



MESTERSÉGES INTELLIGENCIA ALKALMAZÁSA A KÖZÉPTÁVÚ IDŐJÁRÁS-ELŐREJELZÉSEK BEN

Gál Ferenc Máté ^(1,2), Soósné Dezső Zsuzsanna ⁽¹⁾ , Pongrácz Rita ⁽¹⁾ 

⁽¹⁾ ELTE Eötvös Loránd Tudományegyetem, Földrajz- és Földtudományi Intézet,
Meteorológiai Tanszék, 1117 Budapest, Pázmány Péter sétány 1/A

⁽²⁾ MH Kiss József 86. Helikopter dandár, 5008 Szolnok, Kilián út 1.

e-mail: galferencmate@gmail.com, zsuzsanna.dezso@ttk.elte.hu, prita@nimbus.elte.hu

Bevezetés

Doktori kutatásom keretében az időjárás-előrejelzési modellek legújabb generációjával foglalkozom, ezen belül is hangsúlyozottan azt tervezem vizsgálni, hogy ezek a modellek milyen pontossággal írják le a mediterrán ciklonokat. A fókusz elsősorban az indokolja, hogy a mediterrán ciklonok előrejelzése gyakran bizonytalan. A bizonytalanságot az adja, hogy jelenleg nem lehet tökéletesen modellezni a légköri mozgásokat, illetve a Mediterráneum komplex orográfiája is befolyással bír a ciklonpályákra és a csapadék eloszlására. Így különösen fontos a modellek esetleges hiányainak feltérképezése, s ezzel a fejlesztendő funkciók azonosítása annak érdekében, hogy a régió időjárásának változékonysága is kellő mértékben legyen reprezentálva.

A modellfejlesztések üteme a 2020-as években felgyorsult. Így az AI (Artificial Intelligence/mesterséges intelligencia) már nem csak a nyelvi modellek szintjén jelent meg, hanem a meteorológia tudományában is. Több ilyen AI-alapú időjárás-előrejelző modell már operatív használatban van, miközben folyamatos fejlesztések alatt állnak a minél pontosabb prognózisok érdekében. Az általam vizsgált AI-alapú modelleken túl, több kutatási, illetve fejlesztési fázis alatt álló előrejelzési modell is van, mint például az AURA, FourCastNet, valamint a Pangu-Weather (Bi et al., 2023; Kurth et al., 2023; Bodnar et al., 2025).

A modellek általános bemutatása

A numerikus időjárás-előrejelző (NWP) modelleknek az utóbbi években jelentősen javult a pontossága és a beválása az adatasszimiláció, valamint az informatika fejlődésével. A hagyományos fizikai alapú modellek kimeneti paramétereit jelenleg csak nagy teljesítményű szuperszámítógépek képesek megadni (Gentine et al., 2018). A pontosság növekedését elsősorban az adatasszimilációs módszerek fejlődésével, különösen a négydimenziós variációs (4D-Var) módszer bevezetésével érték el. Tehát a kezdeti feltételek értékeinek pontosabbá válásával az előrejelzések megbízhatóbbakká váltak (Rabier et al., 2000).

A 4D-Var egy négydimenziós adatasszimilációs módszer, melynek lényege, hogy képes optimálisan integrálni a térben és időben rendkívül eltérő műholdas, repülőgépes és felszíni állomási méréseket egy asszimilációs ablakba (Rabier et al., 2000; Bonavita & Laloyaux, 2020).

Ezzel párhuzamosan az előrejelzések fejlesztésének egy teljesen új iránya is megjelent (Reichstein et al., 2019). Az adatasszimilációs módszerek fejlődése mellett nagy hangsúlyt kaptak a gépi tanuláson alapuló (ML vagy AI) modellek. Ezeknek a modelleknek az alapja az, hogy hatalmas mennyiségű múltbeli meteorológiai adatot dolgoznak fel, ennek segítségével próbálják megtanulni a légkör statisztikai változásait és a folyamatok összefüggéseit (Keisler, 2022; Kurth et al., 2023).

Az időjárás-előrejelző modelleknek köszönhetően képesek vagyunk a légkör komplex dinamikáját szimulálni, így sokkal pontosabban lehet előrejelezni az időjárás

változékonyságát, és akár a veszélyes jelenségeket is (pl. alacsony felhőalap, turbulencia, jegesedés, stb.). Az éghajlatváltozás hatására gyakoribbá válnak a szélsőséges időjárási események (medikánok, extrém hőhullámok). Így a meteorológusok munkáját segítő szükségesszerűvé vált, hogy az időjárás-előrejelzési modellek eredményei gyorsabban és költséghatékonyabban készüljenek el. Ezt például az AI-alapú modellek fejlesztésével érhetjük el. Ugyanakkor fontos leszögezni, hogy az AI-alapú modellekkel nem az a cél, hogy kiváltsuk a hagyományos fizikai alapú modelleket és a meteorológusokat, hanem egy újfajta megközelítéssel, egy plusz lehetőségként segítsék a meteorológusok operatív munkáját. Mivel ezek az AI-alapú modellek a múltbeli adatok feldolgozásával tanulnak, futtatásuk sokkal gyorsabb, továbbá sokkal gyorsabban képesek a tanult mintázatból korrekciót végezni az előrejelzéseken. Mindez különösen a középtávú előrejelzésekben figyelhető meg (Keisler, 2022; Lang et al., 2024a). Ez az integráció a közeljövőben egyre fontosabbá válik a globális időjárás-előrejelző rendszerekben, mint például az ECMWF-nél (European Centre for Medium-Range Weather Forecasts) vagy a Google DeepMind kutatásaiban (Lang et al., 2024a).

A doktori kutatásom konkrét célja mediterrán ciklonok detektálása a megfigyelési/reanalízis adatbázisokban. A detektálást a pályák követése egészíti ki, majd a ciklonokhoz tartozó csapadékmezők azonosítása. Verifikálásra kerül 3 előrejelzési modell (ECMWF AIFS, Google DeepMind GraphCast és ECMWF IFS) a felépített adatbázissal a ciklonpályák és a csapadékmezők alapján. A vizsgálat tárgyát az képezi, hogy rövidebb, illetve középtávon melyik modell teljesíti a legjobban a vizsgált paraméterek alapján. A csapadékmező vizsgálata különösen fontos, mivel egyre gyakrabban fordulnak elő súlyos aszályok Dél-Európában és hazánk régiójában is, ahol a mediterrán ciklonok okozzák az éves csapadék többségét. Így az esetleges károk mérséklése érdekében fontossá válik a tartósan csapadékmentes időszakok mielőbbi előrejelzése.

Az ECMWF IFS modell

Az ECMWF IFS (Integrated Forecasting System) modellje a globális numerikus előrejelzések egyik legfejlettebb verziója. A légköri folyamatokat fizikai és dinamikai szabályok alapján modellezi. Az 1980-as évektől kezdődően az IFS modell folyamatos fejlesztés alatt áll, így ma már az egyik legmegbízhatóbb középtávú előrejelzési modell. Az IFS egy spektrális dinamikai magra épülő globális modell, mely a Navier-Stokes egyenletekkel közelíti a légkör fizikai változásait, valamint az óceán-légkör kölcsönhatásokat (Gentine et al., 2018) [1 – ECMWF].

A modell rendkívüli nagy pontosságát az adatasszimilációs rendszerének köszönheti (4D-Var), mely jelenleg a legfejlettebb adatasszimilációs módszer. Az operatív futtatásokban a modell 9 km körüli felbontással rendelkezik, így lehetővé teszi a szinoptikus, valamint a mezoskálájú folyamatok megfelelő szimulációját. Vertikálisan több mint 130 különböző szintet különböztethetünk meg, így a modell képes a teljes troposzférát és a felsőlégkört leíró folyamatokat is figyelembe venni [1 – ECMWF].

Az IFS egyik legnagyobb előnye, hogy rendelkezik ensemble (ENS) futásokkal. Ez jelenleg 51 tagból áll, melyből 1 a kontroll futás és 50 a perturbált futás. Így biztosítja a felhasználók számára a modell bizonytalanságának reprezentálását. Több extrém esemény korrekt előrejelzését is biztosítja az ENS, mint például a mediterrán ciklonokét, a trópusi ciklonokét és a hőhullámokét (Leutbechner & Palmer, 2008).

A modell pontosságát az is mutatja, hogy a verifikációs eredmények szerint a 2010-es évek közepéig, a 7 napos előrejelzések pontossága megközelíti a 20 évvel azelőtti 5 napos előrejelzések szintjét. Az eltelt egy évtized alatt a modellek fejlődése lelassult, így jelenlegi állapotában a 7 napos előrejelzések pontossága 80% körül van (Gentine et al., 2018). Emiatt

az IFS etalonnak számít a globális NWP modellek között is, amikhez gyakran viszonyítják a regionális modelleket is.

Mint minden modell, az IFS is folyamatos fejlesztés alatt áll, melynek két fő iránya van. Az egyik a numerikus modell parametrizációinak finomítása (ezek főképpen a felhőfizikai, a sugárzási, valamint a határreteg folyamatokat érintik); a másik a gépi tanulási módszerek integrálása, melyeknek a segítségével gyorsabban és költséghatékonyabban készülhetnek az előrejelzések. Ez azt jelenti, hogy a jövőben az IFS nem önálló modellként fog működni, hanem helyette egy hibrid megközelítést fog alkalmazni a globális folyamatok leírására. Így a nagytérségi áramlási mintázatok felismerésében a modell inkább az AIFS-re fog hagyatkozni, míg a kistérségű, finom skálájú folyamatok leírásához az IFS modellt lehet majd felhasználni. Így mindkét modell az erősségeik alapján kerülhet felhasználásra (Bonavita & Laloyaux, 2020).

Az ECMWF AIFS modell

2024-ben publikálták az ECMWF Artificial Intelligence/Integrated Forecasting System (AIFS) előrejelzési modellt, amely az első olyan hibrid modell a világon, ami az AI-alapú és fizikai alapú NWP rendszerek kombinációjából áll (Lang et al., 2024a). Az AIFS modellt az ún. Meteorology Meets AI (MetAI) projekt keretében fejlesztették ki, amiben felhasználásra kerültek a GraphCast és a FourCastNet architektúrára épülő neurális hálózatok (Kurth et al., 2023; Lam et al., 2023). Az AIFS neurális hálózati komponenseinek tanítását az ERA5 reanalízis adatbázison végezték el, amely biztosítja a globálisan konzisztens, hosszú idősoros adatkészletet. Jelenleg ez a modell csak 25 km-es horizontális, valamint 1 km-es vertikális felbontással rendelkezik, azonban több nagyságrenddel gyorsabban fut le, mint az IFS. Az AIFS-ben a gépi tanulási komponens (ML) az IFS kimenetére van finomhangolva, így biztosítják a fizikai törvények betartását és az operatív előrejelzésekhez szükséges operatív stabilitást (Lang et al., 2024a).

A legelső verifikációs vizsgálatok során meglepő módon kiderült, hogy az AIFS 10 napos előrejelzési intervalluma közelítette az IFS pontosságát, különös tekintettel a trópusi ciklonok pályáinak előrejelzésére (Lang et al., 2024b). Az AIFS fő előnye az IFS-sel szemben a gyorsaság, mivel az AIFS percek alatt képes lefutni, csökkentve ezzel az energiaigényt; ezzel szemben az IFS modell futási ideje több ezer processzoron akár több órán keresztül is eltarthat (Lang et al., 2024a).

A modell fejlesztése során fontos hangsúlyt helyeztek arra, hogy ne csak rövid távon teljesítsen jól, hanem középtávon is stabil eredményt tudjon felmutatni, és hogy ne halmozódjanak fel a neurális hálózatokból származó hibák. Ezt úgy oldották meg, hogy az AI kimeneteit folyamatosan összevetik a fizikai modellek által szimulált mezőkkel, így biztosítható a fizikai megmaradási törvények érvényesülése, amely kulcsfontosságú a meteorológiai alkalmazások megbízhatóságában.

Az AIFS egy másik előnye, hogy az ensemble tagokat sokkal nagyobb gyakorisággal képes futtatni. Az ensemble előrejelzések lényege, hogy a modellt több szálon futtatják, apró eltéréseket eszközölve a kezdeti értékekben, esetleg modell perturbációt hajtanak végre, így ez nem csupán egyetlen, „legvalószínűbb” futást ad eredményül, hanem a bizonytalanságot is számszerűsíti. Az ensemble futások a bizonytalanság érzékeltetése mellett lehetőséget nyújtanak a valószínűségi előrejelzések készítésére is. Az IFS (ENS) futásai hatalmas számítási energiát igényelnek, ezért csak korlátozott számban állnak rendelkezésre. Az AIFS rövid futtatási ideje lehetővé teszi azt, hogy több ensemble tag kerüljön kiszámításra. Jelenleg az AIFS ENS 51 tagból áll, 6 órás felbontásban, 15 napos időtávon (Lang et al., 2024a).

Fontos megemlíteni, hogy a modell betanítása az ERA5 reanalízis adatbázisra épült. Ennek az adatbázisnak a térbeli és időbeli felbontásából adódóan bizonyos, finomabb skálájú

jelenségek, mint például a mélykonvekció, vagy lokális szélrendszerek, alulreprezentáltak. Emiatt az AIFS is jellemzően alulbecsüli ezeket.

Az AIFS már elérhető 2025 tavaszától operatív felhasználásra, így lehetőség nyílt az IFS modellel való összevetésre. A jövőbeli alkalmazáshoz még további fejlesztésekre és részletes elemzésekre van szükség (ECMWF Strategy, 2021; Lang et al., 2024a). A fő cél az extrém időjárási jelenségek, például hőhullámok, zivatarrendszerek, vagy más hasonlóan ritka események megjelenéseinek minél gyorsabb és időben történő detektálása. Ebből kifolyólag a neurális hálózatoknak olyan mintázatokat kell kezelniük, melyek a múltban kevésbé, vagy csak gyengébb verzióban vannak jelen a tanító adatbázisban.

A Google DeepMind GraphCast modell

A Google DeepMind fejlesztette ki a GraphCast modellt, ami 2023 novemberében került publikálásra. Alapja egy grafikus neurális hálózati architektúra, mely ikozahedrális ráccsal közelíti a felszínt és a légkört. Ezzel a rácsközelítéssel lehet legjobban kiküszöbölni a pólusok torzulását a szimulációban, illetve ez biztosítja a felszín egyenletes felbontását (Lam et al., 2023).

A GraphCast globális előrejelzéseket biztosít 6 órás időlépcsővel, $0,25^\circ$ horizontális felbontással. A felbontásból adódik, hogy a gyors fejlődésű és lokális fejlődésű eseményeket (pl. turbulencia, tornádó, stb.) nem képes megfelelően szimulálni. Hasonlóan az AIFS modellhez, a modell múltbeli események alapján jelzi előre a következő időlépcsőre a várható időjárást, rekurzív előrejelzési módszerrel. Lam et al. (2023) eredményei azt mutatják, hogy a GraphCast több paraméter esetében (500 hPa-os geopotenciális magasság, 850 hPa-os hőmérséklet, felszíni légnyomás) felülmúlta az ECMWF nagyfelbontású (HRES) előrejelzését 1-5 napos időtávon. Emellett meglepően pontos eredményeket ért el a trópusi ciklonok pályáinak a modellezésében, sokszor pontosabb előrejelzést készített a ciklonközpontokra és azok mozgására vonatkozóan, mint a hagyományos NWP rendszerek [2 – DeepMind].

Hasonlóan az AIFS-hez, a GraphCast-nak is alacsonyak a számítási igényei a hagyományos fizikai alapú modellekhez képest. Kb. 60 másodperc alatt képes lefutni egy NVIDIA TPU v4 processzoron (Lam et al., 2023). A Google DeepMind a GraphCast modellt nyílt forráskódúvá, és ezzel közvetlenül elérhetővé tette a kutatók és az operatív felhasználók számára, így bárkinek szabadon hozzáférhetővé vált [2 – DeepMind].

Hátrányai ennek a modellnek is vannak. A felbontásán túl, mivel a modell tanítása nagyrészt az ERA5 reanalízis adatbázisra épült, így az előrejelzési képességei függenek attól, hogy mennyire voltak gyakoriak és milyen pontossággal voltak reprezentálva az adatbázisban a különféle légköri folyamatok. Így a ritka eseményeket (pl. hőhullámokat, zivatarrendszereket) sokszor alulbecsüli. Ugyanakkor már elérhetőek a GraphCast GenCast nevű ensemble futások eredményei is, mely 50 tagból áll, s 12 órás lépcsőkben végez 15 napos távra valószínűségi előrejelzéseket. Ez lehetővé teszi, hogy a szélsőségesebb jelenségek detektálása pontosabb legyen.

A GraphCast modell nagy előnye, hogy nyilvánosan hozzáférhető, így bármelyik kutatóintézmény szabadon tesztelheti (ECMWF, NOAA). Emellett bebizonyította, hogy az AI-alapú előrejelző rendszereket már nemcsak kiegészítő információként lehet felhasználni, hanem bizonyos jelenségek esetében már képes felülmúlni is a hagyományos numerikus modelleket (Lam et al., 2023).

Összehasonlítás és operatív jelentőség

Az AIFS, a GraphCast és az IFS modellek összevetése rávilágít arra, hogy napjainkban is szükség van az előrejelzési modellek folyamatos fejlesztésére. Továbbá az is hasznos, hogy

megjelentek az új generációs AI-alapú megközelítések a hagyományos fizikai alapú modellek mellett. Az IFS már régóta megbízható globális előrejelzéseket szolgáltat, különösen a közép- és hosszútávú prognózisok terén nyújt kiemelkedő teljesítményt. Ezzel szemben az AIFS és a GraphCast a mesterséges intelligenciára alapozva sokkal kevesebb energiabefektetéssel, és gyorsabban, rövidebb futtatási idővel képes előrejelzéseket biztosítani, miközben a pontosságuk közelíti, bizonyos esetekben el is éri az IFS szintjét. Ez arra utal, hogy a jövőben képesek leszünk nem kizárólag a numerikus modellekre hagyatkozni az operatív felhasználásban, hanem ezeket kiegészíthetjük az AI-alapú modellek gyorsabban megkapható eredményeivel.

Az AIFS és a GraphCast közös fő kihívása, hogy az alapvető fizikai törvényszerűségeket megfelelően kövessék a szimulációs eredmények. Ezt az ECMWF az AIFS vonatkozásában hibrid technológiával igyekszik megoldani (Lang et al., 2024a). A GraphCast esetében a validációk szerint a globális mezők integrálja még a fizikailag elfogadható tartományba esik, azonban a hosszútávú kumulatív hibákat csökkenteni kell, és ez még számos további vizsgálatot igényel (Lam et al., 2023).

Az összehasonlító vizsgálatok alapján a GraphCast elsősorban a középtávú (3-10 napos) előrejelzésekben megbízható: sok paraméter esetében meghaladja az IFS pontosságát, például a felszíni légnyomás és az 500 hPa-os szint geopotenciális magasság előrejelzésének terén, ami elengedhetetlen a ciklonok és a hozzájuk tartozó frontok detektálásában (Lam et al., 2023). Az AIFS előnye a gyors futtatás és az ECMWF adatasszimilációs rendszerébe való szoros illeszkedése, ami lehetővé teszi, hogy kísérleti vagy hibrid eszközként tudja támogatni az operatív munkát (Lang et al., 2024a). Ezek után jelenleg még mindig az IFS a legmegbízhatóbb előrejelzési modell hosszútávon (10-15 nap), valamint a szezonális skálájú folyamatok szimulációjában, ahol a fizikai folyamatok részletes reprezentálása kritikus jelentőséggel bír.

A szükséges számítási infrastruktúra szempontjából sok a különbség az említett két AI-alapú modell és az IFS között. Az IFS futtatásához nagyteljesítményű szuperszámítógép megléte elengedhetetlen, de így is több óra szükséges, mire egy előrejelzés elkészül. Ezzel szemben a GraphCast és az AIFS futtatása másodpercek alatt megtörténik, sokkal kevesebb energiát igényelnek, így a napi többszöri frissítésükre is lehetőség van. Ez különösen fontos a gyorsan fejlődő rendszerek (pl. trópusi ciklonok) előrejelzésében. Az AI-alapú modellek további fejlesztése szükségsszerű, mivel ezek a modellek a mintázatok felismerése alapján becslik a várható időjárást, így a fizikai törvények betartása nem feltétlenül garantált. Így a jövőben egyszerre kell pontosnak lenniük, ugyanakkor fizikai értelemben konzisztens előrejelzést kell adniuk, továbbá képesnek kell lenniük az ensemble technikát alkalmazni. Mindez főleg az extrém eseményeknél kulcsfontosságú.

A jelenlegi kutatások azt mutatják, hogy az operatív előrejelzések szempontjából a hibrid megközelítés a legígéretesebb. Míg a fizikai alapú IFS megbízható, hosszútávú és részletes háttérinformációt nyújt, addig az AIFS és a GraphCast gyors alternatívát kínál, ami támogathatja a meteorológusok mindennapi munkáját, valamint a veszélyjelzések időben történő kiadását.

Jövőbeli kilátások

A kutatások rávilágítanak arra, hogy az AI-alapú modellek fejlődése új lehetőségeket teremt az időjárás előrejelzésében. Az említett két AI-modell példája azt is mutatja, hogy bizonyos esetekben nem csak kiegészítésre képes, hanem arra is, hogy pontosabb előrejelzést készítsen a hagyományos modellekhez képest. A jövőben arra számíthatunk, hogy a fizikai és az AI-alapú megközelítés egyre közelebb kerül egymáshoz, egészen addig, amíg össze nem

fonódnak, így végül is hibrid előrejelzési rendszerek formájában jelennek meg (Reichstein et al., 2019, Lang et al., 2024a).

A legfontosabb irány a skálázás, valamint a finomabb felbontás elérése. Az AI-modellek alacsony erőforrásigényük miatt könnyen skálázhatóak (akár a kilométer alatti horizontális felbontásra is), ami előrelépést jelenthet a lokális skálájú képződmények előrejelzésében (pl.: mélykonvekció, turbulencia, jegesedés). Ezzel szemben további nehézség lehet az adatasszimiláció, mivel az AI-alapú modellek nem tudják olyan hatékonyan integrálni a friss megfigyeléseket, mint a hagyományos numerikus modellek.

Nagy hangsúly helyeződik még az AI-alapú modellek átláthatóságára és magyarázhatóságára, mivel az IFS jól ismert fizikai törvényeken alapul, így könnyen kiderül, hogy az egyes időjárási eseményeket mi alapján jelzi előre. A GraphCast és az AIFS fekete-doboz-szerű működése viszont a tudományos bizalom szempontjából megkérdőjelezhető. Ez alapján jelenthető ki, hogy nagy szükség van a hibrid megoldások kifejlesztésére, mely ötvözi az AI előnyeit a numerikus modellek törvényszerűségeivel. A legvalószínűbbnek az tűnik, hogy a következő évtizedekben az AI-alapú modellek csak kiegészítő szerepben lesznek jelen, esetleg egy ensemble tagként. Ugyanakkor az energiahatékonyság és a gyors futtathatóság miatt a fejlődő országok meteorológiai szolgálatai is gyorsan átvehetik ezek felhasználását.

Jelenleg Európában a mediterrán ciklonok előrejelzése nagy kihívást jelent a meteorológusok számára ezeknek a ciklonpályáknak a nagy szórása miatt, mivel a tenger-légkör kölcsönhatásokat és az orográfia hatását (amik a fő hajtó erejei a mediterrán ciklonoknak) nehéz pontosan szimulálni. Emiatt a hozzájuk tartozó csapadék eloszlásának a szimulációja is nehézkessé válik. A végső cél tehát az, hogy az AI-alapú modellek ezeket a gyorsan fejlődő/változó rendszereket a jelenleginél sokkal pontosabban képesek legyenek előrejelezni.

Hivatkozások

- Bi, K., Xie, L., Zhang, H., Chen, X., Gu, X., Tian, Q., 2023: Accurate medium-range global weather forecasting with 3D neural networks. *Nature*, 619(7970): 533–538.
<https://doi.org/10.1038/s41586-023-06185-3>
- Bodnar, C., Bruinsma, W. P., Lucic, A., Stanley, M., Allen, A., Brandstetter, J., ... & Perdikaris, P., 2025: A foundation model for the Earth system. *Nature*, 641: 1180–1187.
<https://doi.org/10.1038/s41586-025-09005-y>
- Bonavita, M., Laloyaux, P., 2020: Machine learning for model error inference and correction. *Journal of Advances in Modeling Earth Systems*, 12(12): e2020MS002232.
<https://doi.org/10.1029/2020MS002232>
- ECMWF Strategy, 2021: ECMWF Strategy 2021–2030. European Centre for Medium-Range Weather Forecasts. 18p. <https://doi.org/10.21957/s21ec694kd>
- Gentine, P., Pritchard, M., Rasp, S., Reinaudi, G., Yacalis, G., 2018: Could machine learning break the convection parameterization deadlock? *Geophysical Research Letters*, 45(11): 5742–5751. <https://doi.org/10.1029/2018GL078202>
- Lam, R., Sanchez-Gonzalez, A., Willson, M., Wirnsberger, P., Fortunato, M., Alet, F., ... & Battaglia, P., 2023: GraphCast: Learning skillful medium-range global weather forecasting. *Science*, 382(6677): 1416–1421 <https://doi.org/10.1126/science.adi2336>
- Lang, S., Alexe, M., Chantry, M., Dramsch, J., Pinault, F., Raoult, B., ... & Rabier, F., 2024a: AIFS--ECMWF's data-driven forecasting system. *arXiv preprint arXiv:2406.01465*.
<https://doi.org/10.48550/arXiv.2406.01465>
- Lang, S., Alexe, M., Chantry, M., Dramsch, J., Pinault, F., Raoult, B., ... & Nemesio, A.P., 2024b: AIFS: a new ECMWF forecasting system. *ECMWF Newsletter*, 178 (winter 2023/2024): 4–5. <https://doi.org/10.21957/1a8466ec2f>

- Leutbecher, M., Palmer, T., 2008: Ensemble forecasting. *Journal of Computational Physics*, 227(7): 3515–3539. <https://doi.org/10.1016/j.jcp.2007.02.014>
- Keisler, R., 2022: Forecasting global weather with graph neural networks. *arXiv preprint arXiv:2202.07575*. <https://doi.org/10.48550/arXiv.2202.07575>
- Kurth, T., Subramanian, S., Harrington, P., Pathak, J., Mardani, M., Hall, D., ... & Anandkumar, A., 2023: Fourcastnet: Accelerating global high-resolution weather forecasting using adaptive fourier neural operators. In *Proceedings of the platform for advanced scientific computing conference*, 13: 1–11. <https://doi.org/10.1145/3592979.3593412>
- Rabier, F., Järvinen, H., Klinker, E., Mahfouf, J.-F., Simmons, A., 2000: The ECMWF operational implementation of four-dimensional variational assimilation. *Quarterly Journal of the Royal Meteorological Society*, 126(564): 1143–1170. <https://doi.org/10.1002/qj.49712656415>
- Reichstein, M., Camps-Valls, G., Stevens, B., Jung, M., Denzler, J., Carvalhais, N., Prabhat., 2019: Deep learning and process understanding for data-driven Earth system science. *Nature*, 566(7743): 195–204. <https://doi.org/10.1038/s41586-019-0912-1>

Internetes hivatkozások

- [1 – ECMWF] <https://www.ecmwf.int/en/forecasts/documentation-and-support/changes-ecmwf-model>
- [2 – DeepMind] <https://deepmind.google/discover/blog/graphcast-ai-model-for-faster-and-more-accurate-global-weather-forecasting/>
-

ORCID

Soósné Dezső Zs.  <https://orcid.org/0000-0003-1325-1303>
Pongrácz R.  <https://orcid.org/0000-0001-7591-7989>