

Meteorológiai adatasszimiláció

2023.11.09. és 2023.11.23.

Kardos-Várkonyi Anikó

varkonyi.a@met.hu

A számszerű előrejelzés lépései

Adat-
asszimiláció

mérési információk
gyűjtése, ellenőrzése,
modell rácsra történő
előállítás

Modell
integrálás

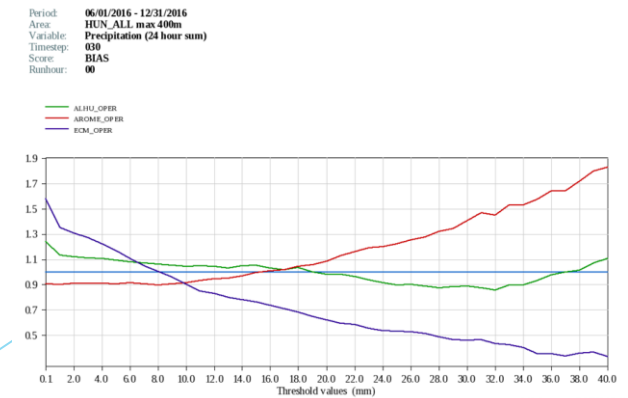


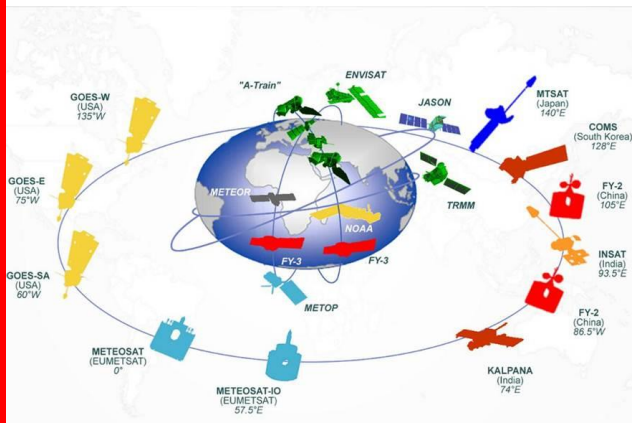
a légkör hidro-
termodinamikai
egyenletrendszerének
közelítő megoldása

Utófeldolgozás

speciális
paraméterek
származtatása,
megjelenítés

Verifikáció

az előrejelzések
minőségének
vizsgálata



Bevezetés

Mi az adatasszimiláció célja?

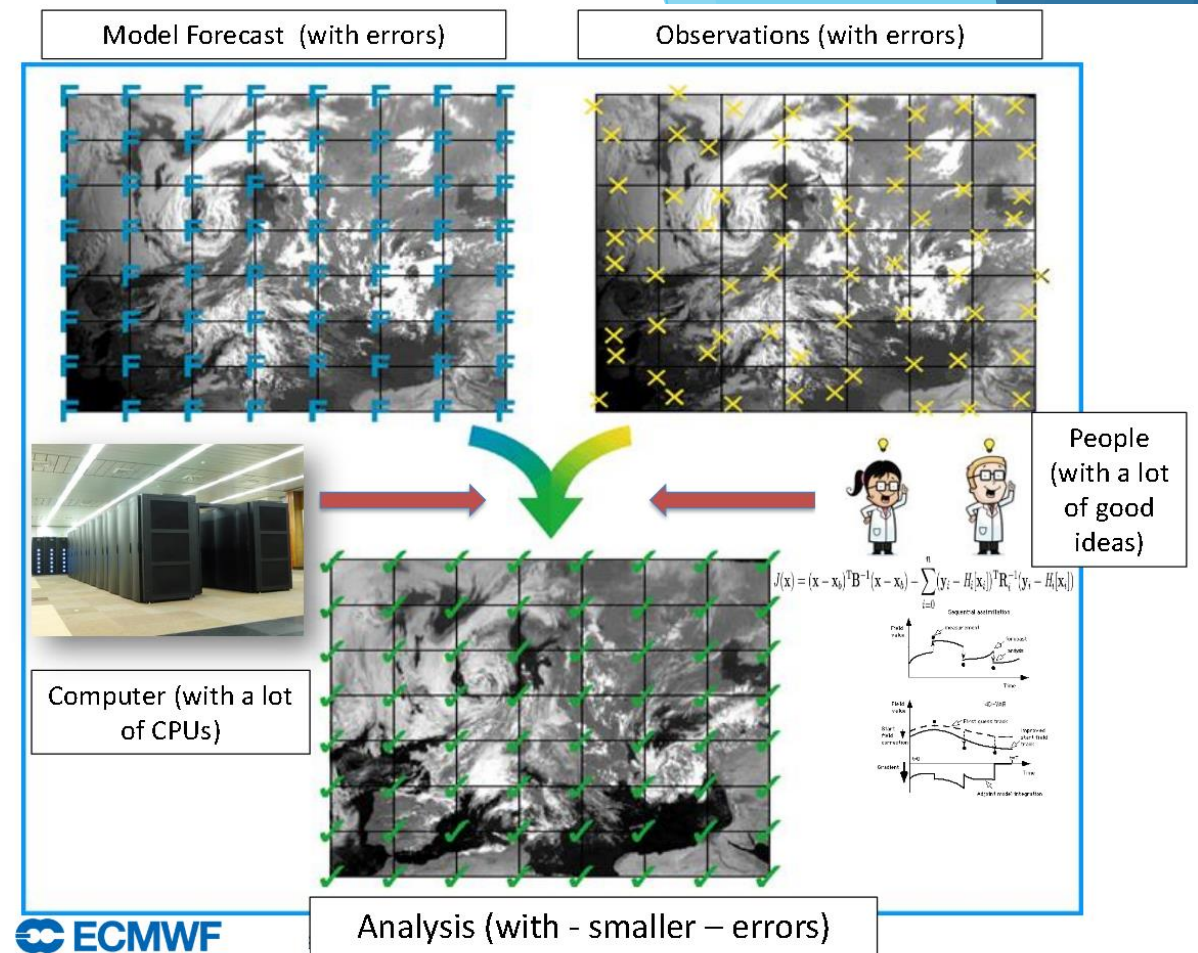
- Kezdeti feltételek biztosítása a numerikus modellek számára → Lényeges a pontosság a HTER megoldásának kezdeti feltételekre való érzékenysége miatt (a légkör kaotikus viselkedése)
- A bizonytalanságok meghatározása

Mik szükségesek az adatasszimilációhoz?

- Modell előrejelzés (background)
- Megfigyelések
- Számítási kapacitás
- Emberi erőforrás

Mik a legnagyobb nehézségek?


- A megfigyelések nem a modell rácspontjaiban helyezkednek el + indirekt és gyakran bonyolult változók mérése → megfigyelési operátor
- A modell előrejelzés és a megfigyelések is hibával terheltek → optimálisan kell ezeket ötvözni



Forrás: Massimo Bonavita, ECMWF NWP training, 2019



Az adatasszimiláció jelentősége

700 hPa relatív nedvesség & szél
kezdeti feltétel műholdas adatokkal




Nedvesség > 95%

700 hPa relatív nedvesség & szél
kezdeti feltétel műholdas adatok nélkül



Thursday 31 August 2017 00 UTC ecmf 500 hPa Vorticity (relative)
Thursday 31 August 2017 00 UTC ecmf 500 hPa U component of wind/V component of wind
gt0v




Az adatasszimiláció jelentősége

Műholdas mérések hatása

Északi félteke



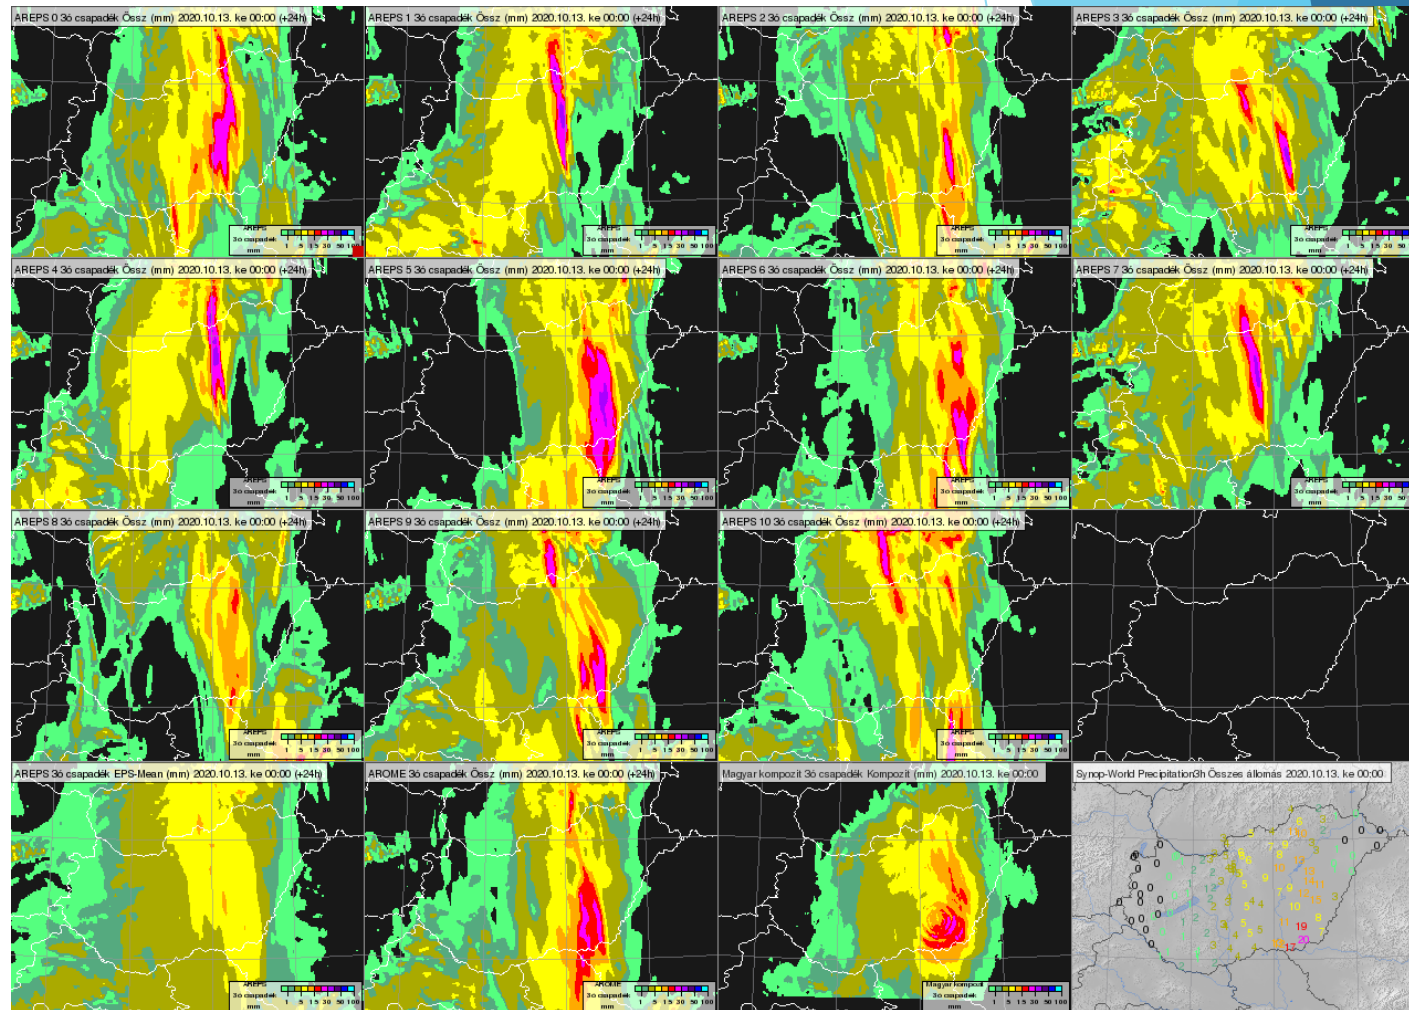
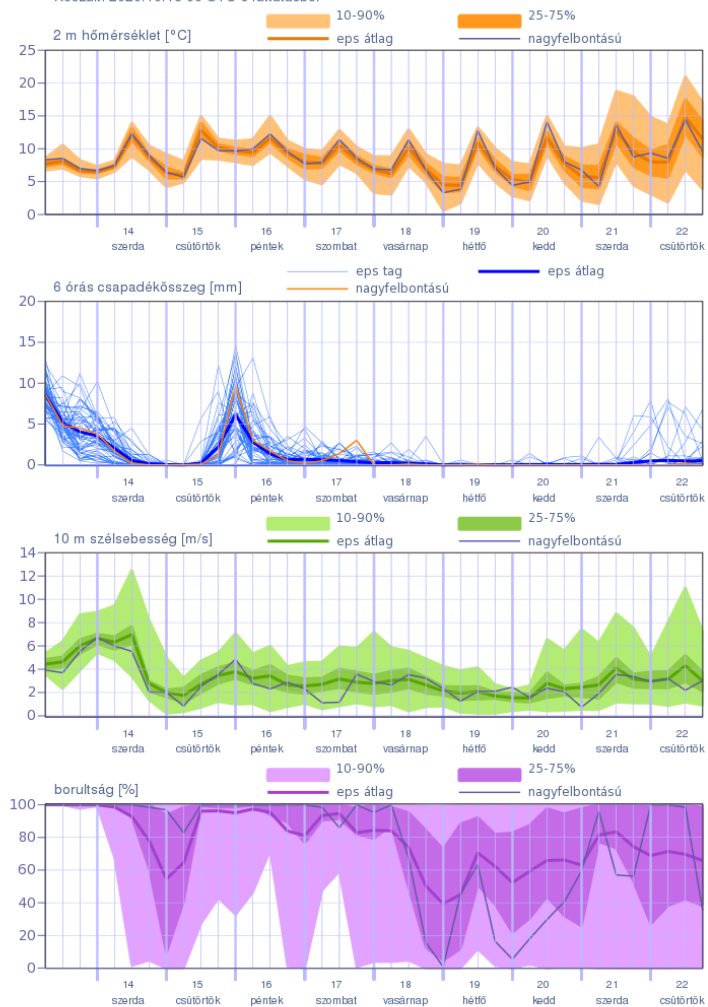
Déli félteke



Az adatasszimiláció jelentősége

ECMWF valószínűségi előrejelzés: Budapest

Készült: 2020.10.13 00 UTC-s futtatásból



Milyen igényeket támasztunk?

1. A kezdeti feltétel ugyanazon a **rácson** álljon rendelkezésre, mint amin az előrejelzést elkészítjük
2. Használjunk fel **minden** rendelkezésünkre álló **információt** - mik ezek az információk és **hogyan használjuk fel ezeket?**

Miért nem elegendő csak a méréseket felhasználnunk?

- A modell rácspontjaihoz képest kevesebb mérés áll rendelkezésre
- Nem elegendők ahhoz, hogy megfelelő pontossággal az összes rácspontra meghatározzuk a modell prognosztikai változóit
- Alulhatározott lenne a feladat
- Még több információra van szükség (korábbi előrejelzések felhasználása)

- Mérések és megfigyelések
- Korábbi előrejelzések
- Tudás a légkörről

Milyen igényeket támasztunk?

1. A kezdeti feltétel ugyanazon a **rácson** álljon rendelkezésre, mint amin az előrejelzést elkészítjük
2. Használjunk fel minden rendelkezésünkre álló **információt** - **mik ezek az információk és hogyan használjuk fel ezeket?**



- **Optimálisan** ötvözzük a rendelkezésre álló információkat (minimális becslési hiba)
- **Vegyük figyelembe** a felhasznált információk hibáját (ezeket is csak becsülni tudjuk)
- A becslés legyen **összhangban a HTER-rel** (dinamikai konzisztencia)

Milyen hibái lehetnek a felhasznált információknak?

- Műszerek hibái
- Reprezentativitási hiba
- Átszámítási hibák
- Modell előrejelzések hibája

Mi történik ha nem megfelelő a dinamikai konzisztencia?

- Zajok megjelenése
- Modellinstabilitás

Idealizált eset

- 1 térbeli pont
- 1 változó: x
- x_a becslést adunk x_t -re (a valós állapotra)
- rendelkezésünkre állnak y_1 és y_2 megfigyelések ε_1 és ε_2 hibával terhelve:

$$y_1 = x_t + \varepsilon_1$$

$$y_2 = x_t + \varepsilon_2$$

$$x_a = \hat{x}_t = f(y_1, y_2)$$

Szeretnénk a terem hőmérsékletét megbecsülni a jelen pillanatban – T_t

Rendelkezésünkre áll két mérés:

1. Digitális hőmérő: T_1



2. Analóg hőmérő: T_2



A rendelkezésre álló információk hibája:

$$\varepsilon_1 = T_1 - T_t \quad \text{és} \quad \varepsilon_2 = T_2 - T_t$$

Idealizált eset

Feltesszük, hogy:

- a mérések torzítatlanok (nincs szisztematikus hiba):

$$E(\varepsilon_1) = E(\varepsilon_2) = 0$$

- a becslések (mérések) hibáinak szórásnégyzete ismert:

$$\sigma_1^2 = E(\varepsilon_1^2) \quad \sigma_2^2 = E(\varepsilon_2^2)$$

- a becslések (mérések) hibái korrelálatlanok:

$$E(\varepsilon_1 \varepsilon_2) = 0$$

Idealizált eset

Kérdés:

$$x_a = f(y_1, y_2) = ?$$

Több megközelítés létezik, például:

- Legkisebb négyzetek módszere
- Maximum likelihood módszer

Legkisebb négyzetek módszere

Az **analízist** a becslések lineáris kombinációjaként állítjuk elő:

$$\left. \begin{array}{l} y_1 = x_t + \varepsilon_1 \\ y_2 = x_t + \varepsilon_2 \\ x_a = k_1 y_1 + k_2 y_2 \end{array} \right\} \begin{array}{l} k_1 = ? \\ k_2 = ? \end{array}$$

Szeretnénk, hogy:

- a becslés torzítatlan legyen: $E(x_a - x_t) = 0 \longrightarrow k_1 + k_2 = 1$
- a becslés négyzetes hibája minimális legyen: $\sigma_a^2 = E((x_a - x_t)^2) = \min$

1. feladat:

$$\left. \begin{aligned} y_1 &= x_t + \varepsilon_1 \\ y_2 &= x_t + \varepsilon_2 \\ x_a &= k_1 y_1 + k_2 y_2 \end{aligned} \right\} \begin{aligned} k_1 &= ? \\ k_2 &= ? \end{aligned}$$

Mutassuk meg, hogy

$$E(x_a - x_t) = 0 \quad \Rightarrow \quad k_1 + k_2 = 1$$

1. feladat:

$$E(k_1 y_1 + k_2 y_2 - x_t) = 0$$

$$E(k_1(x_t + \varepsilon_1) + k_2(x_t + \varepsilon_2) - x_t) = 0$$

$$E(k_1 x_t + k_1 \varepsilon_1 + k_2 x_t + k_2 \varepsilon_2 - x_t) = 0$$

$$E(k_1 x_t) + E(k_1 \varepsilon_1) + E(k_2 x_t) + E(k_2 \varepsilon_2) - E(x_t) = 0$$

$$k_1 E(x_t) + \cancel{k_1 E(\varepsilon_1)} + k_2 E(x_t) + \cancel{k_2 E(\varepsilon_2)} - E(x_t) = 0$$

$$k_1 E(x_t) + k_2 E(x_t) - E(x_t) = 0$$

$$E(x_t)(k_1 + k_2 - 1) = 0$$

Ez csak akkor 0, ha: $k_1 + k_2 = 1$

$$\left. \begin{aligned} y_1 &= x_t + \varepsilon_1 \\ y_2 &= x_t + \varepsilon_2 \\ x_a &= k_1 y_1 + k_2 y_2 \end{aligned} \right\}$$

Torzítatlanság miatt

2. feladat:

$$\left. \begin{array}{l} x_a = k_1 y_1 + k_2 y_2 \\ k_1 + k_2 = 1 \end{array} \right\} x_a = k_1 y_1 + (1 - k_1) y_2$$

$$\left. \begin{array}{l} y_1 = x_t + \varepsilon_1 \\ y_2 = x_t + \varepsilon_2 \\ x_a = k_1 y_1 + k_2 y_2 \end{array} \right\}$$

Feladat: $\min \sigma_a^2(k_1)$

$$\begin{aligned} \sigma_a^2(k_1) &= E((x_a - x_t)^2) = E\left(\overbrace{\left(k_1 \overbrace{(x_t + \varepsilon_1)}^{y_1} + (1 - k_1) \overbrace{(x_t + \varepsilon_2)}^{y_2}\right)}^{x_a} - x_t\right)^2 \\ &= E(\cancel{k_1 x_t} + k_1 \varepsilon_1 + \cancel{x_t} - \cancel{k_1 x_t} + (1 - k_1) \varepsilon_2 - \cancel{x_t})^2 \\ &= E\left((k_1 \varepsilon_1 + (1 - k_1) \varepsilon_2)^2\right) \quad 0 \text{ (korrelátlanság miatt)} \\ &= k_1^2 E((\varepsilon_1)^2) + 2k_1(1 - k_1) \overbrace{E(\varepsilon_1 \varepsilon_2)} + (1 - k_1)^2 E((\varepsilon_2)^2) \\ &= \boxed{k_1^2 \sigma_1^2 + (1 - k_1)^2 \sigma_2^2} \quad \min \rightarrow k_1 \text{ szerinti derivált } 0 \end{aligned}$$

k szerinti derivált: $2k_1\sigma_1^2 - 2(1 - k_1)\sigma_2^2 = 0$

$$k_1\sigma_1^2 = (1 - k_1)\sigma_2^2$$

$$k_1(\sigma_1^2 + \sigma_2^2) = \sigma_2^2$$

$$k_1 = \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2} \quad \longrightarrow \quad k_2 = 1 - k_1 = \frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2}$$

A becslés:
$$x_a = \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2} y_1 + \frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2} y_2$$

A becslés megbízhatósága:
$$\frac{1}{\sigma_a^2} = \frac{1}{\sigma_1^2} + \frac{1}{\sigma_2^2} = \sum_{i=1}^p \frac{1}{\sigma_i^2}$$


Minden megfigyelés
növeli a
megbízhatóságot!

Maximum likelihood módszer

A meteorológiai változók „jól” modellezhetők normális eloszlású valószínűségi változókként

$$x \in N(m, \sigma^2)$$


$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x-m)^2}{2\sigma^2}\right)$$



Az y_1 és y_2 mérések független becslést adnak x_t -re x várható értékkel, σ_1 és σ_2 szórással:

$$f_1(x) = \frac{1}{\sigma_1 \sqrt{2\pi}} \exp\left(-\frac{(x-y_1)^2}{2\sigma_1^2}\right)$$

$$f_2(x) = \frac{1}{\sigma_2 \sqrt{2\pi}} \exp\left(-\frac{(x-y_2)^2}{2\sigma_2^2}\right)$$



Becslés: x_a a minta együttes sűrűségfv-ének x szerinti maximuma


$$x_a \rightarrow \max_x f_1(x)f_2(x) = \max_x \frac{1}{\sigma_1\sigma_2 2\pi} \exp\left(-\left(\frac{1}{2} \frac{(y_1-x)^2}{\sigma_1^2} + \frac{1}{2} \frac{(y_2-x)^2}{\sigma_2^2}\right)\right) =$$

$$= \min_x \left(\frac{1}{2} \frac{(y_1-x)^2}{\sigma_1^2} + \frac{1}{2} \frac{(y_2-x)^2}{\sigma_2^2} \right)$$

$$x_a = \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2} y_1 + \frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2} y_2$$

$$\frac{1}{\sigma_a^2} = \frac{1}{\sigma_1^2} + \frac{1}{\sigma_2^2} = \sum_i \frac{1}{\sigma_i^2} \quad \Rightarrow \quad \text{Minden megfigyelés növeli a megbízhatóságot!}$$

Példa:



$$y_1=5; \sigma_1=1$$

$$y_2=10; \sigma_2=2$$

$$x_a=6; \sigma_a=0,89$$

Összefoglalás

Normális eloszlású hibák esetén a legkisebb négyzetek módszere és a maximum likelihood módszerek ekvivalensek

Legkisebb négyzetek módszere
Pl. optimális interpoláció
(lineáris regresszió)

$$\mathbf{x}_a = \sum_{i=1}^p \mathbf{k}_i y_i$$

$$\mathbf{k}_i = ?$$

Maximum likelihood módszer
Pl. variációs módszer
(veszteség függvény)

$$J(\mathbf{x}) = \frac{1}{2} \sum_{i=1}^p \frac{(\mathbf{x} - y_i)^2}{\sigma_i^2}$$


$$\operatorname{argmin} J(\mathbf{x}) = ?$$

(iteratív minimum kereső algoritmusok)

Adatasszimiláció a gyakorlatban

A numerikus modellek egy 3D **rácson** oldják meg a HTER-t. A rácson értelmezett meteorológiai változók együttese az **állapotvektor (továbbiakban \mathbf{x})** amely a mai modellek esetében $n \sim 10^7$ nagyságrendű.


Adatasszimiláció: az állapotvektor megadása a kezdeti időpillanatban (**analízis**) úgy, hogy az minél közelebb legyen a valósághoz.




Felhasználható becslések

Megfigyelések:


- Időben rendszeres számszerű mérések
- Térben **szabálytalan rács**
- Összetett összefüggés (lehet) a mért és a modell változók között
- Analízisenként $p \sim 10^5$ nagyságrendű megfigyelést használunk



Megfigyelések globális rendszere



Forrás: Tony McNally, ECMWF NWP training, 2015

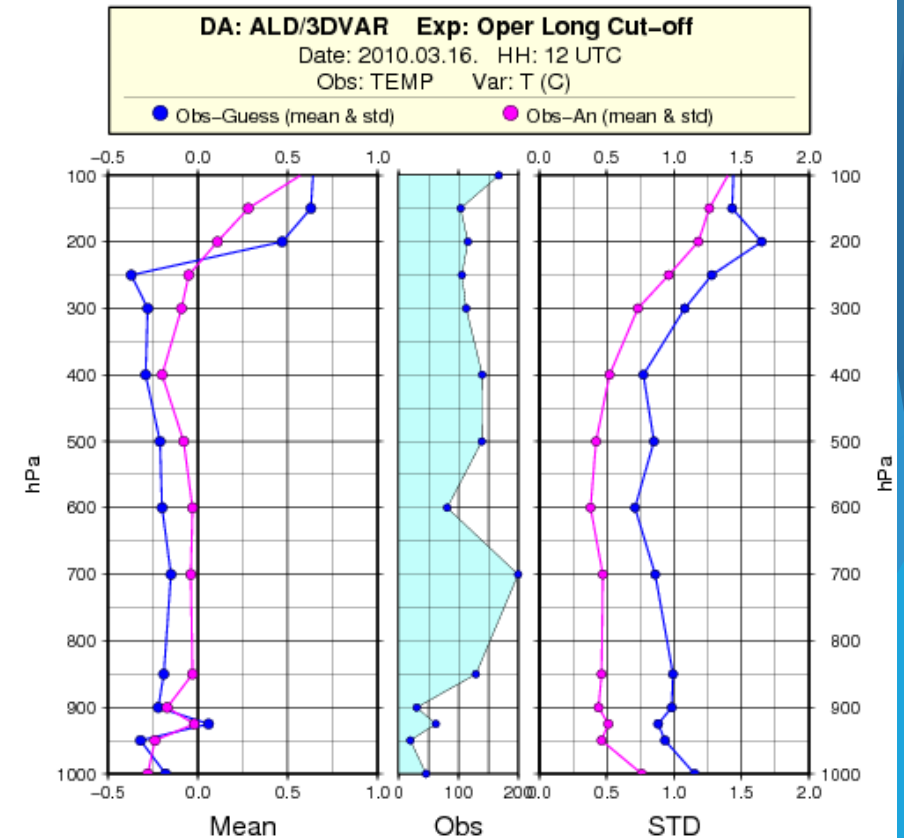


24 órás előrejelzés esetén:

- 70 % : műholdas adatok
- 30 %: in situ megfigyelések

Konvencionális megfigyelések

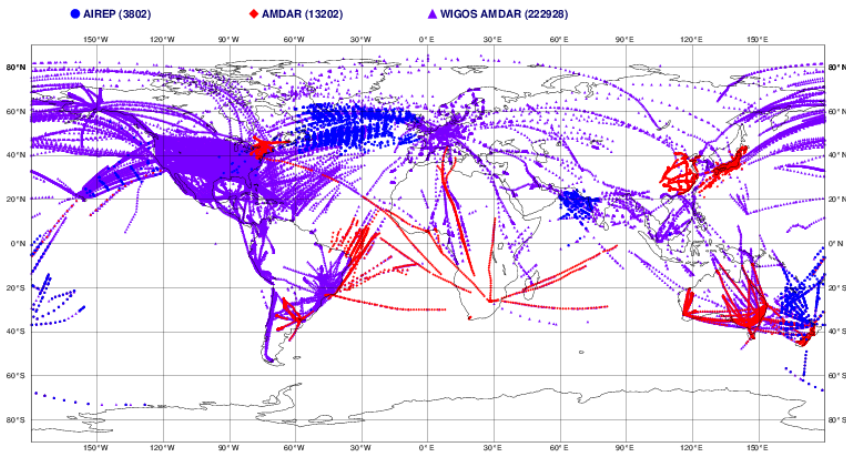
| Eszköz | Változó | Szint |
|---|---|------------------------|
| SYNOP SHIP METAR | hőmérséklet, harmatpont, szél, légnomás | Felszín, 2m, 10m, 25m |
| Bóják | hőmérséklet, légnomás, szél | 2m |
| Rádiószondák TEMPSHIP Ejtőszondák | hőmérséklet, légnomás, szél, nedvesség | Profil |
| Profilerek | szél | Profil |
| Repülőgépek | hőmérséklet, légnomás, szél | Profil, repülési szint |



Konvencionális/in-situ megfigyelések

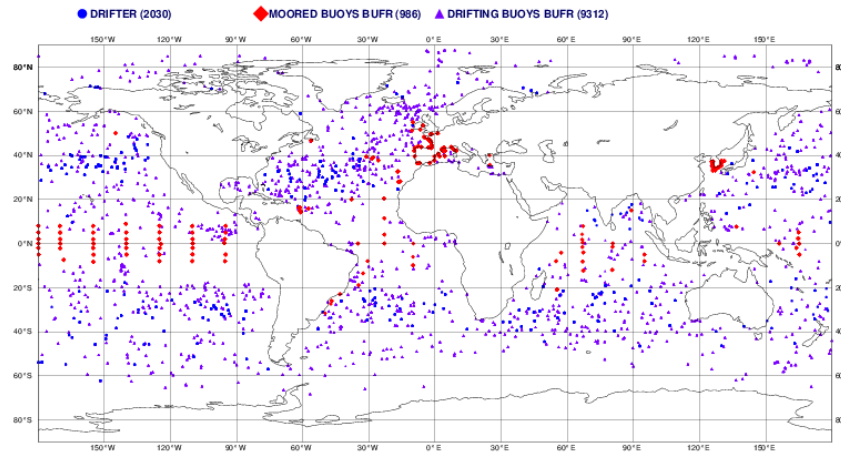
ECMWF data coverage (all observations) - AIRCRAFT
13/11/2018 00

Total number of obs = 239932



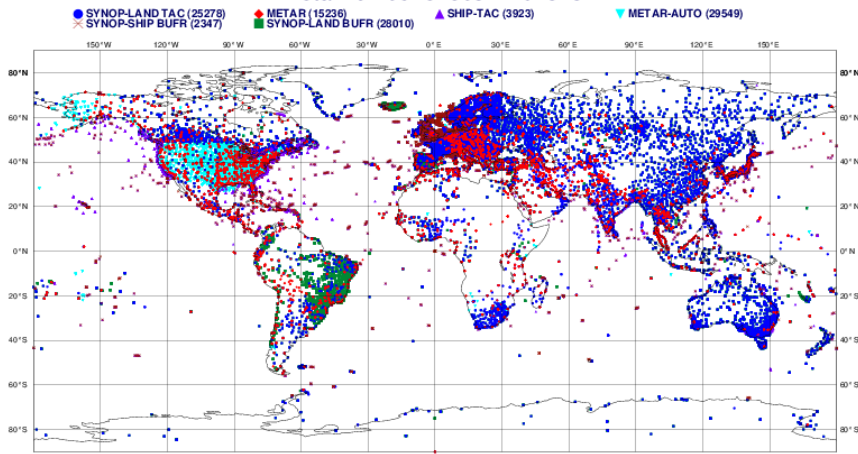
ECMWF data coverage (all observations) - BUOY
13/11/2018 00

Total number of obs = 12328



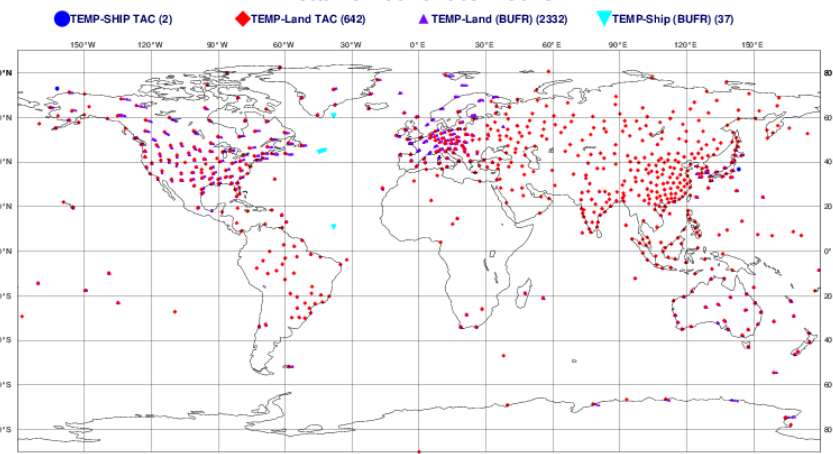
ECMWF data coverage (all observations) - SYNOP-SHIP-METAR
13/11/2018 00

Total number of obs = 104343



ECMWF data coverage (all observations) - RADIOSONDE
13/11/2018 00

Total number of obs = 3013



In-situ megfigyelések jellemzői


- Nem egyenletes térbeli és időbeli lefedettség
- Pontszerű mérések
- Nem egységes adatminőség

- Közvetlenül azt mérik, amit a modellben is használunk
- Értelmezésük és használatuk az adatasszimiláció során „egyszerű”



Műholdas mérések

Geostacionárius és kvázipoláris (low Earth orbit) műholdak

GEO

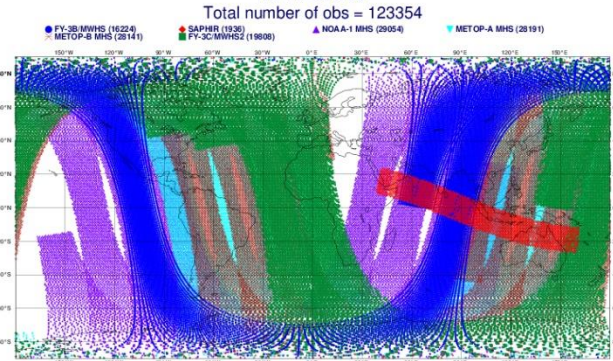


LEO

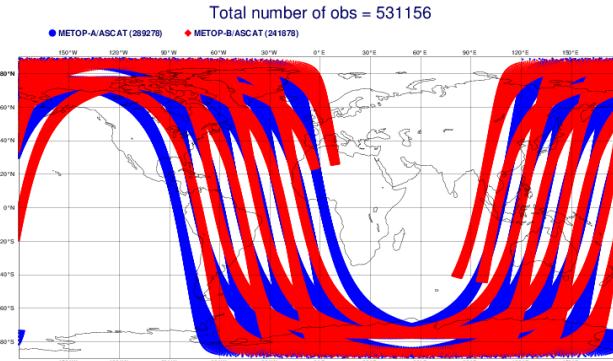


Távérzékeléses mérési lefedettség

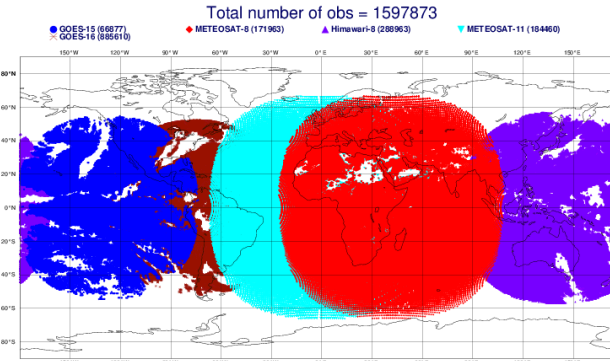
ECMWF data coverage (all observations) - MICROWAVE HUMIDITY SOUNDERS
13/11/2018 00




ECMWF data coverage (all observations) - SCATTEROMETER
13/11/2018 00



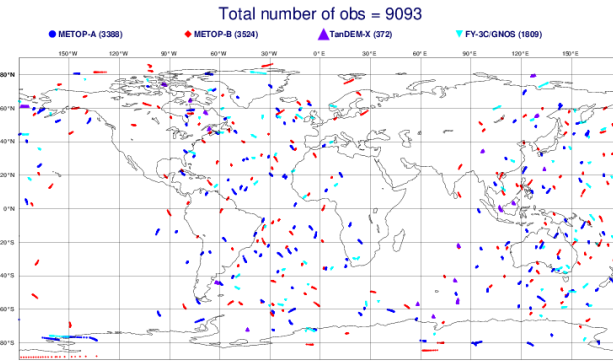
ECMWF data coverage (all observations) - GEOSTATIONARY RADIANCES
13/11/2018 00




ECMWF data coverage (all observations) - IASI
13/11/2018 00



ECMWF data coverage (all observations) - GPSRO
13/11/2018 00



ECMWF data coverage (all observations) - HIRS
13/11/2018 00



Távérzékelési megfigyelések jellemzői az adatasszimiláció szempontjából

- Nehézség a műholdas adatokkal: indirekt és gyakran bonyolult változók mérése, ami a modell számára NEM azonnal felhasználható → átalakítások szükségesek → radiatív transzfer egyenlet segítségével megoldható a probléma
- Nehezítő körülmények (pl. felhőzet)
- Hatalmas adatmennyiség

- Egyenletes, globális térbeli lefedettség
- Nagy időbeli sűrűség
- A műholdas „pixelek” közelebb állnak a modellrácshoz


Hátrányok

Előnyök

Adatasszimiláció hatékonyságának az ellenőrzése

FSOI - Forecast Sensitivity Observation Impact

Fcst Error



Felhasználható becslések-folytatás

Megfigyelések:

- A megfigyelések nem feltétlenül esnek a modellrácspontra
- Nem közvetlenül a modellezett mennyiségeket mérik
- A megfigyelések száma ma is kevesebb, mint a modellrács pontjainak száma

Background/first guess:

- A modell által előrejelzett állapotvektor
- Térben szabályos rács
- Közvetlenül modell változók
- Dimenzió: $n \sim 10^7$

To access this activity, students
go to zzi.sh and insert

ake94796

 Copy class code

