




Fizyka Pogody i Klimatu, zima 2025

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

$$\begin{aligned}\frac{d\mathbf{u}}{dt} + 2\boldsymbol{\Omega} \times \mathbf{u} &= -\frac{1}{\rho}\nabla p - \nabla\Phi + F_u \\ c_p \frac{dT}{dt} - \alpha\omega &= Q + F_T \\ \frac{d\rho}{dt} &= -\rho\nabla \cdot \mathbf{u}\end{aligned}$$

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.

$$\begin{array}{c}
 R_1 U_1 V_1 T_1 \\
 \hline
 -z_1 \quad R_2 U_2 V_2 \quad p_1 w_1 \\
 \hline
 -z_2 \quad R_3 U_3 V_3 \quad p_2 w_2 \\
 \hline
 -z_3 \quad R_4 U_4 V_4 \quad p_3 w_3 \\
 \hline
 -z_4 \quad R_5 U_5 V_5 \quad p_4 w_4 \\
 \hline
 z_1 \quad p_5 w_5
 \end{array}$$

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 ENIAC. Było to też pierwsze poprawne numeryczne 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, wspomagany 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 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.



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




Rozwój globalnych modeli numerycznych – Peter Bechtold, ECMWF:

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_L319 (~63km)
- 2000: T_L511 (~39km)
- 2006: T_L799 (~25km)
- 2010: T_L1279 (~16km)
- 2015?: T_L2047 (~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





SENSITIVITY MAP

MRF FORECAST

+24 HOURS


ECMWF forecasting system





Porównaj prognozy


Manner-Suomi



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 nieznajomość 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




**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



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=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 Björn 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 (UBER), 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