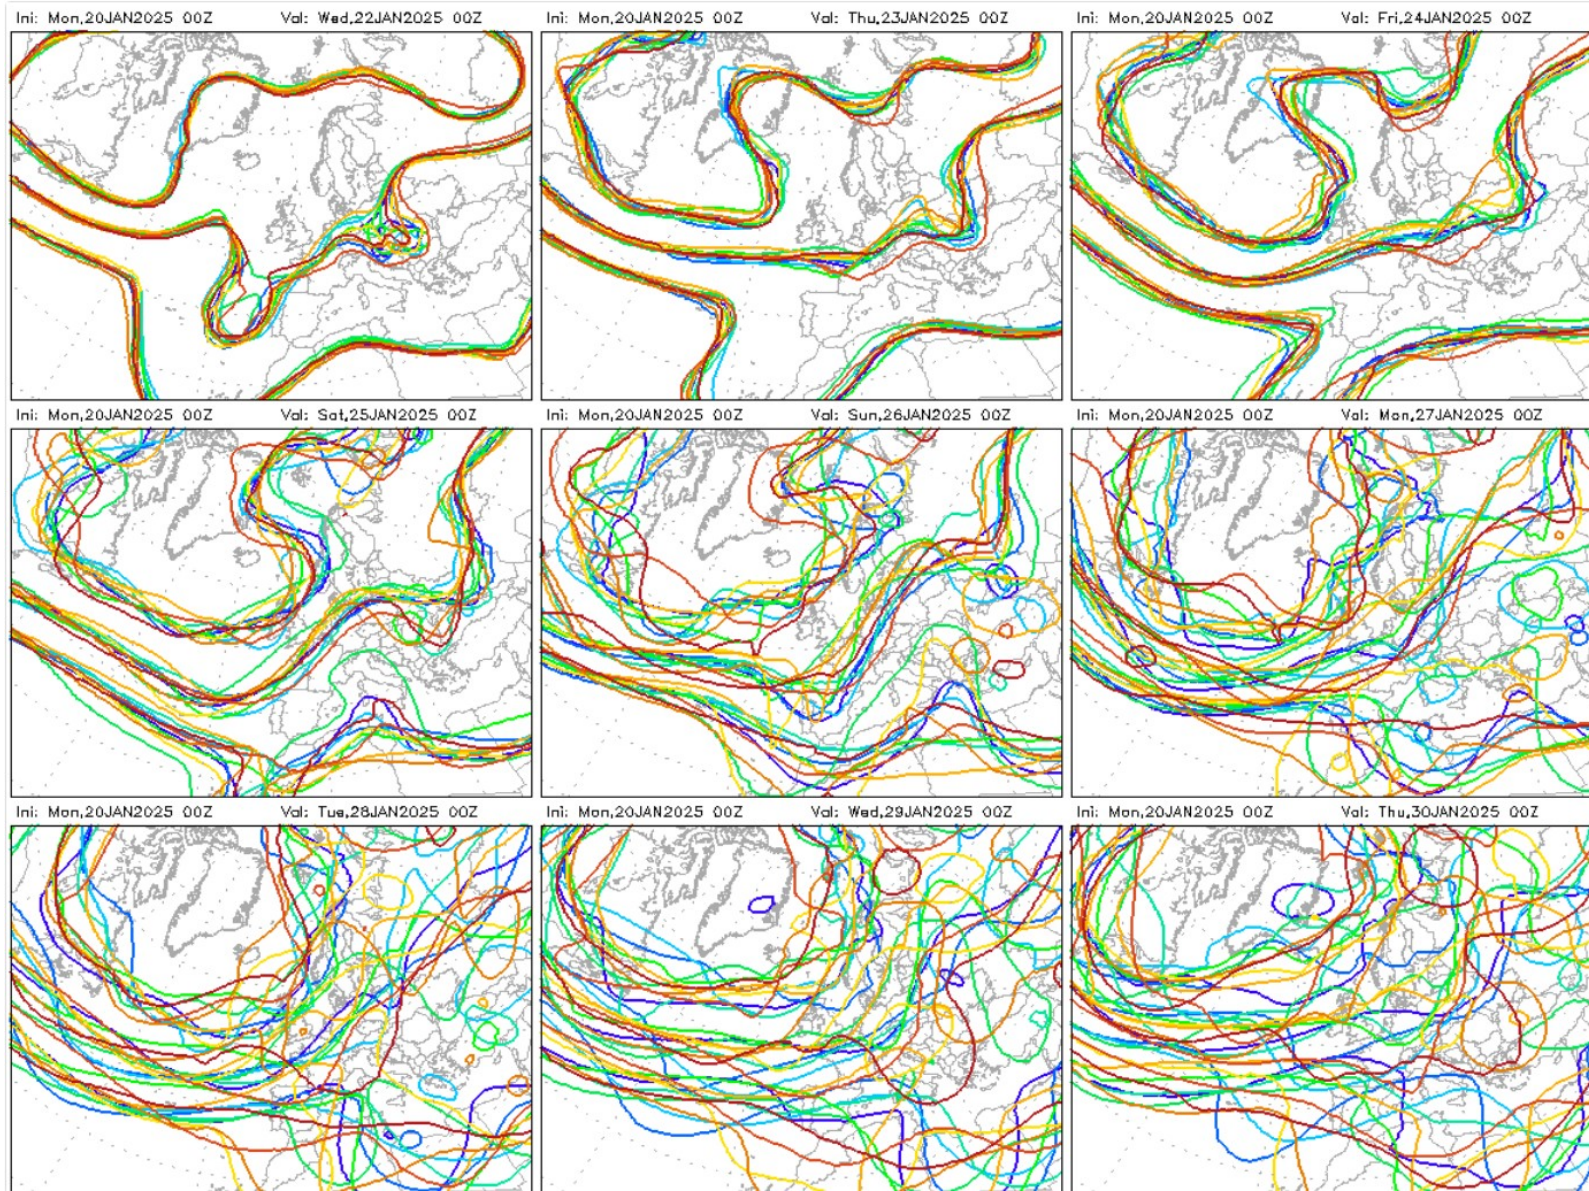


W praktyce np. prognoza temperatury na wys. 850 hPa może wyglądać tak:






A prognoza ciśnienia w atmosferze swobodnej może wyglądać tak:






Inne możliwe podejście:

- „targeted observations” -  
dodatkowe pomiary w  
obszarach niepewności  
(tam gdzie „rozbiegają  
się” prognozy),  
stosowane  
eksperymentalnie np. przy  
huraganach.




+108 HOURS  
MRF FORECAST

ENSEMBLE SPREAD



MRF FORECAST


+24 HOURS



SENSITIVITY MAP



# ECMWF forecasting system








# DeepMind AI accurately forecasts weather – on a desktop computer

The machine-learning model takes less than a minute to predict future weather worldwide more precisely than other approaches.

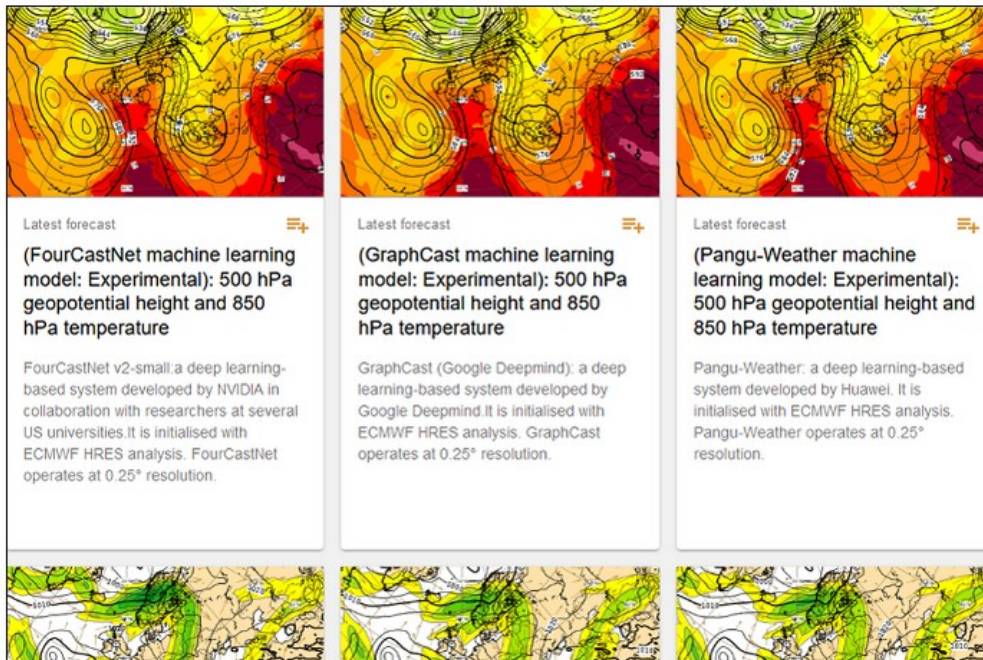

By [Carissa Wong](#)



Conventional weather forecasts are the result of intensive processing of data from weather stations around the world. Credit: Carlos Munoz Yague/Look At Science/Science Photo Library

## How AI models are transforming weather forecasting: a showcase of data-driven systems

6 September 2023



Developments in machine learning are continuing at breathtaking pace, both inside and outside of weather forecasting. To help assess machine learning weather forecasts from different sources, we now show a range of them in [ECMWF's charts catalogue](#).

We are also exploring the use of machine learning models to produce [ensemble forecasts](#), which present the range of future weather possibilities.

Edward N. Lorenz (1917-2008) pokazał co to znaczy przewidywalność (ang. predictability) układu fizycznego.

„Deterministic nonperiodic flow”, 1963 (atraktor Lorenza, efekt motyla)

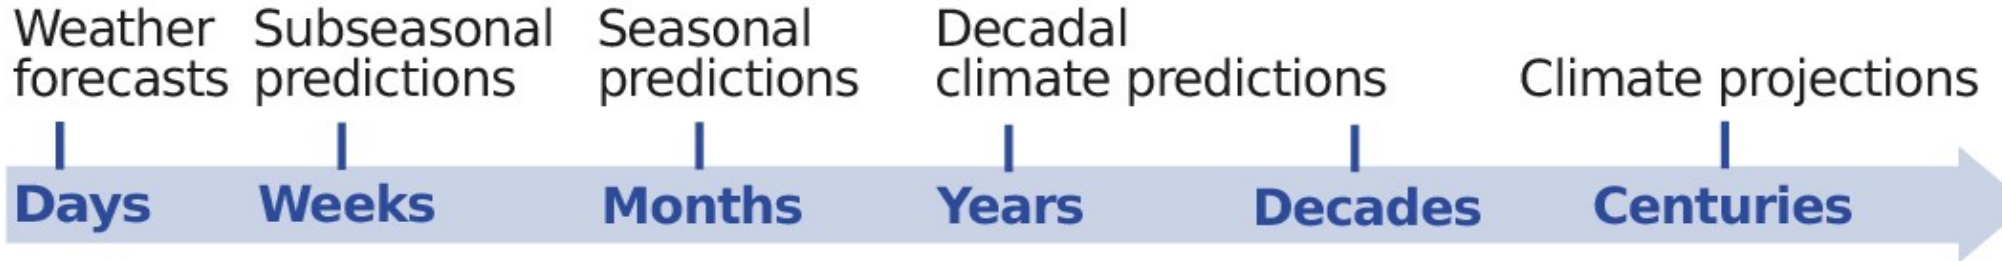
„The problem of deducing the climate from the governing equations”, 1964 (rozdzielenie między brakiem przewidywalności ze względu na nieznaną wartość stanu początkowego układu i ze względu na niepełną znajomość fizyki – równań – układu)

„Climatic change as a mathematical problem”, 1970 (nieprzewidywalność pogody -chaos- nie znaczy że klimat jest nieprzewidywalny)

„Predictability – a problem partly solved”, 2006 (bez komentarza :)

**Boundary  
value problem**

**Initial value problem**



szczegóły przepływów  
procesy „szybkie”

- bilans energii  
- procesy „wolne”

oddziaływania między procesami lokalnymi i szybkimi  
a globalnymi i wolnymi

Prognoza pogody:

prognoza pojedynczej realizacji procesu dynamiczno-stochastycznego, lub prognoza empirycznego rozkładu prawdopodobieństwa różnych realizacji.


Prognoza klimatu:

prognoza pewnych quasi-równowagowych statystyk realizacji procesów dynamiczno-stochastycznych przy ustalonych wymuszeniach zewnętrznych w stosunku do systemu klimatycznego.



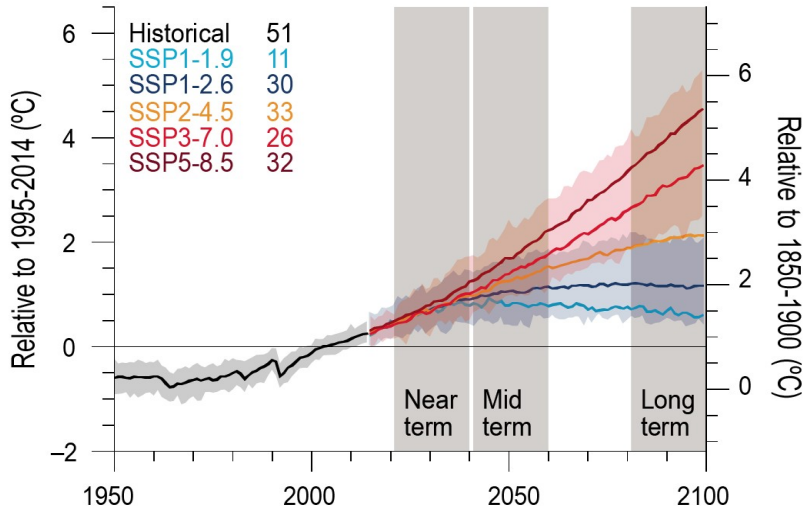
## Ewaluacja modeli klimatu.

Wiązka symulacji przebiegu anomalii temperatury globalnej w XX wieku.




**Figure 1.** The CMIP6 global annual 2m temperature anomaly with respect to the 50-year mean 1850-1900. The EC-Earth ensemble members are presented alongside the CMIP6 mean to assess where the EC-Earth simulations fit within the full CMIP6 ensemble.


(a) Global temperature change




(b) Global land precipitation change



(c) September Arctic sea ice area



(d) Global mean sea level change



Wielomodelowe wiązki projekcji klimatu – niepewność odpowiedzi na warunki graniczne

Prognoza pogody:

zależność od warunku początkowego, krytycznie ważna  
możliwość śledzenia rozwoju pojedynczych niestabilności  
w systemie, krytycznie ważne szczegóły dynamiki.

Prognoza klimatu:

badanie statystyki zachowań układu, krytycznie ważne  
strumienie energii i spełnienie zasad zachowania w  
długim czasie (warunki brzegowe).





NextGEMS to projekt finansowany przez program Horyzont 2020 UE.

Współpracują w nim zespoły z 14 państw europejskich w celu utworzenia kolejnej generacji modeli klimatu o rozdzielczości pozwalającej na reprezentację zespołów konwekcyjnych i chmur burzowych.

Modele nextGEMS będą pozwolą na realistycznie modelowanie systemu klimatycznego na najbliższe 30 lat, co pozwoli oszacować ekstremalne zjawiska meteorologiczne czy szczegóły takich ważnych procesów jak obieg węgla, emisje i przemiany aerozoli, zmiany własności chmur.



Boundary  
value problem

Initial value problem

Weather  
forecasts

Subseasonal  
predictions

Seasonal  
predictions

Decadal  
climate predictions

Climate projections

|  
**Days**

|  
**Weeks**

|  
**Months**

|  
**Years**

|  
**Decades**


|  
**Centuries**



next  
**GEMS**

# Jakie problemy napotyka modelowanie prognozy pogody i klimatu?

Najważniejszy to wielkoskalowość przepływów w atmosferze i oceanie i konieczność parametryzacji procesów podskalowych (o rozmiarach mniejszych niż oczko siatki i zachodzących szybciej niż krok czasowy obliczeń)







Jak sobie radzimy z problemami?

„Multiscale modeling” - modelowanie wieloskalowe, superparametryzacje, GIGA-LES, ILES, w przypadku NextGEMS jest to wielka rozdzielczość pozwalająca na bezpośrednie modelowanie dużych chmur.

Ale... jest jeszcze wiele skal, których nie ma bezpośrednio w modelu.

W IGF UW zajmujemy się tym jak uwzględnić najlepiej procesy zachodzące w małych skalach:

- aerozole i kropelki chmurowe (grupa prof. Hanny Pawłowskiej);
- turbulencję, czyli atmosferyczne przepływy w małej skali (grupa prof. Malinowskiego).

<https://doi.org/10.5194/gmd-17-759-2024>

© Author(s) 2024. This work is distributed under the Creative Commons Attribution 4.0 License.

Article

Assets

Peer review


Metrics

Related articles

Model evaluation paper | 

30 Jan 2024


# Modeling collision–coalescence in particle microphysics: numerical convergence of mean and variance of precipitation in cloud simulations using the University of Warsaw Lagrangian Cloud Model (UWLCM) 2.1



Piotr Zmijewski, Piotr Dziekan , and Hanna Pawlowska



Journal of the  
Atmospheric Sciences

 Volume 79: Issue 10

Sections

References

Editorial Type: Article

Article Type: Research Article

## Detecting Nonequilibrium States in Atmospheric Turbulence

Marta Waclawczyk , Jakub L. Nowak, Holger Siebert, and Szymon P. Malinowski

Online Publication: 10 Oct 2022

Print Publication: 01 Oct 2022

DOI: <https://doi.org/10.1175/JAS-D-22-0028.1>

Page(s): 2757–2772

Kilka spektakularnych symulacji:

<https://www.youtube.com/watch?v=N0qY-ShqKOY>

<https://www.youtube.com/watch?v=EzqjAFJYmgY>

[https://www.youtube.com/watch?v=-l\\_N8nT9Bnc](https://www.youtube.com/watch?v=-l_N8nT9Bnc)

[https://www.youtube.com/watch?v=PNkD0YmEp\\_Y](https://www.youtube.com/watch?v=PNkD0YmEp_Y)

Projekt:

<https://nextgems-h2020.eu/>



# Who we are

nextGEMS is a Horizon 2020 project funded by the European Commission. It is coordinated by Bjorn Stevens at the Max Planck Institute for Meteorology and Irina Sandu at the ECMWF. The nextGEMS consortium is made up of 26 institutes:

Max Planck Institute for Meteorology (MPI-M), Germany

European Centre for Medium-Range Weather Forecasts (ECMWF)

Alfred-Wegener-Institut (AWI), Germany

University of Bergen (UiB), Norway

University of Copenhagen (UCPH), Denmark

French National Centre for Scientific Research (CNRS), France

Stockholm University (SU), Sweden

University of Warsaw (UW), Poland

University of Oxford (UOXF), UK

Helmholtz Centre for Ocean Research Kiel (GEOMAR), Germany

Barcelona Supercomputing Center (BSC), Spain

University of Reading (UREAD), UK

Wageningen University (WU), The Netherlands

Eidgenössische Technische Hochschule Zürich (ETHZ), Switzerland

Universität Bern (UBERN), Switzerland

Instituto Português do Mar e da Atmosfera IP (IPMA), Portugal

University of Helsinki (UH), Finland

University of Trento (UNITN), Italy

Deutsches Klimarechenzentrum GmbH (DKRZ), Germany

Universidad Complutense de Madrid (UCM), Spain

French National Institute for Sustainable Development (IRD), France

Iberdrola Renovables Energía S.A.U. (IBE), Spain

Institut Sénégalais de Recherches Agricoles (ISRA), Senegal

Latest Thinking GmbH (LT), Germany

Karlsruhe Institute of Technology (KIT), Germany

University of Hamburg (UHH), Germany



nextGEMS is funded through the European Union's Horizon 2020 research and innovation program under the grant agreement number 101003470.


[Contact](#)

[Imprint](#)


[Privacy](#)



MTG-I1 FCI



ECMWF IFS 2.8-km forecast



Pierwszy oficjalny obraz w świetle widzialnym z satelity MTG-FCI z EUMETSAT (po lewej) i 12-godzinna symulacja przy użyciu Zintegrowanego Systemu Prognozowania (IFS) ECMWF w rozdzielczości 2,8 km (po prawej), ważna na dzień 18 marca 2023 r. o godzinie 12:00 UTC. Źródło: EUMETSAT/ECMWF